

**DIEGO ROBERTO MORAIS**

**FERRAMENTA INTELIGENTE PARA DETECÇÃO  
DE FALHAS INCIPIENTES EM  
TRANSFORMADORES BASEADA NA ANÁLISE DE  
GASES DISSOLVIDOS NO ÓLEO ISOLANTE**

**FLORIANÓPOLIS  
2004**

**UNIVERSIDADE FEDERAL DE SANTA CATARINA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA**  
**ELÉTRICA**

**FERRAMENTA INTELIGENTE PARA DETECÇÃO**  
**DE FALHAS INCIPIENTES EM**  
**TRANSFORMADORES BASEADA NA ANÁLISE DE**  
**GASES DISSOLVIDOS NO ÓLEO ISOLANTE**

Dissertação submetida à  
Universidade Federal de Santa Catarina  
como parte dos requisitos para a  
obtenção do grau de Mestre em Engenharia Elétrica

**DIEGO ROBERTO MORAIS**

Florianópolis, Fevereiro de 2004.

“O destino não é uma questão de sorte, é uma questão de escolha,  
não é algo a se esperar, é algo a se conquistar”.

*William Jennings Bryan*

## AGRADECIMENTOS

Ao meu pai, minha mãe e meu irmão, pelo apoio, compreensão, carinho, amor e forças, tão necessários para prosseguir lutando em busca dos ideais e de minha realização pessoal.

À minha namorada Denia, que soube entender e assimilar os desencontros, angústias e a saudade do relacionamento à distância, dando-me incentivo, motivação e muito amor.

À minha professora orientadora, e acima de tudo amiga, Jacqueline Gisèle Rolim, que em troca das suas atividades pessoais e profissionais, dedicou-me o seu tempo, com extrema paciência e compreensão, sendo de fundamental importância para o desenvolvimento deste trabalho.

Aos meus demais familiares, em especial meus padrinhos João Matias e Eleni Salete e primos Eduardo e Cristiane, pelos encontros dos finais de semana na terra natal, e pelos sinceros votos de sucesso em todos os momentos.

Aos meus inúmeros novos amigos, em especial Alexandre de Marco e Marco Marin, pelo companheirismo e apoio no decorrer destes últimos dois anos.

Aos meus inúmeros velhos amigos, em especial Luciano Malaquias e Nelson Clodoaldo de Jesus, que deram-me o incentivo necessário para a arrancada nesta caminhada e que em todos os momentos estiveram do meu lado, me incentivando e comprovando o verdadeiro valor de uma amizade.

Aos demais integrantes do LABSPOT – Laboratório de Sistemas de Potência, laboratório este que se transformou e continua sendo a minha segunda grande família.

A todas as pessoas que de alguma forma ou de outra, me auxiliaram no decorrer destes dois anos de mestrado.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pelo apoio financeiro.

Resumo da Dissertação apresentada à UFSC como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica.

## **FERRAMENTA INTELIGENTE PARA DETECÇÃO DE FALHAS INCIPIENTES EM TRANSFORMADORES BASEADA NA ANÁLISE DE GASES DISSOLVIDOS NO ÓLEO ISOLANTE**

**Diego Roberto Morais**

Fevereiro/2004

Orientadora: Jacqueline Gisèle Rolim.

Área de Concentração: Sistemas de Energia Elétrica

Palavras-chave: Diagnóstico de falhas, Transformadores, Análise dos gases dissolvidos no óleo (DGA), Normas, Redes Neurais, Lógica *Fuzzy*.

RESUMO: O presente trabalho de dissertação aborda o desenvolvimento e a implementação de uma ferramenta de diagnóstico de falhas em transformadores de potência através da análise dos gases dissolvidos no óleo (DGA). O sistema computacional desenvolvido baseia-se na utilização de forma conjunta de critérios de análise dos gases referenciados em normas, de uma rede neural artificial e de um sistema de inferência *fuzzy*. O objetivo da ferramenta é fornecer ao usuário uma resposta que combine os melhores resultados não somente dos métodos tradicionais já consolidados na literatura técnica, bem como das técnicas de inteligência artificial, de forma a aumentar a confiabilidade em relação aos métodos individualmente. Para validação da metodologia e da implementação foram utilizados três conjuntos de dados de geração de gases: da IEC, do CEPEL e dados históricos (utilizados para a validação *fuzzy*), sendo este último grupo obtido junto a um grande concessionário do setor elétrico brasileiro. Os resultados se mostraram bastante promissores no que diz respeito ao diagnóstico de falhas incipientes em transformadores, alcançando níveis de acertos com valores acima de 80%.

Abstract of Dissertation presented to UFSC as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering.

# **AN INTELLIGENT TOOL FOR DETECTION OF INCIPIENT FAULTS IN TRANSFORMERS BASED ON THE DISSOLVED GAS ANALYSIS OF INSULATING OIL**

**Diego Roberto Morais**

February/2004

Advisor: Jacqueline Gisèle Rolim.

Area of Concentration: Electric Energy Systems.

Keywords: Fault Diagnosis, Transformers, Dissolved Gas Analysis (DGA), Standards, Artificial Neural Network, Fuzzy Logic.

**ABSTRACT:** The present master research work describes the development and the implementation of a tool of diagnosis of faults in power transformers through the analysis of dissolved gases in oil. The computational system approach is based on a combined use of some traditional criteria of the dissolved gas analysis published in standards, an artificial neural network and a fuzzy logic system. The objective of the tool is to provide the user an answer obtained from analysis not only of the traditional methods already consolidated in the technical literature, but also via artificial intelligence techniques reaching a higher degree of reliability with respect to each technique individually. For validation of the implemented methodology, three groups of data of generated gases were used: one from IEC, another from CEPEL and a set of historical data (used for the validation the fuzzy system), obtained from a large Brazilian utility. The results obtained with this tool are promising in the diagnosis of incipient faults in transformers, reaching success levels above 80%.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO AO PROBLEMA DE AVALIAÇÃO DO ESTADO DE TRANSFORMADORES E EMPREGO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL NA SUA SOLUÇÃO.....</b>	<b>1</b>
1.1	– APRESENTAÇÃO DO PROBLEMA DE AVALIAÇÃO DO ESTADO DO TRANSFORMADOR .....	1
1.2	– HISTÓRICO E REVISÃO BIBLIOGRÁFICA.....	5
1.3	– CONTRIBUIÇÃO DA PESQUISA E ESTRUTURA DO TRABALHO .....	9
1.4	– CONCLUSÕES.....	10
<b>2</b>	<b>ACOMPANHAMENTO DO ESTADO DE ISOLAMENTOS DE PAPEL IMPREGNADO VIA ANÁLISE DE GASES DISSOLVIDOS .....</b>	<b>12</b>
2.1	– INTRODUÇÃO.....	12
2.2	– CARACTERÍSTICAS DE UM ISOLAMENTO ELÉTRICO.....	12
2.3	– CARACTERÍSTICAS DO PAPEL ISOLANTE.....	14
2.4	– CARACTERÍSTICAS DO ÓLEO MINERAL ISOLANTE.....	15
2.5	– CARACTERÍSTICAS DO PAPEL IMPREGNADO .....	17
2.6	– ENVELHECIMENTO DO PAPEL IMPREGNADO .....	18
2.7	– DIAGNÓSTICOS DE ISOLAMENTOS A PARTIR DA ANÁLISE DE GASES DISSOLVIDOS.....	21
2.7.1	– Métodos Convencionais.....	23
2.7.2	– Métodos Que Utilizam Técnicas De Inteligência Artificial .....	25
2.8	– FATORES QUE CAUSAM INCERTEZAS NO PROCESSO DE DIAGNÓSTICO.....	26
2.9	– CONCLUSÕES.....	27
<b>3</b>	<b>REDES NEURAS ARTIFICIAIS E SISTEMAS DE LÓGICA FUZZY .....</b>	<b>28</b>
3.1	– INTRODUÇÃO.....	28
3.2	– REDES NEURAS ARTIFICIAIS .....	28
3.2.1	– Histórico Das Rna.....	30
3.2.2	– Principais Modelos De Redes Neurais Artificiais.....	32
3.2.3	– Algumas Aplicações De Redes Neurais Artificiais Em Diagnóstico Preventivo De Transformadores .....	38
3.3	– LÓGICA NEBULOSA.....	39
3.3.1	– Histórico.....	40
3.3.2	– Conjuntos <i>Fuzzy</i> .....	41
3.3.3	– Operações Com Conjuntos <i>Fuzzy</i> .....	44
3.3.4	– Regras <i>Fuzzy</i> .....	46
3.3.5	– Algumas Aplicações De Lógica <i>fuzzy</i> Em Diagnóstico Preventivo De Transformadores.....	47
3.4	– CONCLUSÕES.....	48

<b>4</b>	<b>DESCRIÇÃO DA METODOLOGIA PROPOSTA PARA AVALIAÇÃO DO ESTADO DO TRANSFORMADOR.....</b>	<b>49</b>
4.1	– INTRODUÇÃO.....	49
4.2	– MÓDULO 1 – UTILIZAÇÃO DAS NORMAS.....	51
4.2.1	– Método clássico de Rogers .....	52
4.2.2	– Método de Doernenburg .....	53
4.2.3	– Método Previsto na NBR7274.....	54
4.3	– MÓDULO 2 – REDE NEURAL.....	55
4.4	– MÓDULO 3 – REGRAS CONSIDERADAS PARA O SISTEMA DECISOR.....	56
4.5	– MÓDULO 4 – SISTEMA DE INFERÊNCIA FUZZY.....	57
4.5.1	– Nível de Gás Gerado (NG) .....	58
4.5.2	– Taxa de Geração.....	61
4.6	– CONCLUSÕES.....	65
<b>5</b>	<b>APLICAÇÃO DA METODOLOGIA E ANÁLISE DOS RESULTADOS .....</b>	<b>67</b>
5.1	– INTRODUÇÃO.....	67
5.2	– MÓDULO 1 – RESULTADOS – APLICAÇÃO DAS NORMAS .....	68
5.2.1	– Método clássico de Rogers .....	69
5.2.2	– Método de Doernenburg .....	70
5.2.3	– Método previsto na revisão da NBR 7274 .....	72
5.3	– MÓDULO 2 – RESULTADOS – REDE NEURAL.....	73
5.4	– MÓDULO 3 – DIAGNÓSTICO CONJUGADO DE NORMAS E REDE NEURAL .....	74
5.5	– MÓDULO 4 – RESULTADOS – LÓGICA FUZZY.....	75
5.6	– CONCLUSÕES.....	79
<b>6</b>	<b>CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS .....</b>	<b>80</b>
6.1	– CONCLUSÕES.....	80
6.2	– SUGESTÕES PARA TRABALHOS FUTUROS.....	81
	<b>ANEXO A.....</b>	<b>82</b>
	<b>ANEXO B .....</b>	<b>85</b>
	<b>ANEXO C .....</b>	<b>91</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>98</b>



## LISTA DE FIGURAS

<i>Figura 2.1 – Efeito da umidade sobre o envelhecimento do papel manilha com redução de sua resistência à tração a 25% de seu valor original.</i> .....	17
<i>Figura 2.2 – Pressões parciais do equilíbrio térmico de Halstead como função da temperatura.</i> .....	22
<i>Figura 2.3 – Triângulo de Duval.</i> .....	24
<i>Figura 3.1 – Esquema dos constituintes da célula neural.</i> .....	29
<i>Figura 3.2 – Grafo arquitetural de um perceptron de múltiplas camadas com duas camadas ocultas.</i> .....	32
<i>Figura 3.3 – Neurônio Elementar.</i> .....	33
<i>Figura 3.4 – Arquitetura da rede GRNN.</i> .....	35
<i>Figura 3.5 – Operação Interna da Unidade Padrão.</i> .....	36
<i>Figura 3.6 – Representação das funções de pertinência mais usuais.</i> .....	44
<i>Figura 3.7 – Representação gráfica da operação de união.</i> .....	44
<i>Figura 3.8 – Representação gráfica da operação de intersecção.</i> .....	45
<i>Figura 3.9 – Representação gráfica da operação de complemento.</i> .....	45
<i>Figura 4.1 – Fluxograma do Método Proposto.</i> .....	49
<i>Figura 4.2 – Pesos utilizados para formulação – Falha Térmica.</i> .....	56
<i>Figura 4.3 – Pesos utilizados para formulação – Falha Térmica.</i> .....	59
<i>Figura 4.4 – Proporção relativa dos gases para ocorrência de Corona no Óleo.</i> .....	59
<i>Figura 4.5 – Proporção relativa dos gases para ocorrência de Arco no Óleo.</i> .....	60
<i>Figura 4.6 – Pesos utilizados para formulação – Falha Elétrica.</i> .....	60
<i>Figura 4.7 – Conjuntos fuzzy de Nível de Gás Gerado Final (NGF).</i> .....	61
<i>Figura 4.8 – Conjuntos fuzzy de Taxa de Geração Anormal Final (TGF).</i> .....	62
<i>Figura 4.9 – Operações com os valores de pertinências dos conjuntos fuzzy.</i> .....	64
<i>Tabela 5.17 – Dados correspondentes a um determinado equipamento e diagnósticos obtidos.</i> .....	77
<i>Figura 5.1 – Interface que representa a saída do programa desenvolvido.</i> .....	79

