

**UNESP - UNIVERSIDADE ESTADUAL PAULISTA  
FACULDADE DE ENGENHARIA DE BAURU  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**DANILO DE MELO BRUNINI**

**LOCALIZAÇÃO DE DESCARGAS PARCIAIS EM TRANSFORMADORES DE  
POTÊNCIA POR MEIO DE SISTEMAS INTELIGENTES E EMISSÃO ACÚSTICA**

**Bauru  
2017**

**DANILO DE MELO BRUNINI**

**LOCALIZAÇÃO DE DESCARGAS PARCIAIS EM TRANSFORMADORES DE  
POTÊNCIA POR MEIO DE SISTEMAS INTELIGENTES E EMISSÃO ACÚSTICA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia de Bauru, da UNESP, como requisito para a obtenção do título de Mestre em Engenharia Elétrica.

Área de Concentração: Automação.

Orientador: Prof. Dr. José Alfredo Covolan Ulson

**Bauru**

**2017**

Brunini, Danilo de Melo.

Localização de descargas parciais em transformadores de potência por meio de sistemas inteligentes e emissão acústica / Danilo de Melo Brunini, 2017  
99 f.

Orientador: José Alfredo Covolan Ulson

Dissertação (Mestrado)-Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2017

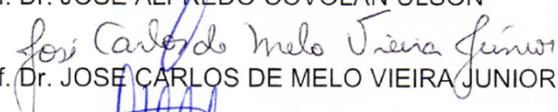
1. Falhas em transformadores. 2. Localização de descargas parciais. 3. Emissão acústica. 4. Sistemas inteligentes. I. Universidade Estadual Paulista. Faculdade de Engenharia. II. Título.

**ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE DANILO DE MELO BRUNINI, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA - CÂMPUS DE BAURU.**

Aos 31 dias do mês de maio do ano de 2017, às 10:00 horas, no(a) Anfiteatro da Seção Técnica de Pós-graduação da FEB, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos seguintes membros: Prof. Dr. JOSE ALFREDO COVOLAN ULSON - Orientador(a) do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, Prof. Dr. JOSE CARLOS DE MELO VIEIRA JUNIOR do(a) Departamento de Engenharia Elétrica / Universidade de São Paulo/São Carlos, Prof. Dr. RENATO CRIVELLARI CREPPE do(a) Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP, sob a presidência do primeiro, a fim de proceder a arguição pública da DISSERTAÇÃO DE MESTRADO de DANILO DE MELO BRUNINI, intitulada **LOCALIZAÇÃO DE DESCARGAS PARCIAS EM TRANSFORMADORES DE POTENCIA POR MEIO DE SISTEMAS INTELIGENTES E EMISSÃO ACÚSTICA**. Após a exposição, o discente foi arguido oralmente pelos membros da Comissão Examinadora, tendo recebido o conceito final: APROVADO . Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelos membros da Comissão Examinadora.



Prof. Dr. JOSE ALFREDO COVOLAN ULSON



Prof. Dr. JOSE CARLOS DE MELO VIEIRA JUNIOR



Prof. Dr. RENATO CRIVELLARI CREPPE

## **DEDICATÓRIA**

Dedico este trabalho à memória de minha avó Olinda, a pessoa mais alegre que já conheci, pelo amor demonstrado por mim enquanto estivemos juntos.

## **AGRADECIMENTOS**

Agradeço primeiramente à Deus, pelo dom da vida, pelo amor demonstrado através de Jesus que, na cruz, me deu vida eterna e por toda sabedoria concedida a mim, sem a qual jamais teria chegado até aqui.

À toda minha família, em especial meus pais, Oswaldo e Karina, meu padrasto, Juan, e minha madrasta, Shirley, pelo empenho e dedicação que tiveram na condução da minha formação moral e educacional e por todo o apoio que me deram.

À minha esposa, Thais, que acompanhou minha trajetória neste mestrado desde o início, quando ainda éramos namorados, sempre me dando suporte e, nos momentos de dificuldade, me incentivando a prosseguir.

Ao Prof. Dr. Alfredo, pela confiança, pelos conselhos que me foram dados, pela compreensão que teve quando estive sobrecarregado com viagens à trabalho e pela orientação que, mesmo à distância, foi conduzida da melhor forma durante todo o mestrado.

Ao Bruno, com quem muito aprendi neste mestrado, por estar sempre disposto a me ajudar e cujo suporte foi fundamental para o desenvolvimento desta dissertação.

Ao Felipe e ao Lázaro, meus amigos e colegas de mestrado, pelo apoio, pelos conselhos, pelas conversas nas viagens para Bauru e por todo o companheirismo demonstrado ao longo do mestrado.

Ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia de Bauru pela oportunidade de realização deste trabalho de pesquisa.

## EPÍGRAFE

*“Porque Deus amou ao mundo de tal maneira que deu o seu Filho unigênito, para que todo aquele que nele crê não pereça, mas tenha a vida eterna.”*

*João 3:16*

## RESUMO

Os transformadores são equipamentos importantes do sistema elétrico de potência, possuem alto custo e suas falhas tem influência direta na qualidade da energia entregue aos consumidores. Uma das principais causas de falhas em transformadores imersos em líquido isolante, as descargas parciais, advém da degradação física e química do sistema de isolação devido à diversos fatores tais como sobrecarga, cargas não-lineares, chaveamento e superaquecimento. Essas descargas parciais aceleram a degradação do dielétrico do transformador e podem levar à destruição do equipamento, ocasionando elevado prejuízo financeiro. Dessa forma, são necessárias ações de prevenção de falhas causadas por descargas parciais em transformadores, através de métodos de monitoramento e localização. Este trabalho teve por objetivo apresentar um método de localização de descargas parciais em transformadores de potência imersos em óleo mineral isolante utilizando o método de emissão acústica e sistemas inteligentes do tipo redes neurais artificiais e algoritmos genéticos. Foram aplicadas métricas de processamento de sinais aos sinais acústicos gerados a partir de descargas parciais e obtidos através de sensores piezelétricos de baixo custo instalados no lado externo do tanque do transformador. Estas métricas foram utilizadas para treinamento das redes neurais a fim de obter a distância euclidiana entre os sensores e as descargas parciais. Essas distâncias euclidianas foram utilizadas em um sistema não-linear de localização o qual foi solucionado através de um algoritmo genético a fim de obter as coordenadas tridimensionais da descarga parcial. A análise dos resultados obtidos nas etapas de treinamento das redes neurais e execução do algoritmo genético foi realizada através de critérios estatísticos como erro absoluto médio, erro relativo percentual, desvio padrão e coeficiente de correlação. Esta técnica de localização mostrou resultados promissores uma vez que as coordenadas tridimensionais de duas descargas parciais, escolhidas para validação, apresentaram erros absolutos médios inferiores a 3 cm.

**Palavras-chaves:** Falhas em transformadores. Localização de descargas parciais. Emissão acústica. Sistemas inteligentes.

## ABSTRACT

Transformers are important devices of the electric power system, which have high cost and their failures have a direct influence on the power quality delivered to the consumers. One of the main causes of failures in oil-immersed transformers, the partial discharges, comes from the physical and chemical degradation of the insulation system due to several factors such as overload, non-linear loads, switching and overheating. These partial discharges accelerate the degradation of the transformer dielectric and they can lead to the destruction of the equipment, causing high financial losses. Thus, actions are necessary to prevent faults caused by partial discharges in transformers, through monitoring and locating methods. The aim of this work was to present a method for locating partial discharges in oil-immersed power transformers using the acoustic emission method and intelligent systems such as artificial neural networks and genetic algorithms. Signal processing metrics were applied to the acoustic signals generated from partial discharges and obtained by low-cost piezoelectric sensors installed on the external side of the transformer tank. These metrics were used to train the neural networks in order to obtain the euclidean distance between the sensors and the partial discharges. These euclidean distances were used in a nonlinear location system, which was solved through a genetic algorithm in order to obtain the three-dimensional coordinates of the partial discharge. The analysis of the results obtained from the stages of neural networks training and genetic algorithm execution was performed through statistical criteria such as mean absolute error, percentage relative error, standard deviation and correlation coefficient. This localization technique showed promising results since the three-dimensional coordinates of two partial discharges, chosen for validation, presented mean absolute errors of less than 3 cm.

**Keywords:** Transformers faults. Location of partial discharges. Acoustic emission. Intelligent systems.

## LISTA DE FIGURAS

<b>Figura 1</b> — Descarga parcial superficial (a), externa (b) e interna (c) .....	20
<b>Figura 2</b> — Caracterização da descarga parcial na cavidade de um material dielétrico (a) e circuito equivalente (b) .....	21
<b>Figura 3</b> — Representação do modelo de aproximação por campo .....	22
<b>Figura 4</b> — Impedância de medição $Z_m$ em série com o capacitor de acoplamento $C_k$ .....	24
<b>Figura 5</b> — Modo de acoplamento via tap capacitivo .....	25
<b>Figura 6</b> — Sensor UHF utilizado para detectar DPs.....	25
<b>Figura 7</b> — Cristal em equilíbrio (a) e dipolo resultante da deformação mecânica (b) .....	34
<b>Figura 8</b> — Construção da cápsula piezelétrica de baixo custo.....	35
<b>Figura 9</b> — Sistema de oscilação da cápsula piezelétrica de baixo custo .....	35
<b>Figura 10</b> — Sinal acústico captado por um sensor piezelétrico no domínio do tempo (a) e frequência (b).....	36
<b>Figura 11</b> — Representação da assimetria (Skewness) de um sinal .....	38
<b>Figura 12</b> — Representação do afastamento da distribuição de frequências (Kurtosis) .....	38
<b>Figura 13</b> — Pontos de mínimo do critério de energia para a determinação do tempo de chegada de um sinal acústico em sensores .....	40
<b>Figura 14</b> — Pontos de mínimo local do critério de Akaike para a determinação do tempo de chegada de um sinal acústico em um sensor .....	41
<b>Figura 15</b> — Sensor acústico atingido por ondas de caminho direto e por ondas propagadas no tanque de aço do transformador.....	42
<b>Figura 16</b> — Esquema para o equacionamento do método de localização de DPs por triangulação de sinais .....	43
<b>Figura 17</b> — Intervalos de tempo entre as detecções da DP utilizando somente o método acústico.....	45
<b>Figura 18</b> — Representação organizacional dos sistemas inteligentes .....	50
<b>Figura 19</b> — Modelo do neurônio artificial .....	52
<b>Figura 20</b> — Funções de ativação mais utilizadas.....	54
<b>Figura 21</b> — Arquitetura das redes neurais artificiais .....	55
<b>Figura 22</b> — Fases <i>forward</i> e <i>backward</i> em uma rede MLP .....	57

<b>Figura 23</b> — Cromossomos com representação binária (a) e real (b) para a cor verde no sistema RGB.....	61
<b>Figura 24</b> — Seleção por roleta (a) e seleção por classificação linear (b) .....	63
<b>Figura 25</b> — Recombinação de um ponto dos pais P1 e P2 (a) gerando os filhos F1 e F2 (b) .....	64
<b>Figura 26</b> — Mutação em um cromossomo binário .....	65
<b>Figura 27</b> — Metodologia proposta para o sistema de localização de descargas parciais .....	67
<b>Figura 28</b> — Eletrodo de latão para a geração de descargas no núcleo do transformador.....	69
<b>Figura 29</b> — Eletrodos de latão acoplados ao núcleo e bobinas de um transformador de distribuição (indicados pelas setas).....	69
<b>Figura 30</b> — Diagrama do circuito elevador de tensão elétrica.....	70
<b>Figura 31</b> — Placa de conexão dos eletrodos .....	71
<b>Figura 32</b> — Sensores acoplados para a captação dos sinais acústicos das DPs ..	73
<b>Figura 33</b> — Dimensões do diafragma piezelétrico de baixo custo.....	73
<b>Figura 34</b> — Diagrama eletrônico do circuito amplificador para cada cápsula piezelétrica.....	74
<b>Figura 35</b> — Etapas de treinamento da Rede Neural .....	76
<b>Figura 36</b> — Arranjo com três RNAs .....	77
<b>Figura 37</b> — Histograma de erros do treinamento 10 realizado com o conjunto de entradas 12 e a topologia 9.....	86
<b>Figura 38</b> — Gráfico de dispersão e coeficiente de correlação entre os valores estimados e desejados obtidos no treinamento 10 com o conjunto de entradas 12 e a topologia 9 .....	86
<b>Figura 39</b> — Valor da aptidão ao longo das gerações na primeira execução do AG para a DP 1.....	89
<b>Figura 40</b> — Valor da aptidão ao longo das gerações na primeira execução do AG para a DP 13.....	91

## LISTA DE TABELAS

<b>Tabela 1</b> — Falha do tipo descarga parcial através dos métodos de Dornenburg e Rogers .....	27
<b>Tabela 2</b> — Coordenadas tridimensionais dos eletrodos de teste.....	70
<b>Tabela 3</b> — Parâmetros dos transformadores utilizados para alimentar os eletrodos .....	71
<b>Tabela 4</b> — Coordenadas tridimensionais dos sensores piezelétricos.....	72
<b>Tabela 5</b> — Quantidade de neurônios nas camadas escondidas para cada rotina de testes .....	77
<b>Tabela 6</b> — Topologias de rede neurais selecionadas para a etapa final de treinamento .....	78
<b>Tabela 7</b> — Conjunto de entradas utilizadas na etapa final de treinamento das redes neurais .....	79
<b>Tabela 8</b> — Sensores escolhidos para localização da descarga parcial .....	80
<b>Tabela 9</b> — Parâmetros do algoritmo genético utilizado .....	81
<b>Tabela 10</b> — Erro médio da distância euclidiana para os conjuntos de entradas que obtiveram os melhores resultados.....	82
<b>Tabela 11</b> — Dados estatísticos dos treinamentos realizados com o conjunto de entradas 12 e a topologia 9 .....	84
<b>Tabela 12</b> — Comparativo entre valores estimados e desejados obtidos no treinamento 10 com o conjunto de entradas 12 e a topologia 9 .....	85
<b>Tabela 13</b> — Distâncias euclidianas estimadas entre os sensores 6, 11 e 13 e as DPs 1 e 13.....	87
<b>Tabela 14</b> — Resultados dos testes de localização da DP1 .....	88
<b>Tabela 15</b> — Resultado dos testes de localização da DP13.....	90

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>14</b>
1.1	Conceitos iniciais.....	14
1.2	Objetivos .....	16
1.3	Estrutura da dissertação .....	16
<b>2</b>	<b>DESCARGAS PARCIAIS EM TRANSFORMADORES DE POTÊNCIA.....</b>	<b>18</b>
2.1	Introdução .....	18
2.2	Definição e caracterização do fenômeno .....	19
2.3	Modelos de descargas parciais .....	20
2.4	Detecção de descargas parciais.....	23
2.4.1	Método elétrico .....	23
2.4.2	Método eletromagnético .....	25
2.4.3	Método óptico .....	26
2.4.4	Método químico .....	26
2.4.5	Método acústico .....	28
<b>3</b>	<b>DETECÇÃO DE DESCARGAS PARCIAIS ATRAVÉS DO MÉTODO ACÚSTICO .....</b>	<b>29</b>
3.1	Introdução .....	29
3.2	Conceitos básicos de acústica.....	29
3.2.1	Modos de propagação .....	29
3.2.2	Impedância acústica .....	30
3.2.3	Reflexão e refração .....	31
3.2.4	Velocidade de ondas acústicas .....	31
3.2.5	Atenuação de ondas acústicas .....	32
3.3	Sensores piezelétricos no método acústico .....	33
3.4	Processamento digital de sinais aplicado ao método acústico.....	36
3.4.1	Valor RMS .....	36
3.4.2	Energia .....	37
3.4.3	Skewness .....	37
3.4.4	Kurtosis .....	38
3.4.5	Valor de pico.....	39
3.4.6	Critério de energia .....	39

3.4.7	Critério de informação de Akaike .....	40
3.5	Deteção de descargas parciais pelo método acústico.....	41
3.6	Localização de descargas parciais pelo método acústico .....	43
<b>4</b>	<b>SISTEMAS INTELIGENTES .....</b>	<b>48</b>
4.1	Introdução .....	48
4.2	Redes neurais artificiais.....	50
4.2.1	Neurônio artificial.....	52
4.2.2	Arquiteturas de redes neurais artificiais .....	54
4.2.3	Estratégias de treinamento .....	56
4.2.4	Treinamento da rede <i>Perceptron</i> multicamadas .....	57
4.3	Algoritmos genéticos .....	58
4.3.1	Algoritmo genético simples .....	60
4.3.2	Representação e aptidão.....	61
4.3.3	População inicial e seleção.....	62
4.3.4	Operadores genéticos .....	63
4.3.5	Geração e critério de parada .....	65
<b>5</b>	<b>METODOLOGIA PROPOSTA.....</b>	<b>67</b>
5.1	Introdução .....	67
5.2	Geração de descargas parciais .....	68
5.3	Aquisição e processamento dos sinais acústicos das descargas parciais .....	72
5.4	Treinamento da rede neural.....	74
5.5	Solução do sistema não linear de localização da descarga parcial por algoritmo genético .....	80
<b>6</b>	<b>ANÁLISE E RESULTADOS .....</b>	<b>82</b>
6.1	Testes de determinação das distâncias euclidianas entre os sensores e as descargas parciais através das redes neurais .....	82
6.2	Testes de determinação das coordenadas tridimensionais das descargas parciais através de algoritmos genéticos .....	87
<b>7</b>	<b>CONCLUSÃO .....</b>	<b>92</b>
	<b>REFERÊNCIAS.....</b>	<b>94</b>

# 1 INTRODUÇÃO

## 1.1 Conceitos iniciais

A estabilidade do fornecimento de energia elétrica é uma das grandes preocupações do gerenciamento e operação de sistemas elétricos, tanto pelas perdas causadas aos setores industrial, comercial e residencial (urbano e rural) devido à interrupção do fornecimento, quanto pelo aumento do consumo de energia elétrica com o passar dos anos. Inserido nesse contexto, a pesquisa e o desenvolvimento de técnicas com o objetivo de prever falhas no sistema elétrico e auxiliar a sua manutenção são muito importantes para o aumento da confiabilidade de todo o sistema, desde a fase de geração até a distribuição da energia.

Um dos equipamentos fundamentais no sistema elétrico é o transformador de potência, responsável pela transferência de energia e alteração dos níveis de tensão na cadeia da energia elétrica, cujas falhas podem causar elevados danos financeiros aos fornecedores e consumidores. Segundo Bartley (2003), existem vários fatores que podem causar falhas em transformadores, dentro os quais podemos citar: umidade, descargas atmosféricas, surtos de tensão e corrente, manutenção inadequada ou ausente, incêndio, sobrecarga, erros de projeto ou fabricação e deterioração da isolamento do transformador (causa líder). Esta última e mais frequente decorre da perda prematura das propriedades físico-químicas do isolante devido à, basicamente, oxidação, calor, acidez e umidade.

Uma das consequências da degradação do sistema de isolamento do transformador é a ocorrência de Descargas Parciais (DP). Segundo Wang et al. (2006), as descargas parciais podem ocorrer quando cargas elétricas são formadas devido à diferença de potencial elétrico em bolhas de gases, trincas ou materiais isolantes degradados, o que resulta em um canal ionizado incompleto com o surgimento de elétrons livres. De acordo com Sarathi, Singh e Danikas (2007), as descargas parciais se manifestam no meio material pela emissão de calor, luz, radiação eletromagnética e ondas de ultrassom na forma de pulsos que se propagam por todas as direções da fonte de descarga. Wada et al. (2013) aponta que a presença de descargas parciais no óleo isolante acelera a sua degradação e, conseqüentemente, diminui a vida útil do transformador.

Com o objetivo de detectar descargas parciais em transformadores, diversos métodos foram desenvolvidos. O trabalho de Markalous (2006) apresenta os métodos mais utilizados, quais são: método elétrico, acústico, eletromagnético, óptico e químico. O método elétrico se baseia na aquisição de pulsos de corrente ou tensão nos terminais de uma impedância de medição. Já o método acústico se fundamenta na aquisição de sinais de ultrassom. O método eletromagnético, por sua vez, se constitui da aquisição de ondas UHF (*Ultra High Frequency*). Por fim os métodos óptico e químico, que se baseiam na detecção da luz e na detecção da variação da composição molecular dos materiais isolantes, respectivamente. Em todos os casos, busca-se detectar as descargas parciais a partir de fenômenos causados pela descarga parcial no material isolante (corrente elétrica, ultrassom, ondas UHF, luz e alteração química).

Dentre os métodos de detecção de descargas parciais, o método de emissão acústica se destaca por ser não-invasivo e permitir não apenas a identificação da descarga parcial mas também a localização do ponto onde a descarga ocorreu. Este método utiliza sensores acoplados ao lado externo do tanque do transformador para captar as ondas de ultrassom emitidas pela descarga parcial no interior do tanque. Ao serem emitidas, estas ondas acústicas sofrem modificações de suas características devido aos obstáculos presentes no interior do transformador, como por exemplo o núcleo, os enrolamentos e as buchas de isolamento, o que dificulta a localização da descarga parcial. Os trabalhos de Markalous (2006), Veloso (2006) e Clerice (2014), bem como a literatura científica em geral, têm abordado a localização de DPs através do método acústico em transformadores imersos a óleo mineral desprovidos dos seus componentes internos.

Tal fato tem motivado o desenvolvimento de novas técnicas de localização de descargas parciais em transformadores completos (incluindo o núcleo), a fim de superar as dificuldades enfrentadas na localização da descarga em um experimento semelhante à operação real, como por exemplo o trabalho de Castro (2016). Com o auxílio de sistemas inteligentes do tipo redes neurais artificiais (RNAs) e sistema de inferência neuro-difuso adaptativo (ANFIS), Castro (2016) obteve bons resultados na determinação das coordenadas x, y e z da descarga parcial.

Diante do exposto nesta subseção, a continuidade dos trabalhos de pesquisa de localização de descargas parciais em transformadores de potência através do

método acústico e de sistemas inteligentes é importante tendo em vista a possibilidade de se obter resultados mais precisos ou metodologias mais simples de implementação a fim de contribuir para o progresso da pesquisa relacionada ao monitoramento de falhas em transformadores.

## **1.2 Objetivos**

O objetivo deste trabalho foi apresentar um método de localização das descargas parciais em transformadores de potência imersos em óleo mineral através do método acústico, de sensores piezelétricos de baixo custo, de métricas de processamento de sinais e de sistemas inteligentes do tipo redes neurais artificiais e algoritmos genéticos. As redes neurais foram treinadas de forma a estimar as distâncias euclidianas entre os sensores e as descargas parciais e estas distâncias, por sua vez, foram utilizadas na solução do sistema não linear de localização da descarga parcial, através de um algoritmo genético, a fim de obter as coordenadas  $x$ ,  $y$  e  $z$  da origem da descarga. Tal abordagem contribui para o desenvolvimento da pesquisa no campo da detecção de falhas em transformadores e, conseqüentemente, para a redução dos custos de manutenção do sistema elétrico.

## **1.3 Estrutura da dissertação**

A dissertação é iniciada pela apresentação da descarga parcial em transformadores de potência, bem como sua definição, suas características e também seus principais métodos de detecção, conteúdo abordado no capítulo 2. O capítulo 3, em seguida, trata da detecção de descargas parciais através do método acústico, seus conceitos básicos, os sensores utilizados, as técnicas de processamento digital de sinais bem como a localização de descargas parciais.

Por sua vez, o capítulo 4 aborda os sistemas inteligentes utilizados neste trabalho para a localização de descargas parciais. São apresentados os conceitos básicos e características principais tanto das redes neurais artificiais quanto dos algoritmos genéticos.

O capítulo 5 expõe a metodologia proposta, detalhando as etapas de geração de descargas parciais, aquisição dos sinais acústicos gerados pelas descargas,

treinamento das redes neurais e solução do sistema não linear através do algoritmo genético.

O capítulo 6 trata da análise e discussão dos resultados da etapa experimental do trabalho. São apresentadas tabelas e gráficos dos resultados obtidos nos testes de determinação da distância euclidiana entre os sensores e as descargas parciais e nos testes de determinação das coordenadas tridimensionais das descargas parciais, com o objetivo de auxiliar a análise dos resultados. Por fim, o capítulo 7 aborda as conclusões desta pesquisa e propõe sugestões para trabalhos futuros.

## 2 DESCARGAS PARCIAIS EM TRANSFORMADORES DE POTÊNCIA

### 2.1 Introdução

Os transformadores de potência são equipamentos elétricos utilizados para abaixar ou elevar as tensões elétricas, mantendo a potência do circuito. A manutenção das condições normais de operação de tais equipamentos é um dos desafios para proporcionar o aumento da confiabilidade do sistema elétrico. Bartley (2003) realizou um estudo dos fatores que podem causar uma diminuição da vida útil do transformador, cuja origem pode ser ambiental, elétrica ou até inerente aos elementos deste equipamento. Segundo Bartley (2003), tais fatores são:

- Sobretensões em linhas, provenientes de chaveamentos e curtos-circuitos em sua maioria;
- Contaminação do óleo devido à carbonização ou perda de suas características físico químicas;
- Sobrecarga;
- Falhas na Isolação por oxidação, acidez, umidade, pirólise;
- Descargas atmosféricas;
- Fogo externo;
- Umidade presente nos transformadores devido a falhas de vedação dos anéis ou outros orifícios.
- Operação e manutenção inadequada, o que provoca o acúmulo de sujeira, corrosões, perdas de conexão às carcaças dos transformadores, entre outros;
- Erros de projeto;

A principal causa de falhas em transformadores está relacionada à deterioração do sistema de isolação. O sistema de isolação dos transformadores é composto basicamente pelos seguintes elementos: o óleo mineral, a porcelana, o papel de base celulósica (geralmente papel Kraft) e os vernizes. A perda das propriedades físico-química destes materiais tem como consequência, segundo Hauschild e Lemke (2014), a ocorrência de descargas parciais, o que compromete o funcionamento adequado do transformador (apud CASTRO, 2016). De acordo com Veloso (2006),

com o passar do tempo, os materiais isolantes submetidos às descargas parciais são carbonizados o que contribui para a redução da resistência de isolamento e aumento da corrente de fuga destes dielétricos.

