

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

BRUNO ALBUQUERQUE DE CASTRO

**LOCALIZAÇÃO DE DESCARGAS PARCIAIS EM
TRANSFORMADORES DE POTÊNCIA POR MEIO DE SENSORES
PIEZELÉTRICOS DE BAIXO CUSTO E SISTEMAS INTELIGENTES**

**Bauru
2016**

Bruno Albuquerque de Castro

**LOCALIZAÇÃO DE DESCARGAS PARCIAIS EM
TRANSFORMADORES DE POTÊNCIA POR MEIO DE SENSORES
PIEZELÉTRICOS DE BAIXO CUSTO E SISTEMAS INTELIGENTES**

Dissertação apresentada à Faculdade de Engenharia de Bauru, como requisito para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. José Alfredo Covolan
Ulson

Coorientador: Prof. Dr. André Luiz Andreoli

Bauru
2016

Castro, Bruno Albuquerque de.

Localização de Descargas Parciais em Transformadores de Potência por Meio de Sensores Piezelétricos de Baixo Custo e Sistemas Inteligentes / Bruno Albuquerque de Castro, 2016
147 f.

Orientador: José Alfredo Covolan Ulson

Dissertação (Mestrado)-Universidade Estadual Paulista. Faculdade de Engenharia, Bauru, 2016

1. Transformador de potência. 2. Localização de falhas. 3. Descarga parcial. 4. Sensor piezelétrico de baixo custo. 5. Sistemas inteligentes I. Universidade Estadual Paulista. Faculdade de Engenharia. II. Título.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Bauru




ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE BRUNO ALBUQUERQUE DE CASTRO, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, DA FACULDADE DE ENGENHARIA.


Aos 25 dias do mês de maio do ano de 2016, às 10:00 horas, no(a) Anfiteatro da Diretoria Técnica de Informática/FE, 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. ROGERIO ANDRADE FLAUZINO do(a) Departamento de Engenharia Elétrica e de Computação / Universidade de São Paulo/São Carlos, Prof. Dr. FABRICIO GUIMARÃES BAPTISTA 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 BRUNO ALBUQUERQUE DE CASTRO, intitulada **LOCALIZAÇÃO DE DESCARGAS PARCIAIS EM TRANSFORMADORES DE POTÊNCIA POR MEIO DE SENSORES PIEZOELÉTRICOS DE BAIXO CUSTO E SISTEMAS INTELIGENTES**. 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. ROGERIO ANDRADE FLAUZINO



Prof. Dr. FABRICIO GUIMARÃES BAPTISTA

Dedicatória

Dedico este trabalho aos meus pais, José Roberto e Rose Mary, que, desde que nasci, não mediram esforços em me proporcionar as condições fundamentais para que eu chegasse até aqui, me apoiando sempre em todos os sentidos. Dedico também a minha avó, Therezinha, que sempre me apoiou e me deu conselhos valiosos para a vida.

Agradecimentos

Primeiramente, a Deus, que me capacitou segundo a Tua graça que me fez chegar até aqui.

Ao Professor Dr. José Alfredo Covolan Ulson, pela amizade, pela dedicação e apoio em todos os momentos. Agradeço também pela confiança, por acreditar no potencial deste trabalho, bem como pelo aprendizado que absorvi durante este tempo. Agradeço todos os conselhos que levarei para minha vida acadêmica e por cada minuto que demandei com as minhas dúvidas.

Ao professor Dr. André Luiz Andreoli pela coorientação, pelo apoio e por acreditar no meu potencial e no potencial desta pesquisa. Foi fundamental na parte prática desta pesquisa e forneceu o transformador que foi utilizado. Agradeço a cada minuto que demandei com minhas dúvidas e solicitações. Agradeço a motivação dada nas horas de incertezas e pelo aprendizado que levarei por minha vida.

Agradeço o apoio dado pelos meus pais, José Roberto e Rose, pelos meus irmãos, Rafael e Larissa, bem como a minha avó Therezinha e minha tia Cristiane.

Agradeço pelo constante apoio dado pelo Professor Dr. Paulo Roberto de Aguiar neste período e pelos trabalhos realizados com o Professor Dr. Fernando de Souza Campos.

Aos meus amigos de laboratório Guilherme Marabuzzi Clerice, Nelson Medeiros e Caio Oba, pelo companheirismo. A todos os funcionários do Departamento de Engenharia Elétrica da Unesp de Bauru e da sessão técnica de pós-graduação.

Agradeço a todos os técnicos de laboratório que não mediram esforços para me ajudar na parte experimental desta pesquisa: Edson, Osmar, Nelson e Elton.

A todos os meus amigos que me apoiaram nesta jornada.

À CAPES pelo auxílio com a bolsa de estudos.

*“Por vezes sentimos que aquilo que fazemos não é senão uma gota de água no mar.
Mas o mar seria menor se lhe faltasse uma gota.”*

Madre Teresa de Calcutá

RESUMO

O monitoramento e a localização precoce de descargas parciais em aparelhos de alta tensão, como nos transformadores de potência, são de fundamental importância para a prevenção de problemas funcionais associados à degradação contínua dos materiais que compõe o isolamento elétrico destes tipos de aparelho. Alguns fatores críticos na operação dos transformadores, como o funcionamento em sobrecarga, superaquecimento, transitórios e sinais elétricos de grande conteúdo harmônico vinculados a sistemas chaveados, em longo prazo, fazem com que o sistema de isolação de um transformador apresente degradação de suas propriedades físicas e químicas intrínsecas aos diversos tipos de materiais utilizados para esta finalidade e, deste modo, surjam descargas parciais. Este trabalho teve como objetivo aplicar sensores piezelétricos de baixo custo para a identificação e localização de descargas parciais em transformadores de potência por meio de sistemas inteligentes do tipo Redes Neurais e sistema de inferência neuro fuzzy adaptativos. Ambos os sistemas foram treinados com algumas métricas de processamento de sinais e os resultados de erro médio de localização chegaram na casa dos milímetros. Variou-se o número de sensores acoplados e foi realizado um estudo sobre os resultados de localização obtidos.

Palavras-chave: Transformador de potência; Localização de falhas; Descarga parcial; Sensor piezelétrico de baixo custo; Sistemas inteligentes.

ABSTRACT

Partial discharge in power transformers require high-cost monitoring procedures based on corrective maintenance or even interruptions of the power system. The development of online non-invasive monitoring systems to detect partial discharges in power transformers has great relevance since it can reduce significant maintenance costs. Some critical factors in the operation of transformers such as overload, nonlinear loads, transient voltage surges by atmospheric origin and switching, can make the insulation system of transformers lose their physical and chemical properties. Therefore, these operating conditions can cause early deterioration of the insulation, causing internal partial discharges that may develop into major defects and thus shorten the useful life of electrical equipment. This research aimed to apply a low cost piezoelectric sensors for partial discharge identification and location in power transformers through intelligent systems such as neural networks and adaptive fuzzy inference systems. Both systems were trained with some signal processing metrics and the results for location error were in the region of millimeters. It varied the number of coupled sensors, and a study was conducted on the obtained location results.

Keywords: Power Transformer; Location failures; Partial Discharge; Low-Cost Piezoelectric Sensor; Intelligent Systems.

SUMÁRIO

CAPÍTULO 1- INTRODUÇÃO.....	12
1.1. Considerações Iniciais.....	12
1.2. Objetivos.....	15
1.3. Relevância Científica	15
1.4. Organização do Trabalho Acadêmico.....	15
1.5. Publicações Realizadas Durante o Período de Mestrado.....	17
CAPÍTULO 2- DESCARGAS PARCIAIS EM TRANSFORMADORES.....	19
2.1. Introdução.....	19
2.2. Definições e Tipos de Descargas Parciais.....	21
2.3. Modelos de Descargas Parciais em Tensão Alternada	23
2.3.1. O Modelo do Circuito Equivalente	23
2.3.2. O Modelo por Aproximação de Campo	26
2.4. Métodos de Detecção de Descargas Parciais	27
2.4.1. O Método Elétrico de Identificação de DPs	28
2.4.2. O Método Eletromagnético de Identificação de DPs	30
2.4.3. O Método Óptico de Identificação de DPs	31
2.4.4. O Método Químico de Identificação de DPs	32
2.4.5. O Método Acústico de Identificação de DPs	35
CAPÍTULO 3- O MÉTODO DE EMISSÃO ACÚSTICA E A IDENTIFICAÇÃO E LOCALIZAÇÃO DE DESCARGAS PARCIAIS.....	37
3.1. Introdução.....	37
3.2. Conceitos Básicos de Acústica.....	37
3.2.1. Ondas e Modos de Propagação.....	38
3.2.2. Impedância Acústica	38
3.2.3. Reflexão e Refração.....	39
3.2.4. A Velocidade do Som nos Meios Materiais	40
3.2.5. Atenuação de Propagação das Ondas Acústicas	41
3.3. Detecção de Descargas Parciais pela Técnica da Emissão Acústica	42
3.4. A Técnica de Localização de Descargas Parciais	44
3.5. Técnicas de Processamento Digital de Sinais Aplicados à Localização.....	49

3.5.1. Valor RMS de um Sinal Acústico.....	49
3.5.2. Energia de um Sinal Acústico.....	50
3.5.3. Skewness de um Sinal Acústico	50
3.5.4. Kurtosis de um Sinal Acústico	51
3.5.5. Valor de Pico de um Sinal Acústico.....	52
3.5.6. Critério de Energia	52
3.5.7. Critério Estatístico de Akaieke (AIC)	53
CAPÍTULO 4- TRANSDUTORES PIEZELÉTRICOS E A TÉCNICA DA EMISSÃO ACÚSTICA NA IDENTIFICAÇÃO DE DESCARGAS PARCIAIS.....	55
4.1. Piezeletricidade e Materiais	55
4.2. Diafragmas Piezelétricos de Baixo Custo.....	57
CAPÍTULO 5- SISTEMAS INTELIGENTES.....	60
5.1. Introdução.....	60
5.2. Redes Neurais Artificiais	62
5.2.1. O Neurônio Artificial	64
5.2.2. Arquiteturas de RNAs.....	66
5.2.3. O Processo de Treinamento das Redes Perceptron Multicamadas	68
5.3. Sistemas Nebulosos ou Sistemas Fuzzy	70
5.3.1. As Funções de Pertinência dos Conjuntos Fuzzy	72
5.3.2. Sistema de Inferência Fuzzy	75
5.3.3. Sistemas de Inferência Neuro Fuzzy Adaptativos	77
CAPÍTULO 6- METODOLOGIA PROPOSTA.....	80
6.1. Introdução.....	80
6.2. Geração de Descargas Parciais	81
6.3. Estudo da Viabilidade do Diafragma Pizelétrico de Baixo Custo para a Identificação de Descargas Parciais	85
6.4. Localização de Descargas Parciais	87
6.4.1. Treinamento da Rede Neural do Tipo Perceptron Multicamadas	89
6.4.2. Treinamento do Sistema de Inferência Neuro Fuzzy Adaptativo	91
6.4.3. Variação do número de sensores para a localização de DPs	92
CAPÍTULO 7- ANALISE E RESULTADOS.....	93

7.1. Comportamento da Resposta do Sensor de Baixo Custo em Relação ao Sensor R15I-AST	93
7.2. Ensaios de Localização por Meio da Rede Neural do Tipo Perceptron Multicamadas	97
7.3. Ensaios de Localização por Meio do Sistema ANFIs	107
7.4. Ensaios de Localização de Descargas Parciais com Variação do Número de Sensores	117
7.4.1 Treinamentos por Redes Neurais Artificiais.....	117
7.4.2 Treinamentos pelo sistema ANFIs	128
CAPÍTULO 8- CONCLUSÃO	137
REFERÊNCIAS.....	140

CAPÍTULO 1- INTRODUÇÃO

Este capítulo apresenta uma introdução geral sobre o assunto abordado salientando os aspectos de motivação, objetivos, relevância, organização da dissertação e as publicações produzidas pelo grupo de pesquisa.

1.1. Considerações Iniciais

O crescente aumento da demanda energética no mundo suscita um significativo debate no que condiz à confiabilidade e qualidade do fornecimento de energia elétrica, seja nos setores de geração, transmissão ou distribuição de energia. Diversas falhas neste setor podem ser a causa de um significativo ônus financeiro que atinge importantes centros consumidores como a indústria, comércio e prestação de serviços.

Como exemplo, muitas falhas que geram transitórios na rede elétrica podem causar danos irreversíveis a equipamentos e máquinas, gerando gastos com manutenção corretiva ou mesmo a própria substituição do dispositivo. Nessa conjuntura também se enquadram as falhas que culminam com a interrupção no fornecimento de energia, gerando ociosidade e grandes perdas produtivas na cadeia econômica.

Dentro deste contexto, o desenvolvimento de técnicas que têm como característica a predição de falhas no sistema elétrico torna-se, por conseguinte, um fator imprescindível para a melhoria dos índices de qualidade e confiabilidade desse sistema, seja no setor de geração, transmissão ou distribuição de energia.

Dentre os diversos dispositivos instalados no sistema elétrico, os transformadores de potência desempenham um papel de elevada significância operacional, pois são responsáveis pela adequação dos níveis de tensão e transferência de energia, desde a unidade geradora até o seu consumo. Desta forma, as ocorrências de falhas em transformadores podem privar os centros consumidores do fornecimento de energia se não existir um acompanhamento contínuo de suas condições de funcionamento. Sendo assim, a aplicação de técnicas de predição de defeitos em transformadores pode, portanto, amenizar o ônus financeiro gerado por falhas que se iniciam nestes dispositivos elétricos, tendo em vista que essas técnicas

permitem manutenções pontuais e programadas prevenindo, então, a interrupção do fornecimento.

Alguns fatores críticos de operação dos transformadores de potência, como a operação em sobrecarga que promove o superaquecimento do equipamento, transitórios, sinais elétricos de grande conteúdo harmônico, dentre outros, podem degradar a isolação destes dispositivos elétricos e, então, diminuir sua vida útil. Tais condições de trabalho suscitam uma perda precoce das propriedades físico-químicas dos materiais que compõe a isolação do transformador culminando, então, com diversos problemas que levam a diminuição da sua vida útil. Um problema muito comum e de destaque é a descarga parcial (DP).

De acordo com a norma IEC-60270 (2011) a descarga parcial é definida como uma descarga elétrica que preenche parcialmente o isolamento entre dois condutores. Podem surgir quando cargas elétricas se formam em decorrência da diferença de potencial elétrico em bolhas de gases, trincas ou materiais isolantes degradados, resultando em um canal ionizado incompleto com o surgimento de elétrons livres (WANG et al, 2006).


Sendo assim, é de grande relevância a detecção e localização precoce de pontos de descargas parciais tendo em vista que o surgimento destas falhas pode ser um indicador primordial de problemas na isolação deste dispositivo. Por exemplo, os transformadores refrigerados a óleo mineral isolante são os mais presentes no sistema elétrico. O aparecimento de descargas parciais no óleo faz acentuar, ainda mais, a degradação do material, tendo como consequência a diminuição da vida útil do transformador.

As descargas parciais impõem ao meio material uma perturbação caracterizada 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 (SARATHI; SINGH; DANIKAS, 2007). A fotografia de uma descarga parcial em óleo mineral de um transformador de potência é apresentada na Figura 1.1.

Tomando estas características particulares, existem diversos métodos de abordagens de identificação de DPs. A busca por metodologias eficientes para a identificação obteve expressivo crescimento no ponto de vista de confiabilidade e qualidade dos resultados obtidos.

No âmbito técnico-científico pode-se verificar quatro metodologias mais utilizadas para esta finalidade, como o método elétrico, que faz uma análise de pulsos

Figura 1.1- Fotografia de descarga parcial em óleo isolante



(Fonte: HAUSCHILD, 1970)

elétricos nas terminações de alta e baixa tensão dos transformadores; o método químico, que analisa a variação da composição molecular dos materiais isolantes no transformador ao longo do tempo; o método por emissão acústica, que detecta sinais de ultrassom gerados pela descarga, o método óptico, que explora a emissão de luz gerada pelo fenômeno e o método eletromagnético, que se vale da detecção de ondas de UHF emitidas pela descarga (MARKALOUS, 2006; VELOSO, 2006).

A técnica de localização de descargas parciais por emissão acústica toma como base a detecção de ondas de ultrassom emitidas por meio do emprego de sensores na parede externa do transformador. Se apresenta como uma técnica não invasiva e de rápida coleta de informações, quando se leva em conta que este teste se inicia apenas com a aquisição de sinais de sensores acoplados à carcaça do transformador de potência. A literatura científica carece de abordagens que estudam a localização de DPs em transformadores montados de forma plena, isto é, dotados de todos os seus componentes funcionais como o núcleo de aço silício, enrolamentos, buchas de isolamento. O que se observa é apenas o desenvolvimento de técnicas de localização de DPs em transformadores imersos a óleo mineral, desprovidos de núcleo, ou seja, sem a principal parte funcional deste dispositivo, denominada de parte ativa. Tudo isso se deve ao fato que os componentes internos de um transformador se tornam obstáculos para a propagação das ondas, modificando todo conteúdo acústico original emitido pelo fenômeno de descarga parcial.

Segundo Markalous (2006), Clerice (2014) e Veloso (2006), autores que propuseram métodos de localização de DPs no interior de tanques de transformadores

sem a parte ativa instalada, ou seja, com o dispositivo dotado apenas de carcaça e óleo isolante, as mudanças acústicas ocasionadas por estes obstáculos, dificultam o processo de localização exata do problema. Além disso, verifica-se que algumas abordagens de identificação e localização de DPs pelo método da emissão acústica empregam sensores industriais de elevado custo financeiro, fator limitante na aplicação desta técnica.

Consequentemente, o monitoramento e o estudo da identificação e localização de pontos de descargas parciais (DPs) em transformadores de potência tem grande importância na confiabilidade da operação do sistema elétrico, pois pode se evitar uma interrupção prolongada no fornecimento de energia (SHENG, et al, 2014). Sendo assim, o desenvolvimento de técnicas não intrusivas que auxiliem na predição de falhas em transformadores de potência possui grande relevância no sistema elétrico diante do exposto nesta seção.

1.2. Objetivos

Diante do conteúdo apresentado, o objetivo desta pesquisa foi o estudo da localização de descargas parciais em transformadores de potência imersos em óleo mineral por meio do emprego de diafragmas piezelétricos de baixo custo, (também conhecidos como Titanato Zirconato de Chumbo ou capsulas piezelétricas), bem como o emprego de sistemas inteligentes para o tratamento dos sinais. Mais especificamente, os sinais acústicos captados pelos diafragmas, que atuaram como sensores, foram tratados computacionalmente e levados a sistemas inteligentes do tipo redes neurais artificiais do tipo “*Perceptron* Multicamadas” e sistemas de inferência neuro difuso adaptativos (ANFIS). Os sistemas inteligentes foram treinados e, então, obteve-se a localização do fenômeno de descarga parcial, promovendo, desta forma, a redução de custo desta tecnologia, e também o estudo da localização de DPs com o transformador montado por inteiro, isto é, dotado de núcleo, bobinas, buchas, etc.

1.3. Relevância Científica

Conforme observado em Sakoda e Nieda (2001), Markalous (2006), Markalous, Tenbohlen e Feser (2008) e Veloso (2006), o conteúdo acústico das ondas originadas pela fonte de descarga parcial são modificadas nas atenuações, refrações e reflexões

de onda no interior do transformador. A onda acústica originada pela fonte de descargas parciais se propaga pelo interior do transformador de potência e incide por diversos tipos de materiais como por exemplo o óleo mineral, o núcleo de aço, bobinas de cobre, dentre outros. Sendo assim, os componentes do dispositivo acabam se tornando obstáculos mecânicos que atenuam o sinal e também modificam suas características iniciais, interferindo negativamente na exatidão da localização do ponto de descarga parcial.

O presente trabalho contemplou a localização de DPs com o transformador de potência em plena montagem, isto é, dotado de todos os seus componentes que serviram de obstáculos para a propagação acústica de ondas geradas pelas descargas parciais, fato pouco explorado na literatura científica.

1.4. Organização do Trabalho Acadêmico

A dissertação se inicia, no Capítulo 2, pela apresentação do estado da arte dos modelos que representam física e matematicamente as descargas parciais bem como os métodos de detecção mais comuns utilizados no ambiente acadêmico e industrial. Este capítulo também visa a contextualização da problemática que envolve os mecanismos que geram as descargas parciais. Após, o trabalho passa a dar o foco no método acústico de identificação e localização das descargas, salientando os aspectos vigentes na bibliografia bem como a dificuldade de se localizar uma descarga com o transformador montado por completo, tendo em vista a teoria acústica de ondas. Neste capítulo também é apresentado a importância da identificação e localização das DPs bem como as métricas matemáticas de processamento de sinais utilizadas neste trabalho. Nos Capítulos 3 e 4 são apresentados aspectos relativos à localização de descargas e a teoria de sensores piezelétricos, respectivamente. Já no Capítulo 5 os sistemas inteligentes utilizados nesta pesquisa, isto é, as redes neurais do tipo *perceptron* multicamadas, bem como os sistemas de inferência neuro *fuzzy* difuso adaptativos (ANFIS) são apresentados.

A parte experimental deste trabalho é discutida no Capítulo 6 pela qual apresenta os experimentos realizados e a metodologia adotada.

Os resultados e conclusão desta pesquisa, bem como o direcionamento para pesquisas futuras são abordados nos capítulos 7 e 8 deste trabalho.

1.5. Publicações realizadas durante o período de mestrado

1.5.1. Trabalhos Publicados na Área desta Pesquisa em Congresso Internacional

- Castro, B. A. ; Clerice, G. A. M. ; Ulson, J. A. C. ; Andreoli, A. L. ; Creppe, R. C.; Alves, A. F. **Mitigação de Defeitos em Transformadores de Potência por Meio de um Sistema Piezelétrico de Detecção de Descargas Parciais.** In: The XI Latin-American Congress Electricity Generation and Transmission - CLAGTEE, São José dos Campos, 2015.
- Castro, B. A.; Clerice, G. A. M.; Ulson, J. A. C.; Baptista, F. G.; Flauzino, R. A. **Monitoramento de Ondas Acústicas Geradas por Descargas Parciais em Óleo Isolante Mineral de Transformadores de Potência Por Meio de Sensores Piezoelétricos de Baixo Custo.** In: XXI Congresso Internacional de Engenharia Eletrônica, Elétrica e Computação - IEEE, Arequipa, Peru, 2014.
- Castro, B. A.; Clerice, G. A. M.; Ulson, J. A. C.; Baptista, F. G.; Andreoli, A. L.; Campos, F. S. **Localização de Danos em Estruturas Metálicas pelo Método da Emissão Acústica, Análise Wavelet e Sensores Piezelétricos de Baixo Custo.** In: IEEE/IAS International Conference on Industry Applications - INDUSCON, Juiz de Fora, 2014.
- Clerice, G. A. M.; Castro, B. A.; Ulson, J. A. C.; Andreoli, A. L.; Campos, F. S. **Caracterização da Sensibilidade dos Sensores Piezoelétricos do Sistema PZT para Identificação de Descarga Parcial em Transformadores.** In: XXI Congresso Internacional de Engenharia Eletrônica, Elétrica e Computação - IEEE, Arequipa, Peru, 2014.
- Clerice, G. A. M.; Castro, B. A.; Ulson, J. A. C.; Andreoli, A. L.; Campos, F. S.; Riehl, R. R. **Identificação de Descargas Parciais em Transformadores de Potência por Meio de Cápsulas Piezoelétricas de Baixo Custo.** In: IEEE/IAS

International Conference on Industry Applications - INDUSCON, Juiz de Fora, 2014.

1.5.2. Capítulo de Livro Internacional Publicado

- Campos, F. S.; Ulson, J. A. C.; Castanho, J. E. C.; Castro, B. A.; Riehl, R.R. **A New FPN Cancellation Circuit for Time-Domain CMOS Image Sensors.** Optoelectronics - Materials and Devices. 1ed.: InTech, 2015, p. 381-395.

1.5.3. Trabalho completo publicado em anais de congresso nacional

- Castro, B. A.; Clerice, G. A. M.; Ulson, J. A. C.; Andreoli, A. L.; Baptista, F. G.; Campos, F. S.; Aguiar, P. R. **Localização de danos em barras de alumínio, pelo método da emissão acústica, análise de energia do sinal e sensores piezelétricos de baixo custo.** In: COBEF - Congresso Brasileiro de Engenharia de Fabricação, Salvador, 2015.

CAPÍTULO 2- DESCARGAS PARCIAIS EM TRANSFORMADORES DE POTÊNCIA

Este capítulo apresenta os aspectos gerais das descargas parciais em transformadores, fazendo uma abordagem dos modelos consolidados que regem este fenômeno e também apresenta os métodos mais comuns de detecção de DPs.