## LISTA DE TABELAS

<i>Tabela 2.1 – Principais técnicas utilizadas na estimativa do envelhecimento e degradação do sistema isolante. ....</i>	<i>20</i>
<i>Tabela 2.2 – Efeito da temperatura na formação de gases dissolvidos.....</i>	<i>26</i>
<i>Tabela 2.3 – Resultados de exatidão para resultados DGA para diferentes laboratórios. ....</i>	<i>27</i>
<i>Tabela 4.1 – Tabela de definição dos códigos do método de Rogers. ....</i>	<i>52</i>
<i>Tabela 4.2 – Tabela de diagnóstico do método de Rogers em função do código. ....</i>	<i>52</i>
<i>Tabela 4.3 – Agrupamento de Diagnósticos para o Método de Rogers.....</i>	<i>53</i>
<i>Tabela 4.4 – Critério de identificação de falha de Doernenburg. ....</i>	<i>53</i>
<i>Tabela 4.5 – Tabela de concentração dos gases para validação do método de Doernenburg.....</i>	<i>54</i>
<i>Tabela 4.6 – Tabela de concentração dos gases para identificação de condição de normalidade para o método de Doernenburg, segundo a IEEE. ....</i>	<i>54</i>
<i>Tabela 4.7 – Agrupamento de Diagnósticos para o Método de Doernenburg. ....</i>	<i>54</i>
<i>Tabela 4.8 – Interpretação da Análise de Gases conforme NBR7274.....</i>	<i>55</i>
<i>Tabela 4.9 – Agrupamento de Diagnósticos para a NBR7274. ....</i>	<i>55</i>
<i>Tabela 4.10 – Regras estipuladas para saídas conflitantes. ....</i>	<i>57</i>
<i>Tabela 4.11 – Tipos de Dúvidas considerados na Análise Fuzzy. ....</i>	<i>57</i>
<i>Tabela 4.12 – Regras estipuladas para o Sistema Fuzzy. ....</i>	<i>63</i>
<i>Tabela 4.13 – Resposta do Sistema Fuzzy.....</i>	<i>63</i>
<i>Tabela 4.14 – Combinações consideradas na ocorrência de dúvidas do tipo 1.....</i>	<i>65</i>
<i>Tabela 5.1 – Dados de diagnósticos corretos por conjunto de dados. ....</i>	<i>69</i>
<i>Tabela 5.2 – Dados de diagnósticos corretos para o conjunto de dados históricos.....</i>	<i>69</i>
<i>Tabela 5.3 – Identificação dos tipos de diagnósticos errôneos. ....</i>	<i>70</i>
<i>Tabela 5.4 – Distribuição percentual dos diagnósticos incorretos para o método de Rogers.....</i>	<i>70</i>
<i>Tabela 5.5 – Dados de diagnósticos corretos por conjunto de dados. ....</i>	<i>71</i>
<i>Tabela 5.6 – Dados de diagnósticos corretos para o conjunto de dados históricos.....</i>	<i>71</i>
<i>Tabela 5.7 - Distribuição percentual dos diagnósticos incorretos para o método de Doernenburg.....</i>	<i>71</i>

<i>Tabela 5.8 – Dados de diagnósticos corretos por conjuntos de dados.....</i>	<i>72</i>
<i>Tabela 5.9 – Dados de diagnósticos corretos para o conjunto de dados históricos.....</i>	<i>72</i>
<i>Tabela 5.10 – Distribuição percentual dos diagnósticos incorretos para a NBR7274. ....</i>	<i>72</i>
<i>Tabela 5.11 – Dados de diagnósticos corretos por conjuntos de dados.....</i>	<i>73</i>
<i>Tabela 5.12 – Dados de diagnósticos corretos para o conjunto de dados históricos.....</i>	<i>73</i>
<i>Tabela 5.13 – Distribuição percentual dos diagnósticos incorretos para a NBR7274. ....</i>	<i>74</i>
<i>Tabela 5.14 – Distribuição percentual dos diagnósticos – Normas e Rede Neural. ....</i>	<i>74</i>
<i>Tabela 5.15 – Dados de diagnósticos corretos para o conjunto de dados históricos.....</i>	<i>75</i>
<i>Tabela 5.16 – Distribuição percentual dos diagnósticos corretos.....</i>	<i>75</i>

# **1 INTRODUÇÃO AO PROBLEMA DE AVALIAÇÃO DO ESTADO DE TRANSFORMADORES E EMPREGO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL NA SUA SOLUÇÃO**

## **1.1 – APRESENTAÇÃO DO PROBLEMA DE AVALIAÇÃO DO ESTADO DO TRANSFORMADOR**

Os transformadores de potência são os componentes mais críticos e caros de qualquer subestação, e seu desligamento, quase que inevitavelmente, causa dano à operação do sistema elétrico e à produção industrial.

A demanda crescente por energia e a sobrecarga atual dos sistemas de potência impõem a necessidade cada vez maior do uso de ferramental adequado de monitoramento e diagnóstico do estado operativo dos sistemas e equipamentos elétricos, de modo a aumentar sua confiabilidade e reduzir o número de paradas programadas e eventuais, otimizando assim o fornecimento de energia elétrica e o uso das instalações (VARELLA, CHEIM et al., 2000).

O grande investimento em capacidade de geração após a Segunda Guerra Mundial, até meados da década de 70, resulta em uma população transformadora, que na teoria está se aproximando do final de sua vida, justificando um maior número de inspeções para se manter a confiabilidade desejada (SPARLING, 2001).

COSTA E BRANDÃO (2001), constataram em seus estudos que o valor anual médio de taxa de falha de transformadores de um dado sistema é de aproximadamente 2%, e que estas falhas podem ser divididas em dois grupos, caracterizados por possuírem, ou não, comutador de tensão sob carga (OLTC – On Load Tap Changers). A maior taxa de falha naqueles que possuem OLTC está ligada a este componente, e nos transformadores que não o possuem, a defeitos nos enrolamentos. As falhas nos comutadores de tensão sob carga estão ligadas ao tempo de transição dos contatos, falhas no dielétrico, erosão dos contatos e ao mecanismo de acionamento. Já com relação aos enrolamentos, atribui-se a deterioração do sistema de isolamento ao envelhecimento, que é um processo decorrente da ação de altas temperaturas. O equipamento torna-se sensível às solicitações eletrodinâmicas que causam o deslocamento de enrolamentos e o afrouxamento das peças de fixação e também às solicitações elétricas, como as sobretensões.

Diversas áreas têm considerado a manutenção com base nas condições de operação do equipamento, a qual prevê o monitoramento e o diagnóstico de forma contínua ou periódica de alguns parâmetros para se estimar as condições atuais e remanescentes da vida útil. Este tipo de manutenção proporciona, deste modo, uma integração entre as condições do material, desempenho do equipamento, taxa de degradação e ações preventivas.

Por muitos anos, os programas de manutenção preventiva em transformadores consistiram em inspeções, testes e ações periódicas em intervalos de tempo normalmente sugeridos pelo fabricante ou determinados através da experiência prática. Incluem-se nestes programas os testes de rotina e a execução de serviços como medição de perdas dielétricas; de resistência de isolamento e dos enrolamentos; análise físico-química e cromatográfica do óleo; monitoramento manual ou automático da temperatura e do carregamento; tratamento, troca ou a regeneração do óleo isolante; limpeza dos terminais; e outros. (COSTA E BRANDÃO, 2001).

HAN, SONG, et al. (2003), definem condição de monitoramento como a técnica ou o processo de monitoramento das características de operação do equipamento, que pode fornecer a necessidade ou não de manutenção preventiva, antes que ocorra séria deterioração, desligamentos ou para estimar a “saúde” da máquina.

Manutenção baseada no tempo, analisando as máquinas desenergizadas, de acordo com o agendamento ou horas de funcionamento, pode evitar muitas falhas, mas também pode causar desligamentos desnecessários, com desperdício de mão-de-obra, tempo e dinheiro.

Um sistema de monitoramento das condições deveria ser capaz de monitorar as máquinas em operação com a existência de interferência elétrica, identificando e localizando os defeitos em detalhes, e estimando regularmente a vida das máquinas. Quatro partes principais deveriam estar contidas neste tipo de sistema para a ativação destas funções:

1) Sensores: podem converter quantidades físicas em sinais elétricos. Quantidades e fenômenos seriam monitorados e sua alteração poderia revelar a existência de falhas incipientes antes da ocorrência de falhas catastróficas. A seleção de sensores dependeria do método de monitoramento e do conhecimento dos mecanismos de falha da máquina.

2) Aquisição de Dados: a unidade de aquisição de dados seria construída para realizar a amplificação e pré-processamento dos sinais de saída dos sensores.

3) Detecção da Falha: O propósito principal é descobrir se existe o aparecimento de uma falha incipiente na máquina. Existem dois métodos diferentes para detecção da falha, por comparação com modelo referenciado ou através da extração das características de operação. A forma de detecção de falha por comparação dos resultados das medições com os modelos

pré-estabelecidos pode ser feita por modelos de simulação matemática ou baseados em inteligência artificial. Para a maioria dos métodos baseados na extração das características, tecnologias de processamento de sinais seriam usadas para obter “assinaturas”, a qual poderiam representar as condições de operação normal ou sob falha.

4) Diagnóstico: A detecção de sinais anormais era comumente realizada por especialistas ou análises *off-line*, e agora passaram a ser implementadas *on-line* e automaticamente por computador, através de tecnologia avançada. O resultado esperado que seria apresentado ao usuário incluiria o nome e localização de cada defeito, status da máquina e avisos sobre possíveis manutenções.

Dentro deste panorama o uso de processamento avançado de sinais e tecnologias de inteligência artificial são atrativos para esta aplicação. Como funções de interpretação automática e diagnóstico *on-line* são consideradas cada vez mais importantes no sistema de monitoramento das condições, modernos sistemas do tipo podem ser chamados de monitoramento inteligente das condições, com características de cálculos rápidos, análise inteligente e baixo custo.

Neste trabalho de dissertação o enfoque principal é dado à análise dos gases dissolvidos no óleo, contemplando o estudo de técnicas de monitoramento do envelhecimento da isolação principal e dos enrolamentos, os quais são os problemas que mais afetam a vida do transformador (HAN, SONG et al., 2003). Estas condições podem ser indicadas ainda pela ação da temperatura ao longo do tempo, descargas parciais e análise de umidade.

Uma das técnicas de diagnóstico de falhas incipientes em isolamentos de papel mais empregada e difundida é a análise de gases dissolvidos em óleo. Os métodos de diagnóstico a partir da análise de gases começaram a ser desenvolvidos nos anos 60 e durante muitos anos foram as únicas técnicas de monitoração com equipamento em operação a permitir uma avaliação de processos de degradação do isolamento em sua fase inicial. O óleo submetido à ação do calor se decompõe através de reações complexas produzindo uma série de gases, que tendem a se manter dissolvidos. Em função da temperatura atingida em uma região do óleo os produtos resultantes da decomposição são alterados. Assim existe uma correlação entre os tipos de gases encontrados dissolvidos no óleo e as temperaturas atingidas no seu interior. A estimativa da quantidade desses gases, formados em função da temperatura, pode ser feita por modelos teóricos simplificados, por determinação experimental em laboratório sob condições controladas ou ainda por métodos estatísticos, considerando aplicações práticas com condições razoavelmente conhecidas (ZIRBES, 2003).

Dessa forma a ocorrência de sobreaquecimento no isolamento deve elevar a temperatura com valores que variam em função de sua severidade. Da mesma forma a ocorrência de ruptura da rigidez dielétrica do óleo, com o surgimento de descargas, pode ser associada com as temperaturas de formação do arco em função de sua intensidade. Assim são estabelecidas faixas de temperatura para as quais existe uma maior probabilidade de ocorrência de um determinado processo. Estabelecida a correlação entre a temperatura, o processo de falha e sua intensidade, é possível estimar nos equipamentos os processos envolvidos e faixas de temperaturas esperadas para falhas específicas. Esta é a forma usual de estabelecer uma correlação entre a formação de gases no óleo e processos ou falhas específicas (ZIRBES, 2003).

Segundo ZHANG, DING et al. (1996), diferentes padrões de gases são gerados devido às diferentes intensidades de energia dissipadas por várias falhas. Totalmente ou parcialmente dissolvidos no óleo, os gases apresentados em suas amostras tornam possível a determinação da natureza da falha pela identificação do tipo e quantidade do gás gerado.

De forma complementar, as características da análise das concentrações, condições e proporções dos componentes gasosos podem identificar as razões para a formação do gás e indicar a necessidade de manutenção. (HAN, SONG et al., 2003).

Ainda levando em conta o problema de diagnóstico preventivo em transformadores, BARONI, GUIDA, et al. (1997), definem as principais razões de interesse para a aplicação de tecnologia de sistemas baseados em conhecimento em sua solução:

- a tarefa de avaliação do estado, diagnóstico preventivo e planejamento da intervenção requer a avaliação de várias fontes de conhecimento, incluindo: conhecimento empírico, conhecimento estrutural, conhecimento acerca da dinâmica dos fenômenos físicos internos e correta interpretação de medidas históricas de variáveis medidas;
- a competência e a experiência necessária para avaliação do estado, diagnóstico preventivo, e planejamento da intervenção são geralmente possuídos por somente alguns especialistas;
- as rotinas de gerenciamento de transformadores de potência geralmente são operadas por pessoas que não são especialistas em transformadores e podem ter dificuldades na correta avaliação do estado do transformador, no entendimento de ocorrências críticas, na previsão de falhas incipientes e no planejamento apropriado das intervenções.