Devido à importância do estudo relativo ao fenômeno das descargas parciais, cabe definir suas características, bem como seus modelos e também seus métodos de detecção, conforme aborda a literatura científica pertinente ao tema.

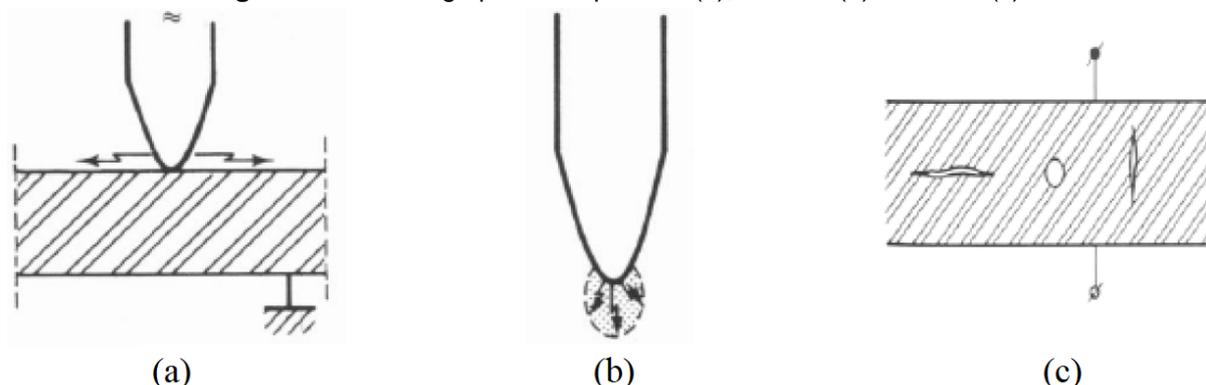
## 2.2 Definição e caracterização do fenômeno

A norma IEC-60270:2000 intitulada “*High-voltage test techniques - Partial discharge measurements*” define descarga parcial como “uma descarga elétrica localizada que atravessa parcialmente o isolamento entre condutores e que pode ou não ocorrer próxima ao condutor” (IEC, 2000, p. 2). Tais descargas são acompanhadas pela emissão de som, luz, calor e reações químicas (IEC, 2000). Segundo Wang et al. (2006), conforme citado por Castro (2016), as descargas parciais possuem característica impulsiva de duração inferior à  $1\mu\text{s}$  e podem surgir em decorrência da diferença de potencial elétrico presente em bolhas de gases, trincas, entre outros, o que resulta em um canal ionizado incompleto com o surgimento de elétrons livres. O trabalho de Mason (1995) classifica as descargas parciais em três tipos: superficial, externa e interna.

Segundo Gutnik (2014), as descargas parciais superficiais, Figura 1 (a), podem ocorrer em gases, líquidos ou na superfície de materiais dielétricos e geralmente partem do eletrodo para a superfície do material. De acordo com Gulski (1995), a descarga parcial superficial ocorre quando a componente do campo elétrico tangente à superfície excede o valor crítico de isolamento do material. Conforme Mason (1995), as DPs superficiais provocam alterações na superfície do dielétrico, em um fenômeno denominado trilhamento, que pode levar à sua ruptura completa.

As descargas parciais externas, Figura 1 (b), frequentemente referenciadas como “descargas corona”, ocorrem quando a intensidade do campo elétrico supera a rigidez dielétrica do gás envolvido e são comuns em eletrodos do tipo ponta ou que possuam pequenas curvaturas em suas extremidades (GUTNIK, 2014). Este tipo de descarga, segundo Gutnik (2014), desencadeia processos químicos que podem ser prejudiciais aos materiais isolantes como, por exemplo, a produção de gás ozônio, que pode causar fissuras nas isolações poliméricas.

**Figura 1** — Descarga parcial superficial (a), externa (b) e interna (c)



Fonte: Adaptado de Kreuger (1989).

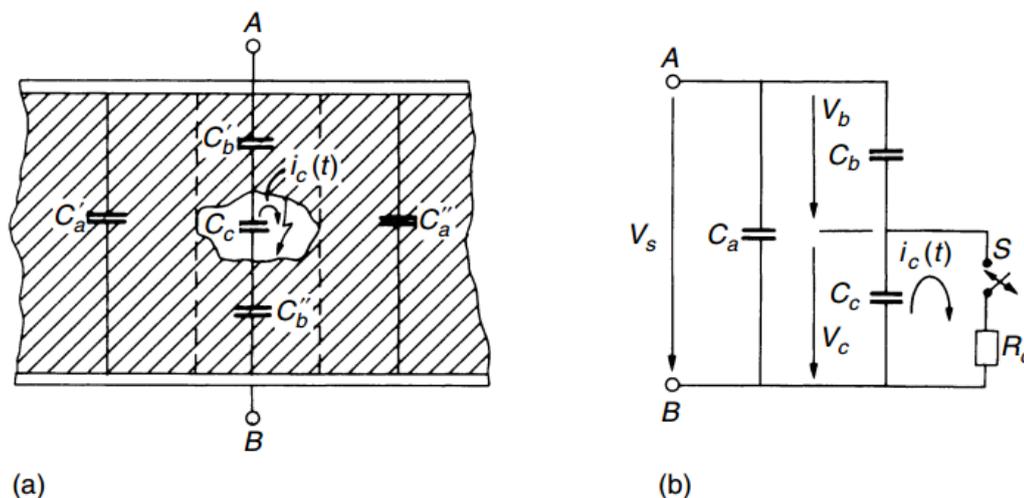
De acordo com Gutnik (2014), conforme citado por Castro (2016), as descargas parciais internas, Figura 1 (c), objeto deste trabalho, ocorrem devido às imperfeições nos materiais que compõem a isolamento de um dispositivo. Em sólidos, o aparecimento de descargas parciais é decorrente de cavidades na própria estrutura do material, seja por estresses ao qual foi submetido ou por falhas no processo de manufatura, o que possibilita a infiltração de gás no material como, por exemplo, o ar. Segundo Lemke (2008), em líquidos isolantes, as descargas parciais surgem geralmente em bolhas de gases originárias de fenômenos térmicos, elétricos e devido à presença de vapor d'água.

### 2.3 Modelos de descargas parciais

De acordo com Gutnik (2014), conforme citado por Castro (2016), existem basicamente dois modelos que caracterizam as descargas parciais: o modelo do circuito equivalente e o de aproximação por campo.

O primeiro modelo desenvolvido para caracterizar o fenômeno da descarga parcial foi proposto por Gemant e Philipoff (GEMANT; PHILIPOFF, 1932), conhecido como modelo circuito equivalente. A Figura 2(a) caracteriza a descarga parcial através de uma cavidade no material dielétrico (fluido ou sólido), que pode ser, por exemplo, uma bolha de gás ou uma descontinuidade. No modelo do circuito equivalente, esta descarga pode ser descrita por um circuito, conhecido também como o modelo a-b-c, conforme ilustrado na Figura 2(b).

**Figura 2** — Caracterização da descarga parcial na cavidade de um material dielétrico (a) e circuito equivalente (b)



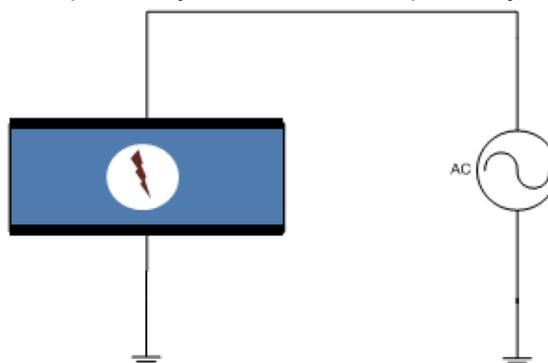
Fonte: Adaptado de Kuffel, Zaengl e Kuffel (2000).

Segundo Gutnik (2014), para o modelo do circuito equivalente, uma tensão alternada é aplicada ao material através de um eletrodo, representado pelos pontos “A” e “B”. As capacitâncias  $C_a$ ,  $C_b$  e  $C_c$  correspondem, respectivamente, à capacitância do material em perfeito estado ( $C_a$ ), à capacitância entre o eletrodo e as paredes de uma não conformidade no material ( $C_b$ ) e à capacitância da cavidade ( $C_c$ ). A chave S é controlada pela tensão  $V_c$  e simula a descarga. Esta chave permanece fechada durante um curto intervalo de tempo, simulado pelo resistor  $R_c$ , no qual a corrente  $i_c$  está presente. As capacitâncias  $C'_a$ ,  $C''_a$ ,  $C'_b$  e  $C''_b$  são representações geradas pela dualidade geométrica do material, respectivamente, à esquerda, à direita, acima e abaixo da cavidade, considerando o material inalterado.

Quando a tensão elétrica  $V_c$  no interior da cavidade atinge um determinado valor, ocorre uma descarga, o que faz com que a tensão na cavidade caia. Após a descarga, a tensão na cavidade tende a aumentar novamente devido à superposição do campo elétrico aplicado e do campo residual gerado pelas cargas superficiais que permaneceram na parede da cavidade após a última descarga (GUTNIK, 2014). De acordo com Bartnikas e McMahon (1979), este fenômeno é repetido várias vezes durante o semiciclo da tensão alternada. É importante ressaltar que, conforme vários trabalhos (KELEN; DANIKAS, 1995; McALLISTER, 1997; PEDERSEN; CRICHTON; McALLISTER, 1991), o modelo a-b-c não leva em conta fatores como geometria, localização da cavidade, entre outros, ou seja, este modelo não corresponde

necessariamente à diversidade de processos físicos presentes em um sistema real (apud GUTNIK, 2014).

**Figura 3** — Representação do modelo de aproximação por campo



Fonte: Gutnik (2014).

No caso do modelo de aproximação por campo, segundo Gutnik (2014), um material dielétrico envolve uma cavidade esférica e é submetido à uma tensão alternada por meio de dois eletrodos metálicos, conforme mostra a Figura 3.

De acordo com os trabalhos de Boggs (1990) e Edin (2001), conforme citado por Gutnik (2014), este modelo representa, de forma mais próxima à real, os fenômenos que regem uma descarga parcial em tensão alternada. Antes da ocorrência da primeira descarga, o campo elétrico na cavidade é aproximadamente uniforme e sua variação é proporcional à tensão aplicada.

Satisfeitas as condições de ocorrência da descarga, cargas elétricas são aceleradas em direção à parede da cavidade do material, onde são retidas e, conseqüentemente, o campo elétrico passa ser a soma do campo gerado pela tensão alternada e do campo gerado pelas cargas presentes na superfície do material. Dessa forma, as descargas posteriores ocorrerão quando esta superposição de campos elétricos atingir o campo de início. Um ponto importante deste modelo é que o processo de formação de uma descarga pode ocorrer ainda que a tensão aplicada ao eletrodo seja nula. Isso se deve ao fato das cargas depositadas na superfície da cavidade poderem levar o campo elétrico interno a atingir um valor suficientemente alto e, assim, permitir a ocorrência da descarga.

De acordo com Bartnikas e Novak (1993) e Morshuis (1995), os mecanismos de DPs ocorridas em cavidade fechadas são denominados avalanche (*Townsend*) e canal (*Streamer*). Segundo Gutnik (2014), a descarga do tipo avalanche consiste em

uma avalanche autossustentada com sucessores iniciadas no catodo e sua magnitude aumenta linearmente com a sobretensão e independe do tamanho da cavidade. A descarga do tipo canal, por sua vez, consiste em avalanches sucessivas, a partir de fótons de alta energia, iniciadas no gás presente no interior da cavidade e sua magnitude independe do aumento da sobretensão mas aumenta com o tamanho da cavidade (GUTNIK, 2014).

## 2.4 Detecção de descargas parciais

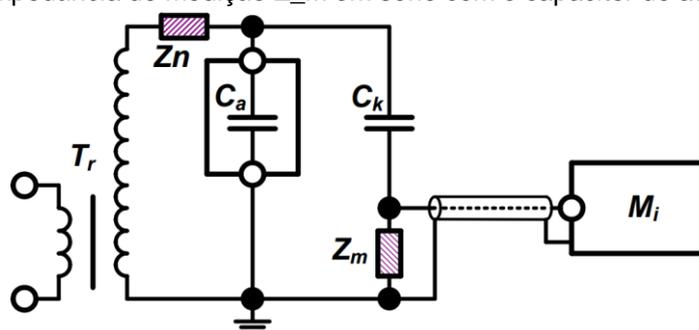
A ocorrência de descargas parciais em transformadores de potência está relacionada diretamente às condições de seu sistema de isolamento (BARTLEY, 2003; GUTNIK, 2014). Dessa forma, o monitoramento deste fenômeno torna-se essencial para a garantia do funcionamento adequado do transformador. Alguns métodos de detecção de descargas parciais estão consolidados na literatura e possuem características específicas, como por exemplo o método elétrico, eletromagnético, óptico, químico e acústico. As seções seguintes apresentam cada um destes métodos.

### 2.4.1 Método elétrico

Segundo Markalous (2006), o método elétrico se baseia na detecção do movimento de cargas em um circuito elétrico e a aquisição de pulsos de corrente ou tensão nos terminais de um objeto de teste. A Figura 4 mostra um circuito elétrico utilizado para medição de descargas pelo método elétrico, encontrado na norma IEC 60270 (2000). Esta configuração é frequentemente utilizada em testes de laboratório (MARKALOUS, 2006).

Segundo a norma IEC 60270 (IEC, 2000), este método tem por objetivo medir a queda de tensão sobre uma impedância de medição  $Z_m$ , causada pelo impulso de corrente gerado a partir da descarga parcial. No circuito da Figura 4, o capacitor  $C_a$  representa a capacitância do objeto de teste,  $C_k$  representa o capacitor de acoplamento,  $Z_m$  corresponde à impedância de medição,  $Z_n$  corresponde ao filtro de ruído e  $M_i$  representa o instrumento de medição.

**Figura 4** — Impedância de medição  $Z_m$  em série com o capacitor de acoplamento  $C_k$



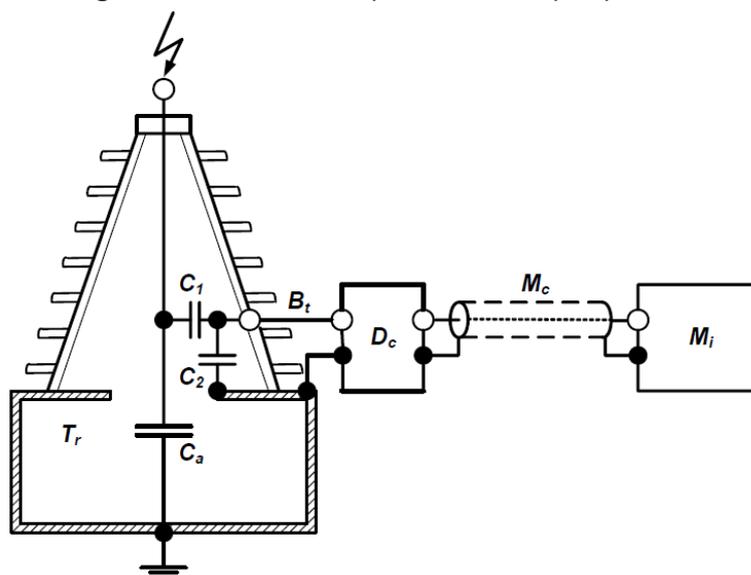
Fonte: Lemke (2008).

A função do capacitor de acoplamento é prover o retorno dos pulsos transitórios de alta frequência gerados pelas descargas. O filtro de ruído  $Z_n$ , por sua vez, possui a função de impedir que os ruídos eletromagnéticos originários do lado de alta tensão do transformador de teste  $T_r$  interfiram na medição (GUTNIK, 2014). Segundo Cuenca (2005), o aterramento de uma das extremidades do objeto de teste possui o propósito de proteger o equipamento de medição de possíveis falhas oriundas do objeto em ensaio (apud GUTNIK, 2014).

Para medição de descargas em transformadores de potência, segundo a norma IEC 60270 (IEC, 2000), o circuito de medição utiliza um tap capacitivo, como mostra a Figura 5. O instrumento de medição  $M_i$ , através do cabo de medição  $M_c$ , se conecta ao dispositivo de acoplamento  $D_c$ , onde está inserida a impedância de medição. Este, por sua vez, é conectado ao tap de uma bucha  $B_t$ . O capacitor de acoplamento  $C_k$  é análogo à capacitância da bucha de alta tensão  $C_1$  e a capacitância da bucha de baixa tensão é representada por  $C_2$ . A função do capacitor de acoplamento é transferir componentes de alta frequência dos sinais de DPs, oriundos da capacitância  $C_a$  de teste, para o dispositivo de acoplamento (GUTNIK, 2014).

De acordo com Clerice (2014), conforme citado por Castro (2016), o método elétrico de medição de DP se mostra vantajoso pelo fato de ser caracterizado de forma bem definida, pela sua padronização e pela variedade de equipamentos no mercado. No entanto, para a localização exata da origem da descarga parcial nos transformadores de potência, este método não é adequado, além de ser sensível a interferências eletromagnéticas.

**Figura 5** — Modo de acoplamento via tap capacitivo



Fonte: Lemke (2008).

#### 2.4.2 Método eletromagnético

Este método se baseia na detecção de ondas eletromagnéticas em altas frequências, produzidas pelas descargas parciais, cujo espectro de frequência varia de 300 MHz a 3 GHz (UHF). Neste método, são utilizados sensores capacitivos semelhantes a antenas, como mostra a Figura 6, acoplados internamente à parede de aço do transformador de modo a captar os sinais eletromagnéticos oriundos das DPs. Segundo Markalous (2006), este método permite obter a localização da origem da DP em transformadores de potência a partir da triangulação de sinais UHF.

**Figura 6** — Sensor UHF utilizado para detectar DPs



Fonte: Markalous (2006).

### **2.4.3 Método óptico**

Segundo Chaurasia (1999), este método tem por objetivo detectar a radiação ultravioleta produzida pelas descargas parciais, através de receptores de sinais neste espectro (apud CASTRO, 2016). De acordo com Gutnik (2014), o método óptico necessita de contato visual para detecção da descarga parcial e, se a fonte de DP estiver escondida atrás de alguma parte do equipamento, a detecção será inviabilizada, devido também aos efeitos da atenuação e dispersão provocados pelos materiais isolantes entre a fonte de DP e o sensor (SCHWARZ; JUDENDORFER; MUHR, 2008). Dessa forma, segundo Schwarz, Judendorfer e Muhr (2008), este método tem sido mais empregado no monitoramento de descargas em linhas aéreas, cujo contato visual é facilitado (apud GUTNIK, 2014).

De acordo com Forsyth (1998), conforme citado por Gutnik (2014), em gases a baixa pressão, apenas 1% da energia liberada pela DP é convertida em luz, sendo que em líquidos e sólidos este percentual é ainda menor. De acordo com Schwarz, Judendorfer e Muhr (2008), as emissões de luz por DPs em óleo isolante são originadas predominantemente na presença de hidrocarbonetos e hidrogênio, cujo range espectral está situado, em sua maior parte, dentro do espectro de luz visível (apud GUTNIK, 2014). Segundo Schwarz, Judendorfer e Muhr (2008), este método apresenta desvantagens, como os problemas de acessibilidade e possibilidade de perda de calibração. Por outro lado, dentre as principais vantagens deste método, está o fato de ser isolado galvanicamente bem como protegido da interferência de sinais eletromagnéticos indesejados nas medições (apud GUTNIK, 2014).

### **2.4.4 Método químico**

Segundo Gutnik (2014), este método se baseia na análise cromatográfica dos gases dissolvidos no óleo isolante do transformador. As reações químicas provenientes da degradação dos materiais isolantes produzem substâncias cujas concentrações permitem indicar a provável falha ocorrida no interior do transformador. Segundo Clerice (2014), o método químico é um dos métodos mais utilizados por empresas que prestam serviços de manutenção nestes equipamentos elétricos.

Na literatura existem diversos tipos de métodos utilizados na análise de gases dissolvidos em óleo isolante, dentre os quais estão os seguintes: método do Gás

Chave, método de Dornenburg, método de Rogers e o método de Duval (IEEE, 2009; DUVAL, 2002). O método do gás chave, por exemplo, permite identificar a ocorrência de uma falha no transformador quando as concentrações dos gases no óleo isolante, associadas a esta falha, ultrapassam os valores normais de degradação. Neste método, o gás cuja concentração elevada indica a ocorrência de DPs é o Hidrogênio ( $H_2$ ) (CLERICE, 2014).

No caso dos métodos de Dornenburg e Rogers, a identificação de falhas é baseada na relação entre as concentrações de dois gases presentes no óleo isolante, de um rol de cinco gases, que podem ser: hidrogênio ( $H_2$ ), metano ( $CH_4$ ), etano ( $C_2H_6$ ), etileno ( $C_2H_4$ ), acetileno ( $C_2H_2$ ). Para falhas do tipo descargas parciais, as relações de concentração, pelos métodos de Dornenburg e de Rogers, são mostrados na Tabela 1 (IEEE, 2009).

**Tabela 1** — Falha do tipo descarga parcial através dos métodos de Dornenburg e Rogers

<b>Relação de Concentração entre Gases</b>	<b>Dornenburg</b>	<b>Rogers</b>
$CH_4/H_2$	< 0,1	< 0,1
$C_2H_2/C_2H_4$	x	< 0,1
$C_2H_2/CH_4$	< 0,3	x
$C_2H_6/C_2H_2$	> 0,4	x
$C_2H_4/C_2H_6$	x	< 1,0

Fonte: Adaptado de IEEE (2009).

Já o método de Duval correlaciona as concentrações de três tipos de gases (acetileno, etano e metano) com o tipo de falha em um mapa triangular onde cada aresta representa a concentração de um gás, conhecido como triângulo de Duval (DUVAL, 2002). Este mapa é subdividido em várias partes de forma que a intersecção entre as concentrações dos gases indica o tipo de falha ocorrida.

Segundo Castro (2016), embora o método químico tenha eficácia da identificação de descargas parciais, através da análise cromatográfica dos gases presentes no óleo mineral, sua aplicação não permite a localização da origem da descarga parcial.

#### **2.4.5 Método acústico**

O método acústico de detecção de descargas parciais em transformadores de potência, escopo deste trabalho, se baseia na captação das ondas de ultrassom, emitidas pelas descargas parciais, através de sensores acoplados ao lado externo do tanque do transformador. Este método não destrutivo permite a localização da descarga parcial e será discutido com mais detalhes no capítulo 3.

### **3 DETECÇÃO DE DESCARGAS PARCIAIS ATRAVÉS DO MÉTODO ACÚSTICO**

#### **3.1 Introdução**

Segundo Veloso (2006), a técnica da emissão acústica é um método monitoramento de equipamentos, estruturas e processos, de forma não-destrutiva, cuja sensibilidade permite o diagnóstico preciso de falhas. De acordo com Markalous (2006), a ocorrência de descargas parciais em transformadores imersos à óleo isolante libera energia, o que resulta, dentre outros aspectos, em ondas mecânicas que se propagam no interior do tanque do transformador, sofrendo reflexões e refrações nos seus componentes internos. Geralmente, os sensores utilizados para detecção das ondas acústicas são do tipo piezelétricos e as características destas ondas podem ser obtidas através do processamento digital dos sinais emitidos por estes sensores.

Dessa forma, conhecer as características de propagação da onda acústica, dos sensores piezelétricos bem como das métricas de processamento digital de sinais é essencial para a aplicação do método acústico na localização de descargas parciais.

#### **3.2 Conceitos básicos de acústica**

A fim de compreender melhor as características de propagação de uma onda acústica, alguns conceitos básicos de acústica serão apresentados nas subseções seguintes, quais são: modos de propagação, impedância acústica, reflexão, refração, velocidade no meio e atenuação.

##### **3.2.1 Modos de propagação**

O som se propaga em um movimento ondulatório através de um meio material em quatro modos principais (VELOSO, 2006):

- ondas longitudinais: a oscilação e a trajetória da onda possuem a mesma direção;

- ondas transversais: a direção da oscilação da onda é perpendicular à sua trajetória;
- ondas de superfície: estas ondas possuem componentes longitudinais e transversais, resultando em um movimento com órbita elíptica. Estas ondas, também chamadas de ondas Rayleigh, são geradas quando uma onda longitudinal intersecta uma superfície com um determinado ângulo de incidência (NDT, 2017);
- ondas *plate*: são semelhantes às ondas de superfície, porém só são geradas em materiais com espessura da ordem de alguns comprimentos de onda (NDT, 2017). A onda oscila de forma perpendicular à direção de trajetória e pode ser do tipo Lamb (movimento perpendicular à superfície) ou Love (movimento paralelo ao plano da superfície).

Nos meios líquido, como o óleo isolante, e gasoso, como o ar, o único modo de propagação da onda acústica é o longitudinal. Em meio sólido, a onda acústica pode se propagar nos quatro modos citados (NDT, 2017).

### 3.2.2 Impedância acústica

A impedância acústica específica de um meio é dada pela razão entre a pressão sonora e a velocidade da partícula que sofre o distúrbio (VELOSO, 2006). Para ondas planas, a impedância acústica  $Z$  em  $\text{kg/m}^2\text{s}$  é dada pela Equação 1:

$$Z = \rho_0 \cdot c \quad (1)$$

onde  $c$  é a velocidade do som em  $\text{m/s}$  e  $\rho_0$  é a densidade em  $\text{kg/m}^3$ , ambos em relação ao material onde ocorre a propagação. Esta característica é fundamental para a determinação da transmissão e reflexão da onda acústica na interface de dois materiais distintos bem como na absorção de energia acústica pelo meio (VELOSO, 2006).

### 3.2.3 Reflexão e refração

Uma onda, ao se propagar de um meio para um outro, de densidade diferente, sofrerá a reflexão e a refração, o que resulta em uma perda de energia da onda transmitida (VELOSO, 2006). Dessa forma, o coeficiente de transmissão  $\alpha_t$  para uma incidência perpendicular da onda é dado pela Equação 2:

$$\alpha_t = \frac{I_t}{I_i} = \frac{4Z_1Z_2}{(Z_1 + Z_2)^2} \quad (2)$$

onde  $I_t$  é a intensidade da onda transmitida,  $I_i$  é a intensidade da onda propagada e  $Z_1$  e  $Z_2$  são as impedâncias acústicas dos meios. Entre o óleo e o aço, o valor do coeficiente de transmissão é de 0,11 (VELOSO, 2006). Para uma incidência oblíqua da onda, a onda transmitida terá seu ângulo alterado, segundo a Lei de Snell, como mostra a Equação 3:

$$\frac{\text{sen}(\varphi_t)}{c_t} = \frac{\text{sen}(\varphi_i)}{c_i} \quad (3)$$

onde  $\varphi_t$  é o ângulo de incidência da onda transmitida,  $\varphi_i$  é o ângulo de incidência da onda refratada para outro meio,  $c_t$  é a velocidade de propagação da onda transmitida e  $c_i$  é a velocidade de propagação da onda propagada (CASTRO, 2016).