2.1. Introdução

Os transformadores de potência são dispositivos elétricos empregados para elevar ou rebaixar tensões elétricas, sendo responsáveis, também, pela transferência de energia e pela alteração da impedância de um sistema elétrico. Tendo em vista estes aspectos, o diagnóstico do estado e das condições operacionais dos transformadores de potência é de fundamental importância para se ter um alto grau de confiabilidade do sistema elétrico.

Alguns fatores críticos na operação dos transformadores de potência podem diminuir a vida útil destes dispositivos. Um estudo realizado por Bartley (2003), propôs uma análise e classificação destes fatores, que podem ser de origem elétrica, ambiental ou mesmo intrínseco aos componentes deste dispositivo. São eles:

- Descargas atmosféricas;
- Sobrecarga;
- Sobreensões em linhas, advindas dos chaveamentos e curtos-circuitos, entre outras anormalidades da linha de transmissão;
- Falhas na Isolação por oxidação, acidez, umidade, pirolise;
- Contaminação do óleo: situações em que o óleo fica carbonizado ou perde suas características físico-químicas;
- Operações inadequadas e manutenções impróprias, resultando no acúmulo de sujeira, umidade, ninhos de pássaros e insetos, corrosões e perdas de conexão às carcaças dos transformadores;
- Fogo externo: com o superaquecimento do transformador pode ocorrer falha interna nos dispositivos;
- Erros de projeto;

- Umidade presente nos transformadores devido a falhas de vedação dos anéis ou outros orifícios, resultantes de corrosão ou vandalismo.

Em se tratando especificamente dos componentes que constituem a isolação elétrica dos transformadores, como o óleo mineral, a porcelana, o papel composto de celulose, os vernizes, estes têm como função minimizar o fluxo de corrente entre dois condutores submetidos a uma diferença de potencial e devem ser estáveis quimicamente na ocorrência de transitórios elétricos. Além disso, alguns materiais, como o caso do óleo isolante, atuam também na transferência de calor do dispositivo. Contudo, a ocorrência de fatores críticos na operação dos transformadores, como citados anteriormente, podem ocasionar a perda das propriedades físico-químicas nos materiais que compõe o isolamento elétrico do transformador e, assim, o funcionamento adequado deste dispositivo fica comprometido (CLERICE, 2014).

Segundo Hauschild e Lemke (2014), as descargas parciais são consequências de imperfeições ou não conformidades nos materiais que compõe a isolação do transformador. Um exemplo disso são os gases dissolvidos nos materiais isolantes sejam eles sólido ou líquido ou materiais deteriorados. Estas não conformidades, que se caracterizam pela discrepância da composição físico-químico original do material, geralmente são inerentes ao processo de fabricação ou mesmo gerados através da degradação e contaminação do isolamento pelas características de funcionamento ou pelo próprio ambiente como citado por Bartley (2003).

Pode-se concluir que a incidência de DPs está correlacionada ao estado do isolamento elétrico dos transformadores de potência pois, além disso, as descargas parciais causam a deterioração do material isolante por ação de transformações químicas (KUFFEL; ZAENGL; KUFFEL, 2000). Observa-se, ao longo do tempo, que os materiais isolantes submetidos a descargas parciais são carbonizados, o que leva a redução da resistência de isolamento, aumentando a corrente de fuga destes dielétricos (VELOSO, 2006).

Mediante a estas características, o estudo deste fenômeno ganhou grande importância, surgindo, deste modo, alguns modelos que explicam de forma física e matemática este fenômeno, bem como as técnicas de identificação deste tipo de falha.

2.2. Definições e Tipos de Descargas Parciais

Segundo a norma IEC-60270 (2011) a descarga parcial é definida como uma descarga elétrica que preenche parcialmente o isolamento entre dois condutores. Tem característica impulsiva com duração menor que $1\mu s$, e podem surgir quando cargas elétricas se formam em decorrência da diferença de potencial elétrico em bolhas de gases, trincas, materiais isolantes degradados, resultando em um canal ionizado incompleto com o surgimento de elétrons livres (WANG et al, 2006). Sendo assim, fenômeno em questão fornece uma perturbação semelhante a uma explosão que emite calor, luz, radiação eletromagnética e ondas de ultrassom que se propagam em todas as direções da fonte de descarga (VELOSO, 2006; SARATHI; SINGH; DANIKAS, 2007; CLERICE, 2014).

Segundo Mason (1995), as descargas parciais podem ser classificadas de acordo com sua origem: superficial, externa e interna.

Segundo Gutnik (2014), as descargas superficiais ocorrem em líquidos, gases e em materiais dielétricos. Geralmente esta descarga parte de um eletrodo (fonte de tensão) para a superfície do material isolante. Para que esta DP ocorra o campo elétrico tangente à superfície deve exceder o valor limite de isolação do material (GULSK, 1995). O fenômeno, além de causar alterações superficiais, pode formar trilhas condutoras que levam à ruptura completa deste material (MASON, 1995; GUTNIK, 2014).

As descargas parciais externas são referenciadas, geralmente, como “descargas corona”. São comuns em eletrodos dotados de pontas ou que possuem pequenas curvaturas em suas terminações, onde há concentração de campo elétrico. Uma vez que a rigidez dielétrica do ar é superada, a descarga se inicia. O fator primordial para a degradação das propriedades isolantes é que este tipo de descarga produz o gás ozônio, que pode causar fissuras nas isolações poliméricas (GUTNIK, 2014). No mais, a formação de óxidos de nitrogênio, formados a partir deste fenômeno, quando em contato com a água, corroem os metais e podem formar depósitos de condutores na superfície de um dielétrico, provocando o trilhamento do isolador (GUTNIK, 2014).

As descargas parciais internas, estudadas por este trabalho, ocorrem devido a imperfeições observadas dentro dos materiais que compõe a isolação de um dispositivo. É muito comum o surgimento de bolhas de gases na estrutura de um sólido

ou líquido, tanto devido a própria manufatura do material, que por algum motivo possibilita a infiltração de um gás (como o próprio ar) no material, quanto devido a estresses químicos que contribuem para o aparecimento de vacúolos gasosos (GJAERDE, 1997; GUTNIK, 2014). Nos isolantes líquidos, como no óleo mineral, bolhas de gases surgem com frequência devido a vapor d'água presente no ar infiltrado por aberturas estreitas e folgas nas vedações do transformador, devido também a fenômenos físico-químicos e elétricos que liberam gases no material isolante (GUTNIK, 2014).


No caso específico dos transformadores de potência, Boczar (2009), realizou um estudo que definiu múltiplas formas de ocorrência de DPs nos componentes de isolamento deste dispositivo elétrico:

- Descargas parciais ponto a ponto em óleo isolante: relacionadas a defeitos de isolamento entre duas espiras adjacentes do enrolamento de um transformador;
- DPs ponto a ponto em óleo isolante com bolhas: este tipo de falha também é causada por DP entre duas espiras adjacentes do enrolamento, mas a condição de degradação do isolamento permite a formação de bolhas de gás;
- Ponto de plano em óleo isolante: defeitos no sistema de isolamento do enrolamento causam descargas parciais entre as partes ligadas à terra do tanque do transformador;
- Descargas de superfície entre dois eletrodos: é o tipo mais comum de DP, que ocorre entre dois eletrodos isolados com papel-óleo chamado ponto triplo, onde a superfície do eletrodo está em contato com dielétricos sólidos e líquidos;
- DPs de superfície entre um eletrodo e um eletrodo multiponto: as DPs relativas a estes elementos são diferentes da anterior no que condiz à distribuição da intensidade do campo elétrico. Ambos os eletrodos são isolados com papel-óleo;
- Múltiplas descargas no plano: vários pontos danificados no isolamento do enrolamento podem causar DP entre eles e as partes aterradas do tanque;
- Várias descargas no plano com bolhas de gás: a DP, neste caso, ocorre em vários pontos danificados no isolamento dos enrolamentos e as partes aterradas do tanque do transformador, mas na presença de gases em óleo;

- Descargas provocadas por partículas: neste caso, o óleo isolante está contaminado com partículas de fibras de celulose formada pelo processo de degradação do isolamento de papel no óleo, devido ao envelhecimento do transformador de potência. Tais partículas estão em movimento constante do óleo, provocando as descargas.

As múltiplas formas de ocorrência de DP, apresentam, portanto, em todos os tipos de materiais, sendo eles sólidos, líquidos ou em gases. Três fotografias da ocorrência de DP no ar, óleo isolante, como também no acrílico, são apresentadas na Figura 2.1, respectivamente, da esquerda para direita.

Figura 2.1- Fotografia dos canais de DPs em ar (a), óleo (b) e acrílico (c).



(Fonte: HAUSCHILD e LEMKE, 2014)

2.3. Modelos de Descargas Parciais em Tensão Alternada


Segundo Gutnik (2014), existem dois principais modelos que caracterizam as descargas parciais, apresentando uma interpretação de forma física e matemática para o fenômeno: o modelo do circuito equivalente e o de aproximação por campo.

2.3.1. O Modelo do Circuito Equivalente

Nesta abordagem, o fenômeno de descargas parciais pode ser descrito por um circuito equivalente, tradicionalmente conhecido como o “*modelo abc*”. Um esquema ilustrativo deste modelo é apresentado na Figura 2.2 que apresenta um material dielétrico, seja ele um fluido ou um sólido, com uma não conformidade, chamada

também de cavidade, que pode representar uma bolha de gás, uma descontinuidade ou mesmo uma degradação físico-química no isolante.

Figura 2.2- (a) Caracterização da Descarga Parcial em uma cavidade não conforme de material dielétrico. (b) Circuito equivalente.



(Fonte: KUFFEL; ZAENGL; KUFFEL, 2000)

Para o modelo, o material é submetido a uma tensão alternada através de um eletrodo representado pelos pontos “A” e “B” e a distribuição de campo elétrico neste sistema é representada pelas capacitâncias C_a , C_b e C_c . Estas capacitâncias representam, respectivamente, a capacitância do material em perfeito estado (C_a), a capacitância entre o eletrodo e as paredes de uma não conformidade no material (C_b) e a capacitância da cavidade (C_c). As nomenclaturas C'_a , C''_a , C'_b e C''_b representam as capacitâncias geradas pela dualidade geométrica do material, respectivamente, à esquerda e à direita da cavidade, para o material puro, como também acima e abaixo da não conformidade em relação aos eletrodos (KUFFEL; ZAENGL; KUFFEL, 2000).

Sendo assim, quando a tensão aplicada à cavidade cresce, e a descarga ocorre, sua superfície é ionizada e forma dipolos no material. Deste modo, o gradiente de campo elétrico na cavidade aumenta, podendo ser acentuado devido à geometria da cavidade (pontas, quinas, rugosidades) ou mesmo pela permissividade do material. Este efeito físico reduz significativamente a tensão na cavidade causando, então, para o modelo descrito, a descarga do capacitor C_c .

Após a descarga ter ocorrido, se a tensão aplicada continuar em crescimento, tanto no ciclo positivo ou negativo, novas linhas de campo serão formadas, possibilitando que o fenômeno ocorra novamente (GUTNIK, 2014). Pelo fato da ocorrência das descargas parciais necessitarem de um aumento de campo elétrico, este fenômeno ocorre, predominantemente, no primeiro e no terceiro quarto de ciclos de tensão, conforme Figura 2.3 (VELOSO, 2006). O circuito da Figura 2.2b representa a modelagem física do fenômeno. A chave S é controlada pela tensão V_c , que está

sobre o capacitor da cavidade. Quando a chave é fechada a corrente $i_c(t)$ passa a existir em um curto período de tempo na malha do resistor R_c , que simula o período de tempo durante o qual a descarga ocorre e é finalizada (KUFFEL; ZAENGL; KUFFEL, 2000; GUTNIK, 2014). Antes da descarga parcial ocorrer, a tensão através da cavidade é expressa pela Equação 2.1, supondo que C_a esteja carregado por uma tensão V_s :

$$V_s = V_c \frac{C_b}{C_a + C_b} \quad (2.1)$$


Quando a DP ocorre, tomando como um curto-circuito em C_c , a carga transferida ao material da cavidade é representada pela equação 2.2:

$$q = (C_a + C_b).V_s = C_b.V_c \quad (2.2)$$

Sendo assim, a carga q , por definição da norma IEC 60270 (2011), é aquela que, se injetada em um curto período de tempo entre os terminais de um material, expressa um evento que se assemelha a uma um pulso de descarga parcial no mesmo material. Esta carga aparente é a medida que consegue quantificar uma DP.

Conforme análise do circuito da Figura 2.2b, quando a tensão V_c no interior da cavidade atinge a tensão de início da DP, representado pelo fechamento da chave,

Figura 2.3- Ocorrência de pulsos de descargas parciais no ciclo de tensão.



(Fonte: VELOSO, 2006)

uma descarga ocorre na cavidade e a tensão elétrica na cavidade cai (GUTNIK, 2014).

Quando a descarga cessa, pela abertura da chave, a tensão na cavidade torna a aumentar. Esta tensão é a superposição do campo elétrico aplicado e o campo residual formado pelas cargas superficiais que foram deixadas na parede da cavidade depois da última descarga (BARTNIKAS; McMAHON, 1979; KREUGER, 1989; GUTNIK, 2014).

Segundo Gutnik (2014), é importante realçar que este modelo não considera fatores como a geometria, localização da cavidade ou mesmo presença de cargas espaciais. Portanto, a gama de processos físicos que se desenvolvem no sistema real não são considerados (KELEN; DANIKAS, 1995; McALLISTER, 1997; PEDERSEN; CRICHTON, McALLISTER, 1991).

2.3.2. O Modelo por Aproximação de Campo

Nesta abordagem, o fenômeno de descargas é tratado com um modelo qualitativo que melhor explica os fenômenos que regem a DP em tensão alternada (BOGGS, 1990; EDIN, 2001, GUTNIK, 2014). Este modelo considera uma cavidade esférica dentro de um material dielétrico, e uma tensão alternada é aplicada sobre o material por meio de um eletrodo. Antes da ocorrência da primeira descarga, considera-se que o campo elétrico na cavidade é aproximadamente uniforme e varia proporcionalmente à tensão aplicada.

Quando a primeira descarga ocorre, cargas elétricas são liberadas e depositadas na parede da cavidade do material. Sendo assim, o campo elétrico passa a ser a superposição do campo gerado pela tensão alternada e pelas cargas agora presentes na superfície do material (BOGGS, 1990; EDIN, 2001, GUTNIK, 2014). Por conseguinte, quando esta associação de campos for superior ao campo de início, ocorrerá novamente a descarga parcial. Para este modelo, o processo de formação de uma DP pode ocorrer quando a tensão aplicada ao eletrodo for nula, pois depende somente do campo interno à cavidade, não mais pela tensão aplicada como no modelo anterior (BOGGS, 1990; EDIN, 2001, GUTNIK, 2014).

De acordo com Morshuis (1995), sendo satisfeitas as condições para a ocorrência da descarga parcial, apresentando cargas elétricas no interior da cavidade, duas condições mutuamente exclusivas determinam as características do modelo qualitativo das DPs. O primeiro se refere à ionização do gás na cavidade, que reforça

o campo interno por meio do acúmulo de cargas. A segunda característica leva em conta a corrente de deslocamento fluindo externamente, fazendo com que o campo na cavidade seja reduzido (GUTNIK, 2014).

Bartinikas e McMahon (1979) assim como Morshuis (1995) fizeram um estudo referente às descargas parciais em gases, muito comum em transformadores de potência quando se leva em conta a oxidação do material isolante e a liberação de gases no óleo mineral do transformador. Estes autores compararam os mecanismos de DPs para eletrodos metálicos e ocorridas em cavidade fechadas e denominaram dois tipos: o avalanche (*Townsend*) e o canal (*Streamer*). A descarga do tipo “avalanche”, consiste em uma avalanche autossustentada com sucessores iniciadas no catodo e tem sua magnitude aumentando linearmente com a sobretensão, independente da cavidade. Já a DP tipo “canal”, consiste em avalanches sucessivas no próprio gás presente em uma cavidade, a partir de fótons de alta energia. Sua magnitude é independente ao aumento da sobretensão mas sensível ao aumento do tamanho da cavidade. Para sobretensões elevadas, em torno de 5%, o processo de ionização gasosa reforça o campo na cavidade e o mecanismo dominante é do tipo “canal”. Já para sobretensões em torno de 1%, ocorre o efeito da construção da carga espacial é superado pela corrente de condução e o mecanismo dominante é do tipo “avalanche” (BARTINIKAS; McMAHON, 1979; DEVINS, 1984; DISSADO; FOTHERGILL, 1992; GUTNIK, 2014).


2.4. Métodos de Detecção de Descargas Parciais em Transformadores

Como mencionado, a ocorrência de descargas parciais está intimamente ligada a condições do isolamento do transformador de potência. Sendo assim, o monitoramento deste fenômeno torna-se imprescindível para a garantia do funcionamento adequado do transformador. Na literatura alguns métodos de detecção de DPs são consolidados e possuem suas características particulares. Pode-se citar o método elétrico, eletromagnético, optico, químico e acústico, abordados neste trabalho.

2.4.1. O Método Elétrico de Identificação de DPs


O método elétrico de identificação de DPs tem como base a detecção do movimento de cargas em um circuito elétrico que altera a impedância de medição Z_m . Os circuitos elétricos apresentados pelas Figuras 2.4, 2.5 e 2.6 são encontrados na norma IEC 60270 (2011).

Figura 2.4- Impedância de medição Z_m em série com o capacitor de acoplamento C_k .




(Fonte: GUTNIK, 2014)

Figura 2.5- Impedância de medição Z_m em série com o objeto de teste C_a .



(Fonte: GUTNIK, 2014)

Figura 2.6- Ponte balanceada utilizando o braço (C_{a2} e Z_{m2}) como referência em paralelo com o braço de teste (C_{a1} e Z_{m1}).



(Fonte: GUTNIK, 2014)

A ideia principal deste método é medir a queda de tensão causada pelo impulso de corrente gerada pela descarga parcial. Tem-se então os capacitores C_a , representando a capacitância do objeto de teste, C_k , o capacitor de acoplamento, cuja função é dar o caminho de retorno aos pulsos transientes de alta frequência gerados pelas descargas parciais e bloquear as tensões nas frequências industriais para o circuito de medição. Z_m , representa a impedância de medição, pela qual se dará a queda de tensão gerada pelo fenômeno de DP. Tem-se um circuito RLC composto por um resistor de medição, uma indutância na ordem de mH e uma capacitância parasita inerente ao circuito. Já Z_n é denominado como filtro de ruído de medição e tem a função de bloquear ruídos oriundos do lado de alta tensão do transformador de teste. M_i representa o instrumento de medição (GUTNIK, 2014).


A primeira configuração, representada pelo circuito da Figura 2.4, tem a impedância de medição em série com o capacitor de acoplamento, e o objeto de teste tem uma de suas extremidades aterradas. Deste modo, o equipamento é protegido de falhas provenientes do objeto em ensaio. Para ensaios em transformadores, esta configuração é a mais utilizada (GUTNIK, 2014).

Para a configuração vista pelo circuito da Figura 2.5, o objeto de teste se encontra em série com a impedância de medição da descarga, fazendo com que a sensibilidade na detecção de DPs aumente significativamente. O caminho de retorno dos transientes de alta frequência é dado pelo capacitor de acoplamento. Todavia, este circuito emprega uma interrupção da conexão do lado de alta tensão com o terra, exigindo que o lado de baixa tensão tenha o terra isolado também (GUTNIK, 2014).

Para a configuração da Figura 2.6, a forma de medição é em ponte equilibrada, cuja função é eliminar ruídos eletromagnéticos que perturbem as medidas de DPs. Nesta configuração o capacitor de acoplamento não é utilizado. Com o ajuste das impedâncias de medição Z_{m1} e Z_{m2} , a ponte pode ser balanceada de forma que os ruídos de modo comum possam ser eliminados eficazmente por meio de um circuito amplificador em modo diferencial. A ponte deve ser construída com a maior simetria possível.

A Figura 2.7 ilustra a aplicação do circuito da Figura 2.4 na identificação de DPs em transformadores de potência. Nesta configuração, a capacitância da alta tensão C_1 é equivalente ao capacitor de acoplamento C_k e a impedância de medição, como parte do dispositivo de acoplamento D_c , é conectada ao tap de uma bucha capacitiva

Figura 2.7- Modo de acoplamento via tap capacitivo.



(Fonte: LEMKE, 2008)

(B_t) graduada. C_2 representa a capacitância da baixa tensão, T_r o transformador sob teste e M_c o cabo de medição (GUTNIK, 2014; LEMKE, 2008).

Segundo Clerice (2014), a vantagem do método elétrico de medição de DP é de ser caracterizado de forma bem definida, padronizados e com grande disponibilidade de equipamentos no mercado. Todavia, não são adequados para a localização exata do ponto de descarga parcial nos transformadores de potência e são sensíveis a interferências eletromagnéticas, além de colocar operadores diretamente em manipulação com o lado de alta tensão dos dispositivos.

2.4.2. O Método Eletromagnético de Identificação de DPs

Os pulsos de descargas parciais produzem ondas eletromagnéticas em altas frequências que podem chegar na faixa de GHz. Para o método de detecção de descargas parciais por UHF, que pode variar de 300MHz a 3GHz, sensores capacitivos, similares a antenas, são acoplados na parede de aço do transformador de forma a se ter acesso a sua parte interna, e são utilizados para captar estes sinais eletromagnéticos gerados pelo fenômeno de DP. Em alguns casos o sensor é acoplado internamente ao transformador (GUTNIK, 2014). A Figura 2.8 ilustra um sensor UHF utilizado para a identificação de descargas parciais. Em Markalous et al (2008), este método também é utilizado para localização de DPs em transformadores

Figura 2.8- Sensor UHF utilizado para detectar DPs.



(Fonte: MARKALOUS, 2006)

tomando como base a triangulação de sinais de UHF. Este método de localização será abordado no próximo capítulo deste trabalho.

2.4.3. O Método Óptico de Identificação de DPs

Os pulsos de descargas parciais produzem radiação na faixa do ultravioleta e, deste modo, receptores de sinais nestes espectros podem ser utilizados para a detecção óptica do fenômeno (CLERICE, 2014). No entanto, esse método, muito empregado na identificação de descargas em linhas aéreas, necessitam de um contato visual direto com a fonte emissora de luz, que, no caso, é a própria DP. Por conseguinte, se a fonte emissora de luz está oculta atrás de algum aparato, a medição fica prejudicada. Também, a atenuação e dispersão provocadas pela distância dos materiais isolantes até a fonte tem mostrado grande influência na detecção de descargas (GUTNIK, 2014).

Para os gases isolantes a baixa pressão, apenas 1% da energia liberada por uma descarga parcial é convertida em luz. Para os isolantes sólidos e líquidos essa taxa ainda é menor segundo Forsyth (1998). As emissões de luz em óleo são predominantemente formadas através de hidrocarbonetos e hidrogênio, de modo que a região espectral fica em torno de 350 e 700nm (SCHWARZ; JUDENDORFER, 2008; GUTNIK, 2014). Segundo Clerice (2014), a grande vantagem da medição óptica é que se caracteriza por ser isolada galvanicamente e não há influência eletromagnética nas medições e, portanto, o aparato fica livre de sinais indesejados. Todavia, por ser um

método invasivo, isto é, acoplado internamente ao sistema que se deseja medir a descarga parcial, possui a desvantagem de acessibilidade a locais do dispositivo estudado e área de cobertura limitada (SCHWARZ; JUDENDORFER, 2008).

2.4.4. O Método Químico de Identificação de DPs

O processo de degradação dos materiais isolantes libera substâncias decorrentes de reações químicas e alteram as características do material isolante. Sendo assim, um grande indicativo da deterioração dos componentes de isolamento de um transformador é a análise química do óleo mineral que se encontra em contato direto com todos os componentes internos do dispositivo. Há diversos tipos de métodos químicos de identificação de falhas em transformadores. Pode-se citar o Método do Gás Chave, Método de Dornenburg, Método de Duval, Método de Rogers. Todos estes métodos se valem do princípio de que, por meio da presença e da concentração de algumas substâncias conhecidas no óleo mineral do transformador, pode-se identificar os tipos de problemas em transformadores (GUTNIK, 2014). Sendo assim, o método químico de identificação de descargas parciais, que consiste na análise cromatográfica do óleo isolante de um transformador, é um dos métodos mais tradicionais em empresas que prestam manutenção nestes dispositivos elétricos (CLERICE, 2014). A causa primordial é a desintegração de moléculas do material isolante e a consequente formação de gases, é devido a fenômenos físicos e elétricos como o superaquecimento, formação de arco elétrico, descargas parciais, dentre outros. Por exemplo, no que condiz ao óleo isolante, durante sua decomposição são liberados gases como o hidrogênio (H_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4), acetileno (C_2H_2). Já quando há degradação de materiais celulósicos, gases como o monóxido e o dióxido de carbono são dissolvidos no óleo mineral (AZEVEDO, 2009). Sendo assim, é possível inferir o tipo de material danificado através desta análise. No mais, os tipos de gases, bem como suas concentrações, estão intimamente relacionados com a energia envolvida na falha.