Existe ainda, como justificativa para a utilização de técnicas de inteligência artificial ou metodologias para solução do problema, o aumento da necessidade de desenvolvimento de ferramentas de diagnóstico, monitoramento e avaliação de condições internas dos transformadores. Tradicionalmente, rotinas de manutenção preventivas combinadas com

testes regulares eram utilizadas. Com a desregulamentação do setor elétrico, aumentou-se a necessidade de redução dos custos de manutenção bem como da redução do número de desligamentos dos equipamentos, levando a indústria a mover-se dos tradicionais programas de manutenção baseadas no tempo, para programas de manutenção baseados nas condições. Em vez de intervenção em intervalos regulares, a manutenção é somente requerida quando as condições do equipamento assim indicarem. Se existe o problema, o transformador pode ser reparado ou substituído antes de sua falha (WANG, VANDERMAAR, et al., 2002).

## 1.2 – HISTÓRICO E REVISÃO BIBLIOGRÁFICA

Neste item, o trabalho descrito nesta dissertação é situado, tanto no seu contexto histórico, através de uma revisão bibliográfica sobre trabalhos relevantes na área, quanto tecnicamente, através da definição da estrutura do trabalho dentro do problema da avaliação do estado do isolamento do transformador por meio do monitoramento das suas condições.

Primeiramente, serão apresentadas considerações acerca das técnicas e condições de monitoramento de transformadores, e a seguir uma revisão mais detalhada sobre análise dos gases dissolvidos no óleo, combinada a técnicas de inteligência artificial, que se tornou o objeto principal de pesquisas na área de manutenção de transformadores, que mostra resultados realmente significativos, e que é o objeto de estudo principal nesta dissertação.

O trabalho de KELLY (1980), intitulado “Transformer Fault Diagnosis by Dissolved Gas Analysis” é um dos pioneiros no desenvolvimento de uma ferramenta complementar de diagnóstico de falha em transformadores. Segundo o autor, o procedimento para análise consistia em três passos: 1) extração dos gases do óleo por algum tipo de procedimento a vácuo; 2) introdução dos gases em um processo de cromatografia gasosa para separação e identificação e; 3) quantificação.

Ainda com relação à KELLY (1980), os principais gases encontrados em dados históricos de gases dissolvidos no óleo, associados a falhas, são:

- Hidrogênio: grandes quantidades associadas com condições de descarga parcial (corona);
- Hidrogênio, Metano, Etano e Etileno: resultados da decomposição térmica do óleo;
- Monóxido de Carbono: produzido por envelhecimento térmico do papel.
- Acetileno: associado com arco elétrico no óleo.

Além dessa análise, o autor leva em conta a geração total de gases combustíveis para obter o diagnóstico. Se a quantidade total formada estivesse na faixa de 0-500 ppm, o transformador era considerado em operação normal. 500-1000 ppm de gases combustíveis



normalmente mostram uma decomposição significativa. Já o acúmulo de mais de 2500 ppm de gases indicam que a decomposição é severa.

Trabalhos subseqüentes procuraram resolver basicamente o mesmo problema, variando somente a ferramenta utilizada em sua solução. A grande maioria deles, utilizando técnicas de inteligência artificial para a análise dos gases dissolvidos, que se transformou, reconhecidamente, na melhor das ferramentas, conduzindo aos melhores resultados.

DUVAL (1989), propôs um método para identificação da falha baseado nos teores de formação dos gases etileno ( $C_2H_4$ ), metano ( $CH_4$ ) e acetileno ( $C_2H_2$ ), criando o chamado triângulo de Duval. Através do ponto encontrado na área deste triângulo, detalhado no item 2.7.1, as falhas do tipo: arco de alta energia, de baixa energia, corona e condições de sobreaquecimento seriam passíveis de identificação, com cálculos extremamente simples. O autor recorre ainda à criação de diferentes níveis de probabilidade de falha (aceitável, perigoso, etc.) em função da concentração individual de cada gás; baseado na experiência de Hydro-Québec, na formação das regras de um sistema especialista para a obtenção do diagnóstico final. Posteriormente, em 2002, DUVAL fez uma revisão e um aperfeiçoamento do seu método, indicando ainda uma região onde ocorria uma sobreposição das falhas existentes por ele consideradas, mas mantendo as bases publicadas no seu artigo original.

DUKARM (1993), propôs um método que considerava a soma dos gases combustíveis gerados no óleo, aliadas ao nível gerado de cada gás para o estabelecimento dos parâmetros e regras de um sistema especialista baseado em lógica *fuzzy*, e também para o desenvolvimento de diagnóstico através de redes neurais.

ZHANG, DING, et al. (1996), propuseram uma rede neural artificial para diagnóstico de falha em transformadores. O projeto da Rede Neural incluía a seleção da entrada, da saída, a topologia de rede e o peso das conexões nos nós. O algoritmo de aprendizagem utilizado foi o do tipo *back-propagation*, que consistia na repetição do conjunto de treinamento até que seus pesos minimizem o erro de saída do conjunto inteiro. Uma vez que o processo é feito, todos os pesos são retidos e a rede neural está pronta para uso. Como no caso em questão não existiam muitos dados de treinamento, foi utilizado um procedimento denominado *ten-fold-cross-validation*, onde os dados foram divididos igualmente em dez grupos. Alternadamente os dados de cada grupo foram testados pela Rede Neural treinada com os outros nove grupos, aumentando assim, o número de dados de teste, e conseqüente utilização daquele em que o diagnóstico era mais preciso.

XU, WANG, et al. (1997), desenvolveram um “mecanismo consultativo” formado por um sistema especialista e uma rede neural. Baseado na desvantagem dos sistemas especialistas,

que geralmente possuem base de conhecimento incompleta, e desvantagem das redes neurais, que nesta aplicação pode ocorrer diferença significativa entre os dados de entrada e os empregados no treinamento, eles propuseram a combinação de ambos, da seguinte forma:

- (i) quando a rede neural é iniciada, o primeiro passo é comparar a diferença entre as amostras de treinamento e os dados de entrada;
- (ii) se a diferença não é grande, a conclusão é correta;
- (iii) se a diferença é grande, o sistema especialista é iniciado. Existem dois pontos que necessitam de atenção, neste passo:
  - (a) se a inferência foi bem sucedida, ele compara a conclusão do sistema especialista com o resultado da rede neural. Se forem similares, a conclusão está certa. Se forem inconsistentes, o raciocínio da rede neural está errado. Neste caso a estrutura da rede neural deve ser modificada com a inclusão deste novo exemplo de treinamento na sua base;
  - (b) se a inferência do sistema especialista falha, mostra-se que a base de conhecimento é pequena e não existem regras correspondentes. A única forma de solução é aquisição de conhecimento, com o incremento de novas regras. Depois de incluir novas regras, pode-se modificar a estrutura da rede neural com estes novos dados, que vão sendo atualizados continuamente.

WANG, LIU, et al. (1998), também desenvolveram uma ferramenta que combinasse redes neurais artificiais e sistemas especialistas para o diagnóstico de falha em transformadores usando análise dos gases dissolvidos no óleo. Os dados de entrada (concentrações de gases), passavam por dois classificadores normais/anormais, independentemente. Um baseado no conhecimento e outro em redes neurais. Se ambos indicassem estados normais, era recomendada uma ação de manutenção dentro de um nível aceitável. Se um dos classificadores indicasse estado anormal, os dados passavam novamente por detectores de falha individuais, um baseado em conhecimento e outro em redes neurais; independentes, e ambos resultariam em um diagnóstico de falha combinado, recomendando com maior urgência ou não uma ação de manutenção.

No trabalho de SU, LAI, et al. (2000), foi utilizado o método de lógica  $fuzzy$  para identificação de possíveis falhas. Utilizou-se da classificação do tipo de falha de acordo com os códigos de taxas de gases do IEC, e aproximou esses valores em uma função qualidade  $fuzzy$ , obtendo o diagnóstico.

VARELLA, CHEIM, et al. (2000), propuseram a aplicação de um sistema especialista neuro-fuzzy de análise de transformadores, a partir da análise integrada do comportamento e

evolução de quatro parâmetros: concentração de gases dissolvidos no óleo isolante, taxa de evolução dos gases, relações gasosas e a opinião do especialista. Primeiramente obtém-se os valores para os dois primeiros parâmetros, através de dados históricos e atuais, de formação de gases. Após, são obtidas as relações gasosas, para o diagnóstico da rede neural com treinamento supervisionado. Unindo-se as três informações “fuzzificadas”, pede-se a opinião do especialista, que determina a influência do antecedente, no conseqüente, aumentando ou diminuindo a pertinência de cada resultado individual, e obtendo-se o diagnóstico.

GUARDADO, NAREDO, et al. (2001), realizaram um estudo comparativo da eficiência de redes neurais no diagnóstico de transformadores de potência usando análise dos gases dissolvidos. Para tal comparação, eles utilizaram cinco critérios de diagnóstico: Doernenburg, com quatro relações de gases como dados de entrada e 5 tipos de falha como saída; Rogers Modificado, com três relações gasosas na entrada e 7 tipos de falha na saída; Rogers, com quatro relações na entrada e 10 tipos de falha na saída; IEC, com quatro relações na entrada e 10 tipos de falha na saída e CSUS, com cinco concentrações individuais de gases na entrada e 6 tipos de falha na saída. Os dois últimos critérios adotados foram os que apresentaram resultados mais satisfatórios.

ZIRBES (2003), analisa diferentes metodologias de diagnóstico, que representam diferentes enfoques e técnicas aplicadas. Mostra que todas têm como ponto comum a dependência da qualidade dos dados utilizados em sua caracterização e ajuste. Os métodos que utilizam um menor número de classificações para o diagnóstico tendem a ter uma maior eficiência do que aqueles que apresentam um maior número de diagnósticos. Os métodos que utilizam para a identificação da condição de normalidade as concentrações de gases de forma direta apresentam um melhor desempenho. Para uma análise dos métodos é importante não somente o número de diagnósticos corretos ou incorretos, mas também uma qualificação dos diagnósticos errôneos em função de suas conseqüências.

ZIRBES (2003), mostra ainda que alguns métodos como as redes do tipo GRNN (Generalized Regression Neural Network), VLQ (Vector Learning Quantization) e Redes de Bayes apresentam uma capacidade para incorporarem dados sem prejuízo em seu desempenho. As duas primeiras redes que efetuam o reconhecimento por similaridade apresentam uma maior facilidade na identificação, enquanto a última depende da frequência de ocorrência para sua identificação. O algoritmo do tipo análise discriminante (discriminant analysis) apresenta, aparentemente, uma maior dificuldade neste aspecto. Este algoritmo apresentou resultados significativos, entretanto conforme observado anteriormente, deve ser aplicado em um conjunto de dados mais amplo para uma avaliação. A rede bayesiana apresentou resultados significativos, inclusive na generalização e, possivelmente possa

melhorar seu desempenho caso sejam exploradas as possibilidades de sua topologia. Sob a ótica de facilidade e tempos envolvidos na manutenção dos algoritmos e atualização de novos dados, a rede tipo GRNN apresenta as melhores condições. Entretanto, o algoritmo tipo análise discriminante apresenta também boas facilidades de manutenção. De uma maneira geral todos os algoritmos possuem condições de serem utilizados em aplicações de linha, onde os dados medidos podem ser diretamente processados, uma vez que seus tempos de processamento não são longos.

### 1.3 – CONTRIBUIÇÃO DA PESQUISA E ESTRUTURA DO TRABALHO

O trabalho de dissertação de mestrado consiste, basicamente no desenvolvimento de uma ferramenta de diagnóstico de falhas incipientes em transformadores. Considerando a análise dos gases dissolvidos no óleo, a ferramenta, utilizando-se de critérios já consolidados na literatura aliados à técnicas de inteligência artificial, deve ser capaz de determinar o tipo de falha existente no equipamento. As informações empregadas na análise são os resultados históricos e atuais da concentração de gases no óleo mineral isolante.

As principais razões que motivaram a realização deste trabalho, além das já citadas, foram as seguintes:

- o problema não possui uma função matemática que descreve o comportamento da taxa de evolução dos gases em função das falhas existentes, por isso se justifica o emprego de método heurístico de redes neurais, de sistemas especialistas baseados no conhecimento acumulado durante anos, e de lógica *fuzzy* baseada em dados históricos;
- o advento de modernas técnicas de monitoramento *on-line* de transformadores, que além de fornecerem medidas características destes equipamentos, como tensão, corrente, carregamento, entre outras, fornecem dados referentes aos gases dissolvidos no óleo.

Propõe-se, assim, uma ferramenta que atribua maior confiabilidade aos resultados de diagnóstico de falhas em transformadores, e, por conseguinte, forneça ao operador, as informações necessárias para se determinar ações de manutenção, desligamentos ou manobras.

O texto desta dissertação de mestrado está assim dividido: O capítulo 2 apresenta as principais características dos materiais que compõem o isolamento elétrico dos equipamentos, listando as suas principais funções e propriedades. Também apresenta os fatores que mais influenciam nos processos de envelhecimento e degradação destes, e um estudo aprofundado dos mecanismos de diagnósticos de isolamentos a partir da análise de gases dissolvidos,

apresentando os métodos convencionais mais utilizados, métodos que utilizam técnicas de inteligência artificial e fatores que geram incertezas neste tipo de análise.

O capítulo 3 apresenta uma descrição detalhada das duas técnicas de inteligência artificial que serão utilizadas no trabalho. Para as redes neurais é apresentada uma breve descrição, seguida de seu histórico, sua caracterização, aspectos referentes às topologias e processos de aprendizado. Também são comentados os principais modelos de redes e referenciadas algumas aplicações desta técnica ao problema proposto. Para os sistemas de lógica *fuzzy*, após breve descrição, é apresentado o seu histórico, algumas regras referentes à operação com conjuntos *fuzzy*, e por fim, também são referenciados alguns trabalhos que se utilizam destes sistemas em problemas de identificação de falhas incipientes em transformadores.