### 3.2.4 Velocidade de ondas acústicas

A velocidade da onda sonora depende do meio onde ocorre a sua propagação, quer seja gasoso, líquido incompressível, líquido compressível ou sólido (GUTNIK, 2014). As Equações 4, 5, 6 e 7 a seguir descrevem as velocidades do som para os respectivos meios.

$$V_g = \sqrt{\frac{\gamma P}{\rho}} \quad (4)$$

$$V_l = \sqrt{\frac{K}{\rho}} \quad (5)$$

$$V_{lc} = \sqrt{\frac{\gamma K}{\rho}} \quad (6)$$

$$V_s = \sqrt{\frac{Y}{\rho[1 - 2\sigma^2(1 - \sigma)]}} \quad (7)$$

onde:

$V_g$	=	velocidade do som do meio gasoso;
$V_l$	=	velocidade do som do meio líquido incompressível;
$V_{lc}$	=	velocidade do som do meio líquido compressível;
$V_s$	=	velocidade do som do meio sólido;
$\gamma$	=	razão do calor específico;
$P$	=	pressão do gás;
$\rho$	=	densidade do material;
$K$	=	constante de volume;
$Y$	=	constante de Young;
$\sigma$	=	constante de Poisson.

### 3.2.5 Atenuação de ondas acústicas

A atenuação da propagação de ondas acústicas é um fenômeno complexo e depende de parâmetros como a absorção molecular, viscosidade e temperatura do meio (GUTNIK, 2014). De acordo com Sivian (1947), o modelo matemático que define o coeficiente de absorção  $A_B$  de uma onda sonora foi desenvolvido por Stokes e Kirchoff, conforme mostra a Equação 8 (apud GUTNIK, 2014).

$$A_B = \frac{4\pi^2 f^2}{c^3 \rho_0} \left[ \frac{4}{3} \eta + \frac{(\gamma - 1)}{C_p} k \right] \quad (8)$$

onde:

$\eta$	=	coeficiente de viscosidade;
$f$	=	frequência da onda sonora;
$\rho_0$	=	densidade do meio material;
$c$	=	velocidade do som no meio;
$\gamma$	=	razão do calor específico;
$k$	=	calor específico à pressão constante;
$C_p$	=	condutividade térmica do meio.

A partir dos efeitos sofridos pela onda acústica (reflexão, refração e atenuação), é possível concluir que a velocidade da onda apresenta variações em sua propagação. Tais efeitos ocorrem devido aos diversos meios que a onda percorre no interior do transformador, como o óleo isolante, a bobina de cobre, o núcleo de aço, o tanque de aço, entre outros (CASTRO, 2016). Assim, a onda acústica a ser captada através de sensores possui características diferentes daquela formada originalmente pela descarga parcial.

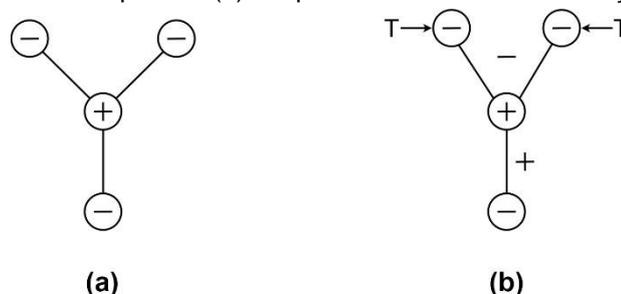
### 3.3 Sensores piezelétricos no método acústico

Alguns materiais, ao serem submetidos a uma tensão mecânica, produzem uma tensão elétrica de saída, através da formação de um dipolo elétrico. Os materiais que apresentam essa característica são denominados piezelétricos. A piezeletricidade foi descoberta por Jacques e Pierre Curie e o termo piezelétrico vem do grego *piezein* (pressão em português). Nesses materiais também ocorre o efeito reverso, ou seja, se forem submetidos a uma tensão elétrica, sofrerão uma deformação mecânica. Esta subseção apresenta as características básicas da piezeletricidade e, para um estudo mais específico do tema, são recomendados os trabalhos de Meitzler (1987) e Ibrahim (1991).

A Figura 7 mostra um cristal piezelétrico sob duas situações: em equilíbrio (a) e em deformação (b). No cristal em equilíbrio, os três dipolos formados pelo íon têm momento total nulo. Quando o cristal é submetido à uma tensão mecânica 'T', os

ângulos entre os dipolos produzem um momento na direção da deformação (ARENÝ; WEBSTER, 2000; MEITZLER, 1987).

**Figura 7** — Cristal em equilíbrio (a) e dipolo resultante da deformação mecânica (b)



Fonte: Adaptado de Areny e Webster (2000).

Segundo Meitzler (1987), as Equações 9 e 10 regem o comportamento dos materiais piezelétricos, de acordo com o critério da energia livre de Gibbs, desconsiderando os efeitos térmicos e magnéticos (apud CASTRO, 2016):

$$S = s^E T + dE \quad (9)$$

$$D = dT + \varepsilon^T E \quad (10)$$

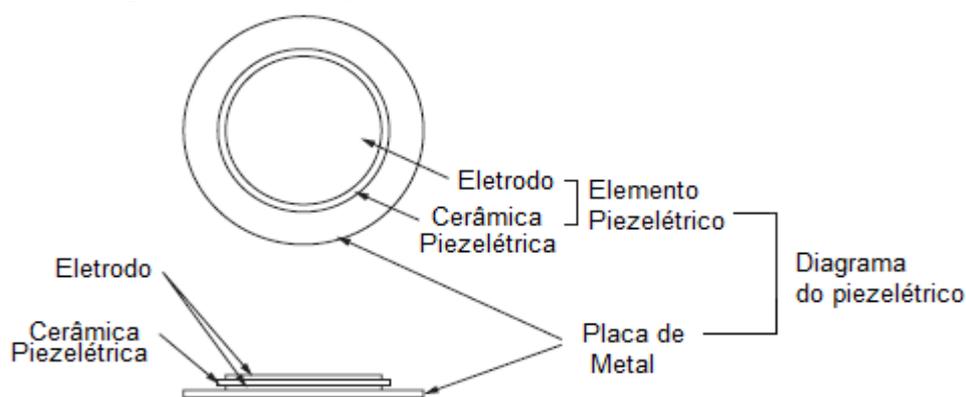
sendo  $S$  uma deformação,  $T$  uma tensão,  $E$  um campo elétrico,  $D$  uma densidade de fluxo,  $s^E$  o tensor de elasticidade do material,  $d$  as constantes piezelétricas e  $\varepsilon^T$  representa as constantes de permissividade dielétricas. Dessa forma, os sensores piezelétricos têm a propriedade de gerar uma diferença de potencial a partir de uma deformação mecânica provocada, por exemplo, por uma onda acústica (CASTRO, 2016).

Entre os materiais piezelétricos, destacam-se o titanato de bário ( $\text{BaTiO}_3$ ), utilizado em transdutores ultrassônicos e, recentemente, o titanato zirconato de chumbo ( $\text{PbZr}_{0,6}\text{Ti}_{0,4}\text{O}_3$ ), conhecido como PZT ou diafragma piezelétrico. De acordo com Marchi (2015), estes diafragmas apresentam algumas vantagens em relação a outros materiais piezelétricos, quais são: bom acoplamento eletromecânico, boa estabilidade, alta rigidez, resposta linear para campo elétrico de baixa intensidade e baixo custo (apud CASTRO, 2016).

A Figura 8 mostra os detalhes construtivos da cápsula piezelétrica de baixo custo utilizada nesta pesquisa, similar ao modelo 7BB-35-3 da Murata. Segundo

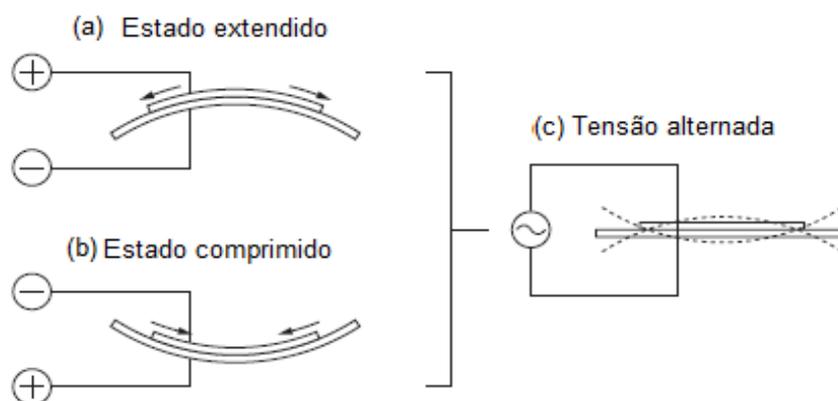
Murata (2015), um diafragma piezolétrico consiste de placas de cerâmica piezolétricas que possuem eletrodos em ambos os lados afixadas à uma placa de metal através de adesivos.

**Figura 8** — Construção da cápsula piezolétrica de baixo custo



Fonte: Murata (2015).

**Figura 9** — Sistema de oscilação da cápsula piezolétrica de baixo busto



Fonte: Murata (2015).

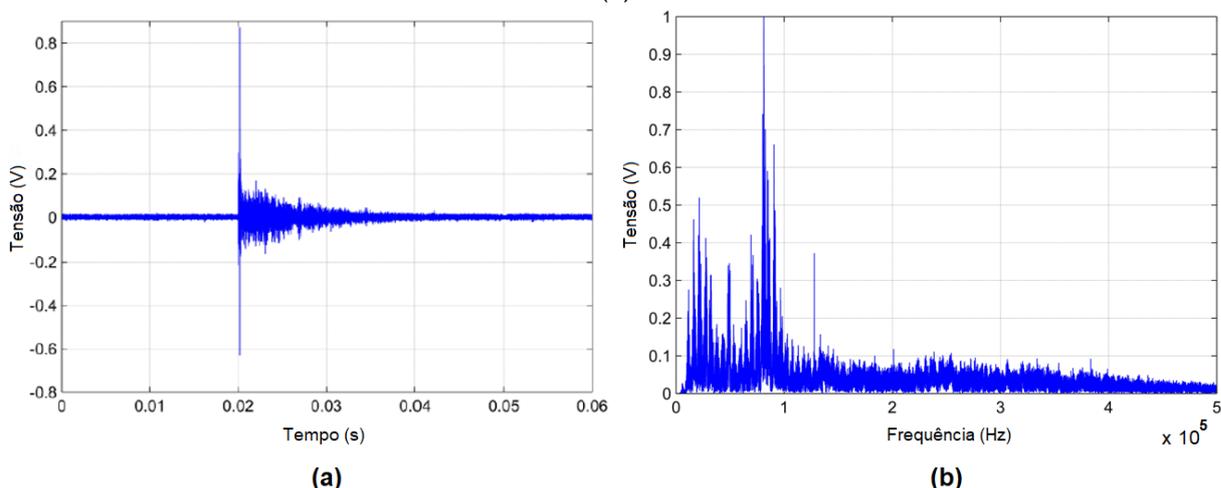
Um elemento piezolétrico submetido à uma tensão elétrica conforme a Figura 9 (a) irá se expandir na direção radial. Caso a polaridade da tensão seja invertida, o material irá se comprimir, de acordo com a Figura 9 (b). Dessa forma, quando uma tensão alternada é aplicada aos eletrodos da cápsula piezolétrica, as flexões ilustradas nas Figuras 9 (a) e (b) são repetidas de forma cíclica, como mostra a Figura 9 (c), produzindo ondas sonoras (MURATA, 2015).

Neste trabalho estas capsulas piezolétricas serão utilizadas como sensores na aquisição dos sinais das ondas acústicas geradas pelas DPs. Métricas de processamento digital de sinais serão aplicadas aos sinais de forma a caracterizá-los e permitir a localização da fonte de descarga parcial.

### 3.4 Processamento digital de sinais aplicado ao método acústico

A aquisição, através de um instrumento de medição, dos sinais acústicos gerados pela descarga parcial e captados pelos sensores piezelétricos, permite realizar o processamento digital desses sinais a fim de extrair suas características. A Figura 10 mostra um exemplo do sinal acústico utilizado neste trabalho, nos domínios do tempo (a) e da frequência (b), captado pelo sensor piezelétrico e tratado por meio de um filtro digital passa alta de 20 kHz. O sinal acústico teve duração de aproximadamente 0,02 s com uma faixa de frequências mais significativa até 250 kHz.

**Figura 10** — Sinal acústico captado por um sensor piezelétrico no domínio do tempo (a) e frequência (b)



Fonte: Castro et al. (2016).

Esta subseção tem por objetivo apresentar as métricas de processamento de sinais utilizadas nesta pesquisa. Tais métricas correspondem ao conjunto de dados de entrada do sistema inteligente (redes neurais artificiais), abordados posteriormente no capítulo 4, que visa a localização das descargas parciais, quais são: RMS ou valor eficaz, energia do sinal, skewness, kurtosis, valor de pico, critério de energia e critério de informação de Akaike.

#### 3.4.1 Valor RMS

Segundo Aguiar, Bianchi e Canarim (2012), conforme citado por Castro (2016), o valor RMS é um dos critérios mais importantes na avaliação de um sinal de saída

do sensor de emissão acústica. Esta métrica pode ser considerada como uma quantidade física de intensidade de som e está diretamente relacionada com a carga aplicada ao sensor. A Equação 11 apresenta o valor RMS tanto para um sinal contínuo no intervalo  $T$  quanto para um sinal discreto:

$$V_{eficaz} = \sqrt{\frac{1}{T} \int_0^T (E(t))^2 dt} = \sqrt{\frac{1}{N} \sum_{i=1}^N E_i^2} \quad (11)$$

onde  $T$  é o tempo de integração,  $N$  é o número de amostras no intervalo  $T$ ,  $E$  é a tensão elétrica do sinal no instante  $t$  e  $E_i$  é a tensão elétrica da amostra  $i$ . No caso de sinais acústicos, que são não periódicos, o sinal é janelado e o tempo de integração é definido como o período de duração da janela (CASTRO, 2016).

### 3.4.2 Energia

A energia do sinal acústico também está relacionada com a carga acústica aplicada ao sensor, como mostra a Equação 12:

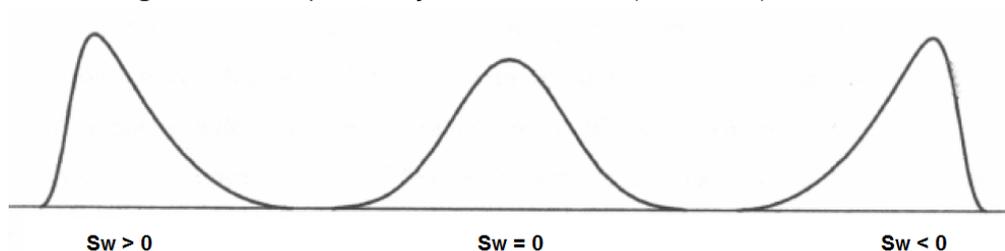
$$\Theta = \int_{-\infty}^{+\infty} |E(t)|^2 dt = \frac{1}{N} \sum_{i=1}^N E_i^2 \quad (12)$$

onde  $\theta$  é a energia do sinal,  $N$  é o número de amostras,  $E$  é a tensão elétrica do sinal no instante  $t$  e  $E_i$  a tensão elétrica da amostra  $i$  (CASTRO, 2016).

### 3.4.3 Skewness

Esta métrica é utilizada para caracterizar a assimetria de um sinal, como mostra a Figura 11. Valores positivos de Skewness (assimetria positiva) indicam uma frequência maior de dados abaixo da média. Para valores negativos de Skewness (assimetria negativa), a frequência é maior nos dados acima da média. Skewness igual à zero indica que a distribuição dos dados é simétrica.

**Figura 11** — Representação da assimetria (Skewness) de um sinal



O Skewness de uma amostra de dados é calculado através da Equação 13 a seguir:

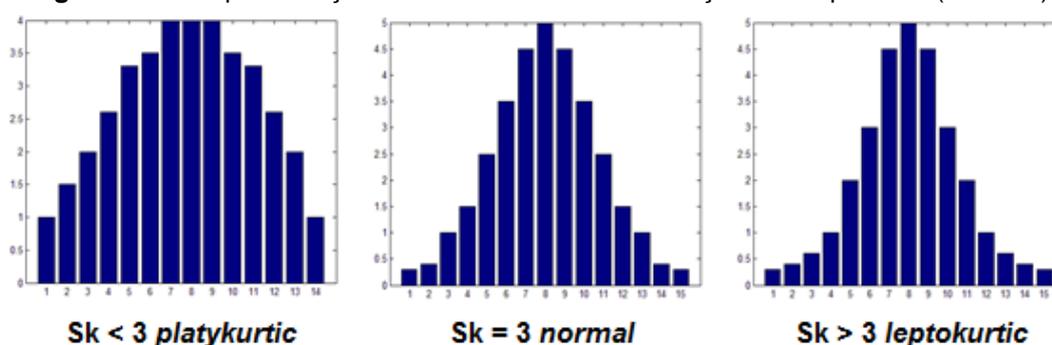
$$S_w = \frac{1}{(n-1)} \frac{\sum_{i=1}^n (V_i - \bar{V})^3}{s^3} \quad (13)$$

onde  $V$  é o valor instantâneo,  $n$  é o número de amostras,  $i$  é o índice do valor,  $\bar{V}$  representa a média aritmética e  $s$  é o desvio padrão entre os dados.

### 3.4.4 Kurtosis

A *Kurtosis* é o coeficiente que indica o afastamento da distribuição de frequência dos dados em relação à distribuição normal, como mostra a Figura 12.

**Figura 12** — Representação do afastamento da distribuição de frequências (Kurtosis)



Fonte: Castro (2016).

As três distribuições apresentadas na Figura 12 são simétricas e com médias e variâncias iguais. Valores de *Kurtosis* menores que três implicam em uma distribuição mais “achatada” (menos concentrada em torno da média), conhecida

como *platykurtic*. Para valores de *Kurtosis* acima de três, a distribuição é mais “afilada” (mais concentrada em torno da média) e é chamada de *leptokurtic*. A distribuição normal possui valor de *Kurtosis* igual a 3. A Equação 14 define o cálculo da *Kurtosis* como:

$$S_k = \frac{1}{(n-1)} \frac{\sum_{i=1}^n (V_i - \bar{V})^4}{s^4} \quad (14)$$

onde  $V$  é o valor instantâneo,  $i$  é o índice deste valor,  $\bar{V}$  representa a média aritmética,  $n$  o número de amostras e  $s$  é o desvio padrão entre os dados.

### 3.4.5 Valor de pico

O valor de pico é o maior valor que uma grandeza considerada atinge em um determinado período. Para um sinal de tensão em função do tempo, a Equação 15 define valor de pico como:

$$V_p = \max(|V_m(t)|) \quad (15)$$

onde  $V_m$  é o valor da amplitude da tensão instantânea e  $t$  é o instante de tempo.

### 3.4.6 Critério de energia

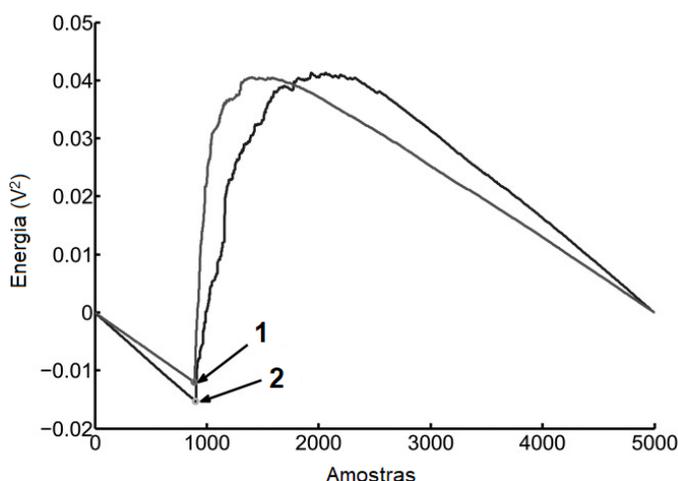
De acordo com Markalous, Tenbohlen e Feser (2008) e Robles, Fresno e Tarifa (2015), o critério de energia tem por objetivo caracterizar a emissão acústica, cuja faixa de frequência e conteúdo energético são variáveis (apud CASTRO, 2016). A curva de energia  $S'_i$  do sinal amostrado  $V$  é definida como a soma cumulativa dos valores de amplitude, conforme a Equação 16:

$$S'_i = \sum_{k=0}^i \left( V_k^2 - i \frac{S_N}{N} \right) \quad (16)$$

onde  $i$  é uma variável de contagem e a curva instantânea de energia depende da energia total do sinal  $S_N$  e do número de amostras  $N$ .

No caso de detecção de sinais acústicos, o mínimo global desta curva equivale ao instante de tempo ao qual um sensor é excitado inicialmente pelas ondas acústicas. A Figura 13 apresenta o critério de energia dos sinais acústicos de dois sensores distintos, onde os pontos 1 e 2 destacados no gráfico representam as amostras de chegada da onda acústica nos sensores. Segundo Markalous, Tenbohlen e Feser (2008), devido à intensidade de energia do sinal ter relação direta com a carga aplicada ao sensor, este critério pode ser utilizado para caracterizar e mensurar um sinal (apud CASTRO, 2016).

**Figura 13** — Pontos de mínimo do critério de energia para a determinação do tempo de chegada de um sinal acústico em sensores



Fonte: Adaptado de Robles, Fresno e Tarifa (2015).

### 3.4.7 Critério de informação de Akaike

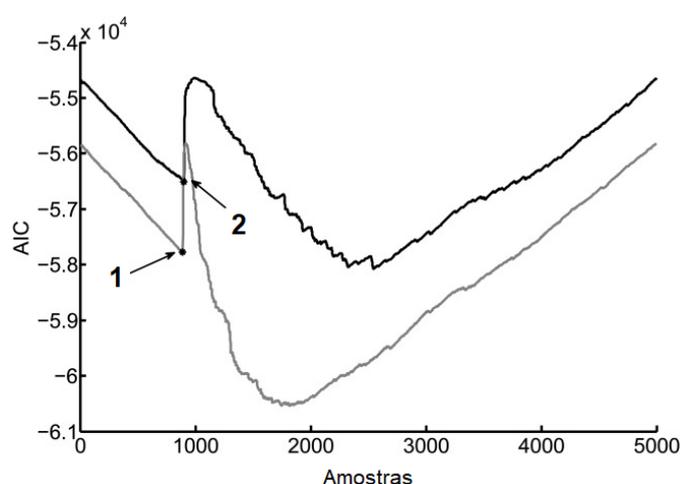
Segundo Robles, Fresno e Tarifa (2015), o critério de informação de Akaike (*Akaike Information Criterion* em inglês) considera os sinais como um processo autorregressivo em que cada amostra é uma combinação linear de amostras passadas. Este critério pode ser utilizado para determinar o tempo de chegada da onda acústica no sensor através da comparação entre dois segmentos do sinal, entre as amostras de 1 a  $n$  e entre as amostras de  $n + 1$  a  $N$ , como mostra a Equação 17:

$$AIC(n) = n \ln[\sigma^2(1, n)] + (N - n - 1) \ln[\sigma^2(n + 1, N)] \quad (17)$$

onde  $n$  é uma amostra do sinal,  $N$  é o número total de amostras e  $\sigma^2$  a variância do segmento.

A Figura 14 mostra o gráfico do critério de informação de Akaike aplicado aos sinais acústicos de dois sensores distintos, onde os pontos 1 e 2 destacados representam representam as amostras de chegada da onda acústica nos sensores (CASTRO, 2016).

**Figura 14** — Pontos de mínimo local do critério de Akaike para a determinação do tempo de chegada de um sinal acústico em um sensor



Fonte: Adaptado de Robles, Fresno e Tarifa (2015).

Embora os critérios de energia e de Akaike permitam determinar os tempos de chegada da onda acústica nos sensores, há uma diferença entre os resultados obtidos, conforme mostrado no trabalho de Markalous, Tenbohlen e Feser (2008). Este comportamento se deve ao problema não ser totalmente determinístico, uma vez que envolve uma região de transitório entre o início da excitação e o sinal normal (apud CASTRO, 2016).

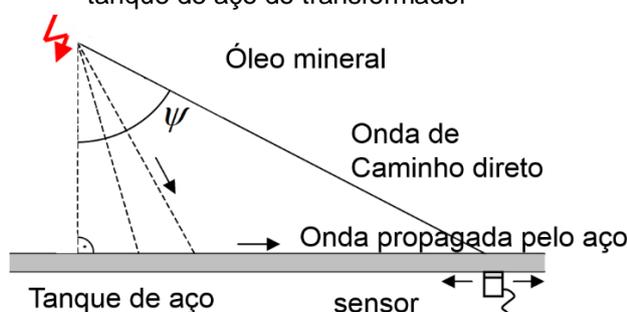
### 3.5 Detecção de descargas parciais pelo método acústico

Segundo Castro (2016), a detecção de descargas parciais pelo método acústico em transformadores consiste na utilização de sensores acústicos, fixados em diferentes pontos na parede do tanque do transformador, e na aquisição e análise dos sinais transmitidos por esses sensores. Tais sensores são excitados por dois tipos de ondas acústicas formadas pela descarga parcial: ondas longitudinais, que percorrem

o óleo isolante e a estrutura interna do transformador, e ondas de superfície, que percorrem a parede do tanque do transformador.

Segundo Markalous, Tenbohlen e Feser (2008) a onda gerada pela descarga parcial se propaga em todas as direções de forma esférica e, conseqüentemente, atinge a parede do tanque do transformador em diferentes instantes de tempo. Devido à onda acústica se propagar com velocidades diferentes no óleo isolante e no tanque de aço do transformador, em torno de 1400 m/s e 5000 m/s respectivamente, existe a possibilidade do sensor acústico captar primeiramente a onda proveniente do tanque de aço e não a de caminho direto, como mostra a Figura 15 (CASTRO, 2016).