O método do gás chave baseia-se no fato que, quando há uma falha em um transformador, as concentrações dos gases associadas a esta falha ultrapassarão os valores normais de degradação (COSTA, 2015). O perfil deste método é apresentado na Tabela 2.1.

Tabela 2.1- Representação das anormalidades e os gases chaves

Anormalidades	Gás Chave
Óleos superaquecidos	Etileno
Celulose superaquecida	Monóxido de Carbono
Descargas Parciais	Hidrogênio
Arco Elétrico	Acetileno

(Fonte: CLERICE, 2014)

O método de Dornenburg e o método de Rogers são formas empíricas de identificação de falhas em transformadores e baseia-se no valor quantitativo da concentração de gases dissolvidos no óleo isolante (ROGERS, 1975; DORNENBURG; GERBER, 1967). A Tabela 2.2 sintetiza o método de Dornenburg e a Tabela 2.3 sintetiza o Método de Rogers (COSTA, 2015).

Tabela 2.2- Identificação de falhas através do método de Dornenburg

Tipos de Falha	Presença de Gases em Concentração Percentual			
	CH₄/H₂	C₂H₂/C₂H₄	C₂H₆/C₂H₂	C₂H₂/CH₄
Decomposição Térmica	>1,0	<0,75	>0,4	<0,3
Descargas Parciais	>0,1 e <1,0	>0,75	<0,4	>0,3
Corona	<0,1	Insignificante	>0,4	<0,3

(Fonte: COSTA, 2015)

O método proposto por Duval (2002) leva em conta apenas a concentração dos gases acetileno, etano e metano para identificar o tipo de falha no transformador. A Figura 2.9 ilustra o critério, na qual um triângulo correlaciona a concentração gasosa com o tipo de falha (CLERICE, 2014).

Cada código, apresentado no triângulo e descrito abaixo, representa uma condição de falha:

PD: descargas parciais;

T1: falha térmica com temperatura $T < 300^{\circ}\text{C}$;

T2: falha térmica com temperatura $300^{\circ}\text{C} < T < 700^{\circ}\text{C}$;

T3: falha térmica com temperatura $T > 700^{\circ}\text{C}$;

D1: descargas de baixa energia;


D2: descargas de alta energia;

DT: mistura de falhas.

Tabela 2.3- Identificação de falhas através do método de Rogers

Tipos de Falha	Presença de Gases em Concentração Percentual			
	CH_4/H_2	$\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$	$\text{C}_2\text{H}_6/\text{C}_2\text{H}_2$	$\text{C}_2\text{H}_2/\text{CH}_4$
Normal	>0,1 e <1,0	<1,0	<1,0	<0,5
Descargas Parciais tipo Corona	$\leq 0,1$	<1,0	<1,0	<0,5
Descargas Parciais com Trilhamento	$\leq 0,1$	<1,0	<1,0	$\geq 0,5$ <3,0 ou $\geq 3,0$
Descarga Contínua	>0,1 e <1,0	<1,0	$\geq 3,0$	$\geq 3,0$
Arco Elétrico com Grande Dissipação de Energia	>0,1 e <1,0	<1,0	$\geq 1,0$ <3,0 ou $\geq 3,0$	$\geq 0,5$ <3,0 ou $\geq 3,0$
Arco Elétrico com Baixa Dissipação de Energia	>0,1 e <1,0	<1,0	<1,0	$\geq 0,5$ <3,0
Superaquecimento para 150°C	$\geq 1,0$ <3,0 ou $\geq 3,0$	<1,0	<1,0	<0,5
Superaquecimento para 150-200°C	$\geq 1,0$ <3,0 ou $\geq 3,0$	$\geq 1,0$	<1,0	<0,5
Superaquecimento para 200-300°C	>0,1 e <1,0	$\geq 1,0$	<1,0	<0,5
Aquecimento dos condutores dos enrolamentos	>0,1 e <1,0	<1,0	$\geq 1,0$ <3,0	<0,5
Circulação de Corrente Elétrica no Núcleo ou Tanque	$\geq 1,0$ e <3,0	< 1,0	$\geq 3,0$	< 0,5

(Fonte: COSTA, 2015)

Figura 2.9- Triângulo de Duval

(Fonte: DUVAL, 2002)

Como visto, o método químico tem grande aplicação e eficácia na identificação de DPs. No entanto, a análise cromatográfica tem caráter comparativo, ou seja, verifica a evolução das substâncias químicas presentes no óleo mineral do transformador e, além de não ser possível mensurar a carga aparente de uma descarga parcial, também não existe a possibilidade de localização exata da fonte de DP.

2.4.5. O Método Acústico de Identificação de DPs

A técnica de análise de descargas parciais em transformadores de potência por emissão acústica (EA) toma como base a detecção destas ondas de ultrassom emitidas através do emprego de sensores fixados na parede externa de aço do dispositivo.

Conforme discutido anteriormente, o fenômeno da descarga parcial se caracteriza por uma perturbação no meio material de um isolante gerada por uma descarga elétrica, semelhante a uma centelha, que preenche parcialmente um material isolante entre dois condutores (VELOSO, 2006). Este fenômeno fornece ao meio material uma perturbação caracterizada 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. Devido às características desta perturbação os métodos elétrico, eletromagnético, óptico e químico foram elaborados. Como o

fenômeno de DP também gera ondas de ultrassom, que se propagam pelo material isolante, a literatura também apresenta a técnica de identificação de descargas por meio do emprego de sensores de emissão acústica. De acordo com Veloso (2006), esta técnica é um método não destrutivo de monitoramento de equipamentos e permite diagnósticos precisos sobre a medição de descargas parciais e será discutida com profundidade no Capítulo 3.

CAPÍTULO 3- O MÉTODO DE EMISSÃO ACÚSTICA E A IDENTIFICAÇÃO E LOCALIZAÇÃO DE DESCARGAS PARCIAIS

Este capítulo aborda os conceitos gerais de acústica aplicados ao método de detecção e localização de descargas parciais, como também mostra as técnicas de processamento de sinais de EA gerados por DPs que serão utilizadas neste trabalho.

3.1. Introdução

A técnica da emissão acústica é um método não-destrutivo de monitoramento de equipamentos, estruturas e processos. Permite obter com precisão um diagnóstico de falhas em diversos tipos de equipamentos elétricos como também em estruturas (VELOSO, 2006).

No que condiz ao fenômeno de descargas parciais em transformadores imersos a óleo isolante, quando este fenômeno ocorre, uma energia é liberada na região e o fluido isolante é bruscamente vaporizado, resultando em ondas mecânicas que se propagam em todas as direções do tanque do transformador (CLERICE, 2014). Estas ondas percorrem toda estrutura do transformador, sofrendo reflexões e refrações, podendo então ser detectadas externamente na parede de aço do dispositivo elétrico através de sensores piezelétricos. Também, ao se propagarem por diferentes meios, produzem um sinal acústico que reflete as características intrínsecas a este meio. Sendo assim, o conhecimento das características de propagação da onda acústica bem como a geometria do transformador, é de fundamental importância para o desenvolvimento de métodos de localização da fonte de DP (VELOSO, 2006).

3.2. Conceitos Básicos de Acústica

Como esta pesquisa visa a localização de descargas parciais em transformadores imersos em óleo mineral pelo método da emissão acústica, alguns conceitos são necessários para dar o entendimento da complexidade do problema em questão. Esta seção fornece uma explicação das características das ondas acústicas ilustrando os modos de propagação, fenômenos de reflexão, refração e atenuação, dentre outras características.

3.2.1. Ondas e Modos de Propagação

O som se propaga por um meio físico através de um movimento ondulatório, isto é, através de uma propagação de um distúrbio através do meio material. Segundo Veloso (2006), as ondas sonoras podem se propagar em quatro modos principais que se traduzem no comportamento oscilatório das partículas de um material. Assim, o som pode se propagar como ondas longitudinais, transversais, ondas de superfície e ondas de plate. Nas ondas longitudinais as oscilações ocorrem na direção de propagação da onda; nas transversais, as oscilações ocorrem na direção perpendicular à direção de propagação da onda; as ondas de superfície as partículas descrevem movimento oscilatório com orbital elíptico; já nas ondas plate, as partículas oscilam perpendicularmente à direção de propagação em chapas muito finas e podem ser do tipo Lamb (movimento perpendicular à superfície) ou do tipo Love (movimento paralelo ao plano de superfície). Nos líquidos, como o óleo isolante, apenas as ondas longitudinais são possíveis (VELOSO, 2006).

3.2.2. Impedância Acústica

Por definição a impedância acústica específica de um meio material é a razão entre a pressão sonora e a velocidade da partícula que sofre o distúrbio que se propaga. É importante na determinação da transmissão e reflexão da onda acústica numa interface entre dois materiais como também na absorção de energia acústica pelo meio (VELOSO, 2006). Sua relação é dada pela Equação 3.1:

$$Z = \rho_0 \cdot c \quad (3.1)$$

Sendo:

c é a velocidade do som no meio;

ρ_0 é a densidade definida pela relação $\rho = m/V$, sendo m a massa e V o volume do material pela qual a onda se propaga.

3.2.3. Reflexão e Refração

De acordo com Veloso (2006), ao se propagar de um meio para um outro cuja densidade difere do meio de origem da onda, ocorrerá a reflexão e a refração, resultando em uma redução de energia da onda transmitida. Sendo assim, quanto maior a diferença entre as impedâncias acústicas, menor será a intensidade da onda transmitida conforme mostra a Equação 3.2:

$$\alpha_t = \frac{I_t}{I_i} = \frac{4Z_1Z_2}{(Z_1 + Z_2)^2} \quad (3.2)$$

Sendo:

α_t é o coeficiente de transmissão;

Z_1 e Z_2 são as impedâncias acústicas de dois meios considerados (meio 1 e meio de propagação 2);

I_t é a intensidade da onda transmitida;

I_i é a intensidade da onda propagada;

Observa-se que o fenômeno de refração, regida pela *Lei de Snell*, altera o ângulo da onda transmitida como também sua velocidade, conforme Equação 3.3:

$$\frac{\sin(\varphi_t)}{c_t} = \frac{\sin(\varphi_i)}{c_i} \quad (3.3)$$

Sendo:

φ_t é o ângulo de incidência da onda transmitida;

φ_i é o ângulo de incidência da onda refratada para outro meio;

c_t é a velocidade de propagação da onda transmitida;

c_i é a velocidade de propagação da onda propagada.

A análise destes fenômenos permite a conclusão de que quando uma frente de onda acústica, cuja origem é uma descarga parcial, atravessa meios diferentes em um transformador, como por exemplo o óleo e o núcleo de aço, tanto a velocidade de propagação e o ângulo de frente são alterados, dificultando assim o equacionamento da distância, velocidade e tempo de propagação da onda em questão.

3.2.4. A Velocidade do Som em Meios Materiais

Segundo Clerice (2014), a velocidade do som depende do meio onde ocorre a propagação e de suas características, ou seja, se o meio é gasoso, líquido ou sólido. A velocidade de som no meio gasoso é definida na Equação (3.4):

$$V_g = \sqrt{\frac{\gamma P}{\rho}} \quad (3.4)$$

Sendo:

V_g é a velocidade do som do meio gasoso;

γ é razão do calor específico;

P é a pressão do gás;

ρ é a densidade definida pela relação $\rho=m/V$, sendo m a massa e V o volume do material.

A Equação 3.5 é para líquidos incompressíveis e a Equação 3.6 é para líquidos compressíveis (CLERICE, 2014).

$$V_l = \sqrt{\frac{\gamma P}{\rho}} \quad (3.5)$$

$$V_{lc} = \sqrt{\frac{\gamma K}{\rho}} \quad (3.6)$$

Sendo que K é a constante de volume de gás. A velocidade do som no meio sólido é definida através da Equação 3.7.

$$V_s = \sqrt{\frac{Y}{\rho(1-c)}} \quad (3.7)$$

V_l é a velocidade do som do meio líquido incompressível;

V_{lc} é a velocidade do som do meio líquido compressível;

V_s é a velocidade do som do meio sólido;

Y é a constante de Young;

$c = 2\sigma^2(1 - \sigma)$;

σ é a razão de Poisson.

3.2.5. A Atenuação de Propagação das Ondas Acústicas

Segundo Gutnik (2014), o fenômeno de atenuação da propagação de ondas acústicas é bastante complexo e depende de parâmetros como a absorção molecular, viscosidade e temperatura do meio. Entretanto, os matemáticos Stokes e Kirchoff desenvolveram um modelo que calcula o fator de absorção de energia pelo meio (*apud* SIVIAN, 1947). A Equação 3.8 define o coeficiente de absorção A_B de uma onda sonora:

$$A_B = \frac{4\pi^2 f^2}{c^3 \rho_0} \left[\frac{4}{3} \eta + \frac{(\gamma - 1)}{C_p} k \right] \quad (3.8)$$

Sendo:

η é o coeficiente de viscosidade;

f é a frequência da onda sonora;

ρ_0 é a densidade do meio material;

c é a velocidade do som no meio;

γ é a razão do calor específico;

k é o calor específico à pressão constante;

C_p é a condutividade térmica do meio.

A Equação 3.8 mostra o efeito atenuador que a viscosidade causa na onda sonora, bem como o efeito provocado pela densidade e velocidade de propagação da onda. Sendo a atenuação da onda sonora aproximadamente proporcional ao quadrado da frequência, pode-se inferir que a velocidade de propagação da onda não é constante, dado que a energia ao longo da trajetória se modifica pelos diferentes efeitos apresentados acima como a reflexão, a refração, a atenuação do meio (HAROLD, 1979; KUNDU; KISHORE; SINHA, 2006; GUTNIK, 2014).

O que se pode concluir, dentro dos aspectos considerados é que a forma de onda produzida por uma descarga parcial, desde seu início, se propaga pelos diversos tipos de materiais diferentes que compõe as estruturas do dispositivo elétrico, como os isolantes, bobinas de cobre, núcleo de aço, tanque de aço. Sendo assim, a forma de onda acústica que pode ser captada na parede de aço de um transformador por um sensor piezelétrico é totalmente modificada de sua forma original.


3.3. A Detecção de Descargas Parciais pela Técnica da Emissão Acústica

A técnica de identificação de descargas parciais pelo método da emissão acústica em transformadores, consiste na fixação de sensores acústicos em diferentes pontos do equipamento e, posteriormente, na aquisição e análise dos sinais. Como o fenômeno de DPs forma ondas sonoras, estas percorrem uma distância até que cheguem ao sensor acústico, fixados na parede de aço do dispositivo elétrico (GUTNIK, 2014). A Figura 3.1 resume o aparato de identificação de DPs em transformadores. Para o transformador, assim que ocorre uma descarga parcial, existem dois tipos de ondas acústicas que excitam um sensor acoplado na parede de aço do dispositivo: a onda longitudinal que percorre o óleo e a estrutura do transformador e a onda de superfície, que percorre a parede de aço. Elas se propagam com velocidades muito diferentes, sendo de fundamental importância a diferenciação destes dois tipos de onda para se fazer a localização da fonte de DPs corretamente (VELOSO, 2006). Segundo Markalous, Tenbohlen e Feser (2008) a onda gerada pela DP se propaga em todas as direções de forma esférica. No óleo ela irá se propagar no modo longitudinal até atingir as paredes do transformador. Também, por ser esférica, ela irá atingir a parede em diferentes instantes de tempo, conforme Figura 3.2 (VELOSO, 2006). Sendo assim, a onda acústica que se propaga no óleo tem velocidade em torno de 1400m/s. Já a onda que se propaga na parede de aço tem velocidade em torno de 5000m/s. Por conseguinte, existe também a possibilidade do sensor de emissão acústica captar primeiramente a forma de onda da parede de aço, não a de caminho direto conforme ilustra a Figura 3.3. Tal fato não é relevante no que condiz à simples identificação de DPs nos transformadores, todavia, para a localização do ponto de origem é um fator muito significativo na modelagem matemática.

Figura 3.1- Esquema de Detecção de Descargas Parciais em Transformadores




Figura 3.2- Propagação de onda no interior do transformador atingindo a parede de aço em diferentes instantes de tempo



(Fonte: VELOSO, 2006)

Figura 3.3- Propagação de onda de caminho direto e propagada pela parede de aço no interior do transformador



(Adaptado de: MARKALOUS; TENBOHLEN; FESER, 2008)

Sendo assim, a identificação de DPs em transformadores pelo método acústico se vale de processamento digital de sinais, que tem como finalidade caracterizar o fenômeno bem como sua evolução, por meio de ferramentas como a transformada

rápida de Fourier, wavelets, energia, entropia, valor RMS do sinal, dentre outros (PHUKAN; KARMAKAR, 2013).

Cabe destacar que a identificação de descargas parciais tem um caráter que define um ganho de qualidade no setor elétrico, quando se leva em consideração que uma simples análise da evolução da ocorrência das descargas parciais através deste método não invasivo pode significar um planejamento na manutenção ou substituição de um transformador. Sendo assim, uma concessionária de energia por exemplo pode, através desta técnica, realizar a manutenção ou troca de um transformador de forma a deslocar as cargas supridas por este, sem que o consumidor final fique desprovido de energia elétrica, fazer um corte temporário no fornecimento de forma planejada e sem prejudicar financeiramente nenhum estabelecimento, dentre outros fatores.

3.4. A Técnica de Localização de Descargas Parciais em Transformadores Imersos em Óleo Mineral

No monitoramento de descargas parciais em transformadores de potência, somente detectar e quantificar descargas parciais não é, certamente, suficiente para se realizar uma manutenção. A localização do problema é de extrema importância para o planejamento da própria manutenção. Se identificar e quantizar a DP se torna fundamental para se determinar o tempo e o momento exato da atuação e reparo do transformador, localizar a falha é de extrema importância quando se leva em consideração o tempo de manutenção realizada. O ponto exato do problema culminará com um menor tempo de execução da manutenção e, conseqüentemente, menor tempo de inatividade de um dispositivo elétrico cuja característica é ser um ativo financeiro de alto custo, quando se leva em conta os transformadores de alta e média tensão presentes nas subestações.


A análise de sinais acústicos, segundo Veloso (2006), se apresenta, na literatura técnica, como o recurso mais apropriado para se localizar a fonte de emissão acústica de uma descarga parcial. A localização de um ponto de DP dentro de um tanque de aço dotado de óleo isolante pode requerer diversos sensores que coletam sinais simultaneamente (LUNDGAARD, 1995), embora existam alguns métodos que propõe tal tarefa utilizando apenas um único sensor, movendo-o ao longo da estrutura (AUCKLAND et al, 1994). Os sinais acústicos aquisitados 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 aplicá-los na solução de um sistema não linear como visto em Markalous (2008). A Figura 3.4 ilustra o esquema de equacionamento do problema, sendo “S” representando um sensor de emissão acústica.

Figura 3.4- Esquema para o equacionamento do método de localização de DPs por triangulação de sinais.



(FONTE: VELOSO, 2006)

Segundo Markalous (2008) e Veloso (2006), um sistema de equação não-linear pode ser obtido segundo a distância euclidiana das coordenadas da fonte de descarga

até a coordenadas dos “ n ” sensores acoplados na parede de aço do transformador. O sistema de equações não lineares é mostrado em 3.9.

$$\begin{aligned}
 (x + x_{s1})^2 + (y + y_{s1})^2 + (z + z_{s1})^2 &= (c \cdot \Delta t_1)^2 \\
 (x + x_{s2})^2 + (y + y_{s2})^2 + (z + z_{s2})^2 &= (c \cdot \Delta t_2)^2 \\
 (x + x_{s3})^2 + (y + y_{s3})^2 + (z + z_{s3})^2 &= (c \cdot \Delta t_3)^2 \\
 &\dots \\
 (x + x_{sn})^2 + (y + y_{sn})^2 + (z + z_{sn})^2 &= (c \cdot \Delta t_n)^2
 \end{aligned} \tag{3.9}$$

Sendo:

x, y e z representam as coordenadas da descarga parcial;


x_{si}, y_{si} e z_{si} representam as coordenadas dos sensores utilizados;

c é a velocidade do som no óleo mineral;

Δt_i é o intervalo de tempo entre o acontecimento 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, que daria o tempo referencial de início da descarga e, conseqüentemente, retornaria todos os valores de Δt_i , por meio da diferença entre os tempos de excitação dos sensores e o instante inicial de tempo da ocorrência da DP pelo método elétrico. 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. Também, o objetivo do método acústico de localização de DPs é utilizar de forma pura essa metodologia. A solução para este problema, discutido em Markalous (2008) e Veloso (2006) consiste em acrescentar ao problema uma incógnita: o tempo de excitação do sensor mais próximo da descarga parcial Δt_1 que, para as equações, pode ser denotado de “ T ”. A Figura 3.5 ilustra os intervalos de tempo entre as detecções da descarga parcial usando apenas o método acústico.

Figura 3.5- Intervalos de tempo entre as detecções da DP utilizando somente o método acústico.



(FONTE: VELOSO, 2006)

Deste modo, o sistema não linear para a localização fica conforme escrito em 3.10:

$$\begin{aligned}
 (x + x_{s1})^2 + (y + y_{s1})^2 + (z + z_{s1})^2 &= (c \cdot T)^2 \\
 (x + x_{s2})^2 + (y + y_{s2})^2 + (z + z_{s2})^2 &= (c \cdot (T + \tau_2))^2 \\
 (x + x_{s3})^2 + (y + y_{s3})^2 + (z + z_{s3})^2 &= (c \cdot (T + \tau_3))^2 \\
 &\dots \\
 (x + x_{sn})^2 + (y + y_{sn})^2 + (z + z_{sn})^2 &= (c \cdot (T + \tau_n))^2
 \end{aligned} \tag{3.10}$$

Sendo τ_i a diferença de tempo entre a excitação do sensor i e o sensor 1, mais próximo do ponto de 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, devido às propriedades acústicas apresentadas na Seção 3.1, 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. Por conseguinte, resolver o sistema não linear pode ser uma tarefa difícil quando se leva em conta a imprecisão dos dados de tempo

fornecidos (VELOSO, 2006). O trabalho realizado por Veloso (2006) utilizou a transformada wavelet para extrair as características de tempo de chegada dos sensores e, para a solução do sistema não linear, foi utilizado algoritmo genético. Já em Markalous (2008) o tempo de chegada foi calculado através do critério de energia do sinal como também o critério estatístico de Akaike. A solução do sistema foi realizada através de algoritmos que solucionam sistemas GPS. Entretanto, devido às complexas características de propagação da onda acústica, estes dois trabalhos contemplaram caixas de transformadores sem a parte ativa, isto é, a DP é dada no óleo isolante e o sinal sofre reflexões e refrações somente na parede de aço da caixa do transformador.

Devido à complexidade da problemática em questão, Clerice (2014) propôs um método que utiliza sistemas inteligentes para a localização de descargas parciais. Foi utilizado um sistema dotado de redes neurais (RNA) e sistemas de inferência neuro-difuso adaptativo (ANFIS). Os sistemas inteligentes foram alimentados com métricas de sinais acústicos como energia, valor RMS, tempo de pico, tempo de subida e critério de energia. A Figura 3.6 ilustra o modelo proposto.

Conforme mostrado, a localização do fenômeno de descargas parciais é de suma importância para a realização de uma manutenção pontual com grande ganho de tempo de serviço e também com ganhos financeiros significativos, quando se leva em conta o menor tempo de inatividade de um dispositivo elétrico de elevado custo como é o transformador de potência. Metodologias são empregadas para esta finalidade e, no entanto, conforme observado nas três proposições, de Veloso (2006), Markalous (2006) e Clerice (2014), não contemplam a localização de DPs com o transformador montado.

Figura 3.6- Modelo de Localização de DPs proposto por Clerice (2014).



(Adaptado de: CLERICE, 2014)

Observa-se também que a literatura carece de sistemas que localizem DPs com o transformador dotado também de sua parte ativa pois, conforme discutido em Veloso (2006), poucos artigos contemplam este estudo pois todo aparato do transformador acaba se tornando obstáculos que modificam a onda acústica original e, deste modo, torna-se complexa a detecção e principalmente a localização da fonte de DP.