O capítulo 4 caracteriza-se pela apresentação da metodologia proposta no desenvolvimento da ferramenta de diagnóstico. Após o fluxograma que nos mostra o processamento interno da mesma, são apresentados os critérios utilizados para a análise dos gases, bem como os aspectos pertinentes a utilização de redes neurais, regras de decisão, equações e desenvolvimento do sistema *fuzzy*.

Já o capítulo 5 é destinado a análise dos resultados fornecidos pela ferramenta aplicada a três conjuntos de dados. São apresentados os resultados para cada técnica empregada na ferramenta individualmente e aqueles obtidos pela ferramenta como um todo. Também são mostrados os principais tipos de diagnósticos errôneos obtidos. Por fim, são selecionados dois transformadores com dados históricos para uma descrição passo a passo do processo de diagnóstico.

Finalmente o capítulo 6 apresenta as conclusões pertinentes obtidas no decorrer deste trabalho de dissertação, dando atenção especial aos objetivos propostos, às metas alcançadas e aos resultados obtidos pela ferramenta desenvolvida.

## 1.4 – CONCLUSÕES

Neste capítulo foi introduzido o problema de avaliação e diagnóstico do estado dos transformadores, iniciando pela importância da manutenção deste tipo de equipamento no novo modelo do setor elétrico brasileiro.

Também foi apresentada uma revisão bibliográfica que incluiu citações e resumos breves de trabalhos referentes ao tema principal, situando historicamente o problema e

apontando contribuições importantes no desenvolvimento de várias técnicas de inteligência artificial na sua solução.

Com base nos trabalhos existentes e brevemente apresentados anteriormente, sobre avaliação do estado do transformador levando em conta a análise dos gases dissolvidos no óleo, que se utilizavam de métodos convencionais e de técnicas de inteligência artificial, foram determinados os principais argumentos que motivaram a realização da pesquisa e as contribuições pretendidas com o trabalho final.

## **2 ACOMPANHAMENTO DO ESTADO DE ISOLAMENTOS DE PAPEL IMPREGNADO VIA ANÁLISE DE GASES DISSOLVIDOS**

### **2.1 – INTRODUÇÃO**

No capítulo anterior foi apresentada uma revisão bibliográfica com relação à aplicação de novas técnicas de monitoramento das condições dos transformadores, bem como da utilização de critérios e métodos já consolidados pelo setor elétrico para análise e interpretação dos gases dissolvidos no óleo como ferramenta de diagnóstico de falhas no isolamento elétrico destes equipamentos.

Já este capítulo visa a apresentação das principais características e respectivas funções dos materiais que formam o isolamento elétrico nos transformadores, bem como os fatores responsáveis pelos processos de degradação e envelhecimento destes. Também tem o objetivo de descrever a análise dos gases dissolvidos no óleo (DGA) como ferramenta de diagnóstico, comentando as principais técnicas convencionais utilizadas, aliadas às técnicas de inteligência artificial que estão sendo aplicadas para este fim. Por fim, são apresentados alguns fatores que geram incertezas nos dados advindos da análise cromatográfica e são apresentadas as conclusões referentes ao capítulo.

### **2.2 – CARACTERÍSTICAS DE UM ISOLAMENTO ELÉTRICO**

A isolação elétrica em equipamentos de alta tensão tem como função principal minimizar o fluxo de corrente entre os condutores submetidos a diferenças de potencial elétrico, suportando o campo elétrico resultante. Deve atuar também na transferência de calor gerado entre os condutores, apresentando boa estabilidade térmica, apresentar propriedades mecânicas que possam suportar os esforços eletromecânicos quando da ocorrência de transitórios e ainda apresentar uma estabilidade química dentro de níveis que possam garantir as suas funções como isolante elétrico (ZIRBES, 2003).

O estabelecimento das condições de um isolamento consiste na avaliação da sua capacidade de desempenhar suas funções sob condições de trabalho estabelecidas em seu projeto, ou sob condições de operação à que está submetido.

Os isolamentos sofrem uma redução de sua capacidade em função do tempo, mesmo quando submetidos às condições normais de projeto. Após um longo tempo de operação as

condições da isolamento dos transformadores são substancialmente alteradas. Contudo, metodologias tradicionais baseadas em testes e identificação de diferentes características algumas vezes não nos dão a idéia de como qualificar e, particularmente, como quantificar a condição do equipamento (SOKOLOV, BERLER, et al., 2001).

De outra forma, quando submetidos à condições mais severas de operação, a vida útil estimada é reduzida. Na medida em que ocorre uma redução de sua capacidade vários processos podem ocorrer no sentido de acelerar esta redução, levando a uma incapacidade de realizar sua função, ou seja, à falha do isolamento. Os processos que atuam no sentido de acelerar a redução da capacidade do isolamento, quando em sua fase bem inicial são denominados de falhas incipientes. Essas falhas são normalmente recuperáveis com um custo reduzido (ZIRBES, 2003).

Assim, e de forma mais ampla, a determinação do estado do isolamento envolve também a estimativa e a avaliação da redução de sua capacidade, a determinação e identificação de falhas incipientes que possam estar instaladas e uma estimativa comparativa na redução de vida útil (ZIRBES, 2003).

O isolamento de papel impregnado é um isolamento composto de celulose e óleo isolante, onde cada um destes apresenta seus processos normais de degradação, podendo alterar parcialmente quando há interação entre eles. Esse processo envolve várias reações físicas e químicas que, de forma conjunta, atuam no sentido de acelerar ainda mais os níveis de degradação.

De uma forma geral, água, oxigênio, produtos do envelhecimento do óleo (particularmente ácidos) e partículas de diferentes origens são agentes de degradação, os quais podem diminuir significativamente a vida do transformador, através da ação térmica, elétrica, eletromagnética e eletrodinâmica. (SOKOLOV, BERLER, et al., 2001). Os métodos de avaliação da degradação podem medir diretamente as características do isolamento, identificar e avaliar os produtos de sua degradação, ou ainda seus efeitos em parâmetros físicos e químicos conhecidos (ZIRBES, 2003).

Os principais métodos utilizados nas concessionárias do setor elétrico são a análise dos gases dissolvidos e ensaios físico-químicos no óleo, medições de fator de dissipação e medição de descargas parciais. A aplicação destas metodologias no processo de análise requer um prévio conhecimento das características individuais do papel isolante, do óleo isolante e do conjunto papel-óleo.



### 2.3 – CARACTERÍSTICAS DO PAPEL ISOLANTE

O papel isolante não impregnado é uma associação entre celulose e ar e sua densidade varia em função do processo de fabricação e da qualidade (ZIRBES, 2003). A maior parte da isolação sólida dos transformadores é de natureza celulósica, ou seja, é constituída de papel.

Existem vários tipos de papel para aplicação em isolação elétrica. Dependendo de sua matéria prima, e de seu processo de fabricação, eles possuem diferentes composições e características. Os principais tipos de materiais celulósicos empregados na isolação dos transformadores são (MILASCHI, 1984):

Papel Kraft – feito de fibra de madeira;

Papel Manilha – feito de fibras de madeira e cânhamo;

Papelão Kraft – feito de fibra de madeira;

Pressboard – feito de papelão com fibra de algodão.

As propriedades elétricas mais importantes deste tipo de material isolante são a constante dielétrica, o fator de dissipação e rigidez dielétrica (KHALIFA, 1990). Para efeitos de análise de comportamento, normalmente utiliza-se o fator de dissipação, pois ele pode ser medido nos isolamentos e independe de fatores geométricos para sua determinação.

O fator de dissipação representa a relação entre a componente resistiva e a componente capacitiva da corrente, e o seu valor pode variar em função da frequência, do campo elétrico aplicado, da temperatura em que está sendo efetuada a medição, do teor de umidade, da pressão aplicada e de fatores característicos de sua fabricação.

Já a rigidez dielétrica para o papel, normalmente é muito baixa, e pode ser variante em função do seu material, sua forma e tamanho, seu ambiente, a duração da tensão à ele aplicada, etc. Por sua própria constituição, o dielétrico que determina a rigidez do papel é o próprio ar, chegando a valores, então, um pouco superiores ao de uma camada de ar de mesma espessura. Outra característica pertinente à rigidez dielétrica é que o valor obtido pela superposição de várias camadas de papel mais fino é em geral superior à rigidez obtida por uma camada equivalente de mesma espessura (ZIRBES, 2003). Pela aplicação de uma tensão reduzida, é possível identificar falhas, variações significativas de densidade e presença de partículas condutoras.

Não somente durante a construção do isolamento, mas ao longo de toda sua vida útil, o papel deve possuir também boas qualidades mecânicas, que diminuem tanto mais rapidamente quanto maior for o seu teor de água. A resistência mecânica é uma das características mais importantes, pois caso o papel não venha a suportar os esforços, ocorrerá

seu rompimento e conseqüente falha na isolação. A diminuição da resistência mecânica da isolação tem sido indicada para medir seu tempo de envelhecimento (MILASCHI, 1984).

## **2.4 – CARACTERÍSTICAS DO ÓLEO MINERAL ISOLANTE**

O óleo mineral isolante utilizado em transformadores é extraído do petróleo e suas características vão depender da natureza deste petróleo e do processo utilizado na sua preparação. O petróleo e, por conseguinte, o óleo, podem ser classificados como parafínicos, naftênicos, aromáticos ou de grupos intermediários de moléculas, sendo que os dois primeiros, historicamente, eram os tipos de óleos mais utilizados.

Com a redução das fontes de petróleo naftênico, que tradicionalmente era o mais utilizado devido a sua capacidade de absorção de gás, a utilização do óleo parafínico se torna cada vez mais imperiosa.

O óleo mineral isolante é constituído em sua maioria de uma mistura de hidrocarbonetos, e de não hidrocarbonetos, ou heterocompostos, em pequena proporção. Estima-se que cerca de 2.900 é o número de compostos existentes no óleo mineral (MILASCHI, 1984).

Tendo em vista a presença de um elevado número de componentes em diferentes quantidades em sua composição, a caracterização de um óleo mineral para utilização como isolante não é feita pela composição da mistura do mesmo, mas por uma série de parâmetros físico-químicos, os quais são afetados pela sua composição e por apresentarem reflexos em sua utilização. Assim, o estabelecimento de limites para estes parâmetros tem como objetivo alcançar uma uniformidade de comportamento como isolante e referências de qualidade para sua utilização (ZIRBES, 2003).

As principais características físico-químicas, ou ensaios, utilizados como parâmetros de classificação do óleo isolante são: a sua cor, ponto de fulgor, ponto de fluidez, densidade, viscosidade, ponto de anilina, teor de água, rigidez dielétrica, tensão interfacial e outros. Algumas destas características servem não somente como parâmetros de projeto de isolamento, mas também na avaliação e acompanhamento do óleo em serviço, indicando possível contaminação, estimativas de sua deterioração ou determinação de suas condições funcionais.

Sobre a função do óleo isolante, a rigidez dielétrica é o parâmetro mais importante no estudo de seu desempenho. Ela representa a capacidade do isolante suportar a aplicação de campos elétricos sem a perda de sua característica de dielétrico. Esta característica pode ser

obtida e avaliada através da aplicação de uma tensão entre dois eletrodos separados por uma distância fixa. A tensão aplicada é elevada até o valor de ruptura do dielétrico. O valor da tensão em que ocorre a ruptura é definido como tensão de ruptura e a rigidez em kV/cm leva em conta a distância de separação dos eletrodos. O valor da rigidez dielétrica para óleos novos e secos é de aproximadamente 200 kV/cm (SCHMIDT, 1979).

Alguns fatores influenciam os valores obtidos para a rigidez dielétrica do óleo isolante, dentre eles a temperatura, a estrutura dos eletrodos e as impurezas existentes. A tensão de ruptura ou a rigidez dielétrica varia também com a classe de tensão em que o óleo é usado, bem como do equipamento em que é empregado (SCHMIDT, 1979).

O efeito da temperatura na rigidez dielétrica pode ser descrito em função da solubilidade e da quantidade de água existente neste óleo. Se por sobrecarga do equipamento ou outro fator, a temperatura do óleo aumenta, a quantidade de água dissolvida no óleo também cresce. Quando a temperatura do óleo baixar, parte da água dissolvida passará para o estado livre e sua rigidez dielétrica terá um valor mais baixo (ZIRBES, 2003).

O efeito da estrutura dos eletrodos, no que diz respeito ao seu tamanho e forma, determina o volume de líquido sujeito aos campos elétricos não uniformes. Quanto maior este volume, maior é a probabilidade da existência de impurezas.

As impurezas abrangem partículas sólidas de carbono, produtos formados pelo envelhecimento e ocorrência de descargas, fibras celulósicas, resíduos de processos de filtragem, água, ácidos e gases. A presença destas impurezas causa a redução da rigidez dielétrica do líquido isolante, sendo que os seus efeitos ainda podem ser aumentados, na presença simultânea de umidade (KHALIFA, 1990).

Outro componente que pode ser encontrado nos óleos isolantes e que pode alterar a sua caracterização e seu comportamento é a umidade. Basicamente, ela pode se apresentar no líquido isolante sob três formas distintas, na forma de solução, em estado de emulsão ou em dispersão grosseira. Sob forma de vapor, é solúvel no óleo em quantidades que dependem da composição do óleo, temperatura e pressão. Ao atingir a saturação, a quantidade excedente não se encontra em solução, podendo estar sob a forma de emulsão. No estado de emulsão, como as partículas de umidade formadas possuem pequenas dimensões, não ocorre a precipitação devido às forças de tensão superficial e viscosidade do óleo. Quando as partículas formadas possuem dimensões maiores, a água se encontra em uma dispersão grosseira e ocorre sua precipitação em forma de gotículas (ZIRBES, 2003).