**Figura 15** — Sensor acústico atingido por ondas de caminho direto e por ondas propagadas no tanque de aço do transformador



Fonte: Adaptado por Castro (2016) de Markalous, Tenbohlen e Feser (2008).

Dessa forma, a detecção da descarga parcial é realizada por meio do processamento digital de um sinal acústico que contém componentes dessas duas ondas (caminho direto e propagada pelo tanque) e de outras ondas provenientes de reflexões e refrações no interior do transformador. Segundo Phukan e Karmakar (2013), o processamento do sinal é realizado através de ferramentas como a transformada rápida de Fourier, wavelets, energia, entropia, valor RMS do sinal, dentre outras (apud CASTRO, 2016).

É importante ressaltar que a identificação de descargas parciais em si, através do método acústico, já promove uma significativa melhora no planejamento da manutenção de um transformador e, conseqüentemente, aumenta a confiabilidade do sistema elétrico como um todo. Todavia, para uma manutenção mais rápida e eficaz, faz-se necessária a localização da origem da DP no interior do transformador.

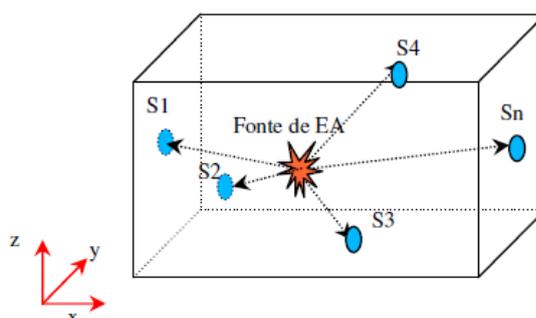
### 3.6 Localização de descargas parciais pelo método acústico

A localização de um ponto de DP pelo método acústico, dentro de um taque de aço dotado de óleo isolante, requer diversos sensores que coletam sinais acústicos simultaneamente (LUNDGAARD, 1995), embora existam alguns métodos que propõem tal tarefa utilizando apenas um único sensor, movendo-o ao longo da estrutura (AUCKLAND et al., 1994). Os sinais acústicos adquiridos são processados e algumas análises de dados são realizadas, como por exemplo a intensidade, componentes espectrais do sinal, formato, energia do sinal, intervalos de tempo relativos entre os sensores, dentre outros.

O método que utiliza apenas um sensor não contempla a localização precisa da fonte e o deslocamento deste através das paredes de aço faz com que a operação se torne perigosa, uma vez que o sensor deve ocupar também posições próximas a níveis elevados de tensão (VELOSO, 2006).

Na literatura, o método que utiliza vários sensores (no mínimo quatro), fornece com precisão a localização de descargas parciais e se vale da triangulação de sinais acústicos. O método se dá por meio de um equacionamento de um sistema não linear cujas variáveis conhecidas são as posições dos sensores, a velocidade de propagação da onda no óleo isolante e também o tempo de chegada da onda nos sensores. A essência do método é extrair os instantes de tempo em que os sensores são atingidos pela frente de onda de descarga parcial e aplica-los na solução de um sistema não linear como visto em Markalous, Tenbohlen e Feser (2008).

**Figura 16** — Esquema para o equacionamento do método de localização de DPs por triangulação de sinais



Fonte: Veloso (2006)

A Figura 16 ilustra o esquema de equacionamento do problema, sendo “S” representando um sensor de emissão acústica. Segundo Markalous, Tenbohlen e Feser (2008), um sistema de equações não lineares pode ser obtido a partir da distância euclidiana entre o local da descarga parcial e os “n” sensores acoplados na parede de aço do transformador. Esse sistema é mostrado nas Equações 18, 19, 20 e 21.

$$(x + x_{s1})^2 + (y + y_{s1})^2 + (z + z_{s1})^2 = (c \cdot \Delta t_1)^2 \quad (18)$$

$$(x + x_{s2})^2 + (y + y_{s2})^2 + (z + z_{s2})^2 = (c \cdot \Delta t_2)^2 \quad (19)$$

$$(x + x_{s3})^2 + (y + y_{s3})^2 + (z + z_{s3})^2 = (c \cdot \Delta t_3)^2 \quad (20)$$

...

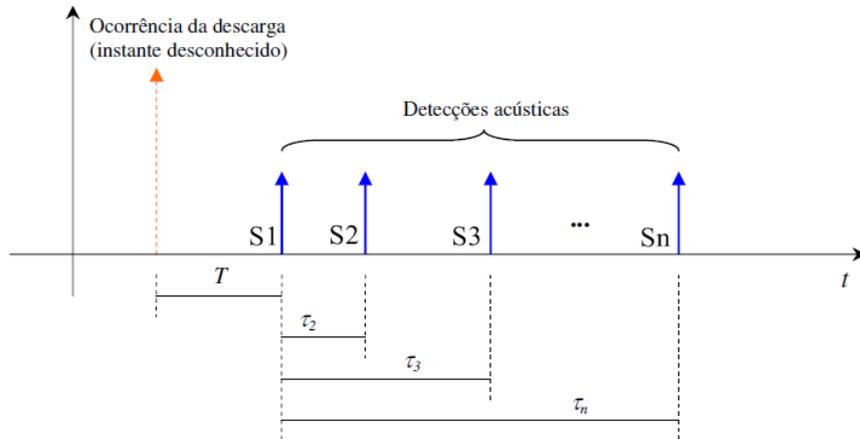
$$(x + x_{sn})^2 + (y + y_{sn})^2 + (z + z_{sn})^2 = (c \cdot \Delta t_n)^2 \quad (21)$$

onde:

$x, y$ e $z$	=	coordenadas da descarga parcial;
$x_{si}, y_{si}$ e $z_{si}$	=	coordenadas dos sensores utilizados;
$c$	=	velocidade do som no óleo mineral;
$\Delta t_i$	=	intervalo de tempo entre a ocorrência da DP e o instante em que a onda incide sobre o sensor.

Para que seja possível identificar o instante de tempo em que a descarga parcial ocorre, seria necessário a utilização do método elétrico. Dessa forma, seria possível obter todos os valores de  $\Delta t_i$  por meio da diferença entre os tempos de excitação dos sensores e o instante inicial de tempo da ocorrência da DP. Contudo, o emprego paralelo do método elétrico de detecção de DPs com o método acústico retornaria todas as desvantagens provenientes do aparato elétrico já mencionados no capítulo 2.

**Figura 17** — Intervalos de tempo entre as detecções da DP utilizando somente o método acústico



Fonte: Veloso (2006).

A solução para este problema, discutido em Markalous, Tenbohlen e Feser (2008) e Veloso (2006) consiste em acrescentar ao problema uma incógnita: o tempo de excitação do sensor mais próximo à descarga parcial ( $\Delta t_1$ ), denotado por “ $T$ ”, como mostra a Figura 17. Deste modo, o sistema não linear para a localização pode ser descrito conforme as Equações 22, 23, 24 e 25:

$$(x + x_{s_1})^2 + (y + y_{s_1})^2 + (z + z_{s_1})^2 = (c.T)^2 \quad (22)$$

$$(x + x_{s_2})^2 + (y + y_{s_2})^2 + (z + z_{s_2})^2 = (c.(T + \tau_2))^2 \quad (23)$$

$$(x + x_{s_3})^2 + (y + y_{s_3})^2 + (z + z_{s_3})^2 = (c.(T + \tau_3))^2 \quad (24)$$

...

$$(x + x_{s_n})^2 + (y + y_{s_n})^2 + (z + z_{s_n})^2 = (c.(T + \tau_n))^2 \quad (25)$$

onde  $\tau_i$  é a diferença de tempo entre a excitação do sensor  $i$  e o sensor 1, mais próximo à DP. Para a solução do problema acima, os parâmetros de tempo de chegada da onda acústica no sensor devem ser identificados. Todavia, cabe lembrar que o sinal oriundo da fonte de descarga parcial é não estacionário, contendo diferentes informações das frentes de onda. Sendo assim, é preciso distingui-los e, para este método, extrair a frente de onda de caminho direto ao sensor. Nesse contexto, resolver o sistema não linear pode ser uma tarefa difícil quando se leva em conta a imprecisão dos dados de tempo fornecidos (VELOSO, 2006).

No trabalho realizado por Veloso (2006) foi utilizada a transformada wavelet para extrair as características de tempo de chegada da frente de onda de caminho direto nos sensores e, para a solução do sistema não linear, foi utilizado um algoritmo genético. Já em Markalous, Tenbohlen e Feser (2008), o tempo de chegada foi calculado através do critério de energia do sinal como também o critério estatístico de Akaike e a solução do sistema foi obtida através de algoritmos que solucionam sistemas de posicionamento global (GPS). Entretanto, devido às complexas características de propagação da onda acústica, esses dois trabalhos contemplaram transformadores sem a parte ativa (núcleo, bobinas, etc), isto é, a DP é dada no óleo isolante e o sinal sofre reflexões e refrações somente na parede de aço do tanque do transformador.

Devido à complexidade do problema em questão, Clerice (2014) propôs um método que utiliza sistemas inteligentes para a localização de descargas parciais, com o transformador sem a parte ativa. Foram utilizados sistemas inteligentes do tipo redes neurais artificiais (RNAs) e sistemas de inferência neuro-difuso adaptativo (ANFIS) os quais foram alimentados com métricas de sinais acústicos como energia, valor RMS, tempo de pico, tempo de subida e critério de energia. Castro (2016), por sua vez, propôs um método semelhante ao de Clerice (2014), porém com o transformador dotado de sua parte ativa e obteve resultados promissores, tanto através das RNAs quanto pelo ANFIS.

Observa-se também que a literatura carece de sistemas que localizem DPs com o transformador dotado de sua parte ativa pois, conforme discutido em Castro (2016), poucos artigos contemplam este estudo. Os obstáculos que modificam a onda acústica original tornam complexa a detecção e principalmente a localização da fonte de DP.

Este trabalho propõe uma solução alternativa ao sistema não linear apresentado nas Equações 18-21. A fim de evitar a utilização do instante de tempo da ocorrência da descarga, serão utilizadas as distâncias euclidianas tridimensionais entre os sensores e a descarga parcial a qual se deseja obter as coordenadas. Dessa forma, são necessárias apenas três equações para obter a solução do sistemas não linear, ou seja, são necessários três sensores para determinar a localização da descarga parcial, como mostram as Equações 26, 27 e 28:

$$(x + x_{S1})^2 + (y + y_{S1})^2 + (z + z_{S1})^2 = (d_1)^2 \quad (26)$$

$$(x + x_{S2})^2 + (y + y_{S2})^2 + (z + z_{S2})^2 = (d_2)^2 \quad (27)$$

$$(x + x_{S3})^2 + (y + y_{S3})^2 + (z + z_{S3})^2 = (d_3)^2 \quad (28)$$

onde  $d_i$  é a distância entre o sensor  $S_i$  e a descarga parcial. Tais distâncias serão estimadas através de redes neurais alimentadas com as métricas dos sinais acústicos de 16 sensores, a fim de gerar uma maior quantidade de amostras para o treinamento da rede. A partir dos valores das distâncias estimadas, o sistema não linear apresentado será solucionado através de um algoritmo genético. Tanto as redes neurais quanto os algoritmos genéticos, utilizados na localização da descarga parcial, serão abordados no capítulo 4.

## 4 SISTEMAS INTELIGENTES

### 4.1 Introdução

Inteligência artificial pode ser descrita como “o estudo da representação e da busca por meio do qual a atividade inteligente pode ser executada em um dispositivo mecânico.” (LUGER, 2013, p. 29). O termo inteligência artificial (IA) foi utilizado oficialmente em 1956 por John McCarthy em um seminário no Dartmouth College, que reuniu pesquisadores interessados em redes neurais, teoria de autômatos e estudo da inteligência (RUSSEL; NORVIG, 2013).

O primeiro trabalho reconhecido atualmente como de IA, no entanto, remonta à um período anterior ao seminário em Dartmouth e foi realizado por Warren McCulloch e Walter Pitts. Em 1943, os dois pesquisadores propuseram um modelo de neurônios artificiais baseados no conhecimento da fisiologia e função dos neurônios, na análise da lógica proposicional de Bertrand Russel e Alfred North Whitehead e na teoria da computação de Alan Turing (RUSSEL; NORVIG, 2013).

O objetivo da IA, segundo Sage (1990), é o desenvolvimento de algoritmos que demandam máquinas para executar tarefas cognitivas, para as quais os humanos são melhores na atualidade (apud HAYKIN, 2001). De acordo com Haykin (2001), um sistema inteligente deve ser capaz de:

- Armazenar conhecimento;
- Aplicar o conhecimento armazenado para resolver problemas;
- Adquirir novo conhecimento através da experiência.

Dessa forma, é possível sintetizar tais características dos sistemas inteligentes em três componentes fundamentais: representação, raciocínio e aprendizagem (SAGE, 1990). A representação significa o uso de uma linguagem simbólica para representar tanto o conhecimento genérico quanto um conhecimento específico de determinado problema. O conhecimento nada mais é do que um termo para designar dados (HAYKIN, 2001).

O raciocínio, por sua vez, consiste na habilidade de resolver problemas. Um sistema qualificado como de raciocínio deve satisfazer as seguintes condições (HAYKIN, 2001):

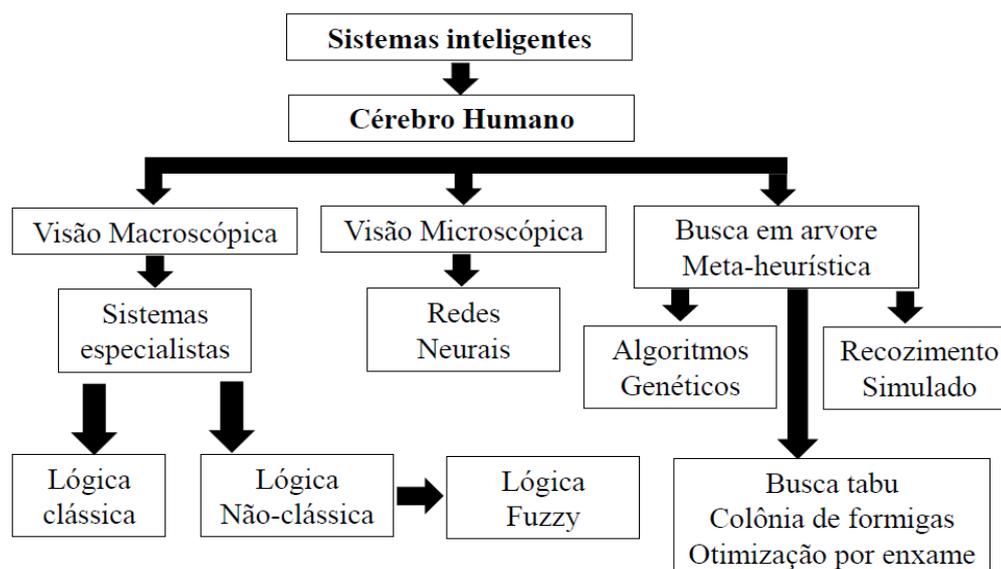
- Ser capaz de expressar e resolver uma vasta gama de problemas e tipos de problemas;
- Ser capaz de tornar conhecidas para ele tanto a informação explícita quanto a informação implícita;
- Ter um mecanismo de controle que determine: quais operações devem ser aplicadas a um determinado problema; quando uma solução para o problema foi encontrada; quando deve ser encerrado o tratamento deste problema.

Por fim, a aprendizagem de um sistema inteligente ocorre a partir de informações fornecidas pelo ambiente. O elemento de aprendizagem manipula esta informação para melhorar a base de conhecimento e o elemento de desempenho utiliza a base de conhecimento para realizar sua tarefa. Caso seja necessário, o sistema avalia suas hipóteses e as revisa através de um mecanismo de realimentação (HAYKIN, 2001).

Estas características gerais de um sistema inteligente permitem sua aplicação na localização de descargas parciais no interior de um transformador imerso à óleo mineral. Dado que o problema de localização de descargas parciais pelo método acústico é extremamente complexo pois envolve sinais de ondas acústicas que sofrem reflexões, refrações e atenuações no interior do transformador, é possível, através de sistemas inteligentes, relacionar esses sinais com a posição de uma descarga parcial ainda que esta relação seja altamente complexa.

Existem diversos tipos de sistemas inteligentes os quais estão atualmente organizados de acordo com a Figura 18 (CASTRO, 2016). Dentre os sistemas inteligentes mencionados, apenas as redes neurais artificiais e os algoritmos genéticos fazem parte deste trabalho e serão abordados nas seções seguintes.

**Figura 18** — Representação organizacional dos sistemas inteligentes



Fonte: Castro (2016).

## 4.2 Redes neurais artificiais

Segundo Silva, Spatti e Flauzino (2010, p. 24) “as redes neurais artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos”. Estas redes podem ser caracterizadas como um conjunto de unidades de processamento, denominados neurônios artificiais, os quais são interligados por uma grande quantidade de conexões (análoga às *sinapses* de um neurônio biológico) representadas por um vetor/matriz de pesos sinápticos. Dentre as principais características das redes neurais artificiais estão (SILVA; SPATTI; FLAUSINO, 2010; HAYKIN, 2001):

- Não-Linearidade: uma rede neural formada por neurônios não lineares é em si não linear e esta característica é distribuída por toda a rede. Tal propriedade é fundamental para a rede neural lidar com sinais de entrada provenientes de mecanismos físicos inerentemente não lineares;
- Mapeamento de Entrada-Saída: uma rede neural pode, a partir de um conjunto de amostras de treinamento que consiste de sinais de entradas e suas correspondentes respostas desejadas, e um critério estatístico apropriado, modificar seus pesos sinápticos de forma a minimizar o erro entre a resposta

desejada e a resposta real da rede produzida por um sinal de entrada, em um processo denominado treinamento supervisionado;

- **Generalização:** uma rede neural treinada possui a habilidade de generalizar o conhecimento adquirido e assim estimar soluções não conhecidas previamente;
- **Adaptabilidade:** as redes neurais possuem a capacidade de adaptar seus pesos sinápticos às alterações do meio ambiente, ou seja, elas não se limitam ao ambiente específico ao qual foi treinada. Uma rede neural pode ser projetada para ajustar seus pesos sinápticos em tempo real caso opere em um ambiente não estacionário;
- **Tolerância a falhas:** devido à natureza distribuída da informação armazenada na rede neural, ela é capaz de tolerar pequenas falhas em sua estrutura sem alterar sua resposta global;
- **Facilidade de prototipagem:** dependendo da característica da aplicação, a maioria das arquiteturas neurais pode ser facilmente prototipada em *hardware* e *software*.

De acordo com Silva, Spatti e Flauzino (2010), diversos problemas relacionados às áreas de engenharia e ciência permitem a aplicação das redes neurais artificiais. As principais aplicações destes modelos computacionais e seus objetivos são listadas a seguir:

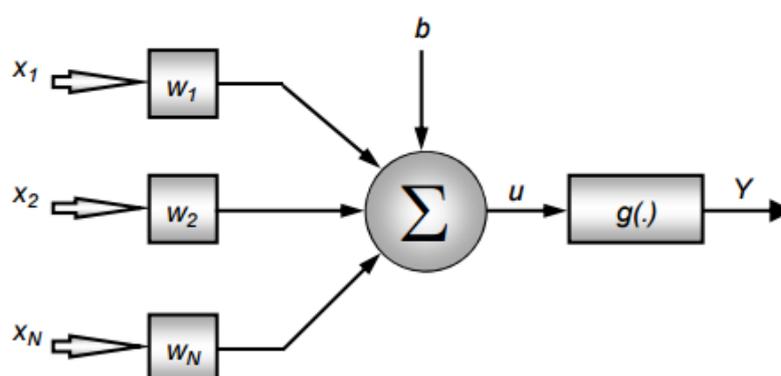
- **Aproximador universal de funções:** tem por objetivo mapear a relação entre as variáveis de um sistema a partir de um conjunto de dados, conhecidos previamente, que o representam;
- **Controle de processos:** o objetivo desta aplicação é identificar ações de controle que atendam aos requisitos de qualidade, eficiência e segurança de um determinado processo;
- **Classificação de padrões:** esta aplicação consiste em associar padrões de entradas (amostras) em categorias previamente definidas;
- **Agrupamento de dados (clusterização):** consiste na identificação de similaridades entre os diversos padrões de entrada de modo a realizar seu agrupamento;

- Sistemas de previsão: tem por objetivo prever valores futuros de um determinado processo considerando medidas anteriores, observadas em seu domínio;
- Otimização de sistemas: o objetivo desta aplicação é minimizar ou maximizar uma função custo levando-se em consideração as restrições impostas para o correto mapeamento do problema;
- Memória Associativas: esta aplicação consiste na recuperação de padrões corretos ainda que os elementos que os constituem sejam apresentados de forma incerta ou imprecisa.

#### 4.2.1 Neurônio artificial

O neurônio artificial, unidade de processamento que compõe as redes neurais, foi inspirado a partir da análise da geração e propagação de impulsos elétricos através da membrana celular dos neurônios biológicos, de acordo com Hodgkin e Huxley (1952), conforme citado por Silva, Spatti e Flauzino (2010). O modelo mais utilizado nas diferentes arquiteturas de redes neurais artificiais, e também o mais simples, foi proposto por McCulloch e Pitts (1943).

Figura 19 — Modelo do neurônio artificial



Fonte: Spatti (2011).

A descrição matemática do neurônio artificial proposto por McCulloch e Pitts resultou em um modelo conforme a Figura 19, o qual possui  $n$  terminais de entrada  $(x_1, x_2, x_3, \dots, x_n)$ , que representam os dendritos, e um terminal de saída  $y$ , que representa um axônio. Os terminais de entrada do neurônio são influenciados pelos

pesos sinápticos ( $w_1, w_2, w_3, \dots, w_n$ ) a fim de simular o comportamento das sinapses. O produto de uma entrada  $x_i$  pelo seu peso sináptico  $w_i$  corresponde ao efeito de uma sinapse particular  $i$  no neurônio. A Equação 29 apresenta o modelo matemático do neurônio artificial (SPATTI, 2011).

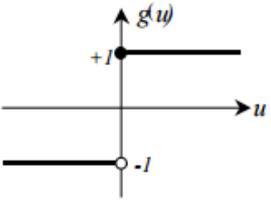
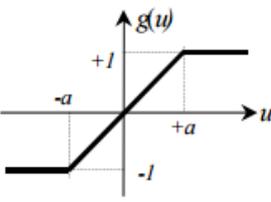
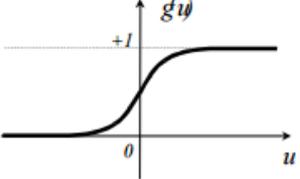
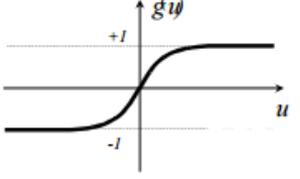
$$y = g\left(\sum_{i=1}^n w_i x_i + b\right) \quad (29)$$

onde:

$n$	=	número de entradas do neurônio;
$w_i$	=	peso associado a $i$ -ésima entrada;
$b$	=	limiar associado ao neurônio;
$x_i$	=	$i$ -ésima entrada do neurônio;
$g(.)$	=	função de ativação do neurônio;
$y$	=	saída do neurônio.

Segundo Spatti (2011), a operação do neurônio artificial ocorre da seguinte forma: os sinais são aplicados à entrada e cada sinal é multiplicado por um peso correspondente à sua relevância na saída da unidade. Então, é realizada uma soma dos produtos sinais-pesos e caso esse resultado exceda um certo limite (*threshold*), a unidade produzirá uma saída. O valor da saída pode ser binário (0 ou 1), bipolar (-1 ou 1) ou real, de acordo com a função de ativação utilizada. As funções de ativação mais utilizadas são mostradas na Figura 20.

**Figura 20** — Funções de ativação mais utilizadas

Função Degrau (bipolar)	Função rampa
	
$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ -1 & \text{se } u < 0 \end{cases}$	$g(u) = \begin{cases} 1 & \text{se } u \geq a \\ u & \text{se } -a < u < a \\ -1 & \text{se } u \leq -a \end{cases}$
Função Sigmóide	Função Tangente Hiperbólica
	
$g(u) = \frac{1}{1 + e^{(-\beta u)}}$	$g(u) = \tanh(u) = \frac{1 - e^{-u}}{1 + e^{-u}}$

Fonte: Castro (2016).