3.5. Técnicas de Processamento Digital de Sinais Aplicadas à Localização

Uma vez que o sinal de emissão acústica gerado pela descarga parcial é captado por sensores piezelétricos e então aquisitados, torna-se factível o processamento computacional dos mesmos para que se extraia suas características e informações. A presente seção visa mostrar as principais técnicas de processamento de sinais utilizadas por este estudo, que visa a localização de DPs por meio de diafragmas piezoelétricos de baixo custo com a aplicação de sistemas inteligentes. São eles: RMS ou valor eficaz, energia do sinal, skewness, kurtosis, valor de pico, critério de energia, critério estatístico de Akaike e densidade espectral de potência.

3.5.1 Valor RMS de um Sinal

Segundo Aguiar, Bianchi e Canarim (2012), o critério RMS é um dos mais importantes para que se possa avaliar o sinal a ser aplicado à saída do sensor de emissão acústica. Esta abordagem pode ser considerada como uma quantidade física de intensidade de som e está diretamente relacionada com a carga aplicada ao sensor, fazendo com que seja um valor muito interessante para ser monitorado. O valor RMS pode ser expresso pela Equação 3.11, sendo que T é o tempo de integração, N o número discreto de amostras no intervalo T , E é a tensão elétrica do sinal e E_i a tensão elétrica da amostra i . Para o caso de sinais acústicos, que são não periódicos, o sinal é janelado e o tempo de integração é definido como o valor da própria janela, se tratando, então, de uma abstração matemática do valor RMS verdadeiro.

$$V_{eficaz} = \sqrt{\frac{1}{T} \int_0^T (E(t))^2 dt} = \sqrt{\frac{1}{N} \sum_{i=1}^N E_i^2} \quad (3.11)$$

3.5.2 Energia de um Sinal

A energia do sinal acústico também mede a carga acústica que pode ser aplicada ao sensor.


Assim sendo, θ é a energia do sinal, T é o tempo de integração definido pela janela do sinal, N o número discreto de amostras no intervalo T , E é a tensão elétrica do sinal e E_i a tensão elétrica da amostra i .

$$\theta = \int_{-\infty}^{\infty} |E(t)|^2 dt = \frac{1}{N} \sum_{i=1}^N E_i^2 \quad (3.12)$$

3.5.3 Skewness de um Sinal

É usado para caracterizar uma distribuição não-normal. O coeficiente de Skewness próximo de zero indica simetria do sinal. Quando o coeficiente é negativo, existe uma tendência da onda para a esquerda e, para números positivos, sinal concentrado à direita, conforme ilustrado na Figura 3.7 e na Equação 3.13 (CLERICE, 2014).

Figura 3.7 - Representação da assimetria calculada pelo Skewness



(Fonte: CLERICE, 2014)


$$S_w = \frac{\frac{1}{(n-1)} \sum_{i=1}^n (V_i - \bar{V})^3}{s^3} \quad (3.13)$$

Sendo que 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 a variância entre os dados.

3.5.4 Kurtosis de um Sinal

Segundo Clerice (2014), kurtosis “é um coeficiente que indica a concentração próxima a média (ou pico) de uma curva. Com um coeficiente menor que três, a distribuição é mais achatada, conhecida como *platykurtic*, porém, coeficientes maiores que três indicam que o pico é acentuado e a distribuição é chamada *leptokurtic*”, conforme Figura 3.8 e a Equação 3.14.

Figura 3.8 - Representação da concentração calculada pelo Kurtosis



(Fonte: CLERICE, 2014)

$$S_k = \frac{\frac{1}{(n-1)} \sum_{i=1}^n (V_i - \bar{V})^4}{s^4} \quad (3.14)$$

Sendo que 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 a variância entre os dados.

3.5.5 Valor de Pico de um Sinal

“É o maior valor de tensão obtida em função do tempo. Sendo que na Equação 3.15, V_m é o valor da amplitude da tensão instantânea e t é o instante de tempo” (CLERICE, 2014).

$$V_p = \max (|V_m(t)|) \quad (3.15)$$

3.5.6. Critério de Energia

De acordo com Markalous, Tenbohlen e Feser (2008) como também em Robles, Fresno e Tarifa (2015), a finalidade do critério de energia é caracterizar a emissão acústica, a qual possui faixa de frequência e conteúdo energético variável.


Este critério possibilita detectar os tempos de chegadas de ondas acústicas em sensores, assim como alterações no sinal ao longo do tempo, a partir de um algoritmo sofisticado. A curva de energia S_i do sinal amostrado x é definida como a soma cumulativa dos valores de amplitude, como mostra a Equação 3.16:

$$S'_i = \sum_{k=0}^i \left(V_k^2 - i \frac{S_N}{N} \right) \quad (3.16)$$

Sendo que i é uma variável de contagem e a curva instantânea de energia depende da energia total do sinal S_N e o número de amostras N . O mínimo global desta curva corresponde ao tempo de início de um sinal, isto é, o tempo pelo qual um sensor é excitado inicialmente por ondas de ultrassom. Pelo fato de a intensidade de energia do sinal estar diretamente relacionada com a carga aplicada ao sensor, este critério pode ser qualificado como uma forma de se caracterizar e mensurar um sinal (MARKAULOUS; TENBOHLEN; FESER, 2008).

É destacado na Figura 3.9, dois sinais segundo o critério de energia de dois sensores de emissão acústica, com pontos de mínimo global 1 e 2, que representam as amostras de chegada da onda acústica em dois sensores.

Figura 3.9 – Pontos de mínimo do critério de energia para a determinação do tempo de chegada de um sinal acústico em sensores.



(Adaptado de: ROBLES; FRESNO; TAFIFA, 2015)

3.5.7. Critério Estatístico de Akaike (AIC)

O critério estatístico de Akaike considera os sinais como um processo autorregressivo a qual cada amostra é uma combinação linear de amostras passadas. Este critério, segundo Robles, Fresno e Tarifa (2015), pode ser aplicado para se determinar o tempo de chegada da onda acústica no sensor, tendo em vista que o valor de Akaike se torna uma comparação entre dois segmentos do sinal acústico conforme a equação 3.17, definida por Akaike.


$$AIC(n) = n \ln[\sigma^2(1, n)] + (N - n - 1) \ln [\sigma^2(n + 1, N)] \quad (3.17)$$

Sendo que n uma amostra do sinal, N , o número total de amostras e σ^2 a variância. Portanto, o critério de Akaike estabelece uma comparação entre dois seguimentos do sinal, ou seja, um vetor que vai da primeira amostra até a n -ésima e outro vetor que consiste da amostra seguinte ao fim do primeiro vetor até a amostra que cessa o sinal acústico. Segundo observado em Markalous, Tenbohlen e Feser (2008) como também em Robles, Fresno e Tarifa (2015), o

pico de mínimo cuja derivada é nula representa o tempo de chegada na frente de onda do sensor. A Figura 3.10 representa o sinal de dois sensores segundo o critério estatístico de Akaike. Os pontos destacados pelos numerais 1 e 2 representam o instante em que o sensor foi excitado pela onda acústica.

Conforme observado em Markalous (2008), o critério de energia bem como o critério estatístico de Akaike remetem os tempos de chegada da onda acústica nos sensores. Todavia, estes dois métodos não retornam tempos iguais pelo fato desse problema não ser totalmente determinístico pois envolve uma região do sinal que estabelece um transitório entre o início da excitação e o sinal normal, sem nenhuma ocorrência. A diferença de tempos entre os critérios, em Markalous (2008) chegaram até $7\mu\text{s}$.

Figura 3.10 – Pontos de mínimo local para a determinação do tempo de chegada de um sinal acústico em um sensor segundo o critério de Akaike.



(Adaptado de: ROBLES; FRESNO; TARIFA, 2015)

CAPÍTULO 4- TRANSDUTORES PIEZELÉTRICOS E A TÉCNICA DA EMISSÃO ACÚSTICA NA IDENTIFICAÇÃO DE DESCARGAS PARCIAIS

Este capítulo aborda os conceitos gerais de piezeletricidade e apresenta as características gerais das capsulas piezelétricas de baixo custo utilizadas neste trabalho.


4.1. Piezeletricidade e Materiais Piezelétricos

Segundo Baptista (2010), a piezeletricidade foi descoberta por Jacques e Pierre Curie em 1880. O termo piezelétrico vem do grego “piezein” que significa pressão. Idealmente, o estudo sobre a piezeletricidade deveria ser precedido de um estudo sobre cristalografia para um melhor entendimento das propriedades físico-químicas que regem o funcionamento deste tipo de transdutor. Por ser um trabalho cujo enfoque é a localização de descargas parciais por meio da utilização de sensores piezelétricos de baixo custo, serão apresentadas apenas as características básicas dessa propriedade. Para um melhor aprofundamento, recomenda-se a leitura de Meitzler et al (1987) e Ibrahim (1991).

O efeito piezelétrico ocorre em materiais que, ao serem submetidos a uma tensão mecânica ' T ', produzem uma tensão elétrica de saída através da formação de um dipolo elétrico no material. A polarização produzida pela tensão elétrica cria cargas e, portanto, um campo elétrico (MEITZLER, 1987). Também ocorre o efeito reverso, ou seja, aplicando-se uma tensão elétrica no material piezelétrico surge uma deformação mecânica. A Figura 4.1 ilustra a compressão de um cristal piezelétrico induzindo um momento de dipolo elétrico na direção da deformação. No cristal sem deformação, os três dipolos formados pelo íon 'a' têm momento total nulo. Quando o cristal é deformado como indicado, os ângulos entre os dipolos produzem um momento na direção da deformação (ARENY; WEBSTER, 2000; MEITZLER, 1987; BAPTISTA, 2010).


Para se determinar a modelagem matemática destes materiais é utilizado um capacitor de placas paralelas, com dielétrico não piezelétrico no qual são aplicadas uma força $\vec{F}$ e uma diferença de potencial elétrica U [V], conforme Figura 4.2.

Figura 4.1 – (a) cristal em equilíbrio. (b) dipolo resultante da deformação mecânica.



(FONTE: ARENY; WEBSTER, 2000)

Figura 4.2 –Capacitor plano de placas paralelas utilizado para determinar as relações construtivas de um piezelétrico.



(FONTE: ARENY; WEBSTER, 2000)

Inicialmente, considera-se que o dielétrico do capacitor seja um material anisotrópico e não piezelétrico. A aplicação da força $\vec{F}$ produz uma deformação $\vec{S}$ e uma tensão $\vec{T}$ que se relacionam através da lei de Hooke dada pela Equação 4.1. O valor de s representa o tensor de elasticidade do material piezelétrico. Os dados destacados em negrito representam vetores e tensores (BAPTISTA, 2010).

$$\vec{S} = s\vec{T} \quad (4.1)$$

Uma diferença de potencial aplicada entre as placas do capacitor cria um campo elétrico $\vec{E}$, que gera uma densidade de fluxo $\vec{D}$ conforme Equação 4.2.

$$\mathbf{D} = \epsilon_0 \mathbf{E} + \mathbf{P} \quad (4.2)$$

Em que $\mathbf{D}$ é a densidade de fluxo elétrico, ϵ_0 é a permissividade no vácuo, cujo valor é 8,85pF/m, e $\mathbf{P}$ o vetor polarização.

Entretanto, se o material dielétrico for um piezelétrico, ocorre a interação entre as grandezas elétricas e mecânicas. Desconsiderando os efeitos térmicos e magnéticos, as equações que regem o comportamento deste tipo de material podem ser escritas segundo o critério da energia livre de Gibbs, conforme as Equações 4.3 e 4.4 (MEITZLER, 1987; BAPTISTA, 2010).

$$\mathbf{S} = \mathbf{s}^E \mathbf{T} + \mathbf{d} \mathbf{E} \quad (4.3)$$

$$\mathbf{D} = \mathbf{d} \mathbf{T} + \epsilon^T \mathbf{E} \quad (4.4)$$

Sendo $\mathbf{s}^E$, o tensor de elasticidade do material, $\mathbf{d}$ as constantes piezelétricas e ϵ^T representa as constantes de permissividade dielétricas.

Por conseguinte, em um material dielétrico existe tanto carga devido a uma tensão mecânica e uma deformação devido a um campo elétrico, se traduzindo em um acoplamento eletromecânico (MEITZLER, 1987; BAPTISTA, 2010).

Estes sensores têm a propriedade de gerar uma diferença de potencial que se relaciona matematicamente com a deformação mecânica gerada por, por exemplo, uma onda acústica.

Segundo Clerice (2014), entre os materiais piezelétricos incluem os titanatos de bário e chumbo, o zirconato de chumbo (PbZrO_3), o di-hidrogenofosfato de amônio ($\text{NH}_4\text{H}_2\text{PO}_4$) e o quartzo. A Tabela 4.1, extraída de Abrahams e Nassau (1991), ilustra alguns materiais piezelétricos e algumas de suas propriedades.

4.2. Diafragmas Piezelétricos de Baixo Custo

Entre os materiais piezelétricos mais utilizadas, destacam-se o titanato de bário (BaTiO_3), que é utilizado em transdutores ultrassônicos e, mais recentemente, o titanato zirconato de chumbo ($\text{PbTiO}_3 \cdot \text{PbZrO}_3$) conhecido como PZTs ou diafragmas piezelétricos. Segundo Marchi (2015), quando comparadas com outros materiais

Tabela 4.1- Propriedade de alguns materiais piezelétricos

Material	Fórmula	Origem	Constante piezelétrica (pm/V ou pC/N)
Fosfato de di-hidrogenofosfato de amônio (ADP)	$\text{NH}_4\text{H}_2\text{PO}_4$	Único cristal	$d_{36}=48$
Titanato de bário	BaTiO_3	Único cristal	$d_{15}=587$
Titanato de bário	BaTiO_3	Cerâmica policristalina	$d_{15}=270$
Titanato zirconato de chumbo (PZT)	$\text{PbZr}_{0,6}\text{Ti}_{0,4}\text{O}_3$	Cerâmica policristalina	$d_{33}=117$
Lantânio titanato zirconato de chumbo (PLZT)	$\text{Pb}_{0,925}\text{La}_{0,5}\text{Zr}_{0,56}\text{Ti}_{0,44}\text{O}_3$	Cerâmica policristalina	$d_{33}=545$
Fluoreto de polivinilideno	$(\text{CH}_2\text{CF}_2)_n$	Filme orientado	$d_{31}=28$
Dihidrogenofosfato de potássio	KH_2PO_4	Único cristal	$d_{36}=21$
Quartzo	SiO_2	Único cristal	$d_{11}=2.3$
Óxido de zinco	ZnO	Único cristal	$d_{33}=12$

(Fonte: ABRAHAMS; NASSAU, 1991; CLERICE, 2014)

piezelétricos, estes diafragmas apresentam algumas vantagens como: bom acoplamento eletromecânico, boa estabilidade, alta rigidez, resposta linear para campo elétrico de baixa intensidade e baixo custo (MARCHI, 2015).

Geralmente, os transdutores piezelétricos utilizados na detecção de danos estruturais são constituídos por pequenas placas delgadas de cerâmicas de PZT revestidas, em ambas as faces, por um filme metálico que serve como eletrodo (MARCHI, 2015). A Figura 4.3 ilustra o esquema construtivo da cápsula piezelétrica de baixo custo utilizada nesta pesquisa (Modelo similar a 7BB-35-3, Murata (2015)).

Para esta cápsula, um elemento piezelétrico deformado por uma onda mecânica ou qualquer outra fonte de tensão mecânica, a distorção se expande numa direção radial, conforme a Figura 4.4 (a). Já quando o material é comprimido, há uma distorção segundo a Figura 4.4 (b). Assim, quando à tensão alternada é aplicada através dos eletrodos, a flexão mostrada na Figura 4.4 (a) e Figura 4.4 (b) é cíclica, como ilustra a Figura 4.4 (c) (CLERICE, 2014). Esta pesquisa tem como objetivo

Figura 4.3 - Construção da cápsula piezelétrica de baixo custo





Figura 4.4 - Sistema de oscilação da cápsula piezelétrica de baixo busto



aplicar estas capsulas piezelétricas de baixo custo com a finalidade de identificar e localizar descargas parciais em transformadores de potência, tomando a propriedade de que a excitação produzida por uma onda acústica gerada por uma DP faz com que a capsula piezelétrica, atuando como sensor, retorne a um sistema de aquisição de dados, um sinal elétrico proporcional à esta excitação mecânica gerada pela descarga parcial.

CAPÍTULO 5- SISTEMAS INTELIGENTES

Este capítulo aborda os conceitos gerais sobre os sistemas inteligentes do tipo Redes Neurais Artificiais e Sistemas de Inferência Neuro-Fuzzy Adaptativos, utilizados neste trabalho.

5.1. Introdução

Inteligência artificial (IA) ou sistemas inteligentes (SI) é o desenvolvimento de algoritmos que requeiram máquinas para realizar tarefas cognitivas, para as quais os humanos são altamente melhores (PEROZIN, 2002). Segundo Perozin (2002), um sistema de inteligência artificial basicamente possui três características:

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

Sendo assim, para realizar tais tarefas citadas acima, os sistemas inteligentes possuem três componentes fundamentais: a representação, raciocínio e aprendizagem (SAGE, 1990).

A representação consiste no uso difundido de uma linguagem simbólica para representar tanto o conhecimento genérico quanto um conhecimento específico de um problema. Em um sistema inteligente o conhecimento significa o aparato de dados de um problema.

No que condiz ao raciocínio, ou seja, habilidade de resolver problemas, para um sistema ser qualificado, ele deve satisfazer algumas condições (PEROZIN, 2002):

- O sistema deve ser capaz de resolver uma vasta gama de problemas e tipos de problemas;
- Deve ser capaz de tornar conhecidas as informações implícitas e explícitas;

- Deve possuir um mecanismo de controle que determine quais operações devem ser aplicadas quando uma solução for encontrada ou quando deve ser encerrado o tratamento deste problema.


Para o elemento de aprendizagem de um sistema inteligente, o ambiente ou um usuário fornece dados ao sistema que forma a base de conhecimento para executar uma determinada tarefa (PEROZIN, 2002). Muitas vezes a informação fornecida tem imperfeições e, então, o sistema inteligente deve revisar as hipóteses segundo uma realimentação dos dados.

Segundo Byrd e Hauser (1991), os sistemas inteligentes fornecem um método padronizado para resolução de problemas importantes e de bastante complexidade a fim de obter resultados consistentes e confiáveis ao longo do tempo. Segundo Krishnakumar (2003), a IA se caracteriza pela habilidade, adaptabilidade, memória, aprendizagem, dinâmica temporal, raciocínio e capacidade de gerenciar informações incertas e imprecisas (CLERICE, 2014).

Há diversos tipos de sistemas inteligentes que atualmente estão organizados de acordo com a Figura 5.1. Esta pesquisa se valerá e ilustrará apenas os sistemas Fuzzy, por meio dos sistemas de inferência neuro-difuso adaptativo (ANFIS) e das Redes Neurais Artificiais.

Tendo em vista estas propriedades gerais dos sistemas inteligentes, torna-se, então, factível a utilização destes na aplicação de localização de descargas parciais, dada a complexidade e a incerteza de informações do sinal de onda acústica, que atravessa meios e sofre reflexões, refrações, perdas, que se traduzem, muitas vezes, em informações de elevada complexidade e incerteza. Como ilustração, verifica-se a incerteza nos próprios critérios de tempos de chegada de uma onda acústica no sensor, caracterizados, neste trabalho, pela proposição de Akaike e o critério de energia. Embora ambos objetivam verificar o instante de tempo de chegada, existe uma discrepância entre as duas respostas por se tratarem de dois métodos distintos.

No mais, destaca-se também a complexidade da modelagem matemática mediante o problema de localização do transformador com todos os seus componentes. Nos trabalhos vistos anteriormente em Markalous (2008) e Veloso (2006) a modelagem realizada no aparato de localização do transformador não dotado de seus componentes, ou seja, somente dotado do óleo isolante, já exigiu algoritmos complexos para solução do problema em questão.

Figura 5.1- Representação organizacional dos sistemas inteligentes

(Adaptado de: CLERICE, 2014)

5.2. As Redes Neurais Artificiais

As redes neurais artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso de seres vivos e possuem a capacidade de aquisição e manutenção do conhecimento e podem ser definidas como um conjunto de unidades de processamento, caracterizadas pelos neurônios artificiais, que são interligadas por um grande número de conexões denominadas “sinapses artificiais”, a qual, matematicamente, são representadas por vetores e matrizes de pesos sinápticos (SILVA; SPATTI; FLAUZINO, 2010). Podem ser aplicadas em diversas áreas do conhecimento como por exemplo a avaliação de imagens captadas por satélite, classificação de padrões de escrita e fala, controle de trens de alta velocidade, identificação de anomalias em imagens médicas, etc. As características principais envolvidas nas aplicações das Redes Neurais são (SILVA; SPATTI; FLAUZINO, 2010):

- Adaptação por experiência: os parâmetros internos de uma Rede Neural Artificial (RNA) são ajustados a partir de uma apresentação sucessiva de exemplos relacionados ao comportamento do problema em questão;

- Capacidade de aprendizado: por intermédio da aplicação de um método de treinamento, a rede consegue extrair o relacionamento entre diversas variáveis em questão;
- Habilidade de generalização: após o treinamento de uma rede, essa é capaz de generalizar o conhecimento adquirido, retornando soluções para casos ainda não conhecidos;
- Organização interna de dados: baseada nas características dos dados de aprendizado de uma rede, ela é capaz de agrupá-los em características comuns;
- Tolerância a falhas: devido ao elevado índice de interconexões, uma RNA é tolerante a falha quando sua estrutura é minimamente corrompida;
- Detém facilidade de prototipagem em hardware e software.

Além disso, conforme Clerice (2014), extraído de Silva, Spatti e Flauzino (2010), as redes neurais possuem grande aplicação em diversos problemas de engenharia e ciências, conforme as áreas enquadradas a seguir:

- Aproximador universal de funções: consiste em mapear o funcionamento entre variáveis de um sistema, cujas modelagens convencionais são de difícil obtenção;
- Controle de processos: consiste em identificar ações de controle que permitem a qualidade, eficiência e segurança de processo. Aplicados em robótica, aeronaves, eletrodomésticos;
- Classificação de padrões: consiste em associar padrões de amostras para uma das classes previamente definidas. Aplicadas em reconhecimento de voz, imagem, etc. O problema deve possuir um conjunto discreto e conhecimento das possíveis saídas desejadas;
- Agrupamento de dados (clusterização): A identificação e detecção de similaridades entre diversos padrões para o agrupamento;
- Sistemas de previsão: têm o objetivo de estimar valores futuros de um determinado processo considerando medidas prévias observadas em seu domínio;
- Nas aplicações enquadram-se: a previsão de séries temporais, previsões de mercados financeiros, previsões climáticas, etc;


- Otimização de sistemas: tende a minimizar ou maximizar uma função custo obedecendo as restrições impostas pelo problema, sendo tratados com otimização restrita, programação dinâmica e otimização combinatorial;
- Memória Associativas: a recuperação de padrões corretos mesmo se os elementos que o constituem se apresentam de forma incerta ou imprecisa. Aplicados a processamento de imagens, transmissão de dados e identificação de caracteres, etc.

5.2.1. O Neurônio Artificial

A estrutura das RNAs foi desenvolvida a partir de modelos conhecidos de sistemas nervosos biológicos e do próprio cérebro humano. Os elementos computacionais ou unidades processadoras, denominadas neurônios artificiais foram inspirados a partir da análise da geração e propagação de impulsos elétricos pela membrana celular dos neurônios. Este modelo, foi proposto em 1943 por McCulloch & Pitts e é o modelo mais utilizado nos diversos tipos de RNAs existentes (SILVA; SPATTI; FLAUZINO, 2010).

Essa descrição matemática resultou em um modelo com n terminais de entrada $x_1, x_2, x_3, \dots, x_n$, que representam os dendritos, e apenas um terminal de saída y , que representa um axônio. Para simular o comportamento das sinapses, os terminais de entrada do neurônio são ponderados pelos pesos sinápticos dados por $w_1, w_2, w_3, \dots, w_n$, cujos valores podem ser positivos ou negativos. O efeito de uma sinapse particular i do neurônio da rede pode ser modelado conforme Figura 5.2 (SPATTI, 2011).