## 2.5 – CARACTERÍSTICAS DO PAPEL IMPREGNADO

O sistema de isolamento formado pelo conjunto papel-óleo é responsável pela rigidez dielétrica, mantendo o isolamento entre os terminais de baixa e alta tensão, e entre fases. Normalmente, o papel isolante utilizado em transformadores é, depois de seco, impregnado de verniz ou resina e posteriormente de óleo isolante. Sua impregnação não impede, mas retarda a penetração de água, embora o verniz, que contém solvente volátil pode dar origem à formação de cavidades na massa isolante, nas quais há a possibilidade de se formarem descargas parciais. Já a impregnação com resina dificulta a formação destas cavidades, dificultando, por conseguinte, a formação destas descargas. A medição do fator de potência da isolamento com tensões elevadas permite a avaliação da extensão das descargas parciais na isolamento (MILASCHI, 1984).

Outra função igualmente importante, mas que é somente atribuída ao isolamento sólido, e já comentada anteriormente, é a sua resistência mecânica (KELLY, 1993). No caso do papel isolante imerso em óleo e aquecido por longo tempo, estes valores são reduzidos, podendo chegar a níveis de não poder resistir aos esforços de curto-circuitos e surtos de tensão. A resistência mecânica do papel também diminui em razão da quantidade de água existente nesse isolamento, como pode ser observado na figura 2.1 (MILASCHI, 1984).

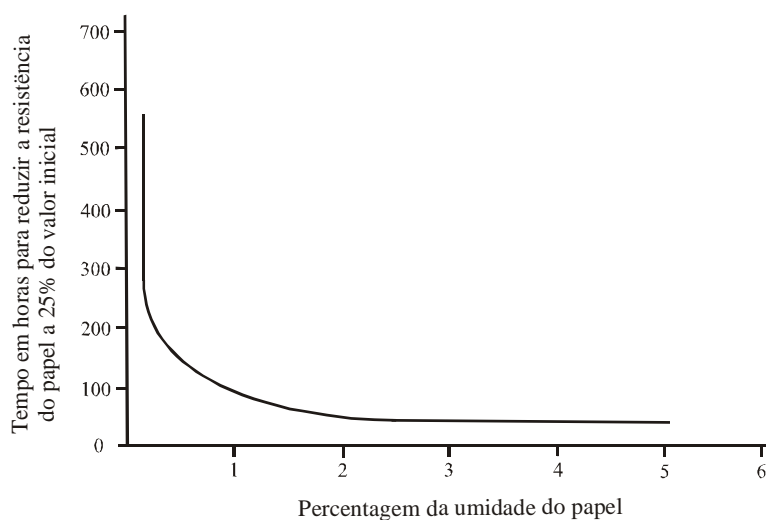


Figura 2.1 – Efeito da umidade sobre o envelhecimento do papel manilha com redução de sua resistência à tração a 25% de seu valor original.

Com relação às propriedades dielétricas do papel impregnado, elas dependem do tipo de líquido de impregnação e suas características em parte dependem da qualidade do papel e sua densidade (ZIRBES, 2003). Os dados das características dielétricas são basicamente experimentais, sendo que os principais envolvidos na caracterização do papel impregnado são a rigidez dielétrica e o fator de dissipação.

A rigidez dielétrica, como mencionado anteriormente, representa a capacidade do isolante suportar a aplicação de campos elétricos sem a perda de sua característica de dielétrico. Apresenta-se significativamente melhor para o papel com a adição de óleo isolante. No caso do papel impregnado, para tensões contínuas e impulsos de tensões, a ruptura do dielétrico deve iniciar por descarga no óleo isolante levando a ruptura total após a primeira descarga. Já a tensão de ruptura em corrente alternada é inferior aos valores correspondentes a tensão contínua e ao impulso. Na aplicação de correntes alternadas, as primeiras descargas ocorrem a uma tensão bem inferior a tensão na qual ocorre a ruptura do dielétrico. Estas descargas denominadas de descargas parciais podem aumentar de intensidade ao longo do tempo com a permanência da tensão aplicada. A ocorrência de descargas parciais em tensões mais baixas é facilitada pela presença de gases, na forma de bolhas ou em vazios do papel, pela umidade aderindo a impurezas ou fragmentos de fibras e partículas em suspensão (ZIRBES, 2003).

Outro fator que influencia na avaliação da rigidez dielétrica é o campo elétrico aplicado ao papel impregnado. Na aplicação de campos elevados existe um efeito de degradação em sua rigidez dielétrica. Este efeito é cumulativo e leva a ruptura do isolamento em função do número de impulsos aplicados ou tempo de exposição a estes campos elevados (ZIRBES, 2003).

Já o fator de dissipação ou tangente delta consiste na medida das perdas elétrica no isolamento. Baixos valores para esta grandeza são normalmente utilizados como prova da boa qualidade do óleo, sendo que aumentos súbitos no valor da tangente delta ao longo do tempo, são utilizados como sinais de deterioração das condições do isolamento (VAN BOLHUIS, GULSKI, et al., 2002). De uma forma geral, os mesmos contaminantes que afetam os valores obtidos para a rigidez dielétrica, também afetam os valores do fator de dissipação do papel impregnado (MIN E HUA, 1988).

## **2.6 – ENVELHECIMENTO DO PAPEL IMPREGNADO**

A degradação do papel ocorre em função basicamente do efeito da temperatura, oxigênio e água, fatores que afetam principalmente as propriedades mecânicas do papel. Normalmente, os ensaios relativos aos efeitos da degradação são feitos em condições controladas, e de preferência individualmente. Quando não é possível a separação de um dos fatores, são utilizados ensaios com fatores combinados e efetuadas comparações com outros

ensaios onde um destes fatores está isolado. Assim por comparação é possível estimar o comportamento individual desejado.

Historicamente, o grau de polimerização (GP) foi um dos primeiros parâmetros de medição indireta a ser utilizado para avaliação do efeito da degradação das propriedades mecânicas do papel ou seu envelhecimento. Como o papel é constituído por cerca de 90% de celulose, e esta possui cerca de 1200 monômeros em sua estrutura, a medição do GP, ou quantidade de monômeros, pode indicar o seu envelhecimento. Levando em conta ainda que existe a redução destes valores durante a fabricação, enrolamento e processamento, considera-se que o papel em transformadores novos deve conter unidades de monômeros ou grau de polimerização em torno de 1000. Considera-se ainda que para GP's entre 1000 e 500, a resistência é constante, mas na faixa de 500 a 200, a resistência é diretamente proporcional ao GP. Ainda podemos considerar que para GP = 150 ou abaixo, a resistência é inadequada para suportar os esforços mecânicos à que o sistema é submetido (VAN BOLHUIS, GULSKI, et al., 2002).

Posteriormente outros métodos de avaliação indireta foram desenvolvidos e normalmente consolidados em sua aplicação pela comparação com o GP. Novos métodos foram desenvolvidos basicamente em função dos subprodutos do envelhecimento, para uma maior facilidade de sua medição do isolamento em serviço (ZIRBES, 2003).

O envelhecimento por ação da temperatura varia conforme a qualidade do papel e também de acordo com o fluxo de nitrogênio no ambiente. De um modo geral, a degradação do papel impregnado depende da temperatura considerada, sendo que ocorre um aumento de sua velocidade de degradação com o aumento desta. KELLY E MYERS (1993), em seus estudos, afirmam que a cada 8°C de aumento na temperatura do papel, a partir de 90°C, decresce sua vida pela metade. Normalmente, o envelhecimento causado pela elevação da temperatura é analisado em conjunto com a influência da umidade. Altas taxas de umidade inicial reduzem significativamente sua vida útil.

O estudo da influência do oxigênio na degradação do papel impregnado com óleo é bastante complexo, pois envolve, vários fenômenos físicos de difusão do gás com influência da temperatura e reações químicas tanto no papel como no óleo (ZIRBES, 2003). O papel e o óleo em seus processos de degradação reagem com o ar, consumindo oxigênio. Portanto, a presença do oxigênio no meio faz com que a velocidade de degradação seja também aumentada.

Os mecanismos de degradação do papel por ação térmica, hidrólise ou por oxidação produzem a cisão das cadeias liberando glucose ou formas degradadas de glucose. A glucose

degrada por ação da água em meio ácido formando os compostos furânicos, que se dissolvem no óleo isolante. Assim estes compostos são um indicador da existência de degradação da celulose (ZIRBES, 2003).

Em suma, como foi apresentado, diversas técnicas foram e continuam a ser desenvolvidas para o diagnóstico do envelhecimento, identificação dos produtos de degradação ou a identificação da ocorrência de falhas em sistemas isolantes de transformadores (papel, óleo e conjunto papel-óleo). A Tabela 2.1 apresenta resumidamente as principais técnicas desenvolvidas, relacionando o seu uso, *status* e a utilização destas nos diferentes setores da engenharia (VAN BOLHUIS, GULSKI, et al., 2002).

Método	Tipo de Teste	Status	Usuários	Disponível para monitoramento
DGA	Envelhecimento do óleo e papel, identificação de pontos quentes, arcos elétricos ou descargas parciais.	Amplamente utilizada. Diversas pesquisas estão buscando o refinamento da ligação entre a formação do gás e causa.	Diversas concessionárias e laboratórios realizam esta análise.	Sim
Grau de Polimerização (GP)	Envelhecimento do papel isolante.	Relação entre o comprimento da cadeia de polímeros e a resistência mecânica.	Principalmente utilizado em pesquisas de laboratórios. Poucas concessionárias o utilizam.	Não
Análise Furfural	Envelhecimento do papel isolante.	Sob pesquisa. Existe ainda comportamento desconhecido da formação de compostos furânicos em transformadores.	Concessionárias e laboratórios.	Sim
Medição da tensão de restabelecimento (RVM)	Quantidade de água e envelhecimento do papel isolante.	Sob pesquisa.	Algumas concessionárias e laboratórios.	Não
Tangente delta	Perdas dielétricas no sistema isolante.	Conhecido. Instrumentos portáteis têm sido desenvolvidos para este fim.	Algumas concessionárias e fabricantes de transformadores, como controle de qualidade.	Tangente delta para buchas de transformadores pode ser medida <i>on-line</i> .
Resistência do isolamento e índice de polarização	Acúmulo de materiais polarizáveis no sistema isolante.	Conhecido.	Principalmente concessionárias. Pode ser usada <i>off-line</i> , em testes periódicos.	Não
Tangente delta ( $f$ )	Resposta em frequência do dielétrico, envelhecimento do papel, acúmulo de materiais polarizáveis no sistema isolante.	Instrumentos são comercialmente avaliados, mas muitas pesquisas estão sendo feitas para interpretação dos resultados.	Algumas concessionárias, laboratórios.	Não
Descargas parciais	Deterioração do sistema isolante, hábil para detectar alguns defeitos localizados.	Bem conhecido. Pesquisas estão sendo feitas para supressão de ruídos, interpretação dos dados e uso <i>on-line</i> .	Diversas concessionárias. A medição dos níveis de PD faz parte dos testes de comissionamento para transformadores de potência.	Sim

Tabela 2.1 – Principais técnicas utilizadas na estimativa do envelhecimento e degradação do sistema isolante.

## **2.7 – DIAGNÓSTICOS DE ISOLAMENTOS A PARTIR DA ANÁLISE DE GASES DISSOLVIDOS**

Através da análise dos gases dissolvidos no óleo isolante é possível avaliar a condição de operação do isolamento, com a identificação de eventuais processos de falha que possam estar ocorrendo. Os processos identificáveis têm como origem o sobreaquecimento do isolamento ou a ocorrência de descargas elétricas em seu interior. As medidas podem ser obtidas com o equipamento em operação normal, seja por amostragem do óleo periodicamente, ou por monitoramento contínuo.

A detecção de certos gases gerados no óleo do transformador em serviço é freqüentemente a primeira indicação de seu mal funcionamento. Descargas de baixa energia, de alta energia e sobreaquecimento são alguns dos mecanismos de falha que podem ser identificados através desta análise. A ocorrência destes eventos pode resultar na decomposição dos materiais isolantes e conseqüente formação de vários gases combustíveis e não combustíveis. A operação de transformadores com grande quantidade de gases combustíveis, não é uma condição normal, mas pode acontecer, desde que investigado e avaliado os possíveis riscos desta operação (IEEE C57.104, 1991). A identificação de uma condição anormal requer a avaliação da quantidade de gases gerados presentes e a sua taxa de geração ao longo do tempo.

Por muitos anos a técnica de análise dos gases dissolvidos no óleo foi a única utilizada para avaliação dos processos de degradação e envelhecimento do isolamento em sua fase inicial. O óleo submetido às constantes variações de temperatura se decompõe, produzindo diversos gases, que tendem a se manter dissolvidos neste óleo.

O processo de falha é relacionado com as temperaturas esperadas no óleo em função de seus mecanismos. Assim a ocorrência de sobreaquecimento no isolamento deve elevar a temperatura a valores que variem em função de sua severidade. Da mesma forma, a ocorrência de ruptura da rigidez dielétrica do óleo, com o surgimento de descargas, pode ser associada com as temperaturas de formação do arco em função de sua intensidade. Assim, são estabelecidas faixas de temperatura para as quais existe uma maior probabilidade da ocorrência de um determinado processo. Estabelecida a correlação entre a temperatura, o processo de falha e sua intensidade, é possível estimar nos equipamentos os processos envolvidos e faixas de temperaturas esperadas para falhas específicas. Esta é a forma usual de estabelecer uma correlação entre a formação de gases no óleo e processos ou falhas específicas (ZIRBES, 2003).