#### 4.2.2 Arquiteturas de redes neurais artificiais

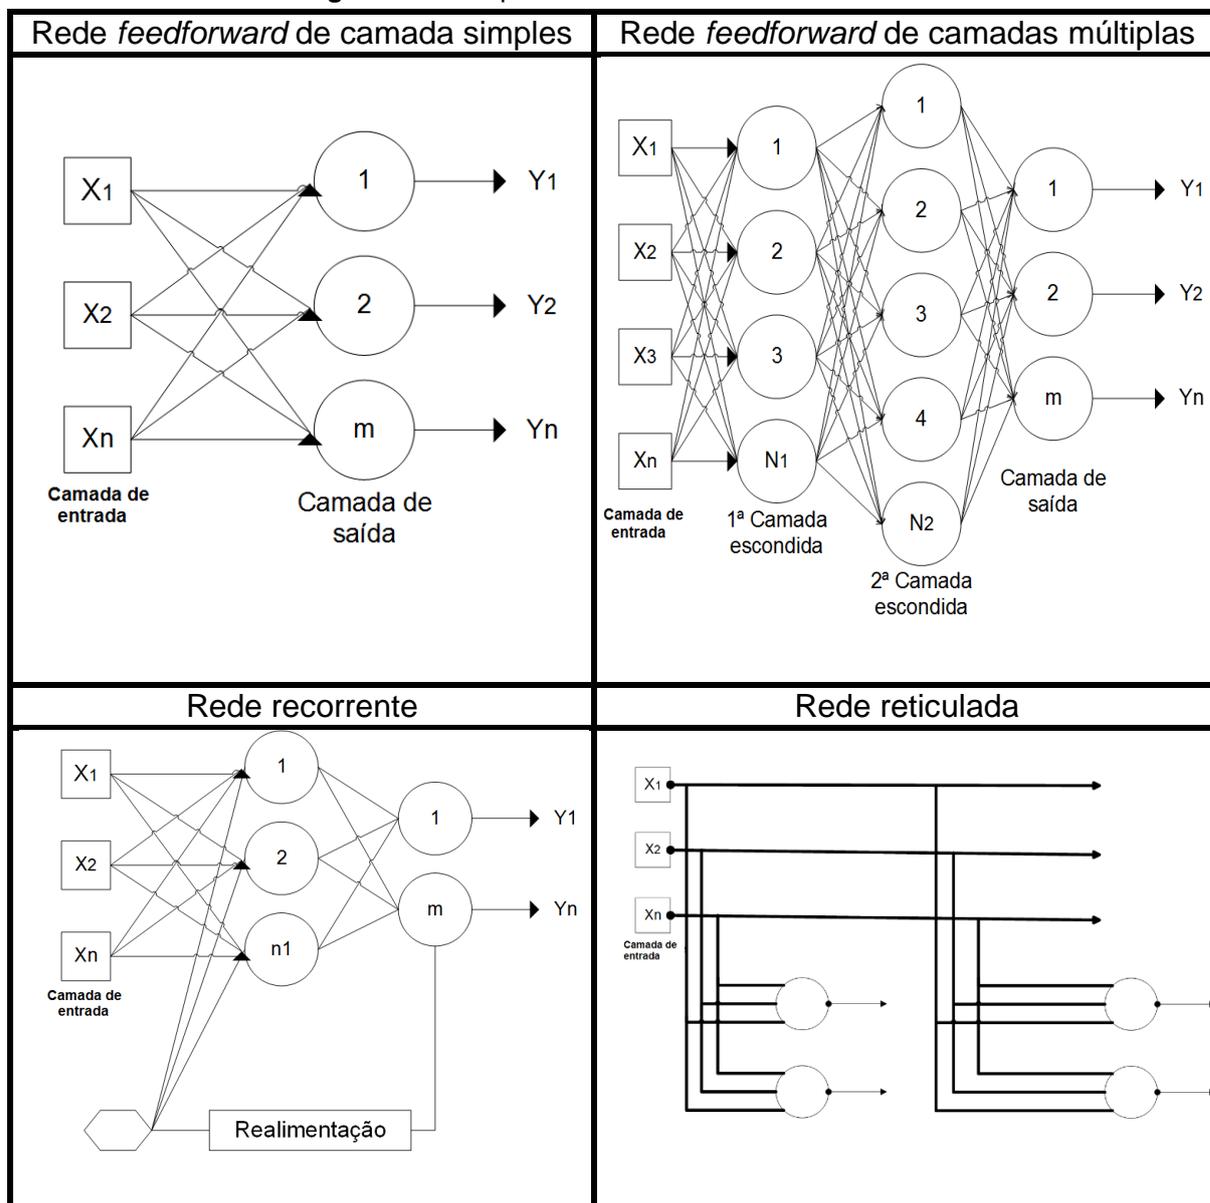
A arquitetura de uma rede neural artificial determina a forma como os neurônios são dispostos e o direcionamento de suas conexões sinápticas. A topologia da RNA é caracterizada pela composição que determinada arquitetura de rede neural poderá assumir, ou seja, a quantidade de neurônios da rede, a função de ativação utilizada, entre outros aspectos (SILVA; SPATTI; FLAUSINO, 2010).

Uma rede neural pode ser dividida basicamente em: camada de entrada, camadas escondidas (ou intermediárias) e camada de saída. A camada de entrada é responsável pelo recebimento de informações (dados) provenientes do meio externo. As camadas escondidas, por sua vez, têm o papel de extrair as características do sistema a ser inferido e realizam quase todo o processamento interno da rede. Por fim, a camada neural de saída é responsável pela produção e apresentação dos resultados finais da rede (SILVA; SPATTI; FLAUSINO, 2010).

As principais arquiteturas de redes neurais artificiais podem ser divididas em: redes *feedforward* (alimentação à frente) de camada simples, redes *feedforward* de

camadas múltiplas, redes recorrentes e redes reticuladas, como mostra a Figura 21 (SILVA; SPATTI; FLAUSINO, 2010).

Figura 21 — Arquitetura das redes neurais artificiais



Fonte: Clerice (2014).

As redes *feedforward* de camada simples possuem uma camada de entrada e uma única camada de neurônios, que é também a camada de saída. Dentre os dos principais tipos de rede com essa arquitetura estão o *Perceptron* e o *Adaline*. Essas redes são mais aplicadas em problemas de classificação de padrões e memórias associativas (SPATTI, 2011).

As redes *feedforward* de camadas múltiplas possuem uma ou mais camadas escondidas de neurônios. Dentre as principais redes que utilizam este tipo de arquitetura estão as redes *Perceptron* multicamadas (*multilayer Perceptron* – MLP), utilizada neste trabalho de pesquisa, e as redes de base radial (*radial basis function* - RBF). Nesta arquitetura, as informações são recebidas pela camada de entrada, depois são processadas pelas camadas escondidas e, por fim, são apresentadas pela camada de saída. As principais aplicações destas redes são: classificação de padrões, aproximação de funções (inclusive não linear), identificação de sistemas, otimização, robótica e controle de processos (SPATTI, 2011; SILVA; SPATTI; FLAUSINO, 2010).

As redes recorrentes possuem como característica principal a realimentação de um ou mais sinais da camada de saída, os quais se tornam sinais de entrada para outros neurônios. Entre os principais tipos de redes recorrentes estão as redes de *Hopfield* e as redes *Perceptron* multicamadas com realimentação. A característica da realimentação permite a aplicação destas redes em sistemas variantes em relação ao tempo, como previsão de series temporais, otimização, controle de processos e identificação de sistemas (SILVA; SPATTI; FLAUSINO, 2010).

As redes reticuladas são caracterizadas pela disposição espacial dos neurônios uma vez que o processo de ajuste de seus pesos e limiares está diretamente relacionado às suas localizações espaciais. A principal representante desta arquitetura é a rede de Kohonen. Dentre as aplicações desta arquitetura estão os problemas de agrupamento (clustering), otimização de sistemas e reconhecimento de padrões (SILVA; SPATTI; FLAUSINO, 2010).

### **4.2.3 Estratégias de treinamento**

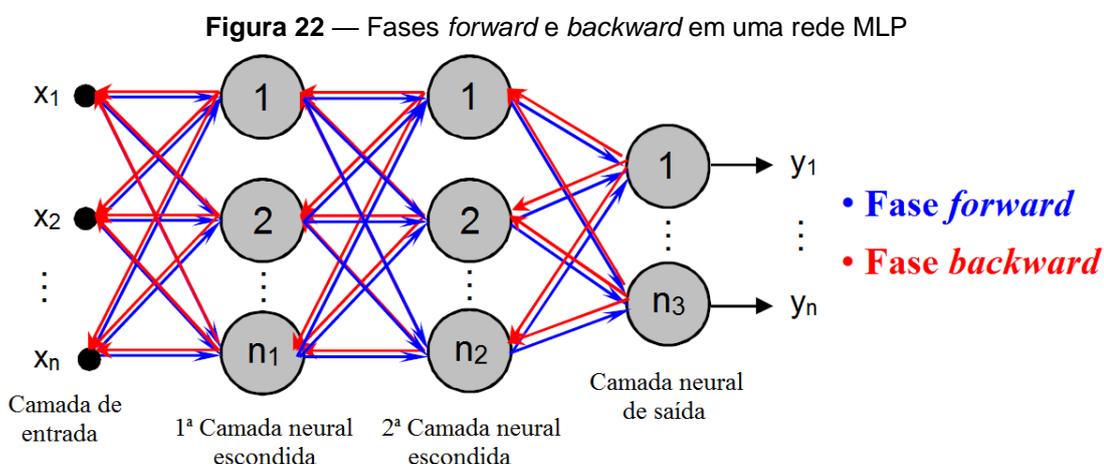
O processo de treinamento de uma rede neural é dado pela execução de passos ordenados (algoritmo de aprendizagem) em um conjunto de amostras de treinamento a fim de sintonizar os pesos sinápticos e limiares dos neurônios, cujo objetivo final é a generalização de soluções a serem produzidas pelas saídas da rede (SILVA; SPATTI; FLAUSINO, 2010). Basicamente, as estratégias de treinamento são divididas em: treinamento não-supervisionado e treinamento supervisionado.

No treinamento não supervisionado, o conjunto de amostras de treinamento não possui as saídas desejadas. Dessa forma, o algoritmo de aprendizado irá detectar similaridades entre os sinais de entrada, agrupando-os em classes (*clusters*), a fim de ajustar os pesos sinápticos e limiares.

Na estratégia de treinamento supervisionado, o conjunto de amostras de treinamento é composto por sinais de entrada e suas correspondentes saídas desejadas os quais representam o processo. Os pesos sinápticos e limiares são ajustados pelo algoritmo de aprendizado através da comparação entre a resposta produzida pela rede e a saída desejada, ambos para um dado sinal de entrada, a fim de minimizar o erro entre ambas (SILVA; SPATTI; FLAUZINO, 2010). A rede *Perceptron* Multicamadas faz uso desta estratégia de treinamento.

#### 4.2.4 Treinamento da rede *Perceptron* multicamadas

O processo de treinamento das redes *Perceptron* multicamadas, *Multilayer Perceptron* (MLP) em inglês, utiliza um algoritmo denominado *backpropagation* ou algoritmo de retropropagação do erro. Este algoritmo de treinamento, conhecido também como regra Delta generalizada, é realizado através da aplicação de duas fases específicas: *forward* e *backward*. A Figura 22 ilustra uma rede MLP constituída por uma camada de entrada, duas camadas escondidas e uma camada de saída, cujas fases *forward* e *backward* são sinalizadas (SILVA; SPATTI; FLAUZINO, 2010).



Fonte: Adaptado de Ulson (2009).

Na primeira fase (*forward*), os sinais de uma amostra do conjunto de treinamento são aplicados à camada de entrada e propagados pelas demais camadas até a produção das respectivas saídas. Essa fase visa obter as respostas da rede e compará-las com as respostas desejadas, obtendo os respectivos erros (SILVA; SPATTI; FLAUZINO, 2010).

Na segunda fase (*backward*), são utilizados os erros obtidos na fase anterior a fim de ajustar os pesos sinápticos e limiares de todos os neurônios da rede, começando pela camada de saída até a primeira camada escondida. As aplicações sucessivas das fases *forward* e *backward* (épocas de treinamentos) implicam em uma diminuição gradativa dos erros (convergência) e, conseqüentemente, no aprendizado da rede (SILVA; SPATTI; FLAUZINO, 2010).

Na prática, o processo de convergência do algoritmo *backpropagation* tende a ser lento e exige um elevado esforço computacional, uma vez que ele possui uma aproximação de primeira ordem. Dessa forma, diversas variações do método *backpropagation* têm sido propostas a fim de aumentar a eficiência do processo de convergência (SILVA; SPATTI; FLAUZINO, 2010). Segundo Hagan e Menhaj (1994), uma das técnicas mais utilizadas para esse propósito é o algoritmo de Levenberg-Marquardt.

Enquanto que o algoritmo *backpropagation* é um método de descida do gradiente da função erro quadrático, o algoritmo de Levenberg-Marquardt é uma aproximação do método de Newton. Através do método de Levenberg-Marquardt, o processo de treinamento das redes MLP pode ser realizado de 10 a 100 vezes mais rápido que o algoritmo *backpropagation* convencional (SILVA; SPATTI; FLAUZINO, 2010; HAGAN; MENHAJ, 1994).

Para maiores detalhes sobre os aspectos teóricos e práticos das redes neurais artificiais, bem como a implementação do algoritmo *backpropagation* e do método de Levenberg-Marquardt, recomenda-se a leitura dos trabalhos de Silva, Spatti e Flauzino (2010), Haykin (2001) e Hagan e Menhaj (1994).

### **4.3 Algoritmos genéticos**

Os algoritmos genéticos (AGs) são modelos computacionais inspirados nos mecanismos de seleção natural de Charles Darwin e de herança genética de Gregor

Mendel (VELOSO, 2006; VITA, 2009). Esses modelos, juntamente com as Estratégias Evolucionárias e a Programação Evolutiva, pertencem a uma classe de algoritmos de pesquisa denominada Algoritmos Evolucionários (BARCELLOS, 2000).

Em 1975, John Henry Holland propôs os Algoritmos Genéticos em seu livro *Adaptation in Natural and Artificial Systems* como uma abstração da evolução biológica (COLHERINHAS, 2016). O intuito do trabalho de Holland era estudar a adaptação e a evolução no mundo real através de simulações computacionais, porém os algoritmos genéticos transcenderam a este propósito (LINDEN, 2012). Em 1989, os algoritmos genéticos foram introduzidos como uma técnica de otimização por David Edward Goldberg (GOLDBERG, 1989).

Basicamente, os algoritmos genéticos se diferenciam dos métodos tradicionais de pesquisa e otimização pelas seguintes características (GOLDBERG, 1989; AKAMINE, 2005):

- Trabalham com uma codificação do conjunto de parâmetros (cromossomos) e não com os parâmetros propriamente ditos;
- Realizam a pesquisa a partir de uma população de pontos e não de um único ponto;
- Utilizam uma função custo e não derivadas ou outro conhecimento auxiliar;
- Empregam regras de transição probabilísticas.

Quanto à aplicação dos algoritmos genéticos, de acordo com MITCHELL (1995), os AGs têm sido utilizados em diversos problemas de engenharia e de outras áreas científicas. Dentre as aplicações desses algoritmos computacionais, incluem-se as seguintes:

- Otimização: otimização numérica, problemas de otimização combinatória, entre outras tarefas de otimização;
- Programação Automática: desenvolvimento de programas computacionais para tarefas específicas e para projetar outras estruturas computacionais, como autômatos celulares e redes de ordenação;
- Aprendizado de Máquina: aplicações de aprendizagem de máquina, incluindo tarefas de classificação, predição e aspectos particulares de sistema de

aprendizado como por exemplo o ajuste dos pesos sinápticos em redes neurais;

- Modelos econômicos: modelagem de processos de inovação, desenvolvimento de estratégias de licitação bem como o surgimento de mercados;
- Modelos ecológicos: modelagem de fenômenos ecológicos como coevolução hospedeiro-parasita, simbiose e fluxo de recursos em ecologias;
- Modelos de sistemas sociais: estudos sobre aspectos evolucionários dos sistemas sociais tais como a evolução da cooperação e a evolução da comunicação.

#### 4.3.1 Algoritmo genético simples

Segundo Barcellos (2000), o algoritmo genético proposto por Holland é conhecido geralmente como Algoritmo Genético Simples (*Simple Genetic Algorithm* em inglês). O funcionamento desse algoritmo pode ser descrito de acordo com os seguintes passos:

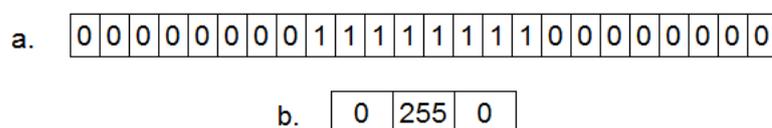
1. Defina uma representação (cromossomo) para as variáveis do problema;
2. Defina uma função de aptidão  $f(x)$  de acordo com o problema;
3. Gere aleatoriamente uma população de  $n$  cromossomos onde cada cromossomo representa uma solução potencial;
4. Avalie a aptidão de cada cromossomo da população;
5. Selecione alguns cromossomos da população de acordo com sua aptidão;
6. Crie novos cromossomos através da recombinação de pares dos cromossomos selecionados;
7. Altere os genes dos novos cromossomos através de mutação;
8. Elimine cromossomos da população anterior e insira os novos cromossomos mantendo a população com  $n$  cromossomos;
9. Avalie a aptidão de cada cromossomo da nova população;
10. Se o critério de parada for atingido, retorne o cromossomo com a melhor aptidão. Caso contrário, volte ao passo 5.

Mais detalhes da implementação deste algoritmo serão apresentados nas subseções seguintes, quais são: representação, aptidão, população inicial, seleção, operadores genéticos, geração e critério de parada.

### 4.3.2 Representação e aptidão

Nos algoritmos genéticos, as soluções do problema são representadas por um cromossomo onde cada gene está associado à uma variável (COLHERINHAS, 2016). Os cromossomos (indivíduos) podem assumir basicamente dois tipos de codificação: binária ou real. Na codificação binária, que é a mais tradicional, a solução é representada por uma sequência de bits '0' e '1' (LINDEN, 2012). Na codificação real, por sua vez, a solução é representada por números reais. A Figura 23 mostra dois cromossomos sendo um com codificação binária e outro com codificação real, considerando um dado problema cuja solução é a cor verde no sistema RGB (*Red-Green-Blue*) (VELOSO, 2006).

**Figura 23** — Cromossomos com representação binária (a) e real (b) para a cor verde no sistema RGB



A representação binária apresenta dificuldades em lidar com problemas multidimensionais de variáveis contínuas, especialmente quando é requerida grande precisão (LINDEN, 2012). Nestes casos, a representação real se adequa melhor ao problema e permite gerar cromossomos menores, além de ser mais facilmente compreendida do que a representação binária (AKAMINE, 2005; TORRES, 2003).

Em relação à aptidão (*fitness* em inglês), esta avalia o quanto um indivíduo é adequado como solução do problema e é realizada normalmente através de uma função (VITA, 2009). A função de aptidão deve ser elaborada de acordo com o critério que define a solução ótima do problema e depende do tipo de codificação utilizada. Em problemas de otimização, pode-se utilizar a função de aptidão como a própria função objetivo, porém em muitos casos é necessário fazer um mapeamento entre elas (VELOSO, 2006).

### 4.3.3 População inicial e seleção

Após as definições da representação e da função de aptidão dos cromossomos, o algoritmo genético irá gerar uma população inicial onde cada gene do cromossomo receberá um valor a partir de uma distribuição aleatória e restrita à um intervalo pré-determinado (COLHERINHAS, 2016). A escolha do tamanho da população inicial é arbitrária porém, segundo Barcellos (2000), é mais comum que a população tenha entre 20 e 200 indivíduos. O aumento da população amplia a diversidade e reduz a probabilidade do algoritmo genético convergir prematuramente para um mínimo local porém aumenta o tempo necessário para a população convergir para a região ótima no espaço de busca (SRINIVAS; PATNAIK, 1994).

Após a geração da população inicial, os indivíduos com melhor aptidão serão selecionados para reproduzir os novos indivíduos, de forma semelhante ao processo de seleção natural (Barcellos, 2000). Dentre os métodos de seleção mais utilizados estão: seleção por roleta e seleção por classificação.

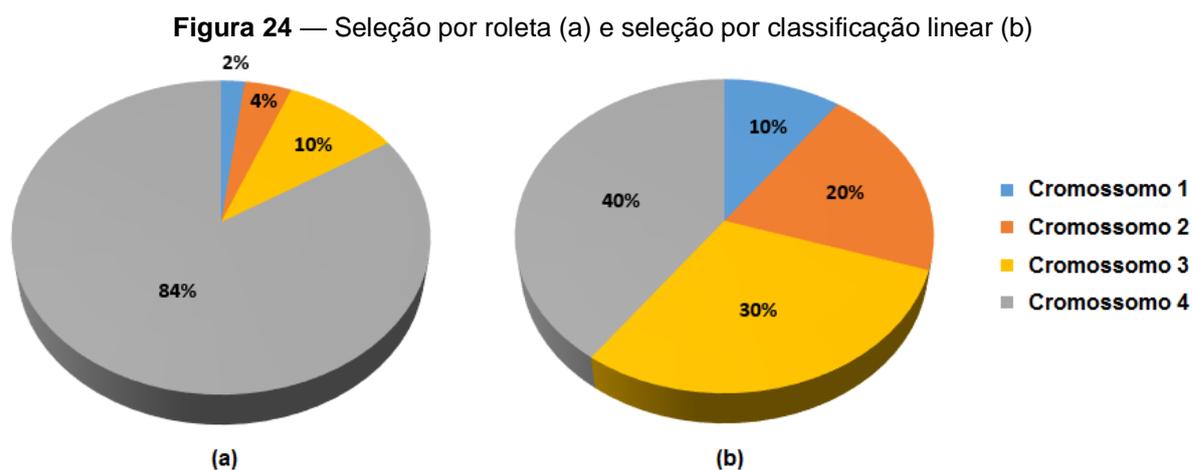
A seleção por roleta (*roulette-wheel* em inglês) é um método de seleção proporcional onde cada cromossomo recebe uma fração da área circular da roleta. O tamanho desta fração é proporcional à razão entre a aptidão do cromossomo e o somatório das aptidões da população (COLHERINHAS, 2016). Em outras palavras, a probabilidade  $P_i$  de um indivíduo  $i$  ser selecionado é dada por:

$$P_i = \frac{f_A(i)}{\sum_{i=1}^N f_A(i)} \quad (30)$$

onde  $f_A(i)$  é a aptidão do indivíduo  $i$  e  $N$  é o tamanho da população. Quanto maior a aptidão do indivíduo, maior será sua probabilidade de ser escolhido para reproduzir os novos indivíduos quando a roleta for girada (COLHERINHAS, 2016).

No caso da seleção por classificação (*rank* em inglês), os indivíduos da população são classificados de acordo com sua aptidão e a probabilidade de escolha do indivíduo é proporcional à sua classificação. Um dos métodos de classificação é o linear, onde os indivíduos são classificados em ordem crescente de aptidão: do pior indivíduo (1º) ao melhor indivíduo (N-ésimo). O restante da seleção segue o mesmo princípio da roleta. Esse método evita uma convergência rápida do algoritmo genético

quando há indivíduo(s) com aptidão elevada em relação aos demais (COLHERINHAS, 2016). Essa característica da seleção por classificação por ser vista na Figura 24, a qual mostra as probabilidades de seleção de quatro cromossomos pelo método da roleta (a) e suas correspondentes probabilidades para a seleção por classificação linear (b).

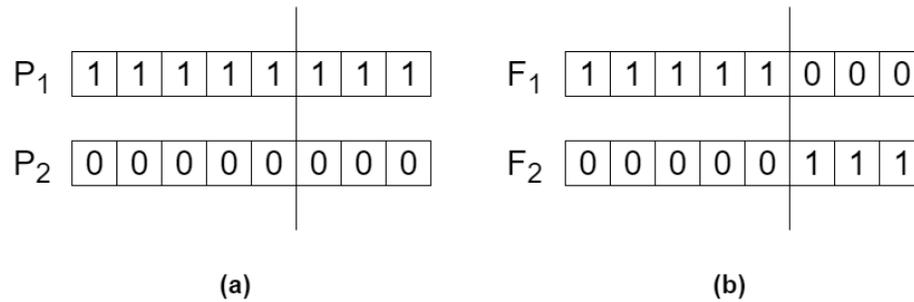


#### 4.3.4 Operadores genéticos

Os operadores genéticos têm a função de gerar a nova população do algoritmo genético e permitir que a população evolua a cada nova geração (VELOSO, 2006). Neste processo, são utilizados dois operadores: recombinação (*crossover* em inglês) e mutação. A recombinação trata da maneira com que os materiais genéticos dos indivíduos selecionados (pais) serão associados para formar novos indivíduos (filhos). A mutação, por sua vez, permite a alteração do material genético desses novos indivíduos.

A recombinação (ou cruzamento) dos genes dos pais pode ser realizada de várias formas e depende do tipo de codificação. Uma das técnicas desenvolvidas é a recombinação de um ponto, onde a sequência de genes de cada pai é dividida em um ponto aleatório de modo que os filhos serão combinações dessas divisões, como mostra a Figura 25. Essa técnica de recombinação possui variações as quais utilizam dois ou mais pontos de corte e pode ser aplicada tanto a cromossomos reais quanto binários.

**Figura 25** — Recombinação de um ponto dos pais P1 e P2 (a) gerando os filhos F1 e F2 (b)



Uma outra técnica de recombinação, aplicada somente à codificação real, é a recombinação aritmética (MICHALEWICZ, 1996). Nesta técnica, os filhos são gerados a partir de uma combinação linear dos cromossomos dos pais, conforme as seguintes expressões:

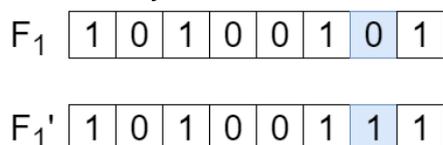
$$F_1 = \beta P_1 + (1 - \beta) P_2 \quad (31)$$

$$F_2 = (1 - \beta) P_1 + \beta P_2 \quad (32)$$

onde  $\beta$  é um número aleatório dentro do intervalo  $[0,1]$ . Em problemas de otimização numérica com restrições onde a região factível é convexa, esse operador é apropriado, pois se os pais pertencerem à região factível então suas combinações lineares (filhos) também pertencerão (LIMA, 2006).

Após o processo de recombinação, os novos indivíduos poderão sofrer mutação. O operador de mutação modifica aleatoriamente um ou mais genes do cromossomo com uma determinada (normalmente baixa) probabilidade de ocorrência, chamada de taxa de mutação. Este operador cria diversidade genética na população e aumenta a probabilidade de se encontrar o máximo global da função de aptidão (COLHERINHAS, 2016; LIMA, 2006).

Existem diversos tipos de operadores de mutação. Para a codificação binária, o método padrão consiste em inverter o valor de um ou mais genes de um cromossomo (HOLLAND, 1975). A Figura 26 mostra um exemplo de mutação em um cromossomo binário.

**Figura 26** — Mutaç o em um cromossomo bin rio

Para cromossomos com codifica o real, um dos m todos mais comuns   a muta o uniforme. Neste tipo de muta o, um ou mais genes  $k \in \{1, 2, \dots, n\}$  do cromossomo  $x = [x_1, \dots, x_k, \dots, x_n]$  s o selecionados aleatoriamente e recebem valores dentro de uma distribui o uniforme aleat ria  $U(L_l, L_s)$  onde  $L_l$  e  $L_s$  s o, respectivamente, os limites inferior e superior da restri o do gene  $x_k$  (COLHERINHAS, 2016). Este m todo   apropriado para problemas de otimiza o sem restri es (KUMAR, 2010).