Figura 5.2- Modelo não linear de neurônio



(Fonte: SPATTI, 2011)

O modelo matemático que descreve o comportamento do neurônio artificial é dado pela Equação 5.1:

$$y = g \left(\sum_{i=1}^n w_i x_i(t) + b \right) \quad (5.1)$$

Sendo:

n o número de entradas do neurônio;

w_i é o peso associado a i -ésima entrada;

b é o limiar associado ao neurônio;

x_i é a i -ésima entrada do neurônio;

$g(.)$ é a função de ativação do neurônio;





y é a saída do neurônio;

No que condiz ao funcionamento do neurônio artificial, quando um sinal é apresentado a sua entrada, estes são multiplicados por um peso sináptico que representa seu grau de relevância na saída. Assim, é feita uma soma ponderada dos sinais, resultando assim em um numeral que, se exceder um certo limite (*threshold*), a unidade produz uma saída y (SPATTI, 2011).

A função de ativação é responsável pelo processamento do conjunto de informações que a rede neural recebe e é incumbida pela saída, podendo assumir valores binários (0 ou 1), bipolares (-1 e 1) ou valores reais. A Figura 5.3 ilustra as funções de ativação mais utilizadas na literatura (SPATTI, 2011).

O processo de treinamento de uma RNA consiste da aplicação de passos ordenados que sejam necessários para a sincronização dos pesos sinápticos e limiares tendo como objetivo final a generalização de soluções a serem produzidas pelas saídas. A estratégia do treinamento supervisionado consiste em se ter disponível, considerando as amostras das entradas, as respectivas respostas de saída do sistema (SILVA; SPATTI; FLAUZINO, 2010). Os pesos sinápticos serão ajustados conforme estes dois conjuntos de dados através de algoritmos aplicados para tal finalidade. No caso do treinamento não supervisionado, isto é, durante a

Figura 5.3- Funções de ativação mais comuns na literatura

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: CLERICE, 2014)


aplicação de algoritmos de aprendizado, inexistem as saídas desejadas e, conseqüentemente, a própria rede deve se organizar para tal. Esta pesquisa se baseou em treinamento supervisionado para atingir o objetivo proposto.

5.2.2. Arquiteturas de RNAs

Um fator relevante é a escolha da topologia da RNA pois está diretamente correlacionada com a configuração das ligações entre os neurônios e ao algoritmo de treinamento. A camada de entrada é responsável pelo recebimento das informações e dados e é o local onde os padrões são apresentados à rede. Já as camadas intermediárias ou escondidas são responsáveis pela extração das características do processo ou sistema ao qual se está estudando. Para finalizar, a camada neural de saída é responsável pela apresentação final do resultado. A Figura 5.4 ilustra as camadas em questão (SPATTI, 2011).


As topologias de redes neurais artificiais se dividem, basicamente, em: redes de camada única, redes de multicamadas, redes recorrentes e redes reticuladas, conforme ilustra a Figura 5.5.

Figura 5.4- As camadas de uma RNA



(Fonte: SPATTI, 2011)

Figura 5.5- Arquitetura das redes neurais artificiais



(Fonte: CLERICE, 2014)

As redes de camada única, ou “*perceptrons*”, se caracterizam por possuir uma única camada de neurônios que é a própria camada de saída. São aplicadas, principalmente, em reconhecimento de padrões e em memórias associativas.

As redes de multicamadas ou redes “*FeedForward*” possuem uma ou mais camadas escondidas ou intermediárias. Neste tipo de Rede, as informações são recebidas pela camada de entrada, processadas pelas camadas intermediárias e apresentadas pela camada de saída. As principais funções destas redes é o reconhecimento de padrões, aproximação universal de funções não lineares, estimação, dentre outros. As principais redes que utilizam este tipo de topologia são as redes *perceptron* multicamadas e a Função de Base Radial (RBF) (SPATTI, 2011).

As redes recorrentes são as redes cujas saídas do neurônio são realimentadas como sinais de entrada para outros neurônios. A característica da realimentação qualifica essas redes para sistemas dinâmicos, ou seja, sistemas variantes em relação ao tempo, como previsão de series temporais, otimização, controle de processos, etc (SILVA; SPATTI; FLAUZINO, 2010). Entre os principais tipos estão as redes de *Hopfield* e *perceptron* multicamadas com realimentação. Tais redes levam em consideração os valores das saídas anteriores para produzirem as saídas atuais (SILVA; SPATTI; FLAUZINO, 2010; SPATTI, 2011).

As redes reticuladas se caracterizam pela disposição espacial dos neurônios visando propósitos de extração de características, isto é, a localização espacial está relacionada ao processo de ajuste de seus pesos sinápticos e limiares. Suas aplicações são aplicadas a problemas que envolvem agrupamentos, reconhecimento de padrões, dentre outros (SILVA; SPATTI; FLAUZINO, 2010). A topologia utilizada por este trabalho é a rede *perceptron* multicamadas. Sendo assim, a próxima seção mostra, simplificada, o processo de treinamento deste tipo de RNA.

5.2.3. O Processo de Treinamento das Redes Perceptron Multicamadas

Os dois tipos básicos de treinamento das redes perceptron multicamadas são realizados pelo algoritmo ‘*backpropagation*’ e o método de Levenberg Maquardt.

Durante o treinamento com o algoritmo *backpropagation*, a rede opera em uma sequência de dois passos: o passo para frente (propagação) e o passo para trás. No primeiro passo, um padrão de treinamento é apresentado à camada de entrada da rede e uma saída é produzida. Para a retropropagação, a saída obtida é comparada à saída desejada e a diferença entre os valores desejados e a saída produzida pela rede é calculado. Este erro então é retropropagado a partir da camada de saída até a camada de entrada, e os pesos sinápticos são atualizados (HAYKIN, 2001; COELHO, 2014). Esse processo é iterativo até que o erro quadrático médio das saídas alcance um valor aceitável. Entretanto, a utilização desse algoritmo na prática tende a convergir muito lentamente, exigindo assim um elevado esforço computacional, já que ele possui uma aproximação de primeira ordem. Por conseguinte, algumas técnicas de otimização têm sido incorporadas ao algoritmo *backpropagation* a fim de reduzir o seu tempo de convergência e diminuir o esforço computacional exigido pelo mesmo. Dentre as técnicas mais utilizadas para esse propósito destaca-se o algoritmo de Levenberg-Marquardt, que é uma modificação do método Gauss-Newton que usa a estratégia da região de confiança ao invés da busca linear como o algoritmo *backpropagation* (SILVA; SPATTI; FLAUZINO, 2010).

Essencialmente, o algoritmo de Levenberg-Marquardt é um algoritmo de otimização que se baseia em uma técnica iterativa de busca ao mínimo de uma função multivariada expressa como a soma de quadrados de funções não lineares (LEVENBERG 1944; ROCHA, 2015). É um método gradiente de segunda ordem, baseado no método dos mínimos quadrados para modelos não lineares, de forma que o método de busca do menor erro leva em conta o local do ponto de análise (SILVA; SPATTI; FLAUZINO, 2010).

A direção de busca do método Levenberg-Marquardt é definida como a solução da equação 5.2:

$$(\mathbf{J}(x_k)^T \mathbf{J}(x_k) + \eta_k \mathbf{I}) \mathbf{p}_k^{LM} = -\mathbf{J}(x_k)^T \mathbf{r}(x_k) \quad (5.2)$$

Em que η_k é um escalar não-negativo. Pode-se notar na Equação (5.3) que, dado $\eta_k > 0$ existe $\Delta = \Delta(\eta_k) > 0$ tal que o vetor $\mathbf{p}_k^{LM}$ é a solução do subproblema restrito (CLERICE, 2014).

$$\min_{p \in R^n} \frac{1}{2} \|J(x_k)p + r(x_k)\|_2^2 \quad (5.3)$$

Para que as condições sejam satisfeitas na Equação (5.4) deve:

$$\|p\|_2 \leq \Delta \quad (5.4)$$

Quando o método estiver distante do ponto mínimo de erro, o algoritmo tem um passo maior de atualização, e, quando o mesmo estiver próximo de um mínimo global do erro, o algoritmo diminui o passo para a convergência. Tal fato resulta em um ganho de tempo de processamento em relação ao algoritmo de *perceptron*, que utiliza métodos de aproximação de primeira ordem (MUÑOZ 2009; ROCHA, 2015).

5.3. Sistemas Nebulosos ou Sistemas Fuzzy

A teoria da lógica nebulosa foi introduzida em 1965 por Lotfi Zadeh, grande colaborador do Controle Moderno. Zadeh observou que os recursos tecnológicos disponíveis eram incapazes de automatizar as atividades relacionadas a problemas industriais, biológicas e químicos, que compreendessem situações ambíguas, ou seja, não fundamentadas na lógica clássica ou booleana (MORAIS, 2004). Por conseguinte, os sistemas nebulosos ou Sistemas Fuzzy tratam de resoluções de problemas que consistem em informações imprecisas. Estes sistemas também se caracterizam pelo tratamento de informações qualitativas, ou seja, são capazes de tratar informações vagas e aproximadas, expressas por variáveis linguísticas. Abaixo, algumas características dos sistemas Fuzzy são ilustradas, segundo Masselli (2014):

- exploram formas que o cérebro usa para o tratamento de informações qualitativas e incertas;
- suportam os modos de raciocínio que são aproximados, ao invés de exatos, como o ser humano está naturalmente acostumado a trabalhar;
- são sistemas capazes de tratar informações vagas, aproximadas, as quais são expressas por regras linguísticas;
- São sistemas que consistem em aproximar a decisão computacional da decisão humana.

Na teoria clássica, um elemento pertence a um determinado conjunto, segundo uma equação característica, que mapeia um universo e fornece uma fronteira de conjuntos bem definidos. Como exemplo, seja um conjunto universo U e um subconjunto S , tal que S está contido em U , e x um elemento pertencente em S . Define-se uma função característica sendo: $U \rightarrow \{0,1\}$ como na Equação 5.5 (CLERICE, 2014; COELHO, 2014):

$$\mu(x) = \begin{cases} 0, & \text{se } x \in S \\ 1, & \text{se } x \notin S \end{cases} \quad (5.5)$$

Observa-se que a função $\mu(x)$ define dois conjuntos, assumindo valores discretos e, o universo U mapeado.

No entanto, a teoria dos conjuntos *Fuzzy*, é caracterizada por não possuir fronteiras bem delimitadas como na teoria clássica. A abordagem proposta, no caso da Equação 5.5 toma valores mais generalizados, ou seja, pode assumir infinitos valores situados entre 0 e 1, sugerindo que alguns elementos são mais representativos que outros. Portanto, a teoria da lógica nebulosa define, então, o grau de pertinência da função, valor entre 0 e 1, sendo o nível 0 usado para representar total impertinência e 1, total pertinência de uma classe de dados (CLERICE, 2014; COELHO, 2014; BENINI, 2007).

“O modelo proposto no ano de 1965 por Zadeh, conota uma função flexibilizada, indicando que um elemento pode pertencer mais de um conjunto que um outro elemento. Por conseguinte, na teoria *Fuzzy* define-se o conceito de função de pertinência de um determinado conjunto, cuja função é ponderar as características originadas dos elementos em estudo. Sendo assim, a lógica *Fuzzy* pode ser aplicada em problemas com alto grau de complexidade, como também em problemas em que resultados aproximados são aceitáveis” (CLERICE, 2014; COELHO, 2014; BENINI, 2007).


Segundo Clerice (2014) e Coelho (2014), “os sistemas Fuzzy representam uma ferramenta de inteligência artificial que tem como característica modelar conhecimento de senso comum e ambíguo. Diferentemente das RNAs, um sistema puramente nebuloso não possui técnicas de aprendizado, sendo a definição de pertinência é baseada na avaliação do usuário do sistema”.

5.3.1. As Funções de Pertinência dos Conjuntos Fuzzy

Um conjunto *Fuzzy*, F de um universo U é representado por uma função pertinência $\mu: U \rightarrow [0,1]$, que associa um elemento $x \in U$, a um número $\mu(x)$, cujo intervalo varia de 0 a 1, e representa o grau de pertinência de x em F , isto é, o quão importante um numeral x na problemática abstraída (CLERICE, 2014; COELHO, 2014).

As operações básicas entre os conjuntos *Fuzzy* são de complemento, união e intersecção, como ilustra a Figura 5.6. Já as funções de pertinência mais comuns utilizadas são a triangular, trapezoidal, gaussiana, sigmoide e de pertinência unitária conforme Figuras de 5.7 a 5.11 (CLERICE, 2014; COELHO, 2014; MOZELLI, 2008).

Figura 5.6-Operações com conjuntos Fuzzy




(Fonte: MOZELLI, 2008)

Dado um universo U , tem-se uma função de pertinência $\mu(x)$, em que a , b e m pertencem ao conjunto U com $a \leq m \leq b$, definida pela Equação 5.6 (CLERICE, 2014; COELHO, 2014; BENINI, 2007).


$$\mu(x) = \begin{cases} 0; & \text{se } x \leq a \\ \frac{x-a}{m-a}; & \text{se } x \in [a, m] \\ \frac{b-x}{b-m}; & \text{se } x \in [m, b] \\ 0; & \text{se } x \geq b \end{cases} \quad (5.6)$$

Figura 5.7-Função de pertinência triangular




Dado um universo U , tem-se uma função de pertinência $\mu(x)$, em que a, b, m e x pertencem ao conjunto U com $a \leq m, n \leq b$ e $m \leq n$ definida na Equação 5.7 (CLERICE, 2014; COELHO, 2014; BENINI, 2007).

$$\mu(x) = \begin{cases} 0; & \text{se } x < a \\ \frac{x-a}{m-a}; & \text{se } x \in [a, m] \\ 1; & \text{se } x \in [m, n] \\ \frac{b-x}{b-n}; & \text{se } x \in [n, b] \\ 0; & \text{se } x > b \end{cases} \quad (5.7)$$

Figura 5.8- Função de pertinência trapezoidal

A equação que rege a função de pertinência gaussiana é dada, para k maior que 1, dado na Equação 5.8 (CLERICE, 2014; COELHO, 2014; BENINI, 2007).


$$\mu(x) = e^{-k(x-m)^2} \quad (5.8)$$

Figura 5.9- Função de pertinência gaussiana

A função sigmóide, sendo m , o ponto médio entre o intervalo $[a,b]$, é dada segundo a Equação 5.9 (CLERICE, 2014; COELHO, 2014; BENINI, 2007).

$$\mu(x) = \begin{cases} 0; & \text{se } x \leq a \\ 2 \cdot \left(\frac{x-a}{b-a} \right)^2; & \text{se } x \in [a, m] \\ 1 - 2 \cdot \left(\frac{x-a}{b-a} \right)^2; & \text{se } x \in [m, b] \\ 1; & \text{se } x \geq b \end{cases} \quad (5.9)$$


Figura 5.10- Função de pertinência sigmoide



A função pertinência *singleton*, ou função unitária, é dada pela Equação 5.10 (CLERICE, 2014; COELHO, 2014; BENINI, 2007).

$$\mu(x) = \begin{cases} h, & \text{se } x = m \\ 0, & \text{caso contrário} \end{cases} \quad (5.10)$$

Figura 5.11- Função de pertinência unitária




5.3.2. Sistema de Inferência Fuzzy e Variáveis Linguísticas

Zadeh (1973) definiu as variáveis linguísticas como sendo valores que traduzem palavras ou sentenças de ordem natural. Por exemplo, estas variáveis podem assumir valores linguísticos para temperaturas tais como frio, agradável, quente que, na verdade, traduzem um conhecimento específico do ser humano (especialista). Sendo assim, os sistemas de inferência *Fuzzy* podem agregar conhecimento e inferir dados sobre um processo a partir do conhecimento de

especialistas que elaboram regras e modificam as funções de pertinência de um sistema.

Um sistema de inferência *Fuzzy* é constituído basicamente de quatro blocos funcionais, conforme ilustra a Figura 5.12. A interface de *fuzzyficação* ou codificação, transforma as entradas numéricas em variáveis linguísticas, com base nas funções de pertinência (COSTA NETO, 2013).

Figura 5.12- Modelo de Sistema de Inferência Fuzzy



(Adaptado de: Jang, 1993; Costa Neto, 2013)

As entradas então são comparadas com as funções de pertinência para se obter um valor de pertinência ou relevância para cada variável linguística. O conjunto de regras combina os valores de pertinência de cada entrada realizando as operações ilustradas na Figura 5.6. O bloco de decisão realiza operações de inferência e a interface de decodificação ou *defuzzyficação* transforma os resultados obtidos em uma saída numérica (SIVANANDAM; SUMATHI; DEEPA, 2007; NEGNEVITSKY, 2005; COSTA NETO, 2013). Os dois sistemas de inferência mais comuns são o de Mamdani e o Takagi-Sugeno.

O sistema de inferência do tipo Mamdani, consiste basicamente em seis etapas segundo Sivanandam, Sumathi e Deepa (2007) (COSTA NETO, 2013):

- determinação do conjunto de regras difusas;
- codificação das entradas usando funções de pertinência;
- combinação das entradas codificadas de acordo com as operações do termo antecedente;
- determinação da saída de cada regra a partir do termo consequente;
- combinação dos termos consequentes para se ter uma distribuição da saída;

- decodificação da distribuição de saída.

Deste modo, conforme verificado, as saídas dos termos consequentes são combinadas de forma a se criar um único conjunto difuso. Assim, a entrada do processo de agregação consiste de uma lista de funções de pertinência dos termos consequentes e a saída é um único conjunto difuso para cada variável de saída. O processo de inferência termina na decodificação, isto é, traduz a saída do sistema para um valor numérico (COSTA NETO, 2013).

Já no sistema de inferência Takagi-Sugeno somente o termo antecedente das regras é formado por variáveis *Fuzzy*, diferente do método de Mamdani que forma por inteiro um conjunto difuso. Sendo assim, o método de Takagi-Sugeno o consequente de cada regra é expresso por uma função linear dos valores observados das variáveis que descrevem um determinado problema (COSTA NETO, 2013).


5.3.3. Sistemas de Inferência Neuro Fuzzy Adaptativos (ANFIS)

A lógica *fuzzy* é um raciocínio computacional com base na informação obtida de especialistas e convertida em variáveis linguísticas. Todavia, estes sistemas não possuem a capacidade de aprendizagem bem como não se adaptam a novos ambientes como as redes neurais artificiais. Proposto por Jang (1993), os sistemas *neuro-fuzzy* combinam a habilidade de aprendizagem das Redes Neurais juntamente com a capacidade de interpretação linguística dos sistemas *fuzzy*. É chamado na literatura de *Adaptive Network-Based Inference System* (ANFIS), e se caracteriza como uma rede neural com múltiplas camadas em que cada camada do sistema é associada a um passo em particular do processo de inferência *fuzzy* (NEGNEVITSKY, 2005; COSTA NETO, 2013; COELHO 2014; CLERICE 2014).

Como exemplo, a arquitetura ANFIS é composta por cinco camadas, conforme ilustrada na Figura 5.13. De acordo com Clerice (2014) e Coelho (2014), “na primeira camada do sistema, os nós são constituídos pelos conjuntos Fuzzy A_i^j e associados às entradas x_i . A saída de cada nó é a pertinência do valor x_i no conjunto *Fuzzy*. De acordo com Benini (2007), os nós podem ser ajustados e as funções de pertinência podem ser definidas desde que elas sejam diferenciáveis. Esta camada se caracteriza pela codificação dos sinais de entrada. Na segunda camada, os nós não são

adaptativos e não podem ser ajustados, tendo como saída o produto dos sinais de entrada da primeira camada. Conforme ilustra a Figura 5.13 cada saída w_j

Figura 5.14- Arquitetura típica do sistema ANFIS



(Fonte: CLERICE, 2014)

corresponde à intensidade do disparo de uma regra. Assim, a saída se caracteriza pela Equação 5.11”.

$$w_j = \prod_{i=1}^2 \mu_i^j, \text{ para } j = 1, 2 \quad (5.11)$$

Para a terceira camada, a saída desse nó é normalizada para um pré-processamento de defuzzificação. Cada neurônio nesta camada recebe como entrada todas as saídas dos neurônios da camada de regras e calcula o valor normalizado de cada regra. Este valor representa a contribuição de cada regra ao resultado final. A saída é definida pelo quociente entre a intensidade de disparo da j -ésima regra e a soma dos disparos de todas as demais regras, conforme Equação 5.12 (COELHO, 2014; CLERICE, 2014; COSTA NETO, 2013).

$$\bar{w}_j = \frac{w_j}{\sum_{i=1}^2 w_i} = \frac{w_j}{w_1 + w_2}, \text{ para } j = 1, 2 \quad (5.12)$$

Segundo Clerice (2014) e Coelho (2014), “a camada de número quatro, é adaptativa e seus parâmetros p , q e r correspondem a parte consequente de cada regra do modelo. Desta maneira, as saídas $fj = fj(\overline{w_j}, x1, x2, pj, qj, rj)$ são o produto das normalizações da terceira camada, com o valor do consequente da regra na Equação 5.13 (BENINI, 2007)”.

$$fj = \overline{w_j}(pjx1 + qjx2 + rj) \quad (5.13)$$

Para a quinta camada, constituída por um único nó não adaptativo, calcula-se a saída do sistema e promove a defuzzyficação do sistema. Sendo assim, a saída é definida como a soma de todas as saídas parciais representado na Equação 5.14 (CLERICE, 2014; COELHO, 2014; BENINI, 2007).

$$f = \sum_{j=1}^2 fj \quad (5.14)$$

De acordo com Coelho (2014), “a aprendizagem do sistema *ANFIS* tem dois conjuntos que devem ser treinados: os parâmetros do antecedente, que são as constantes que caracterizam as funções descendentes, e os parâmetros do consequente, que são os parâmetros lineares da saída do modelo de inferência. Essa aprendizagem emprega algoritmos do gradiente descendente para aperfeiçoar o antecedente, e se vale do método dos mínimos quadrados para determinar os parâmetros lineares dos consequentes”.

“O treinamento é realizado por duas etapas: primeiramente, os parâmetros dos antecedentes permanecem fixos e utiliza-se o método dos mínimos quadrados como regra; na segunda etapa, com os consequentes constantes e fixos, utiliza o algoritmo *backpropagation* sobre o parâmetro do precedente” (CLERICE, 2014; COELHO, 2014). Esta técnica se vale para soluções de sistemas dinâmicos não lineares por combinar a potencialidade destes dois tipos de sistemas inteligentes.


CAPÍTULO 6- METODOLOGIA PROPOSTA

Este capítulo aborda a metodologia empregada nesta pesquisa, mostrando os testes e os critérios adotados para a confecção do aparato de geração de descargas parciais e validação do sensor de baixo custo para a identificação e localização.

6.1. Introdução

Visando os objetivos propostos, isto é, a localização de descargas parciais em transformadores de potência por meio de diafragmas piezelétricos de baixo custo e sistemas inteligentes, foi montado um aparato de testes conforme Figura 6.1.

Figura 6.1- Metodologia proposta para o sistema de localização



Devido à complexidade do problema de se localizar uma DP interna como abordado nos Capítulos 2 e 3 deste trabalho, o método proposto foi a utilização de sistemas inteligentes como método de resolução da problemática em questão. Sendo assim, os diafragmas piezelétricos de baixo custo, atuando como sensores, captaram os sinais gerados pelas descargas parciais internas ao transformador. Estes sinais, resultado da emissão acústica da DP, foram amplificados com um ganho de aproximadamente 24 vezes por um circuito eletrônico, tendo em vista que o diafragma gera sinais de baixa amplitude. Um oscilógrafo foi utilizado para adquirir os dados a uma taxa de amostragem de 10 milhões de amostras por segundo. De posse dos dados, os sinais foram pré-processados com a utilização de filtros digitais e métricas de estudo de sinais acústicos, conforme ilustrado na seção 3.5. Estas métricas foram utilizadas para o treinamento supervisionado de uma rede neural do tipo perceptron multicamadas e também um sistema de inferência neuro-difuso adaptativo (ANFIS).

Para o melhor resultado e para cada eixo do sistema de coordenadas retangulares, retornado por estes dois SIs, foi realizado um tratamento estatístico que teve como o objetivo verificar a média, desvio padrão, distribuição dos erros gerados pelos sistemas inteligentes bem como a correlação entre os dados reais e os estimados. De posse dos melhores resultados encontrados para os 16 sensores, variou-se a quantidade de diafragmas piezelétricos necessários para a localização a fim de se efetuar um estudo da melhor combinação da quantidade de sensores pelo esforço computacional exigido nos sistemas inteligentes utilizados. O número inicial de sensores foi escolhido empiricamente para se ter um conjunto de dados de treinamento significativo.

6.2. Geração das descargas parciais

Com o intuito de gerar DPs no interior do transformador, foram desenvolvidos 12 eletrodos de latão, conforme ilustrado na Figura 6.2, 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 um cabo conectou os terminais dos eletrodos até uma placa seletora externa ao transformador, cuja função foi viabilizar a escolha do eletrodo que induziu a descarga parcial no transformador.