Dependendo da energia envolvida, da sua localização, da ocorrência intermitente ou contínua, cada tipo de falha afeta o óleo ou papel de uma forma diferente, gerando quantidades relativas características de gases dissolvidos (DUKARM, 1993).

A estimativa da quantidade de gases formados, bem como a sua evolução, em função da temperatura, pode ser visualizada na figura 2.3 (IEEE C57.104, 1991):




Figura 2.2 – Pressões parciais do equilíbrio térmico de Halstead como função da temperatura.

Com base na temperatura de decomposição do óleo, e em função da formação de gases para essa temperatura, supõe-se que uma falha possa estar ocorrendo. Por exemplo, falhas de origem elétrica, do tipo descargas contínuas ou condição de arco elétrico, podem levar a temperatura do óleo na região em torno desta descarga a níveis elevados, alcançando 1800°C, e levar à formação significativa de acetileno (C<sub>2</sub>H<sub>2</sub>).

Para temperaturas entre 150°C e 400°C os gases mais significativos são os de baixo peso molecular como o hidrogênio (H<sub>2</sub>) e o metano (CH<sub>4</sub>), com concentrações mais elevadas de metano. Um aumento mesmo que relativamente pequeno de temperatura faz com que a concentração de hidrogênio seja superior a do metano. Assim a relação entre os dois gases é totalmente alterada. O valor desta relação é uma evidência para discriminar entre falhas térmicas de baixa intensidade. Estes exemplos embora simples e parciais ilustram os mecanismos básicos da metodologia de diagnóstico de falhas através dos gases dissolvidos (ZIRBES, 2003).

Do ponto de vista operacional, os procedimentos de detecção e análise dos gases combustíveis, devem seguir as seguintes prioridades (IEEE C57.104, 1991):

- 1) Detecção: detectar a geração de algum gás que excede as quantidades consideradas “normais” e utilizar critérios apropriados que possam identificar as possíveis anormalidades que por ventura estejam ocorrendo;
- 2) Avaliação: avaliar o impacto desta anormalidade na serviçabilidade do transformador, usando um conjunto de critérios ou recomendações;
- 3) Ação: recomendar ação, que vai desde a confirmação da existência da falha com análise suplementar, redução da carga, ou até mesmo a retirada da unidade de serviço.

A análise dos gases pode ser feita, basicamente de duas formas: a primeira levando em conta as relações de gases, onde são estabelecidas faixas de valores prováveis para a ocorrência de determinados tipos de falhas e a outra levando em conta a formação do gás mais significativo para aquele tipo de falha, também chamado gás chave. Atualmente, estão em intenso desenvolvimento métodos desenvolvidos a partir de técnicas de inteligência artificial, que levam em conta os critérios historicamente definidos, ou ainda, dados históricos de diagnósticos obtidos para determinados equipamentos.

### **2.7.1 – MÉTODOS CONVENCIONAIS**

Como métodos convencionais de diagnóstico de falhas incipientes no óleo isolante de transformadores, podemos citar os métodos que utilizam relações de concentrações de gases, como o método de Rogers, o método de Doernenburg e o projeto de revisão da NBR7274, baseada na IEC 599/78; os métodos que utilizam relações e concentrações individuais de gases, como o proposto pelo Laboratoire Central des Industries Électriques (LCIE) e o método proposto pelo Laboratoire Belge de L'Industrie Électrique (Laborelec); e os métodos envolvendo concentrações individuais de gases, como o trabalho de Duval e o método dos gases indicadores (chaves) recomendado pela IEEE C57.104/91.

Os critérios de Rogers, de Doernenburg, o utilizado pela NBR7274 e o método dos gases indicadores (chaves) foram utilizados e implementados neste trabalho e serão detalhados no capítulo 4. Para os demais, serão comentados a seguir alguns aspectos pertinentes no desenvolvimento destas metodologias.

O método proposto pelo Laboratoire Central des Industries Électriques (LCIE), divide o conjunto de gases em quatro grupos conforme um gás característico. Utiliza onze concentrações de gases diferentes como dados principais e seis relações de concentração como dados auxiliares no diagnóstico. Utiliza as concentrações individuais apenas qualitativamente em função de sua presença ou não dos gases. Este método propõe apenas a identificação das várias falhas, não sendo mencionado um critério para a definição da condição de normalidade do isolamento (ZIRBES, 2003).

O método proposto pelo Laboratoire Belge de l'Industrie Électrique (Laborelec), utiliza como critério de diagnóstico a concentração de três gases individuais, o volume total de gases contendo um ou dois átomos de carbono e uma relação de concentrações. Este método identifica a condição de normalidade do isolamento e as falhas pela sua natureza (elétrica, térmica) com nove níveis e pela sua intensidade com quatro níveis. Este método é um dos métodos de diagnóstico recomendados na NBR 7274 (ZIRBES, 2003).

O método proposto por DUVAL (2002), leva em conta apenas a concentração percentual relativa dos gases acetileno, etano e metano. O princípio de funcionamento do critério é melhor visualizado pela figura 2.4, onde a evolução de gases gerados para determinadas falhas, é representada por um triângulo. As coordenadas são definidas pela relação percentual de cada um dos gases em relação ao total de gases gerados. O critério pode identificar três falhas de origem elétrica e três falhas de origem térmica.




Figura 2.3 – Triângulo de Duval.

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

*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.

## 2.7.2 – MÉTODOS QUE UTILIZAM TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

Como comentado anteriormente, diversas técnicas de inteligência artificial foram e continuam a ser aplicadas para o diagnóstico do isolamento de equipamentos a partir dos dados de gases dissolvidos no óleo. Muitos fatores contribuem para o uso destas ao problema proposto, onde podemos citar a facilidade de integração de várias informações e dados, não necessariamente de mesma origem, o aumento da quantidade de informações referentes ao supervisionamento dos equipamentos em operação e a necessidade de avaliação do estado de um equipamento em função de sua importância ao sistema, dentre outras.

Neste contexto, técnicas computacionais estão sendo desenvolvidas e podem consistentemente diagnosticar condições de falhas incipientes e ainda vislumbrar novos conhecimentos aos especialistas (ZHANG, DING, et al., 1996). Normalmente, as técnicas mais utilizadas são as de sistemas especialistas, lógica *fuzzy* e redes neurais artificiais. Todas estas são utilizadas de forma individual ou ainda na forma de sistemas híbridos, com a aplicação de sistemas neuro-fuzzy ou sistemas especialistas combinados com lógica *fuzzy*.

Os sistemas especialistas de uma maneira geral utilizam os critérios de diagnóstico tradicionais citados anteriormente para a formação de sua base de regras, além de incorporar algumas regras provenientes de experiência prévia na área. Podem conter ainda dados referentes aos modelos de cada equipamento e utilizar os dados característicos na análise final, sugerindo recomendações de intervenção ou reamostragens.

Redes neurais já vinham sendo usadas extensivamente em aplicações onde o reconhecimento de padrões é necessário. Elas são adaptativas, capazes de tratar com relações não lineares e também para generalizar soluções para um novo conjunto de dados. Seguindo estas características, o processo de detecção de falhas incipientes em transformadores usando RN pode ser reduzido à associação do processo de entradas (padrões de concentrações de gases) e saídas (tipo de falha) (GUARDADO, NAREDO, et al., 2001).

O uso de sistemas de diagnóstico baseados em conjuntos *fuzzy* tem como vantagem reduzir a sensibilidade aos processos de amostragem e análise dos gases. Também podem incorporar informações históricas da evolução dos dados de geração de gases, e utilizá-las em seus processos de diagnóstico. Normalmente, o ajuste das funções de pertinência ao conjunto *fuzzy* é dependente dos métodos tradicionais de análise e do conhecimento existente. Também teriam maior facilidade para trabalhar com as incertezas existentes, como por exemplo, a dos dados de medição, obtendo conclusões que métodos convencionais não alcançariam.

## 2.8 – FATORES QUE CAUSAM INCERTEZAS NO PROCESSO DE DIAGNÓSTICO

Muitos são os fatores que geram incertezas nos teor de gases dissolvidos, bem como na interpretação destes valores. Várias técnicas para detecção e medição de gases têm sido desenvolvidas. Contudo, deve ser reconhecido que a análise destes gases e interpretação de seu significado não é uma ciência, mas uma arte sujeita a variabilidade (IEEE C57.104, 1991). Sua presença e quantidade medida de cada um dos gases é dependente do processo de geração de gás no óleo, do processo de amostragem do gás e da análise cromatográfica realizada no laboratório. Ocorre então a utilização de diferentes critérios de interpretação, em diferentes empresas do setor elétrico, dependendo dos fabricantes do equipamento, dos sistemas de preservação e circulação do óleo, do histórico do carregamento dos transformadores, bem como da solubilidade e grau de saturação dos gases (YANG, LIAO, et al., 2001).

Dependendo da temperatura do meio, pode haver a migração de gases entre a celulose e o óleo. Este fenômeno pode levar a concentrações de gases diferentes, como pode ser visualizado na Tabela 2.1 (SOKOLOV, BULGAKOVA, et al., 2001), onde para um mesmo transformador são obtidos valores diferentes para estas concentrações, à diferentes temperaturas. Como exemplo, podemos citar o gás hidrogênio, que à 20°C apresentava traços não significativos de geração. Em temperaturas mais elevadas, no caso à 64°C, a sua formação poderia indicar falsas interpretações e diagnósticos diferentes para uma mesma amostra de óleo, sendo que nenhum tipo de falha está ocorrendo.

Tipos de Gases	Concentração a 20°C	Concentração a 64°C
H <sub>2</sub> (ppm)	Traços	56
CH <sub>4</sub> (ppm)	172	269
C <sub>2</sub> H <sub>4</sub>	78	147
C <sub>2</sub> H <sub>2</sub>	-	1.3
C <sub>2</sub> H <sub>6</sub>	56	90
CO	923	1163
CO <sub>2</sub>	1929	2654
O <sub>2</sub>	0.08	0.09
N <sub>2</sub>	2.9	5.5

Tabela 2.2 – Efeito da temperatura na formação de gases dissolvidos.

Outro fator importante que gera incertezas na análise de gases, é que os estudos de determinados processos de falhas são sempre realizados de forma individual, mas podem ocorrer casos onde estes processos atuam de forma conjunta, ou como conseqüências uns dos outros. Por exemplo, a ocorrência de descargas parciais pode causar a polimerização do óleo

com a conseqüente deposição deste produto sobre o isolamento. Esta deposição, dependendo da localização e da intensidade, pode ocasionar sobreaquecimento em função da alteração de troca de calor (ZIRBES, 2003).

Como já mencionado anteriormente, os processos de amostragem de óleo, com a medição de gases dissolvidos, envolvem incertezas. Para ilustrar essas variações em comparação com os valores reais, são apresentados na Tabela 2.3 os resultados de uma comparação interlaboratorial realizada pela IEC.

	Desvio médio do valor real, em %	
	Amostra A	Amostra B
Melhor Laboratório	7	14
Pior Laboratório	39	70
Maior desvio obtido para um gás	150	400

Tabela 2.3 – Resultados de exatidão para resultados DGA para diferentes laboratórios.

Nota-se pela Tabela 2.3 (DUVAL, 1989), que no pior caso, quando ocorre o maior desvio obtido para um gás, em medições de determinada amostra, esses valores chegam a 400% em relação ao valor real, o que pode resultar em interpretações totalmente equivocadas do processo de falha que possa estar ocorrendo.

## 2.9 – CONCLUSÕES

Neste capítulo foram apresentadas as considerações referentes ao isolamento elétrico, considerando o conjunto papel-óleo, bem como o comportamento de cada um destes materiais separadamente. Alguns valores das principais grandezas elétricas destes materiais foram listados, bem como um resumo de algumas das principais técnicas utilizadas na identificação das suas condições, e seus reflexos na operação dos equipamentos.

Também foram descritos os principais agentes e produtos da degradação e envelhecimento do sistema que compõe o isolamento. Dando maior ênfase ao óleo isolante, foram tratados os principais gases formados quando da ocorrência de determinadas falhas, mostrando a evolução destes valores em função da temperatura e em função da severidade da falha que possa estar ocorrendo.

Verificou-se a importância e a utilidade do monitoramento das condições do isolamento na avaliação do estado de um equipamento elétrico. Foram apresentadas algumas considerações específicas acerca da análise dos gases dissolvidos no óleo, e comentadas as técnicas convencionais e técnicas que se utilizam de inteligência artificial nesse processo de diagnóstico.

### 3 REDES NEURAIS ARTIFICIAIS E SISTEMAS DE LÓGICA *FUZZY*

#### 3.1 – INTRODUÇÃO

Como já mencionado anteriormente, a demanda crescente por energia e a sobrecarga atual dos sistemas de potência impõem a necessidade cada vez maior do uso de ferramental adequado de monitoramento e diagnóstico do estado operativo dos sistemas e equipamentos elétricos, de modo a aumentar sua confiabilidade e reduzir o número de paradas programadas e eventuais, otimizando assim o fornecimento de energia elétrica e o uso das instalações (VARELLA, CHEIM, et al., 2000).

Neste cenário, e especificamente em relação aos transformadores, técnicas de inteligência artificial vêm sendo utilizadas para o monitoramento das condições e para identificação de falhas incipientes, através da análise dos gases dissolvidos no óleo (cromatografia gasosa).