Para problemas de otimiza o com restri o linear, Kumar (2010) prop s um operador de muta o adaptativo (*adaptive mutation operator* em ingl s). Neste m todo, os genes s o alterados de acordo com vetores de dire o e passos de tamanho determinado, gerados aleatoriamente. Caso esses genes alterados estejam em uma regi o inactiv l (fora das restri es), o operador de muta o corrige automaticamente o tamanho do passo e move novamente o gene no vetor de dire o escolhido anteriormente. O processo se repete at  que o gene esteja dentro dos limites das restri es (KUMAR, 2010).

#### 4.3.5 Gera o e crit rio de parada

A cada itera o do algoritmo gen tico, os indiv duos sofrem as a es dos mecanismos de sele o e dos operadores gen ticos a fim de gerar novos indiv duos, os quais ser o inseridos na popula o (VELOSO, 2006). Para que seja mantido o tamanho da popula o,   necess rio que parte da gera o anterior (ou a gera o inteira) seja eliminada, de acordo com aptid o de cada indiv duo.   comum manter na nova popula o uma pequena parcela dos indiv duos com melhor aptid o da gera o anterior, estrat gia conhecida como elitismo. No entanto, o percentual de elitismo da popula o deve ser baixo de modo a evitar a perda de variabilidade gen tica ao passar das gera es (COLHERINHAS, 2016).

O processo iterativo do algoritmo gen tico ocorrer  at  que um determinado crit rio de parada seja atingido. Podem ser utilizados como crit rios de parada, por

exemplo, o número máximo de gerações (iterações), avaliação do melhor indivíduo ou mesmo a convergência do algoritmo, isto é, quando a maior parte dos cromossomos apresentarem desempenho semelhante (AKAMINE, 2005; VITA, 2009).

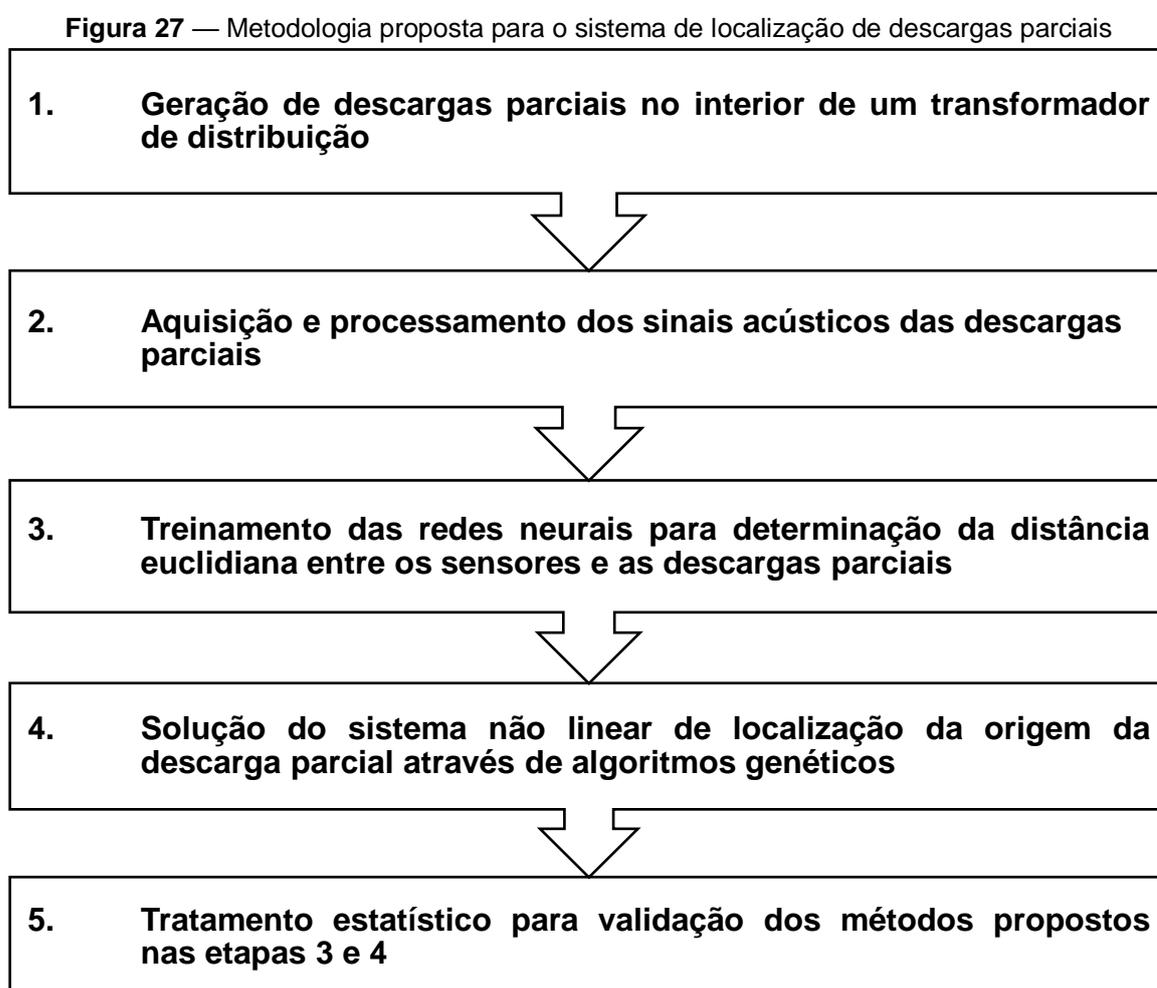
Para que o algoritmo genético obtenha boas soluções com uma convergência rápida, é necessário que sejam testadas diferentes configurações de seus parâmetros. A escolha da função de aptidão a ser utilizada também é fundamental para o correto funcionamento do algoritmo genético (VITA, 2009). Um algoritmo genético cuja função de aptidão foi bem definida e cujos parâmetros foram bem ajustados pode produzir excelentes resultados em problemas para os quais outros métodos seriam incapazes de convergir (VELOSO, 2006).

Para maiores detalhes sobre os aspectos teóricos e práticos dos algoritmos genéticos, bem como a sua implementação, recomenda-se a leitura dos trabalhos de Linden (2012) e Michalewicz (1996). Para aplicações de algoritmos genéticos em problemas de engenharia, recomenda-se a leitura do trabalho de Colherinhas (2016) e Veloso (2006).

## 5 METODOLOGIA PROPOSTA

### 5.1 Introdução

A fim de atingir o objetivo proposto, ou seja, a localização de descargas parciais em transformadores de potência por meio de sistemas inteligentes e emissão acústica, foi elaborada a seguinte metodologia de testes, como mostra a Figura 27.



Esta metodologia é iniciada com a geração de descargas parciais através de eletrodos instalados nas bobinas de um transformador de distribuição de 30 KVA, cujos detalhes serão abordados na subseção 5.2. Os sinais acústicos gerados pelas descargas parciais no interior do transformador foram adquiridos por diafragmas piezelétricos instalados na parede externa do tanque do transformador. Estes sinais, por sua vez, foram amplificados por um circuito eletrônico, tendo em vista que o

diafragma gera sinais de baixa amplitude. Um oscilógrafo foi utilizado para adquirir os sinais que são processados com a utilização de filtros digitais e métricas de estudo de sinais acústicos. Essas etapas, desde a aquisição dos sinais até o processamento, serão detalhadas na subseção 5.3. As seções 5.2 e 5.3 são provenientes dos experimentos realizados por Castro (2016), cujos resultados foram cedidos para a realização deste trabalho.

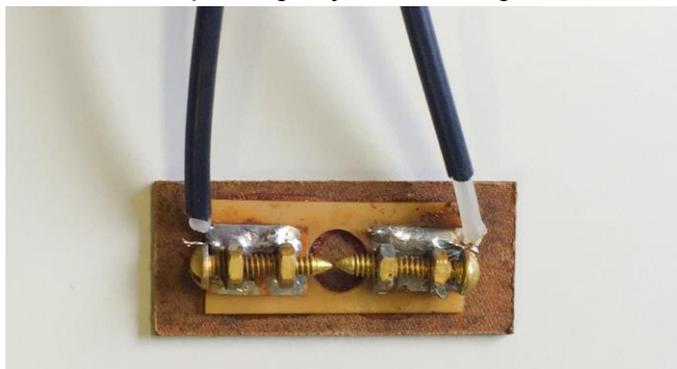
As métricas de processamento aplicadas aos sinais acústicos foram utilizadas para o treinamento supervisionado de um arranjo de redes neurais do tipo *perceptron* multicamadas. A partir do treinamento das RNAs, foram obtidas as distâncias euclidianas entre os sensores e as descargas parciais para tratamento estatístico e validação dos dados, através de critérios como erro absoluto médio, erro relativo percentual, desvio padrão e coeficiente de correlação. A metodologia utilizada no treinamento das RNAs será detalhada na subseção 5.4.

Após o treinamento e validação das RNAs, foram estimadas as distâncias euclidianas entre os sensores e as descargas escolhidas as quais foram utilizadas no sistema não linear de localização da descarga parcial. O sistema não linear foi solucionado através de um algoritmo genético e os resultados foram comparados com as posições reais das descargas parciais através de critérios como erro absoluto médio e desvio padrão. A metodologia utilizada na solução do sistema não linear por algoritmo genético será detalhada na subseção 5.5.

## **5.2 Geração de descargas parciais**

Com o objetivo de gerar DPs no interior do transformador, foi elaborado um aparato para criar as condições necessárias à ocorrência de uma DP. Foram desenvolvidos 16 eletrodos de latão, como mostra a Figura 28, cujos *gaps* foram ajustados para 0,5 mm. Estes eletrodos foram fixados em pontos aleatórios na bobina externa de um transformador de distribuição de 30 KVA e seus terminais foram conectados, através de um cabo, à uma placa seletora externa ao transformador, cuja função foi viabilizar a escolha do eletrodo que gerou a descarga parcial no transformador.

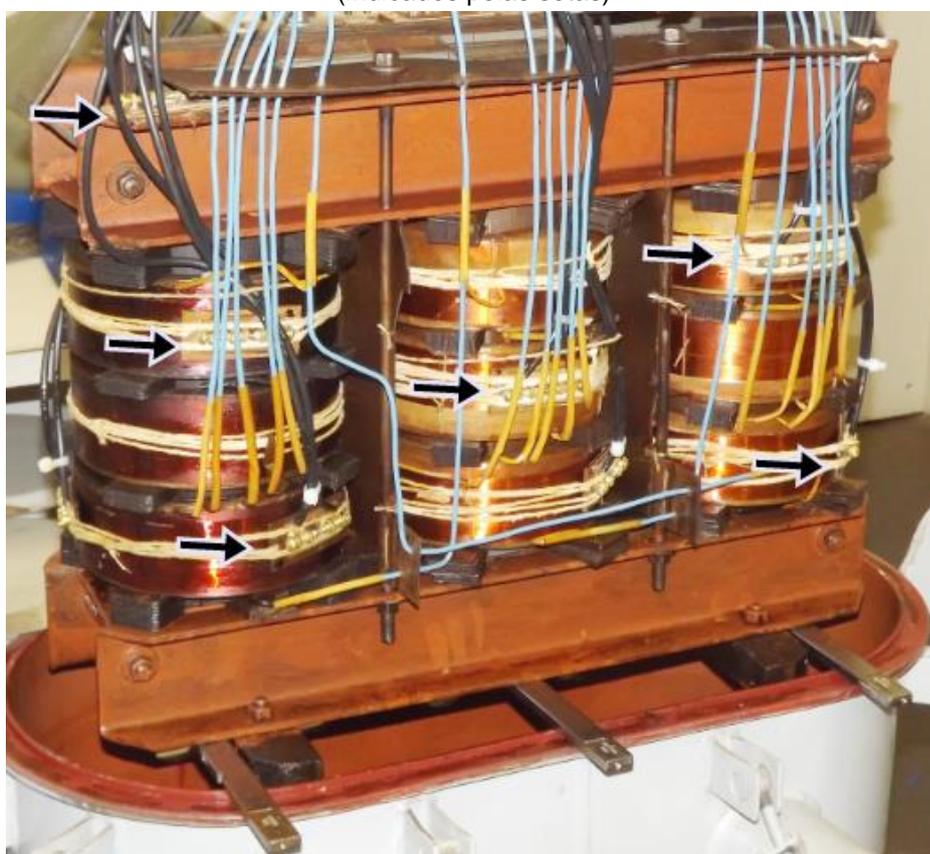
**Figura 28** — Eletrodo de latão para a geração de descargas no núcleo do transformador



Fonte: Castro (2016).

Alguns dos eletrodos acoplados ao núcleo e bobinas do transformador são ilustrados na Figura 29 e as coordenadas tridimensionais dos 16 eletrodos de testes, mediante um referencial pré-determinado na parte externa do tanque do transformador, são indicados na Tabela 2.

**Figura 29** — Eletrodos de latão acoplados ao núcleo e bobinas de um transformador de distribuição (indicados pelas setas)



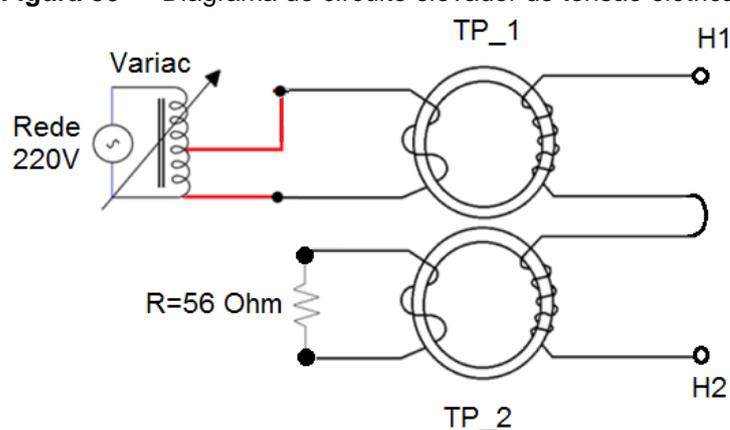
Fonte: Castro (2016).

**Tabela 2** — Coordenadas tridimensionais dos eletrodos de teste

Eletrodo	X [m]	Y [m]	Z [m]
1	0,070	0,135	0,580
2	0,065	0,155	0,430
3	0,060	0,510	0,490
4	0,125	0,605	0,573
5	0,220	0,565	0,285
6	0,243	0,525	0,428
7	0,237	0,475	0,563
8	0,243	0,335	0,488
9	0,205	0,260	0,568
10	0,215	0,120	0,185
11	0,240	0,140	0,428
12	0,205	0,060	0,579
13	0,082	0,327	0,280
14	0,080	0,265	0,500
15	0,080	0,330	0,690
16	0,010	0,410	0,430

Fonte: Castro (2016).

O circuito utilizado para alimentar os eletrodos e, portanto, gerar as descargas parciais é apresentado na Figura 30. H1 e H2 representam os terminais do cabo que foi acoplado à placa seletora conforme mostra a Figura 31.

**Figura 30** — Diagrama do circuito elevador de tensão elétrica

Fonte: Castro (2016).

**Figura 31** — Placa de conexão dos eletrodos



Fonte: Castro (2016).

Um transformador variável monofásico com tensão de saída de 0 a 240 Vac, alimentou o transformador elevador do circuito de alimentação do eletrodo, cujas especificações são fornecidas pela Tabela 3.

**Tabela 3** — Parâmetros dos transformadores utilizados para alimentar os eletrodos

Tipo: Grupo 2	Tensão máxima: 15 [kV]	Potência aparente: 400 [VA]
Tensão do primário: 8.050 [V]	Tensão do secundário: 115 [V]	Relação: 70:1

Fonte: Castro (2016).

Uma resistência elétrica de níquel-cromo foi integrada ao terminal de baixa tensão do transformador de potencial (TP) para limitar a passagem de alta corrente elétrica, tanto no enrolamento de alta quanto no de baixa tensão. Desta maneira, a impedância elétrica do enrolamento do secundário do TP é refletida no primário, conforme a Equação 33:

$$Z_{\text{primário}} = a^2 Z_{\text{secundário}} \quad (33)$$

sendo  $a$  é a relação de transformação,  $Z_{\text{primário}}$  a impedância elétrica no enrolamento de alta tensão do TP e  $Z_{\text{secundário}}$  a impedância elétrica no enrolamento de baixa tensão do TP. Mediante este aparato de geração de descargas parciais, observou-se que, para a ocorrência do fenômeno o valor da tensão aplicada sobre os eletrodos foi, em média, de 3,5 kV.

### 5.3 Aquisição e processamento dos sinais acústicos das descargas parciais

Após a etapa de instalação do sistema de geração das descargas parciais, foi instalado o sistema de localização de descargas parciais. Foram acoplados quatro cápsulas piezelétricas em cada face lateral do tanque do transformador de 30KVA, cujas dimensões são 0,305 m x 0,670 m x 0,625 m, por meio de uma parafina líquida oleaginosa. As coordenadas tridimensionais dos sensores, em relação à um referencial no tanque do transformador, são mostradas na Tabela 4.

**Tabela 4** — Coordenadas tridimensionais dos sensores piezelétricos

Sensor	X [m]	Y [m]	Z [m]
1	0,000	0,205	0,575
2	0,150	0,670	0,100
3	0,305	0,165	0,500
4	0,150	0,000	0,410
5	0,000	0,180	0,125
6	0,150	0,670	0,625
7	0,305	0,190	0,240
8	0,150	0,000	0,290
9	0,000	0,475	0,130
10	0,150	0,670	0,460
11	0,305	0,445	0,140
12	0,150	0,000	0,605
13	0,000	0,475	0,570
14	0,150	0,670	0,300
15	0,305	0,480	0,500
16	0,150	0,000	0,090

Fonte: Castro (2016).

A Figura 32 mostra alguns desses sensores acoplados à parede do transformador bem como o ponto de referência (em amarelo) das coordenadas dos sensores e eletrodos. Cada sensor piezelétrico, modelo 7BB-35-3 da Murata, mostrado na Figura 33, foi amplificado com um ganho de 25 vezes por meio da utilização do amplificador de instrumentação INA 128P da Texas Instruments, com

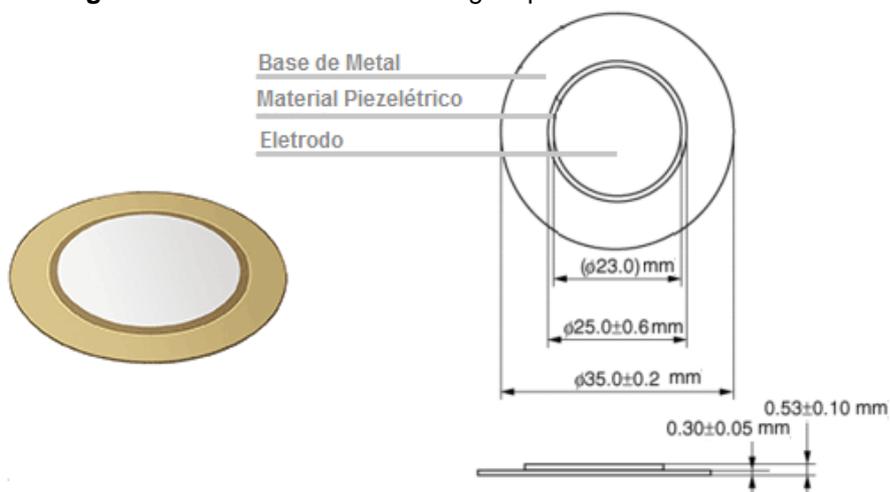
resposta em frequência até 400kHz. Dentre as vantagens desses sensores, conforme citado na subseção 3.3, está a de possuir baixo custo.

**Figura 32** — Sensores acoplados para a captação dos sinais acústicos das DPs



Fonte: Castro (2016).

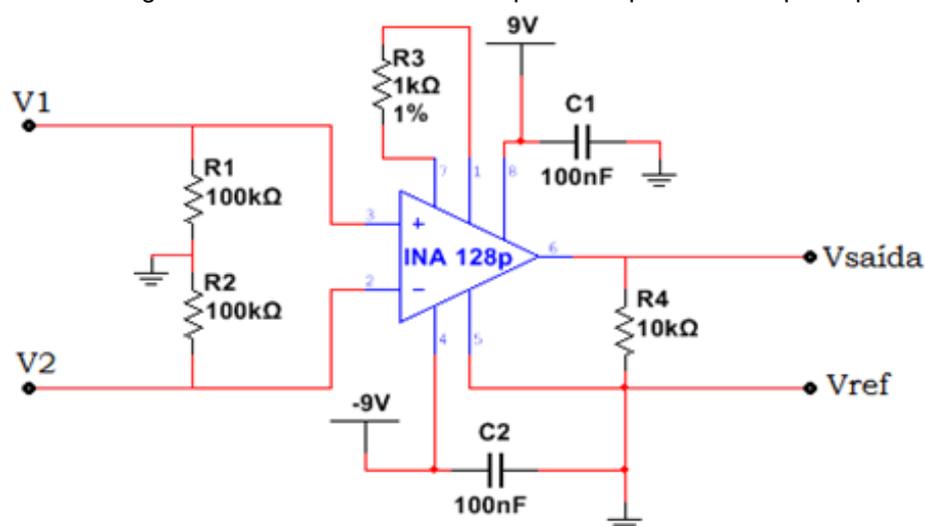
**Figura 33** — Dimensões do diafragma piezelétrico de baixo custo



Fonte: Adaptado por Castro (2016) de Murata (2015).

A Figura 34 apresenta o esquema elétrico do circuito amplificador. Para a amplificação dos 16 sensores, foi projetada uma placa de circuito impresso. Um oscilógrafo, modelo DL-850 do fabricante Yokogawa, foi utilizado para captar os sinais com uma taxa de aquisição de 10 milhões de amostras por segundo. Cada eletrodo induziu uma descarga parcial e, considerando a quantidade de sensores, foram obtidos 16 sinais acústicos por eletrodo. Estes sinais foram tratados com um filtro digital passa alta de 20kHz, a fim de eliminar ruídos oriundos do ambiente. O sistema amplificador executou a função de um filtro anti aliasing devido à sua resposta em frequência ir até 400kHz.

**Figura 34** — Diagrama eletrônico do circuito amplificador para cada cápsula piezelétrica



Fonte: Castro (2016).

Algumas métricas de processamento digital de sinais foram aplicadas aos 16 sinais obtidos a partir de cada descarga gerada no interior do núcleo do transformador, a fim de gerar as entradas da rede neural, quais são: valor RMS do sinal, energia do sinal, skewness, kurtosis, valor de pico do sinal, tempo de chegada segundo o critério de energia e tempo de chegada segundo o critério de informação de Akaike. O treinamento das redes neurais será tratado na subseção seguinte.