Alguns dos eletrodos acoplados ao núcleo são ilustrados na Figura 6.3 e as coordenadas dos 12 eletrodos de testes, mediante um referencial gerado externamente na tampa do dispositivo, são indicados na Tabela 6.1.

Figura 6.2- Eletrodo de latão para a indução de descargas no núcleo do transformador





Figura 6.3- Eletrodos de latão acoplados ao núcleo de um transformador de distribuição (indicados pela seta).



O diagrama elétrico representado pela Figura 6.4 ilustra o circuito utilizado para alimentar os eletrodos e, portanto, gerar as descargas parciais. H1 e H2 representam os terminais do cabo que foi acoplado à placa seletora conforme mostra a Figura 6.5. 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 6.2. Assim como em Clerice (2014), uma resistência elétrica de níquel-cromo foi ligada ao lado de baixa tensão do transformador de potencial (TP) para limitar a corrente nos enrolamentos primário e secundário, sendo a impedância elétrica do enrolamento do secundário do TP refletida no primário, conforme a Equação 6.1.

Tabela 6.1- Posição dos eletrodos de teste em coordenadas retangulares

Eletrodo	Posição dos Eletrodos em coordenadas retangulares		
	x(m)	y(m)	z(m)
E1	0,07	0,135	0,58
E2	0,065	0,155	0,43
E3	0,06	0,51	0,49
E4	0,125	0,605	0,573
E5	0,22	0,565	0,285
E6	0,243	0,525	0,428
E7	0,237	0,475	0,563
E8	0,243	0,335	0,488
E9	0,205	0,26	0,568
E10	0,215	0,12	0,185
E11	0,24	0,14	0,428
E12	0,205	0,06	0,579

Tabela 6.2- Parâmetros dos transformadores utilizados para alimentar os eletrodos.


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

Fonte: Clerice (2014)

$$Z_{\text{primário}} = a^2 \cdot Z_{\text{secundário}} \quad (6.1)$$

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.

Figura 6.4- Diagrama do circuito elevador de tensão elétrica.



(Fonte: CLERICE, 2014)

Figura 6.5- Placa de conexão dos eletrodos




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.

6.3. Estudo da viabilidade do diafragma piezelétrico de baixo custo para a identificação de descargas parciais


Com o objetivo de validar o diafragma piezelétrico de baixo custo para a identificação e localização de descargas parciais, efetuou-se uma comparação dos sinais acústicos captados pelo sensor piezelétrico e por um sensor consolidado na indústria e na academia para aplicações acústicas. O sensor utilizado foi o modelo R15I-AST, fabricado pela *PASA (Physical Acoustic South America)*, apresentado na Figura 6.6 (PASA, 2015). A resposta em frequência fornecida pelo fabricante é dada no Anexo A deste trabalho. O sinal da capsula piezelétrica de baixo custo (modelo 7BB-35-3 da Murata), ilustrada na Figura 6.7, foi amplificado com um ganho de 24 vezes, mediante a utilização do amplificador de instrumentação INA 128P da *Texas*, cuja resposta em frequência se dá até 400 kHz. Na Figura 6.8 é ilustrado o diagrama eletrônico do circuito amplificador. Uma placa de circuito impresso foi projetada para atender à amplificação dos 16 sensores.

Figura 6.6- Sensor de emissão acústica modelo R15I-AST




(Fonte: PASA, 2015)

Figura 6.7- Diafragma piezelétrico de baixo custo



(Adaptado de: MURATA, 2015)

Figura 6.8- Diagrama eletrônico do circuito amplificador para cada cápsula piezelétrica.




(Adaptado de CLERICE, 2014)

Os dois sensores foram acoplados externamente na parede do transformador de distribuição de 30 kVA por meio de parafina líquida oleaginosa. Um eletrodo, conforme descrito na seção 6.2, foi colocado imerso em óleo isolante de forma a permanecer equidistante dos dois sensores. Dez descargas parciais foram realizadas conforme aparato descrito na Seção 6.2 e um oscilógrafo adquiriu os sinais do diafragma piezelétrico, bem como os sinais do sensor R15I-AST com uma taxa de aquisição de 10 milhões de amostras por segundo.

De posse dos dados, os sinais do diafragma foram tratados por meio de um filtro passa alta de 20 kHz a fim de filtrar vibrações oriundas do meio, e a própria faixa de resposta do amplificador foi considerada um filtro anti *aliasing*. O filtro de 20 kHz também foi aplicado para se comparar com melhor efeito a resposta de ambos os sensores, pois o sensor RS15I responde somente frequências de ultrassom.

Mediante isso, houve o tratamento dos sinais no domínio do tempo, com o estudo do sinal puro e do comportamento do valor RMS, bem como sua densidade espectral de potência para ambos os sensores. Para o estudo do comportamento RMS, uma janela de período 1ms varreu o sinal, e os valores RMS foram coletados e normalizados para efeito comparativo entre os sinais. O período de integração se deu pelo tempo de janelamento do sinal. Os dados foram correlacionados e o sensor de baixo custo foi validado para aplicação de identificação e localização de descargas parciais conforme análise do Capítulo 7. O teste de validação do sensor PZT é ilustrado na Figura 6.9.

Figura 6.9- Teste comparativo entre o sensor de baixo custo e o R15I-AST



6.4. Localização de Descargas Parciais

Após a validação do sensor de baixo custo para a identificação de descargas parciais, foi realizada a montagem do sistema de localização de descargas parciais. Dezesesseis sensores foram acoplados na parede do transformador de 30 kVA, de dimensões 0,305 x 0,67 x 0,625 m, por meio de parafina líquida oleaginosa. O número de sensores foi escolhido empiricamente a fim de fornecer um número significativo de massa de dados para alimentar os sistemas inteligentes utilizados neste trabalho. As coordenadas dos sensores são mostradas na Tabela 6.3.

A Figura 6.10 mostra os sensores acoplados no transformador e na Tabela 6.3 é indicada a posição dos sensores mediante um referencial externo à tampa do transformador. Cada sensor teve sua saída amplificada com um ganho de 25 vezes, conforme explicado na seção 6.3 e um oscilógrafo captou os sinais com uma taxa de aquisição de 10 milhões de amostras por segundo. Para cada eletrodo foi gerado uma descarga parcial e, deste modo, para cada DP, 16 sinais foram obtidos. Estes sinais foram tratados com um filtro digital passa alta de 20 kHz, a fim de eliminar vibrações do meio. Foi considerado o próprio sistema amplificador um filtro anti aliasing, pois o mesmo possui resposta em frequência até 400 kHz.

De posse dos 16 sinais de cada descarga gerada internamente ao transformador, algumas métricas foram calculadas a fim de se tornarem as entradas dos sistemas RNA e ANFIS. São elas: valor RMS do sinal, energia do sinal, Skewness, Kurtosis, valor de pico do sinal, tempo de energia mínima segundo o critério de energia

e tempo de mínimo segundo o critério estatístico de Akaike. Para aprofundamento sobre estas métricas utilizadas, pode-se consultar a Seção 3.5 deste trabalho.

Tabela 6.3- Posição dos eletrodos de teste em coordenadas retangulares

Sensor	Posição dos sensores em coordenadas retangulares		
	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

Figura 6.10- Sensores acoplados para o teste de localização de DPs



6.4.1. Treinamento da Rede Neural Perceptron Multicamadas

Para se estimar a localização da descarga parcial, foi treinada uma rede neural *perceptron* multicamadas, com entradas obtidas pelas métricas calculadas. O treinamento da rede foi do tipo supervisionado.

Na Tabela 6.4 é ilustrado a combinação destas métricas para o treinamento da rede neural. A Tabela 6.5 ilustra as combinações de números de neurônios e de camadas escondidas utilizadas neste trabalho. O algoritmo de treinamento utilizado foi o de Levenberg Marquardt, a função de ativação utilizada foi a sigmoide e o critério de parada foi o número de 300 épocas. Para cada topologia, os treinamentos foram separados utilizando-se as métricas do sinal separadas das métricas temporais retornados pelo critério de energia e Akaike, com a finalidade de se comparar a eficácia das entradas que correlacionam às métricas do sinal com as métricas temporais. Os erros médios foram calculados e apresentados apenas para topologias que indicaram um valor de erro médio menor que 0,1m.

Tabela 6.4 – Combinação de entradas da Rede Neural

Treinamento	Combinação de Entradas da Rede Neural
1	RMS
2	RMS e Energia
3	RMS, Energia e Valor de Pico
4	RMS, Energia, Valor de Pico, Kurtosis e Skewness
5	Energia
6	Energia e Valor de Pico
7	Energia, Valor de Pico, Kurtosis e Skewness
8	Valor de Pico, Kurtosis e Skewness
9	Energia, Kurtosis e Skewness
10	RMS, Kurtosis e Skewness
11	Kurtosis e Skewness
12	Tempo de mínimo segundo critério de energia
13	Tempo de mínimo segundo critério de Akaike
14	Tempo de mínimo segundo critério de energia e Akaike

Tabela 6.5- Topologias executadas de redes neurais do tipo perceptron multicamadas para o eixo X, Y e Z.

Topologia	Número de Neurônios nas Camadas Escondidas		
	Camada 1	Camada 2	Camada 3
1	5	0	0
2	10	0	0
3	15	0	0
4	5	5	0
5	10	5	0
6	15	5	0
7	15	10	0
8	15	15	0
9	5	5	5
10	10	5	5
11	10	10	5
12	10	10	10
13	15	10	10
14	15	15	10
15	15	15	15
16	20	10	10
17	20	15	10
18	20	15	15
19	20	10	15
20	20	20	20

A apresentação e a validação estatística dos dados retornados pela rede se deram apenas para o melhor treinamento. Sendo assim, para este treinamento, foi realizado um estudo mais detalhado que envolveu o cálculo do erro relativo médio, desvio padrão do erro relativo médio e do coeficiente de correlação linear entre os dados externados pela rede e seus respectivos valores reais. Também se mostrou a dispersão dos erros e o gráfico de correlação para o melhor treinamento.

6.4.2. Treinamento do Sistema de Inferência Neuro-Difuso Adaptativo

Para o treinamento do sistema ANFIS proposto, foi utilizado a mesma combinação de entradas conforme a Tabela 6.4 e o treinamento também foi supervisionado. Para a topologia dos sistemas utilizados, apenas variou-se o número de funções de pertinência conforme Tabela 6.6.

Tabela 6.6- Topologias executadas de Sistemas ANFIS para X, Y e Z.

Topologia	Número de Funções de Pertinência do Tipo Gaussiana
1	1
2	2
3	3
4	4
5	5
6	6
7	7
8	8
9	9
10	10
11	11
12	12
13	13
14	14
15	15
16	20
17	30
18	40
19	50
20	60

Utilizou-se o sistema de inferência Fuzzy do tipo Takagi-Sugeno, com função de pertinência do tipo gaussiana. O critério de parada foi o número de 300 épocas. Conforme foi realizado para os dados retornados pela RNA, os erros médios foram

apresentados apenas para topologias que indicaram um valor de erro médio menor que 0,1m e a validação estatística dos dados retornados pelo sistema ANFIS se deu apenas para o melhor treinamento mediante as topologias apresentadas. O mesmo estudo também foi realizado para a melhor topologia, isto é, cálculo do erro relativo médio, desvio padrão do erro relativo médio e do coeficiente de correlação linear entre os dados externados pela rede e seus respectivos valores reais. Também se mostrou a dispersão dos erros e o gráfico de correlação para o melhor treinamento.

6.4.3. Variação do número de Sensores para a Localização das DPs

A partir da melhor combinação de treinamento e topologia para a localização de descargas parciais por meio dos sistemas inteligentes do tipo RNA e ANFIS, variou-se a quantidade de diafragmas piezelétricos acoplados na carcaça do transformador. O critério adotado foi diminuir o número de sensores para 12, 8 e 4. Um sensor de cada face do transformador foi retirado para cada quadra de sensores diminuída. Deste modo, variou-se o número de sensores somente para a melhor combinação de entradas de treinamento retornadas pelos resultados obtidos com o número total de sensores utilizados.

Foram treinados novamente os dois tipos de sistemas inteligentes com a mesma configuração dos 16 sensores e, mediante os novos resultados de localização, variou-se as topologias das RNAs e ANFIS, conforme Tabelas 6.5 e 6.6. Para efeito comparativo, foi realizado um estudo breve da relação entre a quantidade de sensores e o custo computacional de se treinar um sistema inteligente com menor massa de dados, já que se reduziu o número de sinais e, conseqüentemente, as métricas de entradas utilizadas para o treinamento supervisionado.

Semelhantemente às Seções 6.4.1 e 6.4.2, somente o treinamento cujo erro médio foi menor que 0,1m foi apresentado. Também foi realizado um estudo estatístico mais profundo somente para a melhor topologia encontrada e cujo erro médio não ultrapassou 0,01m. Para o treinamento do sistema ANFIS foi necessário incrementar mais duas topologias: a 21, com 70 funções de pertinência e a topologia 22, com 80 funções de pertinência.

CAPÍTULO 7- ANÁLISE E RESULTADOS

Este capítulo aborda a os resultados comparativos que culminou com a validação do sensor de baixo custo para a identificação de DPs, bem como os resultados de treinamento das redes neurais e sistema ANFIS para a localização das descargas parciais.

7.1. Comportamento da Resposta do Sensor de Baixo Custo em Relação ao Sensor R15I-AST.

Visando o objetivo de se estabelecer um sistema de baixo custo para a localização de descargas parciais, foi analisado o comportamento do diafragma piezelétrico de baixo custo, também chamado “sensor PZT”, em relação ao sensor R15I-AST, consolidado para esta aplicação. Nas Figuras 7.1 e 7.2 são indicados os sinais dos dois sensores no domínio do tempo para uma descarga parcial. Cabe destacar que o sinal referente ao diafragma piezelétrico (sensor PZT) foi tratado por meio de um filtro digital passa alta de 20kHz

Figura 7.1- Sinal do sensor de baixo custo no domínio do tempo





Figura 7.2- Sinal do sensor R15I-AST no domínio do tempo



Conforme observado nas Figuras 7.1 e 7.2 ambos os sensores apresentaram um pico no instante de tempo de 0,02 segundos, tendo um decaimento até 0,04 segundos. Para uma melhor análise, tem-se o comportamento do valor RMS ao longo do tempo, conforme é verificado nas Figuras 7.3 e 7.4. Os três valores destacados são apresentados na Tabela 7.1 e a janela utilizada foi de 1ms.

Figura 7.3- Comportamento do valor RMS para o sensor PZT





Figura 7.4- Comportamento do valor RMS para o sensor R15I-AST

Os comportamentos de ambos os valores RMS indicam uma grande significância entre os dois sensores, confirmados pela Tabela 7.1 e a Figura 7.5.


Tabela 7.1 Pontos destacados nas Figuras 7.4 e 7.5

Ponto	Valores RMS em relação ao pico máximo (%)	Tempo para o sensor PZT (ms)	Tempo para o sensor R15I-AST (ms)
1	1	2,1	2,1
2	0,707	2,4	2,3
3	0,1	3,6	3,5

Os pontos destacados indicam que, no mesmo instante de tempo ocorreu o valor máximo da onda acústica incidida sobre os dois sensores. A atenuação do sinal teve também um comportamento muito próximo. Houve uma queda de 3dB (0,707V) da tensão máxima, nos instantes 2,3ms para o sensor PZT e 2,4ms para o R15I. Já para a atenuação do sinal acústico em 10% do valor do pico máximo de RMS, essa diferença de tempos se deu também no valor de 1ms. No mais, conforme observado na Figura 7.4, o coeficiente de aproximação linear foi de 0,992, indicando que a emissão acústica gerada pela descarga parcial excitou de forma similar ambos os sensores, já que esta métrica, conforme Seção 3.5.1, avalia a carga sonora aplicada ao sensor. Portanto, através desta análise, pode-se relevar que o sensor de baixo

custo possui um grande potencial para ser aplicado na identificação de descargas parciais.

Figura 7.5- Aproximação Linear para o valor RMS de ambos sensores



Para a análise de sinais no domínio da frequência, utilizou-se a ferramenta de densidade espectral de potência, conforme ilustra a Figura 7.6. Tabela 7.2 retorna os valores destacados na Figura 7.6.

Figura 7.6- Densidade Espectral de Potência para os sensores utilizados




Tabela 7.2 Pontos destacados na Figura 7.6

Sensor	Ponto	Atenuação (dB)	PSD (dB/Hz)	Frequência (kHz)
PZT	1	3	91.5	180
	2	10	98.15	360
R15I-AST	1	3	73.21	260
	2	10	80.21	340

Mediante a análise de distribuição de potência, pode-se notar que o sensor PZT tem uma atenuação de 3dB na frequência de 180kHz e uma atenuação de 10dB em 360kHz para o fenômeno de descargas parciais. Já o sensor R15I-AST possui estas mesmas atenuações em 260kHz e 340kHz, indicando uma maior sensibilidade em frequência do que o sensor de baixo custo. Embora verifique-se esta diferença, pode-se observar que o sensor PZT, mesmo com um ganho menor de densidade espectral, cobriu a mesma faixa de frequência que o sensor consolidado. Para ambos, a faixa mais significativa do fenômeno de descargas parciais se deu em até 250kHz, embora verifica-se um baixo nível de densidade espectral para as frequências de até 400kHz. Sendo assim, pode-se afirmar também que ao sensor de baixo custo possui grande potencial na identificação de descargas parciais tendo em vista o conteúdo de frequência gerado e observado nesta análise.

7.2. Ensaios de Localização de Descargas Parciais por Meio da Rede Neural do tipo Perceptron Multicamadas.

Mediante as combinações de treinamento e topologias apresentados pelas Tabelas 6.4 e 6.5 respectivamente, observou-se que, para as combinações de entrada da rede neural que utilizaram métricas de sinal como o valor RMS, energia, valor de pico, kurtosis e skewness, ou seja, para os treinamentos de 1 a 11, o erro médio de localização fornecido por todas as topologias foi maior que 0,1m para os três eixos. Por conseguinte, os resultados obtidos não foram apresentados de maneira profunda neste trabalho. No entanto, as combinações de treinamento 12, 13 e 14 forneceram resultados significativos conforme mostra a Tabela 7.3

Tabela 7.3 Erro médio de localização retornado pelas topologias da RNA para os três melhores tipos de treinamento.

Topologia	Erro Médio (m) para o Treinamento 12			Erro Médio (m) para o Treinamento 13			Erro Médio (m) para o Treinamento 14		
	x	y	z	x	y	z	x	Y	z
1	0,03	0,08	0,05	0,005	0,02	0,009	0,019	0,04	0,035
2	0,01	0,08	0,03	0,001	0,007	0,003	0,017	0,04	0,08
3	0,02	0,08	0,03	0,001	0,005	0,002	0,02	0,05	0,04
4	0,01	0,07	0,06	0,001	0,003	0,001	0,009	0,03	0,005
5	0,02	0,1	0,02	0,0009	0,004	0,001	0,012	0,02	0,02
6	0,03	0,14	0,02				0,02	0,02	0,02
7	0,02	0,06	0,05				0,03	0,04	0,01
8	0,02	0,13	0,05				0,004	0,01	0,02
9	0,03	0,05	0,02				0,01	0,02	0,02
10	0,03	0,06	0,03				0,01	0,02	0,01
11	0,02	0,07	0,02				0,008	0,03	0,02
12	0,01	0,14	0,04				0,007	0,01	0,02
13	0,05	0,04	0,07				0,007	0,01	0,02
14	0,02	0,05	0,04				0,004	0,03	0,01
15	0,02	0,05	0,04				0,01	0,02	0,02
16	0,01	0,06	0,04				0,006	0,02	0,01
17	0,02	0,08	0,05				0,003	0,01	0,008
18	0,04	0,07	0,04				0,006	0,02	0,012
19	0,03	0,05	0,04				0,004	0,02	0,01
20	0,04	0,05	0,04				0,004	0,03	0,01

Para o treinamento 12, cujas entradas das RNAs do tipo *perceptron* multicamadas foram apenas o valor do tempo mínimo segundo o critério de energia, o erro médio para o eixo x variou de 0,01m a 0,05m, em y de 0,04m a 0,14m e em z o erro médio variou de 0,02 a 0,06m mostrando eficácia neste método em se localizar descargas parciais, uma vez que, estes erros médios apresentados, embora não

retornem de forma exata o ponto de ocorrência da descarga, podem nortear a região de ocorrência da mesma.

Para o treinamento 13, em que as entradas para o treinamento da rede se deram pelo valor de tempo mínimo segundo o critério estatístico de Akaike, todos os valores de erro médio, para os eixos x, y e z, ficaram na casa dos milímetros, indicando grande potencialidade do método para realizar a localização de descargas parciais. Observa-se que, para o eixo x, o erro médio foi de 0,0009m, em y foi de 0,004 e em z, 0,001, indicando grande precisão na localização do ponto de descarga parcial. Esta combinação demonstrou o melhor resultado para o treinamento das redes *perceptron* multicamadas. Este estudo contemplou somente as cinco primeiras topologias para este tipo de treinamento devido ao resultado já retornado pela rede neural. As Tabelas 7.4, 7.5 e 7.6 apresentam os dados retornados pela RNA para as coordenadas da descarga parcial nos eixos x, y e z, respectivamente para a melhor topologia encontrada (Topologia 5). A Tabela 7.7 apresenta os erros máximos, mínimos e médio do treinamento, em questão, bem como o desvio padrão e o coeficiente de correlação entre os dados reais e os dados externados pela rede neural.

Com relação ao treinamento 14, que utilizou como entrada os critérios de energia e Akaike, observou-se que a melhor topologia apresentada foi a 17, indicando um erro de 0,003m para o eixo x, 0,01m para o eixo y e 0,008 para o eixo z. Embora este treinamento tenha retornado um erro médio que indica uma significativa exatidão na localização do ponto de DP, observa-se que o método híbrido (Akaike e energia) utilizado no treinamento 14, ficou aquém do treinamento 13, que utilizou somente o critério de Akaike.

Observa-se que ambos os treinamentos, 13 e 14, foram eficazes, no entanto, a demanda computacional do treinamento 13, que utilizou apenas duas camadas escondidas com 10 e 5 neurônios, foi muito menor que o treinamento 14, que se valeu de três camadas escondidas com, respectivamente, 20, 15 e 10 neurônios. Além disso, o erro médio foi menor para os três eixos em questão.

Tabela 7.4 Coordenada X estimada pela Rede Neural segundo critério de treinamento 13 e Topologia 5.

Valor Real (m)	Valor Estimado (m)	Erro (mm)	Erro Percentual Relativo (%)
0,065	0,065	0,00	0,02
0,065	0,065	0,00	0,02
0,065	0,065	0,00	0,02
0,243	0,243	0,20	0,08
0,237	0,237	0,30	0,11
0,205	0,205	0,10	0,05
0,243	0,243	0,00	0,00
0,215	0,216	0,70	0,31
0,100	0,098	2,40	2,42
0,205	0,204	0,70	0,34
0,205	0,205	0,10	0,05
0,100	0,098	2,40	2,42
0,070	0,069	0,60	0,93
0,065	0,065	0,00	0,02
0,065	0,065	0,00	0,02
0,070	0,069	0,60	0,93
0,065	0,065	0,00	0,02
0,205	0,205	0,10	0,05
0,065	0,065	0,00	0,02
0,220	0,220	0,40	0,19
0,220	0,220	0,40	0,19
0,205	0,205	0,10	0,05
0,205	0,205	0,10	0,05
0,100	0,111	10,90	10,92
0,220	0,224	4,20	1,90
0,065	0,065	0,00	0,02
0,205	0,205	0,10	0,05
0,237	0,237	0,30	0,11
0,100	0,101	1,20	1,23
0,243	0,242	0,80	0,33
0,125	0,141	15,50	12,38
0,065	0,065	0,00	0,02
0,065	0,065	0,00	0,01
0,205	0,205	0,10	0,05
0,237	0,237	0,30	0,11
0,100	0,098	2,40	2,42
0,215	0,216	0,70	0,31
0,065	0,065	0,00	0,01

Tabela 7.5 Coordenada Y estimada pela Rede Neural segundo critério de treinamento 13 e Topologia 5.