Contudo, muitas incertezas existem nos dados de gases devido ao processo de geração do mesmo no óleo, ao processo de amostragem e devido à análise cromatográfica realizada em laboratório. Os critérios de interpretação dos gases, então, variam de ferramenta para ferramenta, dependendo de sua construção, da preservação do óleo, do sistema de circulação deste, do histórico de carregamento do transformador e também do grau de saturação dos gases. Para tratar com estas incertezas, dos classificadores de falha baseados nas quantidades de gases extraídos dos transformadores, também estão sendo propostas na literatura várias técnicas de inteligência artificial, (LIN, LING, et. al., 1993).

Este capítulo visa descrever as técnicas de inteligência artificial, especificamente as redes neurais artificiais e sistemas de lógica *fuzzy*, empregadas neste trabalho. Primeiramente situando as mesmas no contexto histórico, passando por suas características, aspectos pertinentes de cada técnica e finalizando com algumas aplicações ao problema proposto.

#### 3.2 – REDES NEURAIS ARTIFICIAIS

O neurônio biológico tem três tipos de componentes que são de particular interesse no entendimento do neurônio artificial: seus dendritos, soma, e axônios. Os muitos dendritos recebem sinais de outros neurônios. Os sinais são impulsos elétricos que são transmitidos através de processo químico. A ação dos transmissores químicos modifica o novo sinal, de

maneira similar à ação dos pesos na rede neural artificial, (FAUSETT, 1994). A figura 3.1 apresenta os constituintes de uma célula neural biológica.




Figura 3.1 – Esquema dos constituintes da célula neural.

A rede neural artificial é um sistema de processamento da informação que tem características de desempenho em comum com as redes neurais biológicas. Redes neurais artificiais têm sido desenvolvidas como generalização de modelos matemáticos do conhecimento humano, baseado nas suposições que (FAUSETT, 1994):

1. O processamento da informação ocorre através de muitos elementos simples, chamados neurônios;
2. Os sinais são transmitidos entre os neurônios através de um elo de conexão;
3. Cada elo de conexão tem um peso associado, o qual, em redes neurais típicas, são múltiplos do sinal transmitido;
4. Cada neurônio aplica uma função de ativação (normalmente não linear) em sua rede de entrada (soma dos pesos multiplicados pelos sinais de entrada) para determinar seu sinal de saída.

As redes neurais são caracterizadas por (1) seu padrão de conexão entre os neurônios (chamado sua arquitetura), (2) seu método de determinação dos pesos nas conexões (chamado seu treinamento, ou aprendizado), e (3) sua função de ativação (FAUSETT, 1994).

A rede neural consiste num grande número de elementos de processamento simples chamados neurônios, unidades, células ou nós. Cada neurônio é conectado a outro neurônio por meio de elos de comunicação direta, cada qual com um peso associado. Os pesos representam a informação que será usada pela rede para resolver o problema. As redes neurais podem ser aplicadas a uma grande variedade de problemas, tal como armazenagem e recuperação de dados, classificação de padrões, mapeamento de padrões de entrada para



padrões de saída, agrupamento de padrões similares, ou para encontrar soluções em problemas de otimização com restrições (FAUSETT, 1994).

Cada neurônio tem um estado interno, chamado de nível de ativação ou atividade, o qual é função das entradas que ele recebe. Tipicamente, o neurônio envia sua ativação como um sinal para os vários outros neurônios. É importante salientar que um neurônio pode enviar somente um sinal por vez, embora o sinal seja transmitido para os diversos outros neurônios.

Em outras palavras pode-se dizer que uma rede é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede. Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior.

Redes neurais são também classificadas de acordo com a arquitetura em que foram implementadas, topologias, características de seus nós, regras de treinamento, e tipos de modelos.

### **3.2.1 – HISTÓRICO DAS RNA**

A construção de redes neurais artificiais (RNAs) tem inspiração nos neurônios biológicos e nos sistemas nervosos. Entretanto, é importante compreender que atualmente as RNAs estão muito distantes das redes neurais naturais (RNNs) e freqüentemente as semelhanças são mínimas. Os primeiros modelos surgiram com a intenção de imitar a realidade biológica, preocupação não compartilhada por muitos pesquisadores atuais. De fato, dois fatores diferentes motivam a pesquisa hoje em dia (AZEVEDO, BRASIL, et al., 2000):

- o primeiro é modelar o sistema nervoso com suficiente precisão de tal modo a poder observar um comportamento emergente que, sendo semelhante ao comportamento do ser vivo modelado, possa servir de apoio às hipóteses usadas na modelagem.
- o segundo é construir computadores com um alto grau de paralelismo.

O trabalho na direção do conhecimento do sistema nervoso começou há um século aproximadamente. Entretanto só depois dos trabalhos de McCulloch e Pitts, Hebb e Rosenblatt, é que muitos cientistas se interessaram pelo campo. Na seqüência e de igual importância, vieram os trabalhos de Widrow e Hoff; Hopfield; Rumelhart, Hinton e Williams. Abaixo é apresentado um breve histórico de redes neurais:

- neurofisiologista McCulloch e matemático Walter Pitts (1943), desenvolveram uma RNA com apenas uma saída, dependente da função de entrada que consistia na soma do valor de suas diversas entradas associadas aos seus pesos. O fluxo de informação através da rede assumia um degrau como unidade de tempo para a passagem do sinal de um neurônio para o próximo. Este tempo de atraso permitia que a rede modelasse alguns processos fisiológicos, tal como a percepção de calor e frio (FAUSETT, 1994).
- psicólogo Donald Hebb (1949), desenvolveu a primeira lei de aprendizagem para uma rede neural artificial. Sua premissa parte de que se dois neurônios são ativados simultaneamente, então a força da conexão entre eles deveria ser aumentada (FAUSETT, 1994).
- Rosenblatt (1958), introduziu e desenvolveu uma grande classe de redes neurais artificiais chamadas *perceptrons* (FAUSETT, 1994), que se transformaram nas redes mais simples usadas para classificação de padrões ditos linearmente separáveis. Consistem de um único neurônio com pesos ajustáveis e com uma saída binária, além de um valor de polarização, (BARRETO, 1999).
- Widrow e Hoff desenvolveram, em 1960, um modelo bastante semelhante ao do *perceptron* em que o neurônio tem uma saída proporcional a soma ponderada das excitações, sendo, portanto um modelo linear que foi batizado ADALINE (ADAPTative LINEar Element). Mais tarde utilizou um modelo multidimensional que foi denominado MADALINE, (BARRETO, 1999).
- Hopfield (1982) propôs uma rede com ciclos. Esta rede possui neurônios dinâmicos, cuja dinâmica é introduzida por um retardo correspondente ao tempo de funcionamento do neurônio, e uma saída binária (BARRETO, 1999). Estas redes podem ser usadas para resolver problemas sujeitos a restrições (FAUSETT, 1994).
- Rumelhart, Hinton e Williams redescobriram (já havia sido desenvolvido por Werbos, 1974) um poderoso método denominado *Backpropagation*, onde para cada exemplo de treinamento ele realizava os seguintes passos: - cada neurônio de entrada recebe o sinal de entrada e o transmite a todos os outros neurônios da camada intermediária; - cada unidade da camada intermediária aplica a função ativação e envia o sinal para a camada de saída; - cada neurônio da camada de saída aplica a sua função ativação; - cada saída é comparada com a saída meta, sendo feita a correção do erro e *bias* na saída e na camada intermediária; atualiza-se valores e testa-se a condição de parada (FAUSETT, 1994).

### 3.2.2 – PRINCIPAIS MODELOS DE REDES NEURAIS ARTIFICIAIS

Neste item, e para o melhor entendimento do funcionamento das redes neurais, serão descritos os dois tipos de redes mais utilizados na solução de problemas em sistemas de potência: as do tipo *Multilayer Perceptron* (MLP) e as do tipo *General Regression Neural Network* (GRNN), conforme FAUSETT (1994), AZEVEDO, BRASIL, et al., (2000), HAYKIN (2001) e CARDOSO JR. (2003).

#### 3.2.2.1 - Redes do tipo MLP

Tipicamente, a rede MLP consiste de um conjunto de unidades sensoriais (nós de fonte) que constituem a camada de entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída de nós computacionais. O sinal de entrada se propaga para frente através da rede, camada por camada (HAYKIN, 2001). Estas redes, que representam uma generalização do *perceptron* de camada única, utilizam-se de algoritmo de treinamento por retropropagação, e constituem-se na arquitetura de redes neurais mais utilizada, uma vez que estas são capazes de aproximar qualquer função não linear, com maior ou menor precisão, dependendo do número de neurônios (CARDOSO JR, 2003). A figura 3.2 mostra o grafo arquitetural de um *perceptron* de múltiplas camadas com duas camadas ocultas.




Figura 3.2 – Grafo arquitetural de um *perceptron* de múltiplas camadas com duas camadas ocultas.

Basicamente, a aprendizagem por retropropagação de erro consiste de dois passos através das diferentes camadas da rede: um passo para frente, a propagação, e um passo para trás, a retropropagação. No passo para frente, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede e seu efeito se propaga através da rede, camada por camada. Finalmente, um conjunto de saídas é produzido como a resposta real da rede e comparado com a resposta esperada. Durante o passo de propagação, os pesos sinápticos da rede são todos fixos (HAYKIN, 2001). Durante o passo para trás, mediante algum

procedimento matemático, como o método dos mínimos quadráticos, os neurônios modificam os pesos de suas conexões, diminuindo o erro apresentado pela rede. O processo repete-se ciclicamente, até que os neurônios da camada de saída apresentem um erro inferior ao estipulado (CARDOSO JR., 2003).

Geralmente, o neurônio ( $i$ ) (Fig. 3.2) de determinada camada ( $k$ ) recebe informações de entrada, multiplica-as por cada um dos pesos correspondentes às conexões que receberam os dados, efetua o somatório ( $\Sigma$ ) destes produtos e processa este somatório através de uma função de transferência ( $f$ ), produzindo um resultado ( $a^k(i)$ ). Geralmente é utilizado um valor auxiliar  $b$  (*bias*) para representar uma polarização, valor abaixo do qual a saída é nula.




Figura 3.3 – Neurônio Elementar.

Um *perceptron* de múltiplas camadas tem três características distintivas (HAYKIN, 2001):

- o modelo de cada neurônio da rede inclui uma função de ativação não-linear. O ponto importante a se enfatizar aqui é que a não-linearidade é suave, ao contrário da limitação abrupta. Uma forma normalmente utilizada de não-linearidade que satisfaz esta exigência é uma não-linearidade sigmóide definida pela função logística:

$$a_i = \frac{1}{1 + \exp(-v_i)} \quad (3.1)$$

onde  $v_i$  é o campo local induzido (a soma ponderada de todas as entradas sinápticas acrescidas do *bias*) do neurônio  $i$ , e  $a_i$  é a saída do neurônio;

- a rede contém uma ou mais camadas de neurônios intermediários, que não são parte da entrada ou da saída da rede. Estes neurônios capacitam a rede a aprender tarefas

complexas extraindo progressivamente as características mais significativas dos padrões (vetores) de entrada;

- a rede exibe um alto grau de conectividade, determinado pelas sinapses da rede. Uma modificação na conectividade da rede requer uma mudança na população das conexões sinápticas ou de seus pesos.

É através da combinação destas características, juntamente com a habilidade de aprender da experiência através de treinamento, que o *perceptron* de múltiplas camadas deriva seu poder computacional. Estas mesmas características, entretanto, são também responsáveis pelas deficiências no estado atual de nosso conhecimento sobre o comportamento da rede. Primeiro, a presença de uma forma distribuída de não-linearidade e a alta conectividade da rede tornam difícil a análise teórica de um *perceptron* de múltiplas camadas. Segundo, a utilização de neurônios ocultos torna o processo de aprendizagem mais difícil de ser visualizado. Em um sentido implícito, o processo de aprendizagem deve decidir quais características do padrão de entrada devem ser representadas pelos neurônios ocultos. O processo de aprendizagem, conseqüentemente, torna-se mais difícil porque a busca deve ser conduzida em um espaço muito maior de funções possíveis, e deve ser feita uma escolha entre representações alternativas do padrão de entrada.

### **3.2.2.2 – Redes do tipo GRNN**

Neste item, tomamos um enfoque diferente do apresentado anteriormente para as redes MLP, ao ver o projeto de uma rede neural como um problema de ajuste de curva (aproximação) em um espaço de alta dimensionalidade. De acordo com este ponto de vista, aprender é equivalente a encontrar uma superfície, em um espaço multidimensional, que forneça o melhor ajuste para os dados de treinamento, com o critério de “melhor ajuste” sendo medido em um sentido estatístico. Correspondentemente, generalização é equivalente ao uso desta superfície multidimensional para interpolar os dados de teste. No contexto de uma rede neural, as unidades ocultas fornecem um conjunto de “funções” que constituem uma “base” arbitrária para os padrões (vetores) de entrada, quando eles são expandidos sobre o espaço oculto: estas funções são chamadas de funções de base radial (HAYKIN, 2001).

A rede GRNN é uma variação da rede de base radial que apresenta grande capacidade de generalização e é utilizada principalmente para aproximar funções. A rede GRNN é uma rede direta que, a partir de um vetor de entrada  $\underline{x}$  calcula um vetor de saída  $\underline{\hat{y}}$ . Sua arquitetura pode vista na figura 3.3 (CARDOSO JR., 2003).

Para o melhor entendimento de seu funcionamento, as conexões entre as camadas padrão e soma que apresentam pesos iguais a zero foram omitidas. Um peso de valor zero é utilizado quando não há conexão entre estas unidades, enquanto que um peso de valor  $w \neq 0$  representa um elo de ligação entre as mesmas.




Figura 3.4 – Arquitetura da rede GRNN.

As unidades de entrada têm como função distribuir as variáveis  $x$  a todos os neurônios que compõem a camada padrão (unidades padrões), onde:

$\underline{x}$  – o vetor que contém todas as variáveis de entrada.