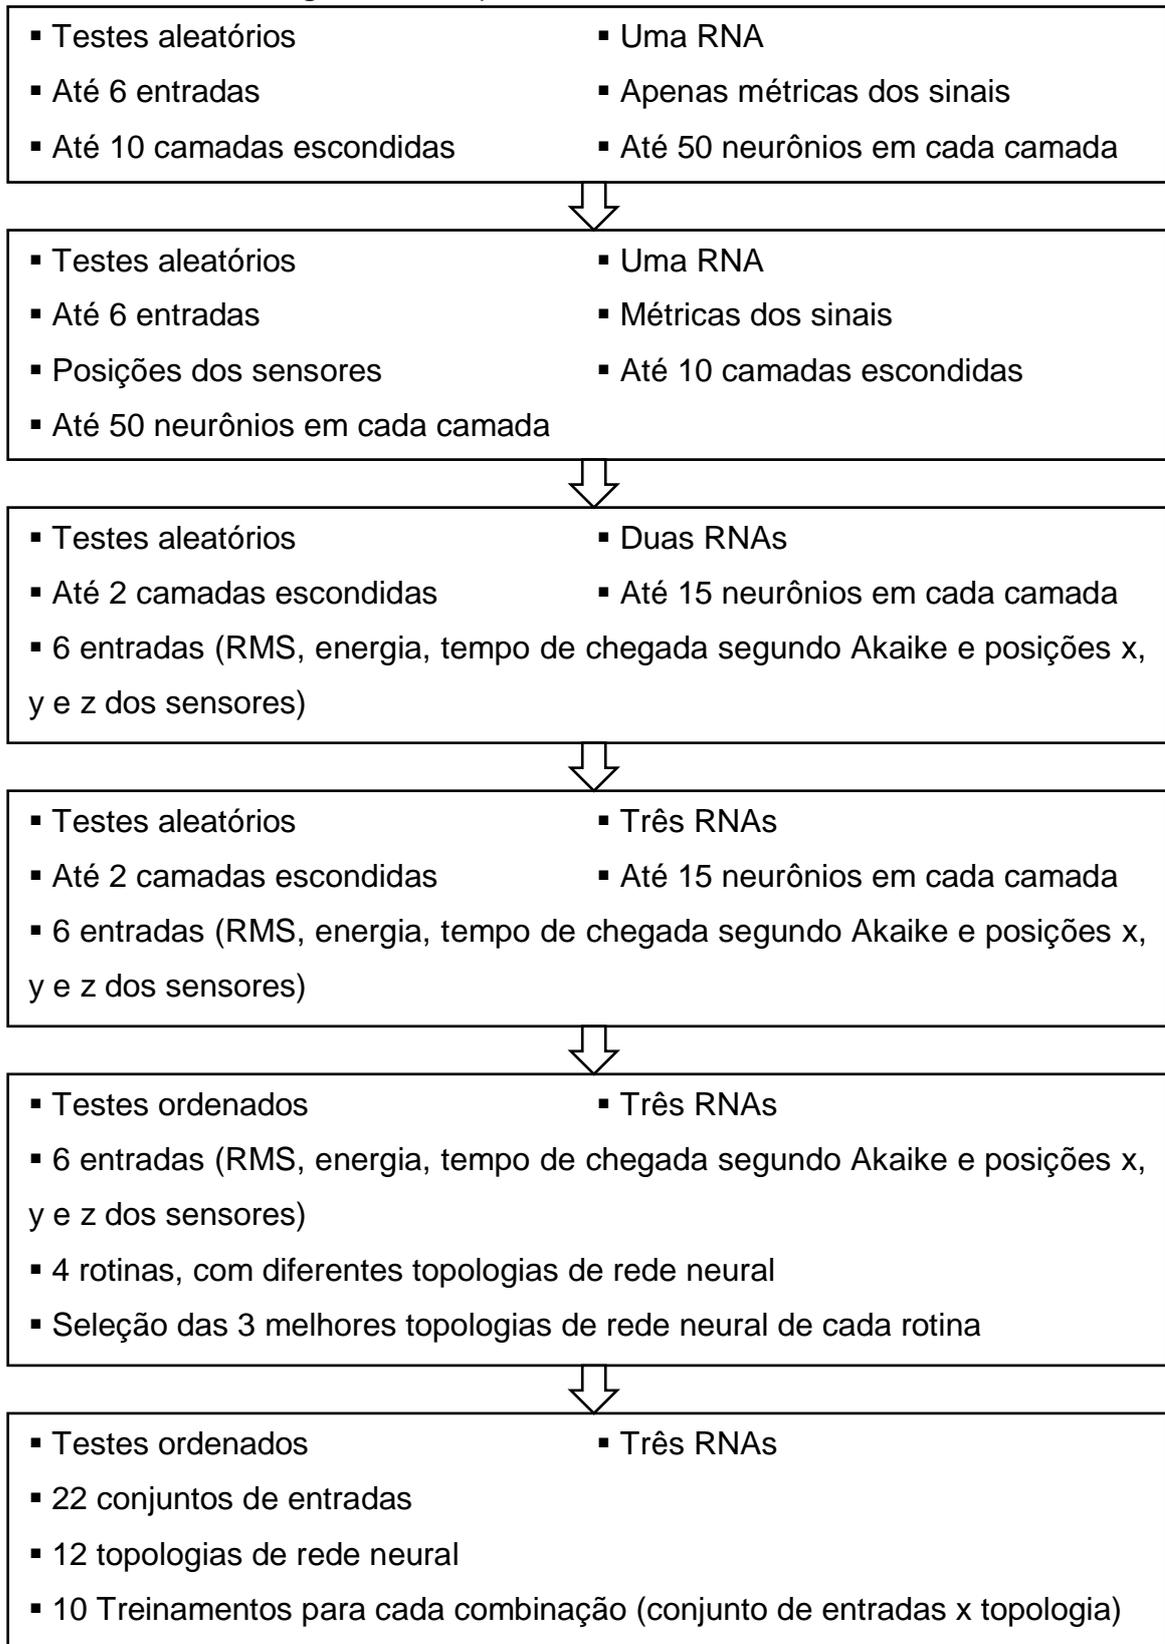
#### 5.4 Treinamento da rede neural

A fim de determinar a distância euclidiana entre a descarga parcial e os sensores, cujo valor será utilizado na localização da descarga parcial, foram

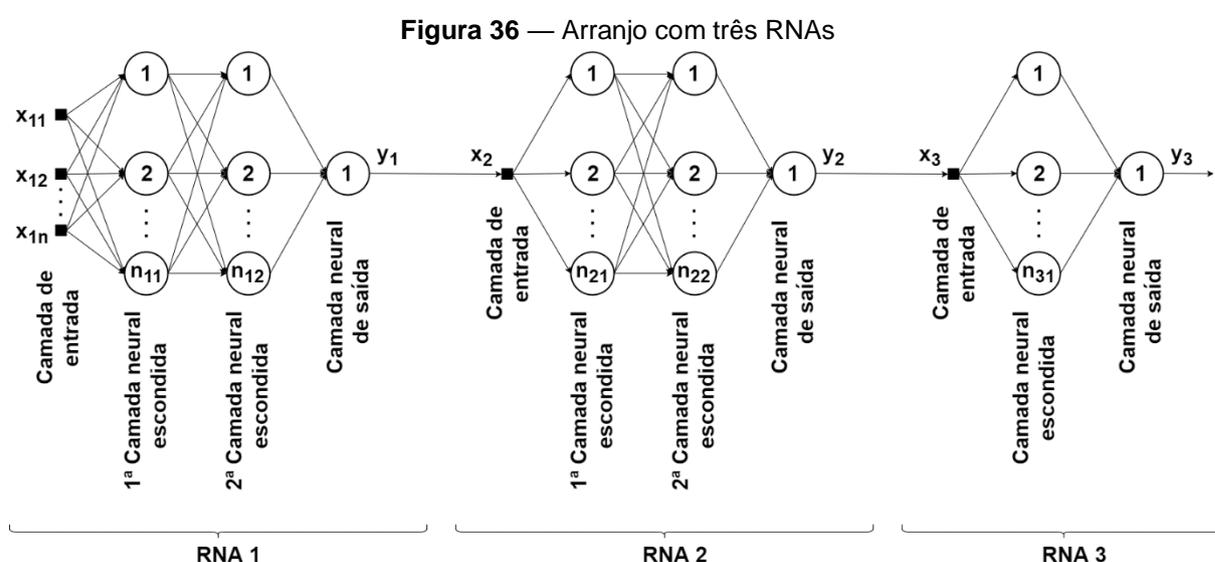
realizadas diversos treinamentos e testes em um arranjo com até três redes neurais do tipo Perceptron multicamadas, utilizando como entradas as métricas dos sinais e as posições dos sensores. O treinamento da rede foi do tipo supervisionado e o algoritmo de treinamento utilizado foi o de Levenberg-Marquardt. O treinamento e a operação das redes neurais foram realizados utilizando o toolbox de redes neurais do software MATLAB® (DEMUTH; BEALE; HAGAN, 2010). A função de ativação utilizada no treinamento foi a sigmoide e o critério de parada foi o de 200 épocas.

Nos treinamentos e testes iniciais, com uma rede PMC e entradas e topologias aleatórias, não foi possível obter resultados satisfatórios, ou seja, resultados de coeficiente de correlação acima de 0,96. As posições x, y e z dos sensores passaram a ser utilizadas também como entradas e o coeficiente de correlação apresentou uma melhora, porém abaixo de 0,4. Nesses testes preliminares, as entradas que tiveram melhores resultados foram RMS, energia, tempo de chegada segundo Akaike e posições x, y e z dos sensores. A Figura 35 mostra as etapas de treinamento e teste realizadas.

**Figura 35** — Etapas de treinamento da Rede Neural



A fim de obter melhores resultados nos treinamentos, foi adicionada uma segunda RNA, tendo como entrada a saída da primeira RNA. Os valores do coeficiente de correlação apresentaram uma melhora mais significativa nessa nova configuração com duas RNAs, ultrapassando 0,8 em muitos casos, porém de forma instável. Ao adicionar uma terceira RNA, Figura 36, os resultados se mostraram satisfatórios, com coeficiente de correlação mais estáveis acima de 0,8 e ultrapassando 0,96 em alguns casos.



Esse arranjo com três RNAs foi mantido e, a partir dessa etapa, foram efetuadas 4 rotinas de testes com variação da quantidade de neurônios em cada camada escondida de cada uma das três RNAs, como mostra a Tabela 5.

**Tabela 5** — Quantidade de neurônios nas camadas escondidas para cada rotina de testes

Rotina	Número de neurônios nas camadas escondidas				
	RNA 1		RNA 2		RNA 3
	Camada 1	Camada 2	Camada 1	Camada 2	Camada 1
1	5,7,10	*	3,5,7	*	1,2,3
2	10,11,12	*	7,8,9	*	2,3,4
3	11,12,13,14	**	9,10,11	*	4,5,6
4	11,12,13,14,15,16,17	**	10,11,12,13	**	4,5
*	Vazia ou igual à camada 1 da mesma RNA				
**	Igual à camada 1 da mesma RNA				

Essas rotinas tiveram o objetivo de selecionar as melhores topologias para a etapa final de treinamento do arranjo de redes neurais, as quais são apresentadas na Tabela 6.

**Tabela 6** — Topologias de rede neurais selecionadas para a etapa final de treinamento

Topologia	Número de neurônios nas camadas escondidas				
	RNA 1		RNA 2		RNA 3
	Camada 1	Camada 2	Camada 1	Camada 2	Camada 1
1	10	10	5	5	2
2	10	10	7	7	1
3	10	10	7	7	2
4	10	10	7	7	3
5	11	11	9	9	4
6	12	12	8	8	3
7	13	13	11	11	5
8	13	13	11	11	4
9	13	13	13	13	5
10	14	14	10	10	4
11	15	15	10	10	5
12	16	16	10	10	4

Na etapa final de treinamento, ao utilizar 80 % dos dados para treinamento e 20 % dos dados para teste, os resultados do coeficiente de correlação não foram, em média, superiores a 0,9. A fim de superar esse valor, foram utilizados 90 % dos dados para treinamento e 10 % dos dados para teste. A Tabela 7 exibe os conjuntos de entradas a serem utilizados nesta etapa de treinamento. Os erros médios foram calculados e apresentados apenas para os conjuntos de entradas que apresentaram coeficiente de correlação médio acima de 0,96 em pelo menos uma das 12 topologias selecionadas.

**Tabela 7** — Conjunto de entradas utilizadas na etapa final de treinamento das redes neurais

<b>Conjunto de entradas</b>	<b>Entradas</b>
1	RMS
2	Energia
3	RMS, energia
4	RMS, energia, kurtosis
5	RMS, energia, skewness
6	RMS, energia, valor de pico
7	RMS, coordenadas do sensor
8	Energia, coordenadas do sensor
9	RMS, energia, posições x, y e z do sensor
10	RMS, energia, kurtosis, posições x, y e z do sensor
11	RMS, energia, skewness, posições x, y e z do sensor
12	RMS, energia, valor de pico, posições x, y e z do sensor
13	Tempo de chegada segundo critério de Akaike
14	Tempo de chegada segundo critério de energia
15	Tempos de chegada segundo critérios de Akaike e energia
16	RMS, energia, tempo de chegada segundo critério de Akaike
17	RMS, energia, tempo de chegada segundo critério de energia
18	Tempo de chegada (Akaike), posições x, y e z do sensor
19	Tempo de chegada (energia), posições x, y e z do sensor
20	Tempos de chegada (Akaike e energia), pos. x, y e z do sensor
21	RMS, energia, tempo de chegada (Akaike), pos. x, y e z do sensor
22	RMS, energia, tempo de chegada (energia), pos. x, y e z do sensor

A análise estatística e apresentação dos dados de saída do arranjo de RNAs foi efetuada apenas para o treinamento que apresentou menor erro médio na determinação da distância euclidiana. A análise desse treinamento envolveu o cálculo do erro absoluto médio, do desvio padrão do erro absoluto médio, do erro relativo percentual e do coeficiente de correlação linear entre os dados estimados pela rede e seus respectivos valores desejados. Essas informações, bem como o gráfico de correlação e a dispersão dos erros, serão apresentadas na subseção 6.1.

## 5.5 Solução do sistema não linear de localização da descarga parcial por algoritmo genético

Com o objetivo de determinar a posição da descarga parcial em coordenadas tridimensionais, foi utilizado o sistema não linear apresentado na subseção 3.6. Através desse sistema, é possível obter as coordenadas de uma descarga parcial a partir das coordenadas de três sensores e das distâncias euclidianas entre esses sensores e uma descarga parcial. A tabela 8 mostra os três sensores escolhidos para a localização da descarga parcial, com suas correspondentes coordenadas tridimensionais. Estes sensores foram escolhidos por estarem localizados no tanque do transformador em lados diferentes.

**Tabela 8** — Sensores escolhidos para localização da descarga parcial

Sensor	X [m]	Y [m]	Z [m]
6	0,150	0,670	0,625
11	0,305	0,445	0,140
13	0	0,475	0,570

A solução do sistema não linear foi obtida através de um algoritmo genético, que é um método de busca inspirado nos mecanismos de seleção natural e herança genética. O cromossomo do algoritmo genético utilizou codificação real e foi constituído pelos genes x, y e z, os quais representam as coordenadas tridimensionais da descarga parcial. A função de aptidão foi construída com base nas equações do sistema não linear. A partir das Equações 26, 27 e 28 são obtidas as seguintes equações:

$$(x + x_{s1})^2 + (y + y_{s1})^2 + (z + z_{s1})^2 - (d_1)^2 = f_1 \quad (34)$$

$$(x + x_{s2})^2 + (y + y_{s2})^2 + (z + z_{s2})^2 - (d_2)^2 = f_2 \quad (35)$$

$$(x + x_{s3})^2 + (y + y_{s3})^2 + (z + z_{s3})^2 - (d_3)^2 = f_3 \quad (36)$$

$$f_a = |f_1| + |f_2| + |f_3| \quad (37)$$

onde  $f_a$  é a função de aptidão, a qual deve ser minimizada para que se obtenha a solução ótima do sistema. Foram utilizadas restrições de fronteira para cada uma das coordenadas tridimensionais, de acordo com as dimensões do transformador mencionadas na subseção 5.3, conforme mostram as equações a seguir:

$$0 \leq x \leq 0,305 \text{ [m]} \quad (38)$$

$$0 \leq y \leq 0,670 \text{ [m]} \quad (39)$$

$$0 \leq z \leq 0,625 \text{ [m]} \quad (40)$$

A implementação do algoritmo genético foi realizada utilizando o toolbox de otimização do software MATLAB® (MATHWORKS, 2017). A Tabela 9 mostra os parâmetros do algoritmo genético utilizados em todos os testes.

**Tabela 9** — Parâmetros do algoritmo genético utilizado

<b>Tamanho da população</b>	100
<b>Função de escalonamento</b>	Classificação
<b>Função de seleção</b>	Roleta
<b>Tamanho da elite</b>	5
<b>Probabilidade de recombinação</b>	0,8
<b>Função de mutação</b>	Adaptável
<b>Função de recombinação</b>	Aritmética
<b>Crítérios de parada</b>	Gerações (300)
	Limite de aptidão (0,01)

A análise estatística e apresentação dos dados obtidos foi efetuada para 10 execuções do algoritmo genético por descarga parcial. A análise envolveu o cálculo do erro absoluto médio e do desvio padrão do erro absoluto médio entre as coordenadas tridimensionais obtidos pelo AG e seus respectivos valores desejados. Essas informações serão mostradas na subseção 6.2, assim como o gráfico da aptidão na primeira execução do algoritmo genético para cada descarga parcial, a fim de mostrar a convergência do algoritmo genético ao longo das gerações.

## 6 ANÁLISE E RESULTADOS

### 6.1 Testes de determinação das distâncias euclidianas entre os sensores e as descargas parciais através das redes neurais

Através dos testes realizados com as combinações de topologias e conjunto de entradas, apresentadas pelas Tabelas 6 e 7 respectivamente, foi observado que os conjuntos de treinamentos 12, 20, 21 e 22 atingiram coeficientes de correlação acima de 0,96 para alguma das 12 topologias. Dessa forma, somente os resultados de erro médio desses conjuntos de treinamentos foram apresentados neste trabalho, conforme mostra a Tabela 10.

**Tabela 10** — Erro médio da distância euclidiana para os conjuntos de entradas que obtiveram os melhores resultados

Topologia	Erro médio da distância euclidiana [m]			
	Conjunto de entradas			
	12	20	21	22
1	0,042	0,040	0,029	0,033
2	0,041	0,043	0,038	0,035
3	0,037	0,036	0,030	0,030
4	0,042	0,048	0,035	0,035
5	0,044	0,032	0,023	0,035
6	0,024	0,029	0,027	0,024
7	0,023	0,073	0,022	0,024
8	0,019	0,021	0,018	0,018
9	0,016	0,024	0,019	0,017
10	0,019	0,021	0,018	0,019
11	0,058	0,023	0,022	0,022
12	0,018	0,019	0,022	0,017

Para o conjunto de entradas 12, cujas entradas do arranjo de redes neurais foram as métricas de RMS, energia, valor de pico e as posições x, y e z do sensor, o erro médio para a distância euclidiana variou de 0,016 m a 0,058 m, considerando os resultados das 12 topologias. A combinação deste conjunto de entradas com a

topologia 9 produziu o melhor resultado do treinamento das redes neurais, atingindo o menor valor de erro médio dos testes (0,016 m), o que demonstra a eficácia deste método na determinação da distância euclidiana entre os sensores e as descargas parciais.

Em relação ao conjunto de entradas 20, cujas entradas foram as métricas de tempo de chegada segundo critério de Akaike, tempo de chegada segundo critério de energia e as posições x, y e z do sensor, o erro médio para a distância euclidiana variou de 0,019 m a 0,073 m. O melhor resultado para este conjunto de entradas foi obtido com a topologia 12 (0,019 m), uma diferença de apenas 3 mm em relação ao melhor resultado do conjunto de entradas 12, o que mostra que este conjunto de entradas também permite estimar a distância euclidiana de forma satisfatória utilizando uma menor quantidade de entradas (5), ou seja, menos recurso computacional.

No caso do conjunto de entradas 21, cujas entradas foram as métricas de RMS, energia, tempo de chegada segundo critério de Akaike e as posições x, y e z do sensor, o erro médio da distância euclidiana variou de 0,018 m a 0,038 m, tendo como melhor resultado as topologias 8 e 10. Para o conjunto de entradas 22, cujas entradas foram as métricas de RMS, energia, tempo de chegada segundo critério de energia e as posições x, y e z do sensor, o erro médio da distância euclidiana variou de 0,017 m a 0,035 m, tendo como melhor resultado as topologias 9 e 12.

Em ambos os casos, 21 e 22, os melhores resultados se mostraram muito próximos ao melhor resultado do conjunto de entradas 12, com uma diferença de 2 mm e 1 mm respectivamente. Outro ponto importante a se ressaltar é que a diferença entre os valores mínimo e máximo do erro médio, 0,020 m para o conjunto 21 e 0,018 m para o conjunto 22, foi menor do que a do conjunto de entradas 12 (0,042 m), o que demonstra que os valores de distância euclidiana, estimados pelas redes neurais treinadas com esses dois conjuntos de entradas, foram os mais estáveis diante da variação de topologia.

A tabela 11 apresenta os dados de erro absoluto médio, desvio padrão e coeficiente de correlação para cada um dos 10 treinamentos realizados com o conjunto de entradas 12 e topologia 9, combinação que obteve os melhores resultados na determinação da distância euclidiana.

**Tabela 11** — Dados estatísticos dos treinamentos realizados com o conjunto de entradas 12 e a topologia 9

<b>Treinamento</b>	<b>Erro absoluto médio [m]</b>	<b>Desvio padrão [m]</b>	<b>Coefficiente de correlação</b>
1	0,007	0,006	0,99
2	0,010	0,016	0,99
3	0,011	0,013	0,99
4	0,018	0,032	0,97
5	0,024	0,023	0,98
6	0,022	0,038	0,96
7	0,009	0,011	0,99
8	0,019	0,035	0,97
9	0,020	0,034	0,97
10	0,015	0,020	0,98

De acordo com a Tabela 11, nota-se que, nos 10 treinamentos realizados, o erro absoluto médio da distância euclidiana variou de 0,007 m a 0,024 m, o desvio padrão do erro absoluto médio variou de 0,006 m a 0,038 m e o coeficiente de correlação variou de 0,96 a 0,99. Os valores médios nos 10 treinamentos foram de: 0,016 m para o erro absoluto médio, 0,023 m para o desvio padrão do erro absoluto médio e 0,98 para o coeficiente de correlação. Tais resultados reforçam a viabilidade deste método na determinação da distância euclidiana, uma vez que o erro absoluto médio foi inferior a 2 cm, com desvio padrão pouco acima deste valor.

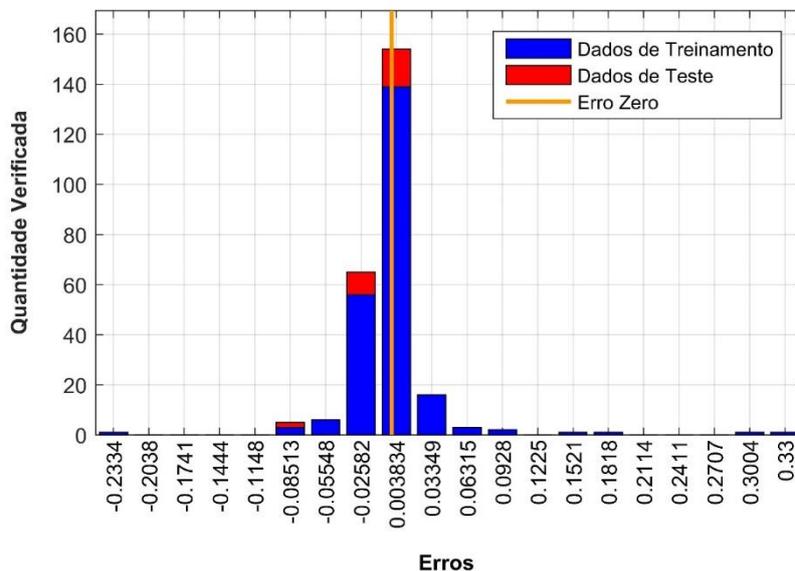
A Tabela 12, por sua vez, apresenta os valores desejados e estimados pelas redes neurais, referentes aos 10% de dados utilizados para teste, bem como os seus respectivos erros absoluto e relativo percentual, para o treinamento 10. A partir da Tabela 12 é possível perceber que o erro absoluto variou de 0 m a 0,082 m e o erro relativo percentual (percentual em relação ao valor desejado) variou de 0 % a 37,05 %. Embora o erro relativo percentual tenha atingido um valor alto (37,05 %), a média dos erros relativos percentuais foi de apenas 4,35 %, ou seja, os valores estimados foram, em geral, similares aos valores desejados.

**Tabela 12** — Comparativo entre valores estimados e desejados obtidos no treinamento 10 com o conjunto de entradas 12 e a topologia 9

<b>Valor estimado [m]</b>	<b>Valor desejado [m]</b>	<b>Erro absoluto [m]</b>	<b>Erro relativo percentual [%]</b>
0,309	0,295	0,015	4,92%
0,367	0,367	0,000	0%
0,632	0,618	0,013	2,18%
0,418	0,419	0,001	0,21%
0,469	0,471	0,002	0,43%
0,385	0,385	0,001	0,18%
0,527	0,543	0,016	2,97%
0,401	0,417	0,016	3,85%
0,512	0,515	0,003	0,56%
0,476	0,443	0,033	7,39%
0,526	0,538	0,012	2,23%
0,243	0,226	0,017	7,53%
0,346	0,349	0,003	0,79%
0,384	0,384	0,000	0%
0,515	0,433	0,082	18,93%
0,517	0,522	0,006	1,10%
0,623	0,605	0,018	2,93%
0,280	0,205	0,076	37,05%
0,420	0,423	0,003	0,81%
0,237	0,226	0,011	4,87%
0,207	0,207	0,000	0%
0,363	0,359	0,004	1,02%
0,520	0,529	0,009	1,66%
0,259	0,243	0,016	6,49%
0,659	0,645	0,014	2,18%
0,608	0,592	0,015	2,60%

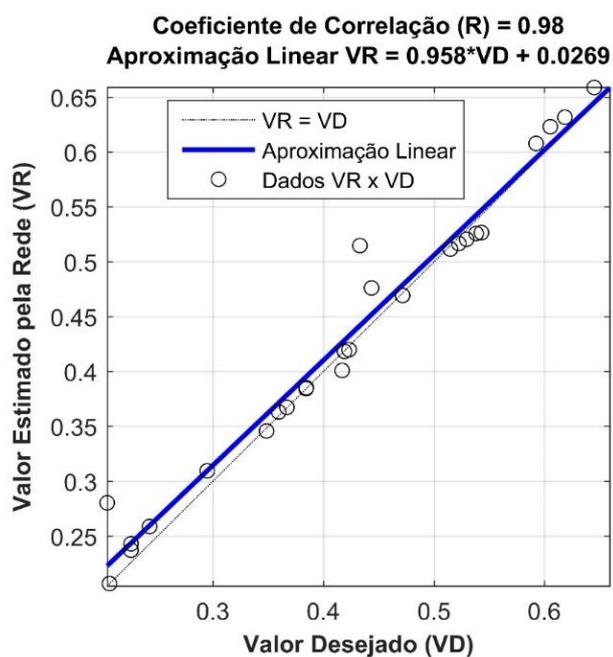
Com o objetivo de analisar os resultados visualmente, através da representação da distribuição dos erros dos dados de treinamento e de teste de forma gráfica, foi gerado o histograma conforme mostra a Figura 37.

**Figura 37** — Histograma de erros do treinamento 10 realizado com o conjunto de entradas 12 e a topologia 9



A Figura 37 mostra que, para o treinamento 10 do conjunto de entradas 12 e topologia 9, a distribuição dos erros entre as distâncias euclidianas desejadas e estimadas teve maior frequência no intervalo entre -0,025 m e 0,003 m tanto para os dados de treinamento quanto para os dados de teste, o que comprova a eficácia do arranjo de redes neurais.

**Figura 38** — Gráfico de dispersão e coeficiente de correlação entre os valores estimados e desejados obtidos no treinamento 10 com o conjunto de entradas 12 e a topologia 9



A análise da Figura 38 confirma o elevado grau de similaridade previsto pela Tabela 12. O coeficiente de correlação (R) igual a 0,98 indica uma forte correlação linear entre as duas variáveis, uma vez que a correlação perfeita possui valor igual a 1,00. Tal similaridade pode ser observada também pela reta de aproximação linear entre as duas variáveis, em azul, que está muito próxima à reta ideal, em cinza.

Os resultados mostraram que a combinação do conjunto de entradas 12 com a topologia 9 do arranjo de redes neurais cumpriu o papel de estimar as distâncias euclidianas entre os sensores e as descargas parciais de modo que estas distâncias possam ser utilizadas na etapa de solução do sistema não-linear de localização de descargas parciais em transformadores.

## 6.2 Testes de determinação das coordenadas tridimensionais das descargas parciais através de algoritmos genéticos

Após a conclusão das etapas de treinamento e validação das redes neurais, estas foram utilizadas para estimar as distâncias euclidianas entre três sensores escolhidos previamente e duas descargas parciais, DPs 1 e 13, as quais terão suas coordenadas tridimensionais determinadas pelo algoritmo genético. Estas descargas parciais foram escolhidas de forma aleatória, porém com a restrição de que não estivessem próximas uma da outra. A Tabela 13 apresenta as distâncias euclidianas estimadas pelas redes neurais e utilizadas na solução do sistema não linear.