Valor Real (m)	Valor Estimado (m)	Erro (m)	Erro Percentual Relativo (%)
0,155	0,155	0,000	0,117
0,155	0,155	0,000	0,117
0,155	0,155	0,000	0,117
0,335	0,331	0,004	1,173
0,475	0,483	0,008	1,670
0,060	0,059	0,001	1,205
0,525	0,528	0,003	0,485
0,120	0,120	0,000	0,308
0,410	0,407	0,003	0,640
0,260	0,257	0,003	0,973
0,060	0,059	0,001	1,205
0,410	0,407	0,003	0,640
0,135	0,135	0,000	0,058
0,155	0,155	0,000	0,117
0,155	0,155	0,000	0,117
0,135	0,135	0,000	0,058
0,155	0,155	0,000	0,162
0,060	0,059	0,001	1,205
0,155	0,155	0,000	0,162
0,565	0,575	0,010	1,683
0,565	0,575	0,010	1,683
0,060	0,061	0,002	2,424
0,060	0,059	0,001	1,205
0,410	0,423	0,013	3,090
0,565	0,569	0,004	0,710
0,155	0,155	0,000	0,117
0,060	0,059	0,001	1,205
0,475	0,483	0,008	1,670
0,410	0,410	0,000	0,034
0,525	0,459	0,066	12,512
0,605	0,585	0,020	3,228
0,155	0,155	0,000	0,117
0,155	0,155	0,000	0,260
0,060	0,059	0,001	1,205
0,475	0,483	0,008	1,670
0,410	0,407	0,003	0,640
0,120	0,120	0,000	0,308
0,155	0,155	0,000	0,260

Tabela 7.6 Coordenada Z estimada pela Rede Neural segundo critério de treinamento 13 e Topologia 5.

Valor Real (m)	Valor Estimado (m)	Erro (m)	Erro Percentual Relativo (%)
0,430	0,430	0,000	0,028
0,430	0,430	0,000	0,028
0,430	0,430	0,000	0,028
0,488	0,486	0,002	0,358
0,563	0,561	0,002	0,401
0,579	0,579	0,000	0,042
0,428	0,428	0,000	0,102
0,185	0,185	0,000	0,079
0,430	0,432	0,002	0,460
0,568	0,565	0,003	0,561
0,579	0,579	0,000	0,042
0,430	0,432	0,002	0,460
0,580	0,580	0,000	0,068
0,430	0,430	0,000	0,028
0,430	0,430	0,000	0,028
0,580	0,580	0,000	0,068
0,430	0,430	0,000	0,014
0,579	0,579	0,000	0,042
0,430	0,430	0,000	0,014
0,285	0,283	0,002	0,860
0,285	0,283	0,002	0,860
0,579	0,579	0,000	0,060
0,579	0,579	0,000	0,042
0,430	0,421	0,009	2,125
0,285	0,282	0,003	1,153
0,430	0,430	0,000	0,028
0,579	0,579	0,000	0,042
0,563	0,561	0,002	0,401
0,430	0,429	0,001	0,228
0,428	0,426	0,003	0,573
0,573	0,570	0,003	0,559
0,430	0,430	0,000	0,028
0,430	0,430	0,000	0,016
0,579	0,579	0,000	0,042
0,563	0,561	0,002	0,401
0,430	0,432	0,002	0,460
0,185	0,185	0,000	0,079
0,430	0,430	0,000	0,028

Tabela 7.7 Análise estatística da melhor topologia e treinamento apresentado para a RNA.

Tipo de RNA	Eixos	Erro Máximo (m)	Erro Mínimo (m)	Erro Médio (m)	Erro Relativo Médio (%)	Desvio Padrão	Coefficiente de Correlação
Treinamento 13 Topologia 5	X	0,02	0	0,001	1	0,003	0,99
	Y	0,06	0	0,005	1,17	0,01	0,99
	Z	0,009	0	0,001	0,28	0,001	0,99

Nas Figuras de 7.7 a 7.9 são apresentados os histogramas de distribuição dos erros dos valores utilizados para o treinamento bem como utilizados para o teste (valores gerados pela RNA) para os eixos x, y e z para o treinamento 13 e topologia 5. As Figuras de 7.10 a 7.12 apresentam a correlação dos dados externados pelo sistema inteligente e os valores reais conhecidos.

Figura 7.7- Histograma de Erros para o Eixo X para o treinamento 13 e topologia 5




Figura 7.8- Histograma de Erros para o Eixo Y para o treinamento 13 e topologia 5




Figura 7.9- Histograma de Erros para o Eixo Z para o treinamento 13 e topologia 5




Figura 7.10- Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pela Rede (VR) e Valores Reais Desejados (VD) para o Eixo X (treinamento 13 e topologia 5).




Figura 7.11- Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pela Rede (VR) e Valores Reais Desejados (VD) para o Eixo Y (treinamento 13 e topologia 5).





Figura 7.12- Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pela Rede (VR) e Valores Reais Desejados (VD) para o Eixo Z (treinamento 13 e topologia 5).



Mediante as Figuras 7.6, 7.7 e 7.8 observa-se que, para o treinamento 13, unicamente pelo critério de Akaike, a distribuição dos erros ficou muito próxima ao erro médio tanto para os dados de treinamento, quanto para os dados de teste (valor estimado pela rede neural) para os três eixos, indicando uma distribuição gaussiana dos erros muito próxima ao erro médio.

A análise das Figuras de 7.10 a 7.12 confirmam o elevado grau de similaridade previsto pelas tabelas de 7.6 a 7.8. Observa-se que, para os três eixos a aproximação linear da coluna do valor estimado pela rede neural (VR) e o Valor Desejado (VD) possuem uma relação de similaridade, para os três eixos, de 99%, indicando que a topologia 5 e treinamento 13 é apta para ser utilizada na localização de descargas parciais em transformadores.

7.3. Ensaios de Localização de Descargas Parciais por Meio Do Sistema ANFIS.

Mediante as combinações de treinamento e topologias apresentados pelas Tabelas 6.4 e 6.5 respectivamente, observou-se que, assim como nos treinamentos das topologias utilizadas das redes neurais, para as combinações de entrada do sistema ANFIS que utilizaram métricas de sinal como o valor RMS, energia, valor de pico, kurtosis e skewness, ou seja, os treinamentos de 1 a 11, o erro médio de localização fornecido por todas as topologias foi maior que 0,1m para os três eixos. Por conseguinte, os resultados obtidos não foram apresentados de maneira profunda neste trabalho. No entanto, as combinações de treinamento 12, 13 e 14 forneceram resultados significativos conforme mostra a Tabela 7.8.

Para o treinamento 12 cujas entradas do sistema ANFIS foram apenas o valor do tempo mínimo segundo o critério de energia, o menor erro médio encontrado foi para a topologia 20, que usa 60 funções de pertinência do tipo gaussiana para treinar o sistema. Observa-se que o erro encontrado para os eixos x , y e z convergem de forma exata da origem da descarga parcial, uma vez que os valores encontrados de erro médio foi de 0,008m para o eixo x , 0,01m para o eixo y e 0,02m para o eixo z . Sendo assim, este critério se mostra eficaz para a localização de descargas parciais, tendo em vista que o erro médio, para os eixos x e y , não ultrapassou 1cm e, no entanto, foi de 2cm para o eixo z .

Para o treinamento 13 cuja entrada se dá apenas pelo critério estatístico de Akaike, a melhor topologia apresentada também se deu com a utilização de 60 funções de pertinência do tipo gaussiana. Obteve-se então, um erro de 0,0006m para o eixo x , 0,001m para y e 0,008m para o eixo z , indicando novamente grande potencialidade deste critério para aplicação de localização de descargas parciais em transformadores. O melhor resultado encontrado para o treinamento do sistema ANFIS se deu neste treinamento e nesta topologia.

Com relação ao treinamento 14, que utilizou como entrada os critérios de energia e Akaike, observou-se que a melhor topologia apresentada foi a que utilizou também as 60 funções de pertinência do tipo gaussiana. No entanto, o erro médio foi superior a 0,01m para o eixo z (0,02m de erro), indicando novamente que o critério

híbrido fica aquém do critério de treinamento que usa puramente os valores fornecidos por Akaike.

Tabela 7.8 Erro médio de localização retornado pelas topologias do sistema ANFIS

Topologia	Erro Médio (m) para o Treinamento 12			Erro Médio (m) para o Treinamento 13			Erro Médio (m) para o Treinamento 14		
	x	y	z	x	y	z	x	y	z
5	0,12	0,15	0,05	0,04	0,04	0,06	0,08	0,1	0,12
6	0,10	0,13	0,06	0,01	0,04	0,03	0,08	0,09	0,1
7	0,09	0,1	0,06	0,01	0,04	0,03	0,09	0,08	0,09
8	0,06	0,1	0,05	0,01	0,03	0,03	0,04	0,08	0,06
9	0,05	0,1	0,05	0,01	0,04	0,03	0,04	0,06	0,04
10	0,04	0,09	0,06	0,01	0,03	0,02	0,02	0,06	0,04
11	0,04	0,09	0,05	0,02	0,04	0,03	0,02	0,05	0,03
12	0,03	0,08	0,04	0,007	0,02	0,01	0,01	0,05	0,02
13	0,02	0,08	0,05	0,01	0,02	0,03	0,01	0,04	0,02
14	0,01	0,06	0,04	0,003	0,006	0,01	0,01	0,02	0,02
15	0,02	0,06	0,04	0,01	0,03	0,02	0,01	0,02	0,02
16	0,02	0,05	0,04	0,008	0,01	0,02	0,01	0,01	0,02
17	0,02	0,05	0,04	0,008	0,01	0,02	0,01	0,02	0,02
18	0,01	0,03	0,02	0,003	0,01	0,02	0,01	0,02	0,02
19	0,009	0,01	0,02	0,003	0,01	0,01	0,02	0,01	0,01
20	0,008	0,01	0,02	0,0006	0,001	0,008	0,007	0,01	0,02

As Tabelas 7.9, 7.10 e 7.11 ilustram os dados retornados pelo sistema ANFIS para cada coordenada da descarga parcial nos eixos x, y e z, para o melhor resultado encontrado para o treinamento 13, isto é, critério puro de Akaike, alimentando um sistema ANFIS com 60 funções de pertinência.

Tabela 7.9 Coordenada X estimada pelo sistema ANFIS segundo critério de treinamento 13 e 60 funções de pertinência do tipo gaussiana.

Valor Real (m)	Valor Estimado (m)	Erro (m)	Erro Percentual Relativo (%)
0,065	0,065	0,000	0,022
0,065	0,065	0,000	0,022
0,065	0,065	0,000	0,022
0,243	0,243	0,000	0,001
0,237	0,237	0,000	0,174
0,205	0,205	0,000	0,000
0,243	0,243	0,000	0,000
0,215	0,215	0,000	0,111
0,100	0,099	0,001	0,625
0,205	0,203	0,002	1,086
0,205	0,205	0,000	0,000
0,100	0,099	0,001	0,625
0,070	0,070	0,000	0,001
0,065	0,065	0,000	0,022
0,065	0,065	0,000	0,022
0,070	0,070	0,000	0,001
0,065	0,065	0,000	0,026
0,205	0,205	0,000	0,000
0,065	0,065	0,000	0,026
0,220	0,220	0,000	0,037
0,220	0,220	0,000	0,037
0,205	0,205	0,000	0,000
0,205	0,205	0,000	0,000
0,100	0,107	0,007	7,304
0,220	0,220	0,000	0,025
0,065	0,065	0,000	0,022
0,205	0,205	0,000	0,000
0,237	0,237	0,000	0,174
0,100	0,099	0,001	1,168
0,243	0,243	0,000	0,000
0,125	0,136	0,011	8,511
0,065	0,065	0,000	0,022
0,065	0,065	0,000	0,012
0,205	0,205	0,000	0,000
0,237	0,237	0,000	0,174
0,100	0,099	0,001	0,625
0,215	0,215	0,000	0,111
0,065	0,065	0,000	0,012

Tabela 7.10 Coordenada Y estimada pelo sistema ANFIS segundo critério de treinamento 13 e 60 funções de pertinência do tipo gaussiana.

Valor Real (m)	Valor Estimado (m)	Erro (m)	Erro Percentual Relativo (%)
0,155	0,155	0,000	0,022
0,155	0,155	0,000	0,022
0,155	0,155	0,000	0,022
0,335	0,335	0,000	0,004
0,475	0,474	0,001	0,174
0,060	0,060	0,000	0,000
0,525	0,525	0,000	0,000
0,120	0,117	0,003	2,779
0,410	0,409	0,001	0,196
0,260	0,291	0,031	11,990
0,060	0,060	0,000	0,000
0,410	0,409	0,001	0,196
0,135	0,135	0,000	0,001
0,155	0,155	0,000	0,022
0,155	0,155	0,000	0,022
0,135	0,135	0,000	0,001
0,155	0,155	0,000	0,026
0,060	0,060	0,000	0,000
0,155	0,155	0,000	0,026
0,565	0,565	0,000	0,019
0,565	0,565	0,000	0,019
0,060	0,060	0,000	0,000
0,060	0,060	0,000	0,000
0,410	0,419	0,009	2,302
0,565	0,565	0,000	0,012
0,155	0,155	0,000	0,022
0,060	0,060	0,000	0,000
0,475	0,474	0,001	0,174
0,410	0,408	0,002	0,370
0,525	0,525	0,000	0,000
0,605	0,593	0,012	2,041
0,155	0,155	0,000	0,022
0,155	0,155	0,000	0,012
0,060	0,060	0,000	0,000
0,475	0,474	0,001	0,174
0,410	0,409	0,001	0,196
0,120	0,117	0,003	2,779
0,155	0,155	0,000	0,012

Tabela 7.11 Coordenada Z estimada pelo sistema ANFIS segundo critério de treinamento 13 e 60 funções de pertinência do tipo gaussiana.

Valor Real (m)	Valor Estimado (m)	Erro (m)	Erro Percentual Relativo (%)
0,430	0,429	0,001	0,341
0,430	0,429	0,001	0,341
0,430	0,429	0,001	0,341
0,488	0,482	0,006	1,197
0,563	0,552	0,011	1,938
0,579	0,590	0,011	1,957
0,428	0,425	0,003	0,726
0,185	0,139	0,046	24,765
0,430	0,427	0,003	0,674
0,568	0,572	0,004	0,698
0,579	0,590	0,011	1,957
0,430	0,427	0,003	0,674
0,580	0,580	0,000	0,024
0,430	0,429	0,001	0,341
0,430	0,429	0,001	0,341
0,580	0,580	0,000	0,024
0,430	0,424	0,006	1,367
0,579	0,590	0,011	1,957
0,430	0,424	0,006	1,367
0,285	0,265	0,020	7,132
0,285	0,265	0,020	7,132
0,579	0,566	0,013	2,221
0,579	0,590	0,011	1,957
0,430	0,414	0,016	3,720
0,285	0,290	0,005	1,751
0,430	0,429	0,001	0,341
0,579	0,590	0,011	1,957
0,563	0,552	0,011	1,938
0,430	0,435	0,005	1,258
0,428	0,429	0,001	0,280
0,573	0,572	0,001	0,156
0,430	0,429	0,001	0,341
0,430	0,434	0,004	0,950
0,579	0,590	0,011	1,957
0,563	0,552	0,011	1,938
0,430	0,427	0,003	0,674
0,185	0,139	0,046	24,765
0,430	0,434	0,004	0,950

Com base nos dados gerados, foram calculados o erro mínimo, máximo, médio, percentual relativo e desvio padrão para cada eixo, conforme Tabela 7.12.

Tabela 7.12 Análise estatística do treinamento 13 com 60 funções de pertinência gaussianas.

Eixos	Erro Máximo (m)	Erro Mínimo (m)	Erro Médio (m)	Erro Percentual Relativo Médio (%)	Desvio Padrão	Coefficiente de Correlação
X	0,01	0	0,0006	0,5	0,002	0,99
Y	0,03	0	0,001	0,6	0,006	0,99
Z	0,04	0	0,008	2,6	0,01	0,99

As Figuras de 7.13 a 7.15 apresentam os histogramas de distribuição dos erros para os eixos x, y e z para o treinamento do sistema ANFIS em questão. Já as Figuras de 7.16 a 7.18 apresentam o gráfico de correlação para a mesma configuração.

Figura 7.13- Histograma de Erros para o Eixo X para o treinamento 13 utilizando 60 funções de pertinência do tipo gaussiana.




Figura 7.14- Histograma de Erros para o Eixo Y para o treinamento 13 utilizando 60 funções de pertinência do tipo gaussiana.




Figura 7.15- Histograma de Erros para o Eixo Z para o treinamento 13 utilizando 60 funções de pertinência do tipo gaussiana.




Figura 7.16- Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pelo sistema ANFIS (VA) e Valores Reais Desejados (VD) para o Eixo X (treinamento 13 e 60 funções de pertinência do tipo gaussiana).




Figura 7.17- Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pelo sistema ANFIS (VA) e Valores Reais Desejados (VD) para o Eixo Y (treinamento 13 e 60 funções de pertinência do tipo gaussiana).





Figura 7.18- Gráfico de Aproximação Linear e Correlação entre os Valores Estimados pelo sistema ANFIS (VA) e Valores Reais Desejados (VD) para o Eixo Z (treinamento 13 e 60 funções de pertinência do tipo gaussiana).



Nas Figuras 7.13, 7.14 e 7.15 observa-se que, para o treinamento 13, unicamente pelo critério de Akaike, a distribuição dos erros ficou muito próxima ao erro médio tanto para os dados de treinamento, quanto para os dados de teste (valor estimado pelo sistema ANFIS) para os três eixos, indicando uma distribuição gaussiana dos erros muito próxima ao erro médio. A análise das Figuras de 7.16 a 7.18 confirmam o elevado grau de similaridade previsto pelas tabelas de 7.12 a 7.14. Observa-se que, para os três eixos a aproximação linear da coluna do valor estimado pelo sistema ANFIS (VA) e o Valor Desejado (VD) possuem uma relação de similaridade, para os três eixos, de 99%, indicando que o treinamento 13 com 60 funções de pertinência do tipo gaussiana é apta para ser utilizada na localização de descargas parciais em transformadores.

Observa-se que, tanto para a RNA de melhor resultado (topologia 20 e treinamento 13), como para o sistema ANFIS, a melhor combinação de entrada de treinamento foi o critério de Akaike. Estes dois tipos de sistemas inteligentes retornaram, nesta pesquisa, o menor erro médio, desvio padrão e correlação verificados. Para efeito comparativo, as Figuras 7.19 e 7.20 ilustram os valores observados de erro médio e desvio padrão para os dois resultados.

Figura 7.19- Comparação entre o erro médio (m) dos dois melhores resultados para RNA e ANFIS.





Figura 7.20- Comparação entre o desvio padrão (m) dos dois melhores resultados para RNA e ANFIS.



Por esta comparação, verifica-se que o erro médio gerado pela rede sistema ANFIS foi menor em relação ao gerado pela RNA, para os eixos x e y . Observa-se que, para ambos os eixos, x e y , a diferença se deu em quatro décimos de milímetros. Já para o eixo z o erro médio gerado pela RNA foi oito vezes menor e a diferença foi de oito décimos de milímetro para a localização do problema. Mediante a análise da Figura 7.20, observa-se que a rede neural utilizada inferiu um menor desvio padrão somente para o eixo z cuja diferença observada foi de nove décimos de milímetro entre os dois sistemas. Para os eixos x e y o sistema ANFIS inferiu um menor desvio cuja diferença foi, para os eixos x e y , respectivamente, de um e quatro décimos de milímetro.

Sendo assim, pode-se afirmar que ambos os sistemas podem ser utilizados para a localização de descargas parciais, tendo em vista que o erro encontrado representa, fisicamente, no transformador, um fator sem significância em virtude de suas dimensões bem como das dimensões de seus componentes.

7.4. Ensaios de Localização de Descargas Parciais com Variação do Número de Sensores.

7.4.1. Treinamentos por Redes Neurais Artificiais

Empregando-se o melhor conjunto de treinamento observado, ou seja, o critério estatístico de Akaike como entrada de treinamento das RNAs e do sistema ANFIS, variou-se a carga de sensores acoplados externamente ao transformador em 12, 8 e 4 sensores, a partir da melhor topologia encontrada com dezesseis sensores acoplados. A tabela 7.13 ilustra os resultados obtidos para o treinamento de uma rede neural do tipo *perceptron* multicamadas para 12 sensores acoplados.

Tabela 7.13 Erro médio de localização retornado pela RNA treinada com 12 sensores

Topologia	Erro Médio (m) para o Treinamento com Doze Sensores		
	X	Y	Z
5	0,001	0,01	0,04
6	0,006	0,003	0,002

Para o uso de dezesseis sensores, a topologia 5 obteve-se um erro médio de 0,001m, 0,005m e 0,001m para o eixo x, y e z, respectivamente. Para o treinamento da mesma topologia com doze sensores, indicado na Tabela 7.13, o erro no eixo x se manteve em 0,001m e cresceu, para os eixos y e z, para 0,01m e 0,04m, respectivamente. Isso indica que a demanda computacional para o treinamento com doze sensores é maior, tendo em vista os resultados obtidos com a topologia 6, que utiliza 5 neurônios a mais na primeira camada escondida. A tabela 7.14 indica o erro mínimo, máximo, médio, percentual relativo e desvio padrão para cada eixo.

Tabela 7.14 Análise estatística para a localização retornada pela RNA treinada com 12 sensores (topologia 6).

Eixos	Erro Máximo (m)	Erro Mínimo (m)	Erro Médio (m)	Erro Percentual Relativo Médio (%)	Desvio Padrão	Coefficiente de Correlação
X	0,003	0	0,001	0,4	0,001	0,99
Y	0,04	0	0,003	1,9	0,008	0,99
Z	0,02	0	0,002	0,5	0,004	0,99

As Figuras de 7.21 a 7.23 apresentam os histogramas de distribuição dos erros para os eixos x, y e z para o treinamento da RNA com 12 sensores. Já as Figuras de 7.24 a 7.26 apresentam o gráfico de correlação para a mesma configuração.

Figura 7.21- Histograma de Erros para o Eixo X para a localização retornada pela RNA treinada com 12 sensores.




Figura 7.22- Histograma de Erros para o Eixo Y para a localização retornada pela RNA treinada com 12 sensores.




Figura 7.23- Histograma de Erros para o Eixo Z para a localização retornada pela RNA treinada com 12 sensores.




Figura 7.24- Aproximação Linear e Correlação entre valores estiados pela RNA (VR) e Valores Reais Desejados (VD) para o Eixo X para a localização retornada pela RNA treinada com 12 sensores.




Figura 7.25- Aproximação Linear e Correlação entre valores estiados pela RNA (VR) e Valores Reais Desejados (VD) para o Eixo Y para a localização retornada pela RNA treinada com 12 sensores.





Figura 7.26- Aproximação Linear e Correlação entre valores estimados pela RNA (VR) e Valores Reais Desejados (VD) para o Eixo Z para a localização retornada pela RNA treinada com 12 sensores.



Nas Figuras 7.21, 7.22 e 7.23 observa-se que, para o uso de 12 sensores, utilizando a topologia 6 alimentada unicamente pelo critério de Akaike, a distribuição dos erros ficou muito próxima ao erro médio tanto para os dados de treinamento, quanto para os dados de teste (valor estimado pela RNA) para os três eixos, indicando uma distribuição gaussiana dos erros muito próxima ao erro médio.

A análise das Figuras de 7.24 a 7.26 confirmam o elevado grau de similaridade previsto pelas Tabelas de 7.13 e 7.14. Observa-se que, para os três eixos a aproximação linear da coluna do valor estimado pela RNA (VR) e o Valor Desejado (VD) possuem uma relação de similaridade, para os três eixos, de 99%, indicando que a utilização de 12 sensores também pode ser utilizada na localização de descargas parciais em transformadores.

A Tabela 7.15 ilustra os resultados obtidos para o treinamento de uma rede neural do tipo *perceptron* multicamadas para 8 sensores acoplados.

Tabela 7.15 Erro médio de localização retornado pela RNA treinada com 8 sensores

Topologia	Erro Médio (m) para o Treinamento com Oito Sensores		
	x	Y	Z
5	0,01	0,03	0,01
6	0,009	0,02	0,08
7	0,008	0,02	0,09
8	0,008	0,04	0,01
9	0,008	0,02	0,01
10	0,006	0,02	0,01
11	0,008	0,01	0,01
12	0,005	0,02	0,01
13	0,005	0,01	0,02
14	0,006	0,01	0,02
15	0,006	0,01	0,008
16	0,006	0,01	0,02
17	0,006	0,02	0,01
18	0,005	0,02	0,02
19	0,005	0,02	0,01
20	0,005	0,02	0,01

Para o uso de dezesseis sensores, a topologia 5 obteve-se um erro médio de 0,001m, 0,005m e 0,001m para o eixo x, y e z, respectivamente. Para o treinamento da mesma topologia com oito sensores, indicado na Tabela 7.16, o erro médio cresceu para 0,01m para o eixo x, 0,03m e 0,01m para os eixos y e z, respectivamente. Mediante os diversos treinamentos efetuados para melhorar o erro, a topologia 15 foi a que obteve um menor erro para os três eixos, sendo 0,006m para o eixo x, 0,01m para o eixo y e 0,008m para o eixo z.

A demanda computacional para este resultado foi maior, tendo em vista os resultados obtidos com a topologia utiliza três camadas escondidas com 15 neurônios cada. No mais, mediante as topologias experimentadas, o erro médio observado no

eixo y ficou na casa de 1cm, muito maior aos treinamentos executados com 16 e 12 sensores que apresentaram erros abaixo de cinco milímetros. Todavia, este treinamento também é apto para se localizar descargas parciais tendo em vista as dimensões do transformador utilizado e de seus componentes internos.

Tabela 7.16 Análise estatística para a localização retornada pela RNA treinada com 8 sensores (topologia 15).

Eixos	Erro Máximo (m)	Erro Mínimo (m)	Erro Médio (m)	Erro Percentual Relativo Médio (%)	Desvio Padrão	Coefficiente de Correlação
X	0,1	0	0,006	3,1	0,02	0,99
Y	0,12	0	0,01	4,1	0,03	0,99
Z	0,1	0	0,008	1,5	0,02	0,99

As Figuras de 7.27 a 7.29 apresentam os histogramas de distribuição dos erros para os eixos x, y e z para o treinamento da RNA com 8 sensores, para os dados de treinamento e teste apresentados à RNA. Já as Figuras de 7.30 a 7.32 apresentam o gráfico de correlação para a mesma configuração.

Figura 7.27- Histograma de Erros para o Eixo X para a localização retornada pela RNA treinada com 8 sensores.




Figura 7.28- Histograma de Erros para o Eixo Y para a localização retornada pela RNA treinada com 8 sensores.




Figura 7.29- Histograma de Erros para o Eixo Z para a localização retornada pela RNA treinada com 8 sensores.





Figura 7.32- Aproximação Linear e Correlação entre valores estiados pela RNA (VR) e Valores Reais Desejados (VD) para o Eixo Z para a localização retornada pela RNA treinada com 8 sensores.



Nas Figuras 7.27, 7.28 e 7.29 observa-se que, para o uso de 8 sensores, utilizando a topologia 15 alimentada unicamente pelo critério de Akaike, a distribuição dos erros ficou muito próxima ao erro médio tanto para os dados de treinamento, quanto para os dados de teste (valor estimado pela RNA) para os três eixos, indicando uma distribuição gaussiana dos erros muito próxima ao erro médio.

A análise das Figuras de 7.30 a 7.32 confirma o elevado grau de similaridade previsto pelas tabelas de 7.15 e 7.16. Observa-se que, para os três eixos a aproximação linear da coluna do valor estimado pela RNA (VR) e o Valor Desejado (VD) possuem uma relação de similaridade aproximada, para os três eixos, de 95%, indicando que a utilização de 8 sensores também pode ser utilizada na localização de descargas parciais em transformadores.

Os resultados obtidos para quatro sensores acoplados obtiveram, para todas as topologias apresentadas neste trabalho, um erro médio maior que 0,1m e um coeficiente de correlação menor que 70%. Esses resultados podem ser consequência do baixo número de dados obtidos para o treinamento da RNA, pois a massa de dados parra treinamento diminuiu com a retirada dos sensores.

A Figura 7.33 resume e apresenta uma comparação dos valores de erro médio gerados pelo sistema inteligente antes da correção realizada por incremento de neurônios e camadas escondidas (topologia 5) para a variação do número de sensores. A Figura 7.34 ilustra, para os três eixos, o erro médio corrigido mediante o uso de topologias de maior demanda computacional para 16, 12 e 8 sensores empregados na localização.

Figura 7.33 - Evolução do erro médio (m) para topologia inicial (5).





Figura 7.34 – Erro médio (m) corrigido para as topologias utilizadas.



Pela análise da Figura 7.33, observa-se que o erro médio cresceu com a diminuição do número de sensores. Sendo assim, o erro foi corrigido aumentando-se a demanda computacional do treinamento da rede, ou seja, aumentou-se a quantidade de neurônios ou de camadas escondidas para que, conforme se observa na Figura 7.34, o erro médio não ultrapassasse a casa de 1cm para os três eixos.

7.1.2. Treinamentos pelo sistema ANFIS

A tabela 7.17 ilustra os resultados obtidos para o treinamento de um sistema ANFIS para 12 sensores acoplados. Mediante os resultados encontrados para a última topologia, ou seja, a que se utiliza 60 funções de pertinência do tipo gaussiana, foram incrementadas mais duas topologias para se obter um melhor resultado de erro médio. Sendo assim, treinou-se mais dois sistemas ANFIS com 70 e 80 funções de pertinência. A Tabela 7.18 indica a análise realizada para o menor erro médio encontrado (topologia 22 com 80 funções de pertinência do tipo gaussiana).

Tabela 7.17 Erro médio de localização retornado pelo sistema ANFIS treinado com 12 sensores

Topologia/Número de Funções de Pertinência	Erro Médio (m) para o Treinamento com Doze Sensores		
	x	y	z
20/60	0,003	0,01	0,01
21/70	0,003	0,03	0,02
22/80	0,001	0,007	0,007

Tabela 7.18 Análise estatística para a localização retornada pelo sistema ANFIS treinada com 12 sensores.

Eixos	Erro Máximo (m)	Erro Mínimo (m)	Erro Médio (m)	Erro Percentual Relativo Médio (%)	Desvio Padrão	Coefficiente de Correlação
X	0,01	0	0,001	1,54	0,004	0,99
Y	0,06	0	0,007	2,96	0,01	0,99
Z	0,03	0	0,007	3,24	0,01	0,99

Para o uso de dezesseis sensores, a topologia 20 obteve-se um erro médio de 0,0006m, 0,001m e 0,008m para o eixo x, y e z, respectivamente. Para o treinamento da mesma topologia com doze sensores, indicado na Tabela 7.17, o erro cresceu para 0,003 no eixo x, 0,01m para o eixo y e 0,01m para o eixo z. Por este motivo, o erro foi corrigindo aumentando-se o número de funções de pertinência e o melhor resultado obtido foi para um treinamento que utilizou 80 funções gaussianas. Os resultados do treinamento estão apresentados pela Tabela 7.21.

As Figuras de 7.35 a 7.37 apresentam os histogramas de distribuição dos erros para os eixos x, y e z para o treinamento do sistema ANFIS com 12 sensores. Já as Figuras de 7.38 a 7.40 apresentam o gráfico de correlação para a mesma configuração.

Figura 7.35- Histograma de Erros para o Eixo X para a localização retornada pelo sistema ANFIS treinado com 12 sensores.




Figura 7.36- Histograma de Erros para o Eixo Y para a localização retornada pelo sistema ANFIS treinado com 12 sensores.




Figura 7.37- Histograma de Erros para o Eixo Z para a localização retornada pelo sistema ANFIS treinado com 12 sensores.




Figura 7.38- Aproximação Linear e Correlação entre valores estiados pelo sistema ANFIS (VA) e Valores Reais Desejados (VD) para o Eixo X para a localização retornada pela RNA treinada com 12 sensores.




Figura 7.39- Aproximação Linear e Correlação entre valores estiados pelo sistema ANFIS (VA) e Valores Reais Desejados (VD) para o Eixo Y para a localização retornada pela RNA treinada com 12 sensores.





Figura 7.40- Aproximação Linear e Correlação entre valores estiados pelo sistema ANFIS (VA) e Valores Reais Desejados (VD) para o Eixo Z para a localização retornada pela RNA treinada com 12 sensores.



Nas Figuras 7.35, 7.36 e 7.37 observa-se que, para o uso de 12 sensores, utilizando a topologia 20, alimentada unicamente pelo critério de Akaike, a distribuição dos erros ficou muito próxima ao erro médio tanto para os dados de treinamento, quanto para os dados de teste (valor estimado pelo sistema ANFIS) para os três eixos, indicando uma distribuição gaussiana dos erros muito próxima ao erro médio.

A análise das Figuras de 7.38 a 7.40 confirmam o elevado grau de similaridade previsto pela Tabela de 7.18. Observa-se que, para os três eixos a aproximação linear da coluna do valor estimado pelo sistema ANFIS (VA) e o Valor Desejado (VD) possuem uma relação de similaridade, para os três eixos, de 99%, indicando que a utilização de 12 sensores também pode ser utilizada na localização de descargas parciais em transformadores.

A Tabela 7.19 ilustra os resultados obtidos para o treinamento de um sistema ANFIS para 8 sensores acoplados externamente na parede do transformador.

Tabela 7.19 Erro médio de localização retornado pelo sistema ANFIS treinado com 8 sensores

Topologia	Erro Médio (m) para o Treinamento com Oito Sensores		
	x	y	z
20	0,02	0,05	0,01
21	0,006	0,02	0,02
22	0,008	0,03	0,02

Para o uso de dezesseis sensores, a topologia 20 obteve-se um erro médio de 0,0006m, 0,001m e 0,008m para o eixo x, y e z, respectivamente. Para o treinamento da mesma topologia com oito sensores, indicado na Tabela 7.20, o erro cresceu para 0,01 no eixo x, 0,05m para o eixo y e 0,01m para o eixo z. Observou-se que o aumento do número de funções de pertinência não fez com que o erro caísse significativamente, como nos casos anteriores.


Tabela 7.20 Análise estatística para a localização retornada pelo sistema ANFIS com 8 sensores.

Eixos	Erro Máximo (m)	Erro Mínimo (m)	Erro Médio (m)	Erro Percentual Relativo Médio (%)	Desvio Padrão	Coefficiente de Correlação
X	0,04	0	0,006	3,2	0,01	0,78
Y	0,1	0	0,02	8,1	0,03	0,88
Z	0,09	0	0,02	3,1	0,02	0,75

O melhor resultado foi obtido pela topologia 21 que externou um erro de 0,006m, 0,02m e 0,02m para os eixos x, y e z, respectivamente. Cabe destacar também que os coeficientes de correlação ficaram abaixo dos encontrados pelos treinamentos anteriores. Apesar dos resultados obtidos neste treinamento, pode-se afirmar que a localização de descargas parciais com 8 sensores, utilizando um sistema ANFIS, é válida quando não se necessita significativa exatidão do sistema, tendo em vista os erros médios e os coeficientes de correlação encontrados.

A Figura 7.41 resume e apresenta uma comparação dos valores de erro médio gerado pelo sistema ANFIS antes da correção realizada pelo incremento de funções


Figura 7.41 - Evolução do erro médio (m) para topologia inicial (60 funções de pertinência).



de pertinência para a variação do número de sensores.

A Figura 7.42 ilustra, para os três eixos, o erro médio corrigido mediante o uso de topologias de maior demanda computacional para 16, 12 e 8 sensores empregados na localização. Mediante análise da Figura 7.41, observa-se que o erro médio cresceu com a diminuição do número de sensores. Sendo assim, o erro foi corrigido, aumentando-se a demanda computacional do treinamento do sistema ANFIS com o aumento da quantidade de funções de pertinência.

Figura 7.42 – Erro médio (m) corrigido para as topologias utilizadas.



Para o treinamento com 12 sensores e Topologia 22, o erro médio não ultrapassou 0,01m conforme a Figura 7.42.

Para efeito comparativo entre os dois tipos de sistemas inteligentes utilizados, a Figura 7.43 indica o erro médio gerado para os resultados fornecidos para a RNA e pelo sistema ANFIS, para todas as quantidades de sensores utilizados para se localizar a descarga parcial. Já na Figura 7.44 é indicado o comportamento do desvio padrão dos ensaios.

Figura 7.43 – Erro médio (m) corrigido para as topologias utilizadas.





Figura 7.44 – Desvio padrão (m) para as topologias utilizadas.



Observa-se que, para o eixo x o erro médio e o desvio padrão fornecido pelo sistema ANFIS foi menor que os valores encontrados no treinamento com RNA. Para os eixos y e z obteve-se um erro médio e um desvio padrão menor para os sistemas treinados pela RNA. Por meio da figura 7.44 pode-se observar que o conjunto de dados treinados por apenas 8 sensores obtiveram um desvio padrão maior que os demais. Deste modo, os ensaios de localização de descargas parciais que utilizaram 16 e 12 sensores se demonstraram mais exatos que os ensaios que utilizam somente 8 sensores.

Os resultados obtidos para quatro sensores acoplados obtiveram, para todas as topologias apresentadas, um erro médio maior que 0,1m e um coeficiente de correlação menor que 70%. Esses resultados podem ser consequência do baixo número de dados obtidos para o treinamento da RNA, pois a massa de dados para o treinamento diminuiu com a retirada dos sensores.

CAPÍTULO 8- CONCLUSÃO

A ocorrência de falhas em transformadores causa um significativo ônus financeiro que se caracteriza muitas vezes por falhas e danos irreversíveis em equipamentos e máquinas gerados por perturbações transitórias de tensão ou mesmo pela ociosidade em diversos setores da economia quando se leva em consideração às interrupções no fornecimento de energia. Sendo assim, a pesquisa em questão apresentou um sistema de localização de descargas parciais em transformadores de isolados a óleo mineral.

Para o objetivo proposto verificou-se que o sensor proposto por este estudo, conhecido como diafragma piezelétrico ou mesmo PZT, tem um grande potencial no que condiz à detecção de descargas parciais, conforme comparação executada com um sensor consolidado no meio industrial e acadêmico (RS15I-AST). Uma vez validado, o sensor foi utilizado para captar os sinais de emissão acústica gerados pela descarga parcial que, por meio de métricas computacionais de processamento digital de sinais, alimentaram dois tipos de sistemas inteligentes: as redes neurais do tipo *perceptron* multicamadas e o sistema de inferência neuro-difuso adaptativo, conhecido pela abreviatura “ANFIS”.

A partir dos dados retornados por estes dois sistemas foi possível obter a localização das descargas parciais geradas dentro do transformador utilizado com significativo grau de exatidão. Fundamentado em tais resultados obtidos no treinamento dos sistemas inteligentes, comparou-se as respostas para os pontos de localização estimados por ambos os tipos de sistemas. Deste modo, pode-se considerar que o modelo proposto por este trabalho se fez eficiente tendo em vista os resultados obtidos de erro médio para as topologias que utilizaram o treinamento com os critérios de energia e Akaike.

Observou-se que os dois tipos de sistemas inteligentes, quando alimentados unicamente pelo critério autorregressivo de Akaike, produziram melhores resultados em comparação aos sistemas treinados pelo critério de energia ou mesmo o critério híbrido (Akaike e energia). Para estes resultados cujo treinamento se deu apenas pelo critério de Akaike, variou-se o número de sensores acoplados externamente na parede de aço do transformador.

Observou-se também que o erro médio aumentou com a diminuição do número de sensores e que, para corrigir isto, foi necessário aumentar a demanda

computacional dos algoritmos utilizados para treinar o sistema ANFIS e RNA. Mediante estas características, estes resultados denotam um conflito de escolha: trabalhar a localização com um número maior de sensores e diminuir a demanda computacional ou optar pelo aumento no número de sensores com menor esforço computacional? Quando se pensa em falhas operacionais humanas, uma menor quantidade de sensores acoplados implica diretamente em menor probabilidade de erro experimental.

Os resultados obtidos poderão contribuir com o desenvolvimento de técnicas de localização de descargas parciais em transformadores de potência, utilizando métodos não invasivos a um custo muito inferior ao mercado. Também os resultados desta pesquisa podem contribuir para o aprimoramento e desenvolvimento de técnicas que possam realizar a localização de DPs em transformadores a plena montagem, já que na literatura, a maioria dos estudos contemplam a localização de descargas parciais em caixas de transformadores sem a parte ativa instalada, isto é, somente com o óleo mineral. Os sensores utilizados neste trabalho não são dedicados especificamente para aplicações acústicas, fazendo surgir inúmeras possibilidades de estudos futuros, seja na área de descargas parciais ou em outras áreas do conhecimento. A partir desta pesquisa surgem então algumas possibilidades para aplicações em trabalhos futuros, tais como:

- A localização de descargas parciais com transformadores atuando a plena carga;
- Realizar um estudo baseado na influência da temperatura na identificação e localização de descargas parciais;
- Realizar um estudo de demanda computacional entre os sistemas do tipo RNA e ANFIS para este caso;
- Utilizar outros tipos de redes neurais como as redes Kohonen, Hopifield ou as *Deep Neural Network* para esta abordagem proposta.

- Realizar um estudo mais profundo entre o conflito do número de sensores pela demanda computacional empregada nos dois sistemas;
- Aplicar esta pesquisa desenvolvida na indústria com a finalidade de que, para cada modelo diferente de transformador fabricado, tenha-se um banco de dados de redes neurais e sistemas ANFIS que possibilitem a localização de descargas parciais em todos os transformadores do mesmo modelo que atuam em campo;
- Projetar um sistema microcontrolado desta pesquisa que possa ser aplicado em campo.

REFERÊNCIAS

- ABRAHAMSON, S.C; NASSAU, N. **In Concise Encyclopedia of Advanced Ceramic Materials**. RJ Brook. Cambridge, MA: MIT Press, pp 351-354, 1991.
- 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.
- ARENY, R. P.; WEBSTER, J. G. **Sensors and Signal Conditioning**. 2ed. New York: John Wiley & Sons, 2000. 587P.
- AUCKLAND, D.W. HYDE, J.R., MCGRIL, 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.
- AZEVEDO, C. H. B. **Metodologia para a eficácia de detecção de descargas parciais por emissão acústica como técnica preditiva de manutenção em transformadores de potência imersos em óleo isolante**. 2009. 89 f. Dissertação (Mestrado), Universidade Federal de Goiás, Goiânia, 2009.
- BAPTISTA, F. G. **Uma contribuição aos sistemas de monitoramento de integridade estrutural baseada na impedância eletromecânica**. 2010. 91f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista Júlio de Mesquita Filho, Ilha Solteira, 2010.
- 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.
- BENINI, L. C. **Estimação da densidade de solos utilizando sistemas de inferência fuzzy**. 2007. 194 f. Tese (Doutorado em Energia da Agricultura). Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista. Botucatu, Brasil. 2007.
- BOCZAR, T. **Application Possibilities of Artificial Neural Networks for Recognizing Partial Discharges Measured by the Acoustic Emission Method**. IEEE Transactions on Dielectrics and Electrical Insulation, 16(1), 214-223, 2009.
- 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.
- BYRD, T. A.; HAUSER, R. D. **Expert systems in production and operations management: research directions in assessing overall impact**. Int. J. Prod. Res., Vol. 29, pp. 2471-2482, 1991.

COSTA, P. I. **Sistema Inteligente para localização de descargas parciais em transformadores de potência**. 2015. 174f. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2015.

COSTA NETO, F. H. **Diagnóstico de falhas incipientes em transformadores de potência utilizando o sistema neuro-difuso ANFIS**. 2013. Trabalho final de curso de Engenharia Elétrica – Universidade Federal do Ceará, Fortaleza, 2013.

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

COELHO, S. S. **Aplicação de sistemas neuro-fuzzy e espectrometria no infravermelho próximo para a identificação em tempo real do teor de nitrogênio foliar em cana de açúcar**. 2014. 153 f. Dissertação (Mestrado) – Faculdade de Engenharia, Universidade Estadual Paulista, Bauru, 2014.

DEVINS, J. C. **The Physics of Patial Discharges in Solid Dielectrics**. IEEE Transactions on Eletrical Insulation. V. EI-19, n.5, p.475-495, 1984.

DISSADO, L. A.; FOTHERGILL, J. C. **Eletrical degradation and breakdown in polymers**. London: Peter Peregrinus, 1992.

DORNENBURG, E.; GERBER, O. E. **Analysis of dissolved and free gases for monitoring performance of oil-filled transformers**. The Brown Boveri Review. v. 54. n.213, p. 104-111, 1967.

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 Dischages 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.

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

GULSK, E. **Digital Analisys 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.

HAROLD, R.T. **Acoustical techniques for detecting and locating electrical discharges**. West Conshohocken: ASTM Publication, v.1: Engineering Dielectrics, 1979.

HAUSCHILD, W. **Zum Öldurchschlag in inhomogenen Feld bei Schaltspannungen**. 1970. Tese – Technical University Dresden, Dresden, 1970.

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.

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.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. **IEC 60270: High-Voltage Teste Techniques - Partial Discharge Measurements**, 2011.

JANG, J.S.R., **ANFIS: Adaptive-Network-based Fuzzy Inference Systems**. IEEE Transactions on Systems, Man, and Cybernetics, Vol. 23, No. 3, pp. 665-685, 1993.

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.

KRISHNAKUMAR, K. **Intelligent systems for aerospace engineering – an overview**. NASA Technical Report, ID: 20030105746, 2003.

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.

KUNDU, P. KISHORE, N. K.; SINHA, A. K. **Simulation and analysis of acoustic wave propagation due to partial discharge activity**. In: IEEE Annual Report Conference Electrical Insulation and Dielectrics Phenomena, Kansas City, p.607-610, 2006.

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

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

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.

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.

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 Eletrical Insulation, v. 2, n. 5, p. 876-888, 1995.

MASSELLI, Y. M. C. **Sistemas Inteligentes em Automação Industrial**. Inatel, Santa Rita do Sapucaí, 2014.

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

MORAIS, D. R. **Ferramenta inteligente para detecção de falhas incipientes em transformadores baseada na análise de gases dissolvidos no óleo isolante**. 2004. 112 f. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal de Santa Catarina. Florianópolis, Brasil. 2004.

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

MOZELLI, L. A. **Controle fuzzy para sistemas Takagi-Sugeno: condições aprimoradas e aplicações**. 2008. 194 f. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal de Minas Gerais. Belo Horizonte, Brasil. 2008.

MUÑOZ, L.A.B. **Learning in Feed-Forward Artificial Neural Networks II**. Encyclopedia of Artificial Intelligence, pp.1004–1011, 2009.

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

NEGNEVITSKY, M. **Artificial intelligence. A guide to intelligent systems**.2. Ed. England: Addison Wesley, 2005.

PASA. Physical Acoustics South America. **Catálogo de produtos**. Disponível em: <<http://www.pacndt.com/downloads/Sensors/AE%20Sensor%20Catalog.pdf>>, acessado 19 de Dezembro de 2015

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.

PEROZIN, A. R. **Inteligência computacional avaliando risco coronariano**. 2002. 208 f. Dissertação (Mestrado em Ciência da Computação). Universidade Federal de Santa Catarina. Florianópolis, Brasil. 2002.

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 sources and localization of partial discharges in noise environments”** Sensors, v.15, p 9882-9898, 2015.

ROCHA, C. A. **Monitoramento da condição da ferramenta de dressagem usando sinais de vibração e modelos neurais**. 2015. 81 f. Dissertação (Mestrado) – Faculdade de Engenharia, Universidade Estadual Paulista, Bauru, 2015.

ROGERS, R.R. **Experiences in the interpretation of incipient faults in power transformers by dissolved gas-in-oil chromatography analysis**. Minutes of Forty-second International Conference of Double Clients, 1975, 10-201.

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 Eletrical Engineering. Vol. 58, pp 91-97, 2007.

SAKODA, H.; NIEDA, K. A. **Characteristics of elastic waves caused by corona discharges in an oil-immersed pole transformer**. IEEE Transactions on Dielectrics and Eletrical Insulation. Vol. 8, pp 276-283, 2001.

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

SHENG, B; ZHOU, W; YU, J; MENG, S; ZHOU, C; HEPBURN, D. **On-line PD Detection and Localization in Cross-bonded HV Cable Systems**. IEEE Transactions on Dielectrics and Electrical Insulation, vol. 21, pp. 2217-2224, 2014.

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

SIVANANDAM, S.N; SUMATHI, S.; DEEPA, S.N. **Introduction to fuzzy logic using Matlab**. 1. Ed. Germany: Springer, 2007.

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 Falhas em Linhas de Distribuição Utilizando Sistemas Especialistas Híbridos**. 2011. 208 f. Tese (Doutorado em Engenharia Elétrica). Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, Brasil. 2011.

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

VELOSO, G. F. C; da SILVA, L.E.B.; LAMBERT-TORRES, G.; PINTO, J.O.P. **Localization of Partial Discharges in Transformers by the Analysis of the Acoustic Emission**. IEEE ISIE 2006, 9-12 de Julho 2006.

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.

ZADEH, L. A. **Fuzzy sets**. *Information and Control*, 8, 338-353, University of California, Berkeley, California, 1965.

ZADEH, L. A. **Outline of a new approach to the analysis of complex systems and decision processes**. IEEE Transactions on systems, Man, and Cybernetics, n. 1, p. 28-44, 1973.

ANEXO A – RESPOSTA EM FREQUENCIA DO SENSOR RS15I-AST