**Tabela 13** — Distâncias euclidianas estimadas entre os sensores 6, 11 e 13 e as DPs 1 e 13

Sensor	Distância euclidiana estimada [m]	
	DP 1	DP 13
6	0,527	0,496
11	0,599	0,305
13	0,321	0,294

A partir da metodologia descrita na subseção 5.5 e dos dados da Tabela 13, foram iniciados os testes de execução do algoritmo genético. Para cada descarga parcial a ser localizada, foi realizada uma rotina de 10 execuções do algoritmo genético de modo a permitir a análise estatística dos resultados obtidos. Em cada execução do algoritmo, será apresentado apenas o melhor resultado (indivíduo). A

diferença entre os resultados de cada execução se deve ao fato do algoritmo genético não ser determinístico. Os parâmetros do algoritmo genético foram mantidos nos testes com as duas DPs, a fim de avaliar o desempenho do algoritmo sob diferentes condições.

A primeira rotina de testes foi realizada para determinar as coordenadas tridimensionais da DP 1. Os resultados obtidos nessa rotina são mostrados na Tabela 14. O critério de parada atingido foi o limite de aptidão (0,01).

**Tabela 14** — Resultados dos testes de localização da DP1

<b>Execução</b>	<b>Gerações</b>	<b>X [m]</b>	<b>Y [m]</b>	<b>Z [m]</b>
1	16	0,041	0,158	0,587
2	24	0,045	0,157	0,595
3	10	0,038	0,159	0,590
4	11	0,043	0,156	0,585
5	3	0,056	0,152	0,600
6	28	0,042	0,157	0,591
7	20	0,052	0,153	0,595
8	39	0,060	0,151	0,598
9	15	0,030	0,159	0,583
10	9	0,020	0,154	0,580
Valor desejado		0,070	0,135	0,580
Erro absoluto médio		0,027	0,021	0,010
Desvio padrão		0,012	0,003	0,007

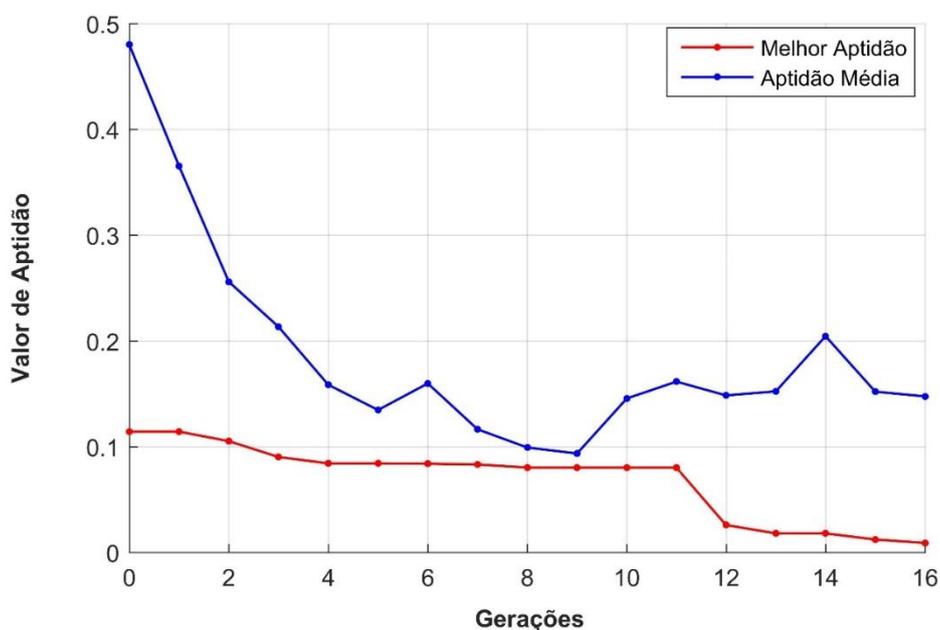
Os resultados da tabela 14 mostram que a coordenada x da DP 1, cujo valor desejado é 0,070 m, variou de 0,020 m a 0,060 m, o que corresponde a um erro absoluto entre 0,010 m e 0,050 m. No caso da coordenada y, o valor obtido variou de 0,152 m a 0,159 m, o que representa um erro absoluto entre 0,017 m e 0,024 m, considerando o valor desejado de 0,135 m. Por fim, a coordenada z variou de 0,580 m a 0,600 m o que, de acordo com o valor desejado de 0,580 m, equivale a um erro absoluto entre 0,000 m e 0,020 m.

Ao avaliar, de forma geral, os resultados obtidos para as coordenadas da descarga parcial 1 através do algoritmo genético, percebe-se a proximidade desses valores com os valores desejados. Tal fato fica evidente ao serem analisados os erros

absolutos médios das coordenadas x, y e z, que são, respectivamente, 0,027 m, 0,021 m e 0,010 m, e cujos respectivos desvios padrões são 0,012 m, 0,003 m e 0,007 m. Estes resultados demonstram a eficácia do algoritmo genético em obter soluções para o sistema não-linear de localização.

Outro ponto importante na avaliação dos resultados é o desempenho do algoritmo genético. Para se atingir o limite de aptidão escolhido (0,01) foram necessárias, em média, 18 gerações, o que indica uma convergência rápida. A Figura 39 mostra o processo de convergência da primeira execução do algoritmo genético para a DP 1.

**Figura 39** — Valor da aptidão ao longo das gerações na primeira execução do AG para a DP 1



A segunda rotina de testes foi realizada para determinar as coordenadas tridimensionais da DP 13. Os resultados obtidos nesta rotina são mostrados na Tabela 15. Para esta rotina, o critério de parada atingido foi o número máximo de gerações (300).

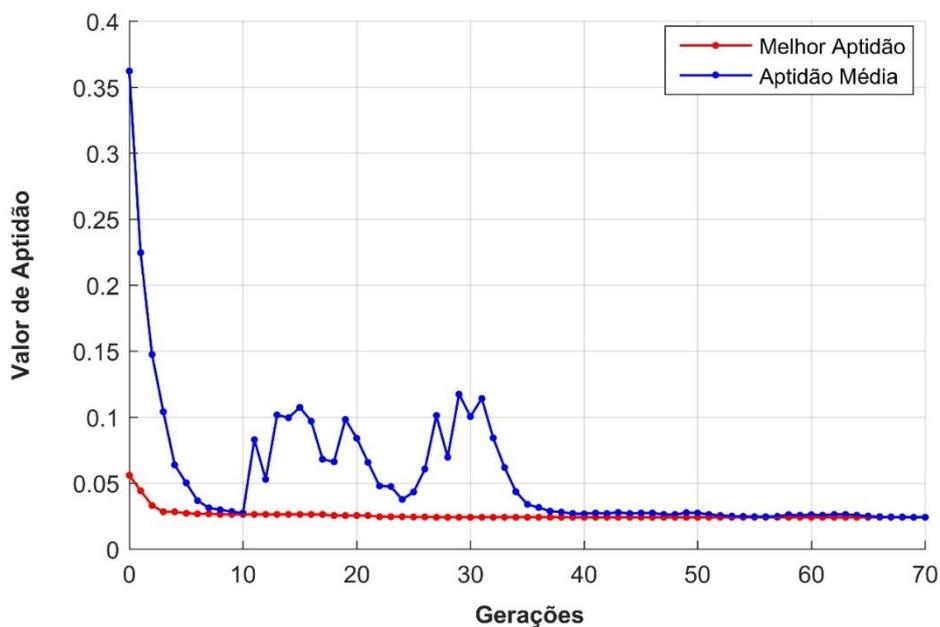
**Tabela 15** — Resultado dos testes de localização da DP13

<b>Execução</b>	<b>Aptidão</b>	<b>X [m]</b>	<b>Y [m]</b>	<b>Z [m]</b>
1	0,024	0,067	0,320	0,284
2	0,024	0,061	0,326	0,279
3	0,024	0,084	0,304	0,296
4	0,024	0,065	0,321	0,282
5	0,025	0,093	0,297	0,303
6	0,024	0,087	0,302	0,299
7	0,024	0,084	0,304	0,296
8	0,025	0,097	0,295	0,305
9	0,024	0,062	0,325	0,279
10	0,024	0,072	0,314	0,288
Valor desejado		0,082	0,327	0,280
Erro absoluto médio		0,012	0,016	0,012
Desvio padrão		0,007	0,012	0,009

Os resultados da tabela 15 mostram que a coordenada x da descarga parcial 13, cujo valor desejado é 0,082 m, variou de 0,061 m a 0,097 m e teve um erro absoluto entre 0,002 m e 0,021 m. No caso da coordenada y, o valor obtido variou de 0,295 m a 0,326 m, o que representa um erro absoluto entre 0,001 m e 0,032 m, considerando o valor desejado de 0,327 m. A coordenada z, por sua vez, variou de 0,279 m a 0,305 m o que, de acordo com o valor desejado de 0,280 m, corresponde a um erro absoluto entre 0,001 m e 0,025 m.

Os resultados obtidos nesta segunda rotina de testes apresentaram comportamentos semelhantes aos da primeira rotina, ou seja, próximos aos valores desejados. Os erros absolutos médios das coordenadas x, y e z foram, respectivamente, 0,012 m, 0,016 m e 0,012 m, e seus respectivos desvios padrões foram 0,007 m, 0,012 m e 0,009 m, o que confirma a eficácia do algoritmo genético.

Quanto ao desempenho do algoritmo genético, embora o AG não tenha atingido o limite de aptidão (0,01) nesta rotina, o menor valor de aptidão atingido foi de 0,024. A convergência a essa aptidão ocorreu, geralmente, em menos de 100 gerações, a exemplo da primeira execução do AG, como mostra a Figura 40. Estes resultados evidenciam o bom desempenho do algoritmo.

**Figura 40** — Valor da aptidão ao longo das gerações na primeira execução do AG para a DP 13

Em relação às duas rotinas de testes realizadas, é importante ressaltar que os valores de distância euclidiana utilizados nas execuções do algoritmo genético são estimados pelas redes neurais e, portanto, possuem erros associados. No entanto, os resultados obtidos nas duas rotinas de testes mostraram a viabilidade deste sistema inteligente em solucionar o sistema não linear de localização da descarga parcial.

## 7 CONCLUSÃO

Este trabalho de pesquisa apresentou um sistema para a localização de descargas parciais em transformadores de potência, isolados a óleo mineral, utilizando o método acústico e sistemas inteligentes do tipo redes neurais e algoritmos genéticos. O método acústico se mostrou eficaz quanto ao seu objetivo de captar as ondas acústicas emitidas pelas descargas parciais através das cápsulas piezelétricos de baixo custo.

O arranjo com três redes neurais do tipo *perceptron* multicamadas trouxe resultados promissores na determinação da distância euclidiana entre os sensores e as descargas parciais através de uma topologia de rede com treze neurônios nas duas camadas escondidas das RNAs 1 e 2 e com cinco neurônios na camada escondida da RNA 3. A combinação desta topologia de redes neurais com o conjunto de entradas referente às métricas RMS, energia e valor de pico e as posições x, y e z dos sensores apresentou resultados de determinação da distância euclidiana cujo erro absoluto médio foi de 1,6 cm com desvio padrão de 2,3 cm. Na comparação entre os valores de distância euclidiana estimados e desejados, o coeficiente de correlação médio foi de 98%, o que comprovou a eficácia do arranjo de redes neurais apresentado em determinar as distâncias euclidianas entre os sensores e as descargas parciais, a partir das quais foi possível determinar a localização da origem da descarga parcial.

O algoritmo genético atingiu o objetivo de solucionar o sistema não linear de localização da descarga parcial. Com a utilização das coordenadas tridimensionais de três sensores e das distâncias euclidianas estimadas pelas redes neurais, foi possível obter as coordenadas tridimensionais de duas descargas parciais, escolhidas para validação do algoritmo genético. As coordenadas tridimensionais obtidas pelo algoritmo genético, para as duas descargas parciais, atingiram valores de erros absolutos médios e desvios padrões inferiores a 3 cm. Estes resultados demonstram a viabilidade da combinação dos sistemas inteligentes, redes neurais e algoritmos genéticos, com o método acústico, como ferramentas para a localização de descargas parciais.

Os resultados obtidos nesta dissertação contribuem com o desenvolvimento do campo de pesquisas relacionadas à localização de descargas parciais em transformadores de potência através de métodos não invasivos e de sistemas

inteligentes. Vale ressaltar que esta aplicação considera o transformador como um todo, de forma semelhante à sua operação normal, e a literatura relacionada carece deste tipo de aplicação.

Em relação ao trabalho de Castro (2016), este trabalho apresenta a vantagem de utilizar um arranjo com três redes neurais, que age como uma rede neural apenas, e um algoritmo genético para a localização da descarga parcial, enquanto o trabalho de Castro utiliza três redes neurais independentes para a localização da descarga parcial, uma para coordenada tridimensional. Outra vantagem deste trabalho é a de utilizar métricas do sinal acústico mais simples do que o critério de informação de Akaike, método autorregressivo utilizado por Castro. Quanto às desvantagens, este trabalho utilizou 6 entradas e 16 sensores para treinamento da rede neural enquanto Castro obteve resultados semelhantes utilizando apenas uma entrada e 8 sensores para o treinamento das três redes neurais.

Para trabalhos futuros, sugere-se a realização de pesquisas voltadas ao desenvolvimento de um protótipo para monitoramento e localização de descargas parciais em transformadores em pleno funcionamento, utilizando o método acústico. Estas pesquisas podem incluir a utilização de novos sensores para a captação das ondas acústicas (ou em menor quantidade), outros meios de transmissão do sinal acústico, novos métodos processamento de sinais acústicos e outros sistemas inteligentes.

## REFERÊNCIAS

AGUIAR, P. R.; BIANCHI, E.C.; CANARIM, R. C. **Monitoring of Grinding Burn by Acoustic Emission**. In: Wojciech Sikorski. (Org.). Acoustic Emission. 1ed. Rijeka, Croatia: Intech, v. 1, pp. 341-364, 2012.

AKAMINE, A. **Explorando Alternativas para Construção de Modelos Neurais de Interação Espacial**. Dissertação (Mestrado em Engenharia Civil). Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, Brasil. 2005.

ARENY, R. P.; WEBSTER, J. G. **Sensors and Signal Conditioning**. 2ed. New York: John Wiley & Sons, 2000. 587P.

AUCKLAND, D.W. HYDE, J.R., MCGRAIL, A.J., VARLOW, B.R. **“The ultrasonic location of discharges in transformers – a new approach”**, Conference Record of IEEE International Symposium on Electrical Insulation, Pittsburgh, PA USA, 1994.

BARCELLOS, J.C.H. **Algoritmos genéticos adaptativos – um estudo comparativo**. Dissertação de Mestrado, Escola Politécnica da USP, São Paulo, 2000.

BARTLEY, W. **Analysis of transformer failures**. In: Proceedings of the 36th Annual Conference for International Association of Engineering insurers, Stockholm, 2003, pp. 137–142.

BARTNIKAS, R; McMAHON, E. J. **Engineering dielectrics: corona measurement and interpretation**. Philadelphia: ASTM, V. 1, chapters 1-2. (ASTM STP - 669), 1979.

BARTNIKAS, R; NOVAK, J. P. On the Character of different forms of partial discharge and their related terminologies. IEEE Transactions on Dielectrics and Electrical Insulation, v. 28, n. 6, p. 956-968, 1993.

BOGGS, S. A. **Partial Discharge – part III: cavity-induced PD in solid dielectrics**. IEEE Electrical Insulation Magazine, v.6, n.6, p. 11-20, 1990.

CASTRO, B. A. **Localização de Descargas Parciais em Transformadores de Potência por Meio de Sensores Piezelétricos de Baixo Custo e Sistemas Inteligentes**. 147 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Bauru, 2016.

CASTRO, B.; CLERICE, G., RAMOS, C.; ANDREOLI, A.; BAPTISTA, F.; CAMPOS, F.; ULSON, J. **Partial Discharge Monitoring in Power Transformers Using Low-Cost Piezoelectric Sensors**. Sensors 16, no. 8, 1266, 2016.

CHAURASIA, D. C. **Scintillation Modeling for insulator String under Polluted Conditions**, Eleventh International Symposium on High Voltage Engineering, vol. 4, pp. 224-227, IEEE, Agosto 23-27, 1999.

CLERICE, G. A. M. **Localização de Descargas Parciais por Meio de Cápsulas Piezelétricas de Baixo Custo e Sistemas Inteligentes**. 120 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Bauru, 2014.

COLHERINHAS, G. B. **Ferramentas de Otimização via Algoritmos Genéticos com Aplicações em Engenharia**. 84 f. Dissertação (Mestrado em Ciências Mecânicas) – Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2016.

CUENCA, W. M. H. **Caracterização dos sinais de descargas parciais em equipamentos de alta tensão a partir de modelos experimentais**. 140 f. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.

DEMUTH, H.; BEALE, M.; HAGAN, M. **Neural Network Toolbox – User’s Guide**. Version 6.0.4. The Mathworks Inc., 901p, 2010.

DUVAL, M. **A Review of Faults Detectable by Gas-in-Oil Analysis Using New IEC Publication 60599 and IEC TC 10 Databases**. IEEE Electrical Insulation Magazine, vol 17, nº 6, p. 22-27, 2002.

EDIN, H. **Partial Discharges Studied with variable frequency of the applied voltage**. 2001. Thesis (Ph.D.) – Electrical Engineering, Kungl Tekniska Hogskolan, Stockholm, 2001.

FORSYTH, K. W. **Optical partial discharge detection**. In: Iris Rotating Machine Technical Conference, 1998.

GEMANT, A.; PHILIPOFF, W. **The spark gap with precondenser**. Zeitschrift fuer Technische Physik, Vol. 13, pp. 425-430, 1932.

GJAERDE, A. C. **Multifactor aging models – oringn and similarities**. IEEE Eletrical Insulation Magazine, v.13. n.1, p. 6-13, 1997.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. 1st. ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1989.

GULSKI, E. **Digital Analisis of partial discharges**. IEEE Transactions on Dielectric and Eletrical Insulation, v.2, n.5, p 822-837, 1995.

GUTNIK, Y. **Estudo dos Piezelétricos na Detecção de Descargas Parciais**. 2014. 298 f. Dissertação (Mestrado em Ciências). Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, Brasil. 2014.

HAGAN, M.T., MENHAJ, M. B. **Training feedforward networks with the Marquardt Algorithm**. IEEE Transactions on Neural Networks, vol. 5, nº 6, 1994.

HAUSCHILD, W.; LEMKE, E. **High-voltage test and measuring techniques**, Springer, 2014.

HAYKIN, S.S. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 P.

HODGKIN, A. L.; HUXLEY, A. F. **A quantitative description of membrane current and its application to conduction and excitation in nerve**. Journal of Physiology, vol. 117, pp. 500-544, 1952.

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. University of Michigan Press, Ann Arbor, 1975.

IBRAHIM, R. C. **Caracterização de Propriedades Físicas de um Material Cerâmico Ferroelétrico do Sistema PZT**. 1991. 155 f. Dissertação (Mestrado em Engenharia Mecânica), Universidade Estadual de Campinas, Campinas, 1991.

IEEE. **C57.104-2008: IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers**, 2009.

IEC. **IEC 60270: High-Voltage Test Techniques - Partial Discharge Measurements**, 2000.

KELEN, A. DANIKAS, M. G. **Evidence and presumption in PD diagnostic**. IEEE Transactions on Dielectrics and Electrical Insulation, v. 2, n. 5, p.780-795, 1995.

KREUGER, F. H. **Partial Discharge detection in high-voltage equipment**. London: Butterworths, 1989.

KUFFEL, R.; ZAENGL, W. S.; KUFFEL, J. **High voltage engineering: fundamentals**. London: Butterworth-Heinemann, 2000.

KUMAR, R. **System and Method for the use of an Adaptive Mutation Operator in Genetic Algorithms**. US Pat. 7660773 B1, 9 fev. 2010. 10p.

LEMKE, E. **WG D1.33: guide for partial discharge measurements in compliance to IEC 60270**. Paris: CIGRE, 2008.

LEVENBERG, K. **A Method for the Solution of Certain Non-linear Problems in Least Squares**. Quarterly of Applied Mathematics, pp.164–168, 1944.

LIMA, T. W. **Algoritmos evolutivos para predição de estruturas de proteínas**. Dissertação (Mestrado em Ciências). Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo. São Carlos, Brasil, 2006.

LINDEN, R. **Algoritmos Genéticos**. 3ª ed. Rio de Janeiro: Editora Ciência Moderna Ltda., 2012.

LUGER, G. F. **Inteligência Artificial**. 6ª ed. São Paulo: Pearson Education do Brasil, 2013.

LUNDGAARD, L. E. “**Partial discharge XIV: acoustic partial discharge detection – practical application**”, IEEE Electrical Insulation Magazine, vol. 8, no. 5, pp. 34-43, 1995.

MARCHI, M. **Uma aplicação do método de impedância eletromecânica na detecção da queima no processo de retificação plana**. 2015. 80 f. Tese (Doutorado em Engenharia Elétrica). Faculdade de Engenharia, Universidade Estadual Paulista. Bauru, Brasil. 2015.

MARKALOUS, S. **Detection and Location of Partial Discharges in Power Transformers using Acoustic and Electromagnetic Signals**. 2006. 130 f. Tese (Doutorado) – Universidade de Stuttgart, Stuttgart, Alemanha, 2006.

MARKALOUS, S. M.; TENBOHLEN, S.; FESER, K. **Detection and Location of Partial Discharges in Power Transformers using Acoustic and Electromagnetic Signals**. IEEE Transactions On Dielectrics And Electrical Insulation, v. 15, n. 6, p.1576-1583, dez. 2008.

MASON, H. M. **Enhancing the significance of PD measurements**. IEEE Transactions on Dielectric and Electrical Insulation, v. 2, n. 5, p. 876-888, 1995.

MATHWORKS. **Global Optimization Toolbox: User's Guide R2017a**. The MathWorks Inc., Massachusetts, 2017.

McALLISTER, I.M. **Partial discharge in spheroidal voids – void orientation**. IEEE Transactions On Dielectrics And Electrical Insulation, v. 4, n. 4, p.456-461, 1997.

MCCULLOCH, W.S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. Bulletin of Mathematical Biophysics, vol. 5, pp. 115-133, 1943.

MEITZLER, A. H. **IEEE standard on piezoelectricity: an american national standard**. New York: IEEE-ANSI, 1987. 66 p. (Std, 176).

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. 3<sup>rd</sup>, Springer-Verlag, 1996.

MITCHELL, M. **Genetic Algorithms: An Overview**. Santa Fe Institute, Santa Fe, 1995.

MORSHUIS, P. **Assessment of dielectric degradation by ultrawide-band PD detection**. IEEE Transactions on Electrical Insulation, v. 2, n.5, p. 744-760, 1995.

MURATA. Murata manufacturing Co. Ltd. **Catálogo de produtos**. Disponível em: <<http://www.murata.com>>. Acesso em: 12 dez. 2015.

NDT. NDT Education Resource Center, Iowa State University. **NDT Course Material - Ultrasound**. Disponível em: <<http://www.ndt-ed.org>>. Acesso em: 28 fev. 2017.

PEDERSEN, A.; CRICHTON, G. C.; McALLISTER, I. W. **The theory and measurement of partial discharge transients**. IEEE Transactions on Electrical Insulation, v. 26, n. 3, p.487-497, 1991.

PHUKAN, R.; KARMAKAR, S. **Acoustic Partial Discharge signal analysis using digital processing techniques**. In: IEEE India Conference (INDICON), 2013.

ROBLES, G.; FRESNO, J.M.; TARIFA, J.M.M. **“Separation of radio-frequency sources and localization of partial discharges in noise environments”** Sensors, v.15, p 9882-9898, 2015.

RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. 3ª ed. Rio de Janeiro: Elsevier, 2013.

SAGE, A.P. **Concise Encyclopedia of Information Processing in Systems and Organizations**, New York, Pergamon, 1990.

SARATHI, R.; SINGH, P. D.; DANIKAS, M. G. **Characterization of partial discharges in transformer oil insulation under ac and dc voltage using acoustic emission technique**. Journal of Electrical Engineering. Vol. 58, pp 91-97, 2007.

SCHWARZ, R.; JUDENDORFER, T.; MUHR, M. **Review of partial discharge monitoring techniques used in high voltage equipment**. In: IEEE Annual Report Conference Electrical Insulation and Dielectric Phenomena, pp 400-403, 2008.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010. 399 p.

SIVIAN, L. J. **High frequency absorption in air and other gases**. The Journal of The Acoustic Society of America, v.19, n.5, p. 914-916, 1947.

SPATTI, D. H. **Automatização de Processos de Detecção de Faltas em Linhas de Distribuição Utilizando Sistemas Especialistas Híbridos**. 208 f. Tese (Doutorado em Engenharia Elétrica). Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, Brasil, 2011.

SRINIVAS, M.; PATNAIK, L. M. **Genetic Algorithms: A Survey**. IEEE Computer, pp. 17-26, 1994.

TORRES, A. C. S. T. **Determinação de rotas ótimas de ônibus urbano utilizando algoritmo genético**. 87 f. Dissertação (Mestrado). Faculdade de Tecnologia, Universidade de Brasília, 2003.

ULSON, J. A. C. **Redes Neurais Artificiais – Capítulo 04**. Programa de Pós-Graduação em Engenharia Elétrica, Faculdade de Engenharia de Bauru – UNESP, pp. 2, 2009. Notas de Aula.

VELOSO, G. F. **Localização de Descargas Parciais em Transformadores pela Análise da Emissão Acústica**. 2006. 136 f. Dissertação (Mestrado em Engenharia Elétrica). Universidade Estadual de Itajubá. Itajubá, Brasil.

VITA, S. S. B. V. **Algoritmos Genéticos multiobjetivos aplicados ao roteamento *multicast* com qualidade de serviço**. 2009. 123 f. Dissertação (Mestrado em Ciência da Computação). Universidade Federal de Uberlândia. Uberlândia, Brasil.

WADA, J; UETA, G; OKABE, S; AMIMOTO, T. **Inhibition Technique of Transformer Insulating Oil Degradation - Evaluation of the Effectiveness of Oxidation Degradation Inhibitors**. IEEE Transactions on Dielectrics and Electrical Insulation, vol. 20, pp. 1641-1648, 2013.

WANG, X; LI, B; ROMAN T. H; RUSSO, L. O; CHIN K; FARMER R. K. **Acousto-optical PD Detection for Transformers**. IEEE Transactions on power delivery, Vol. 21, No. 3, Julho 2006.