$p$  – corresponde ao número de variáveis de entrada.

Cada neurônio pertencente à camada padrão corresponde a um exemplo ou a um centro de grupo (*cluster*). O número de neurônios que compõem esta camada corresponde ao número de exemplares utilizados no aprendizado. Após o aprendizado, quando um novo vetor é apresentado à rede, é calculada a distância entre este e os exemplares previamente definidos e armazenados. Geralmente é utilizada a distância euclidiana na realização destes cálculos.

O valor quadrático ou absoluto destas diferenças é somado e multiplicado pelo *bias*, sendo então enviados a uma função de ativação não-linear. Assim, quando a distância entre o vetor de pesos e o vetor de entrada for próximo a zero, o valor de saída do neurônio será próximo a unidade, o valor do *bias* aplicado tem a finalidade de ampliar ou reduzir a área da função radial. Assim, para cada neurônio é associado um vetor peso, que pode ser visto como o centro de uma superfície gaussiana no espaço multidimensional sendo ajustado seu raio pelo valor do *bias*. A saída da função radial é aplicada a um neurônio como função de ativação

linear que ajusta as saídas. Assim, se o vetor de entrada é diferente do vetor de pesos associado, o valor repassado para a camada com função de ativação linear é pouco significativo. Ao contrário, se o vetor de entrada é idêntico ao vetor de pesos os pesos da segunda camada são repassados integralmente a função de ativação linear.

Normalmente, utiliza-se uma exponencial como função de ativação. O processamento interno de uma unidade constituinte da unidade padrão pode ser visualizado na figura 3.4. O valor 0.8326 é obtido pela raiz quadrada do logaritmo neperiano de 0.5, portanto, se a distância euclidiana for igual ao espalhamento (*spread*), a resposta do neurônio será 0.5.

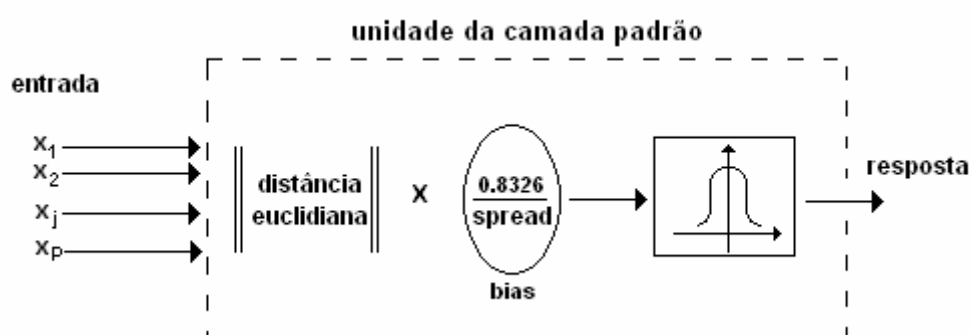


Figura 3.5 – Operação Interna da Unidade Padrão.

O ajuste do parâmetro *spread* é realizado de maneira heurística, sendo este geralmente um valor entre a mínima e máxima distância entre os vetores que correspondem aos padrões armazenados. Caso o parâmetro *spread* seja muito grande, várias unidades poderão ser excitadas quando uma entrada for apresentada à rede. Neste caso a rede apresenta uma capacidade de generalização demasiada. De outra forma, se o valor for muito pequeno implica em uma excitação única e exclusiva da unidade que possui o exemplar mais próximo ao vetor apresentado à rede, sendo esta incapaz de generalizar.

A performance da rede é principalmente influenciada pelo parâmetro de ajuste do *bias* (*spread*) e pelos padrões armazenados. A saída das unidades pertencentes à camada padrão é enviada à camada de soma. O número de unidades que compõem esta camada corresponde ao número de observações (saídas desejadas).

As unidades de soma têm a função de realizar o somatório da saída das unidades padrões, de acordo com o número de observações que cada exemplar representa. Este número de observações varia conforme o número de saídas desejadas. As unidades da camada de saída simplesmente dividem cada um dos somatórios resultantes das unidades de soma pelo somatório total de todas as unidades que compõem a camada de soma.

A saída da rede pode ser calculada de forma direta pela equação 3.2:

$$\underline{\hat{y}}(\underline{p}) = \frac{\underline{w}^T \underline{a}(\underline{p})}{\underline{1}^T \underline{a}(\underline{p})} \quad (3.2)$$

onde:

$$\underline{1} = \begin{pmatrix} 1 \\ 1 \\ \cdot \\ \cdot \\ \cdot \\ 1p \end{pmatrix} \quad (3.3)$$

e

$$a_j(\underline{p}) = f\left(\left\| \underline{w}_j^T - \underline{x} \right\| \underline{b}_j\right) \quad (3.4)$$

sendo  $j$ , o  $j$ -ésimo elemento de  $\underline{a}$  e,  $\left\| \underline{w}_j^T - \underline{x} \right\|$ , a distância euclidiana entre a  $j$ -ésima linha da matriz peso  $\underline{W}$  e o vetor de entrada  $\underline{x}$ . Do mesmo modo,  $\underline{b}_j$ , é o  $j$ -ésimo *bias*. A função de transferência ou função ativação  $f$  é dada por:

$$f(\underline{n}) = e^{-\underline{n}^2} \quad (3.5)$$

A rede GRNN pode ser utilizada para fins de previsão, modelagem, mapeamento, interpolação ou controle. Entre as principais vantagens apresentadas por estas redes, citam-se (CARDOSO JR., 2003):

- o processo de aprendizado ocorre em um único passo (não é um processo iterativo) e pode generalizar a partir de exemplos tão logo estes sejam armazenados;
- fácil implementação;
- o resultado é limitado aos valores mínimos e máximos das observações;
- não converge a um mínimo local da função utilizada como critério de erro (isto pode ocorrer com processos iterativos), uma vez que esta não utiliza tal função.

A principal desvantagem com relação a outras redes é que requer substancial esforço computacional para avaliar novos pontos, quando o conjunto de exemplos utilizados durante o treinamento for muito grande. Neste caso sugere-se a utilização de técnicas de agrupamento (*cluster*) para primeiramente definir o centro dos agrupamentos (CARDOSO JR., 2003).



### 3.2.3 – ALGUMAS APLICAÇÕES DE REDES NEURAS ARTIFICIAIS EM DIAGNÓSTICO PREVENTIVO DE TRANSFORMADORES

Em 1996, ZHANG, DING et al., utilizaram uma rede neural artificial para diagnóstico e detecção de falha em transformadores de força. A saída era caracterizada como: sobreaquecimento, corona, arco e condições normais de operação. Foram testadas diferentes topologias de redes, variando os parâmetros de entrada, o número de camadas escondidas e o número de nós na saída. O algoritmo utilizado para treinamento da rede foi o *back-propagation*. Os vetores de entrada eram constituídos da concentração individual dos gases incluindo em algumas variações o monóxido e dióxido de carbono. Os resultados foram satisfatórios, já que não distinguiam entre falhas de diferentes temperaturas, ou arco de alta ou baixa energia. A topologia ótima para todos os casos, foi a que utilizava duas camadas escondidas.

Posteriormente, em 1998, WANG, LIU et al., propuseram uma ferramenta que combinasse redes neurais artificiais com um sistema especialista. Baseado nas concentrações individuais dos gases como dados de entrada, estes eram submetidos a dois classificadores que indicavam condições normais e anormais de operação; um baseado em redes neurais e outro em sistema baseado no conhecimento. Se ambos indicassem normais, indicariam a não existência da falha, o grau de confiança do diagnóstico e o intervalo a ser considerado para os novos testes. Se não, os dados eram submetidos a dois detectores de falhas individuais também baseados, um em redes neurais e outro em sistema baseado no conhecimento. Combinados os diagnósticos de falhas, a ferramenta também deve indicar o tipo de falha a que o equipamento está submetido, o grau de confiança do diagnóstico e a recomendação de ação para a manutenção.

GUARDADO, NAREDO et al. (2001), realizaram um estudo comparativo da eficiência de redes neurais em diagnósticos de transformadores de potência utilizando DGA. Suas redes neurais foram treinadas de acordo com cinco critérios de diagnóstico comumente utilizados para óleo isolante: Doernenburg, Rogers modificado, Rogers, IEC e CSUS. Nos quatro primeiros critérios foram utilizadas relações gasosas como dados de entrada e no último, concentrações individuais de gases. Em todos estes foi utilizado um algoritmo de aprendizado do tipo *back-propagation*, uma função ativação do tipo sigmóide, uma arquitetura composta de três camadas e número de neurônios da camada escondida variando para cada critério utilizado. O modelo proposto apresenta resultados satisfatórios mantendo uma taxa de acerto de diagnóstico acima de 87% em todos os casos. Vale salientar que os dados utilizados para os testes, foram os mesmos utilizados durante o treinamento.

ZIRBES (2003) em sua dissertação de mestrado também abordou diferentes tipos de redes neurais no processo de diagnóstico de falhas incipientes em transformadores. Utilizando-se dos dados de geração de gases de forma individual ou na forma de relações, comprovou que as técnicas não convencionais podem apresentar resultados de diagnósticos bem mais significativos que as metodologias tradicionais. Entretanto a exemplo das metodologias tradicionais tem uma dependência muito grande da qualidade e representatividade dos dados utilizados. De uma maneira geral, ZIRBES mostrou que todos os algoritmos possuem condições de serem utilizados em aplicações *on-line*, onde os dados medidos podem ser diretamente processados, uma vez que seus tempos de processamento não são longos. Sob a ótica de facilidade, tempo envolvido na manutenção dos algoritmos, atualização de novos dados e resultados, a rede do tipo GRNN apresentou as melhores condições.

### 3.3 – LÓGICA NEBULOSA

Assim como a lógica de primeira ordem tem sua correspondente na teoria dos conjuntos, a lógica nebulosa tem sua correspondente na teoria dos conjuntos nebulosos. Um conjunto nebuloso não possui uma fronteira (um limite) preciso. A dicotomia entre pertencer e não pertencer não existe, mas sim uma gradação de pertinência. A palavra pertinência é adequada, pois se refere a quanto ser pertinente dizer que uma determinada sentença é verdadeira (BARRETO, 1999).

Na lógica de primeira ordem o conjunto de valores é {verdadeiro, falso}. Na lógica nebulosa existem valores intermediários que correspondem à maioria das situações do cotidiano. Em termos de conjuntos, nebulosidade se refere não à incerteza de um elemento pertencer a um conjunto, mas a uma progressão entre pertencer e não pertencer a este conjunto.

A lógica nebulosa consiste em aproximar a decisão computacional à decisão humana. Em vez de uma saída binária (0 ou 1) ou “sim” e “não”, a saída passa a ser representada através de variáveis lingüísticas, do tipo “muito improvável”, “improvável”, “indefinido”, “provável”, “muito provável”, e assim por diante..., facilitando a interação com o usuário e especialista.

Desde 1984 vem crescendo significativamente o uso de lógica nebulosa em sistemas de potência, seja nas áreas de controle, planejamento e operação. Os principais fatores que levaram a esse crescimento são: o baixo esforço computacional envolvido, simplicidade de

implementação e por serem sistemas bastante robustos em aplicações envolvendo informações imprecisas e vagas. Algumas características e requisitos comuns à escolha da lógica nebulosa são (CARDOSO JR., 2003):

- Disponibilidade de regras heurísticas (necessidade da ajuda de especialistas humanos);
- Inexistência de expressão em forma matemática como método de solução;
- A modelagem matemática do problema requer várias simplificações, resultando em um modelo pouco preciso;
- O problema envolve restrições vagas e/ou múltiplos objetivos conflitantes;
- A complexidade do problema torna a solução computacional bastante pesada, caso técnicas convencionais sejam utilizadas;
- Flexibilidade: as funções de pertinência utilizadas para representar determinada ocorrência podem ser alteradas dinamicamente, de acordo com a variação das condições impostas ao problema.

### 3.3.1 – HISTÓRICO

O conceito de conjunto *fuzzy* foi introduzido, em 1965, por Lotfi A. Zadeh (Universidade da Califórnia, Berkeley). A ele é atribuído o reconhecimento como grande colaborador do Controle Moderno. Em meados da década de 60, Zadeh observou que os recursos tecnológicos disponíveis eram incapazes de automatizar as atividades relacionadas a problemas de natureza industrial, biológica ou química, que compreendessem situações ambíguas, não passíveis de processamento através da lógica computacional fundamentada na lógica booleana.

Procurando solucionar esses problemas o Prof. Zadeh publicou em 1965 um artigo resumindo os conceitos dos conjuntos *fuzzy*, revolucionando o assunto com a criação de sistemas *fuzzy*, com limites que não são precisos. A pertinência em um conjunto *fuzzy* não é a questão de afirmativo ou negativo, e sim o grau com que se pode afirmar algo (KLIR E YUAN, 1995).

Poucos trabalhos foram feitos nos anos que se seguiram, havendo até 1971 uma dezena de artigos escritos. Em 1974, o Prof. Mamdani, do Queen Mary College, Universidade de Londres, após inúmeras tentativas frustradas em controlar uma máquina a vapor com tipos distintos de controladores, incluindo o PID, somente conseguiu fazê-lo através da aplicação do raciocínio *fuzzy* (NUNO E SOUZA, 2003).

Esse sucesso serviu de alavanca para muitas outras aplicações. Estimulados pelo desenvolvimento e pelas enormes possibilidades práticas de aplicações que se apresentaram, os estudos sobre sistemas *fuzzy* e controle de processos avançaram rapidamente, culminando com a criação em 1984, da Sociedade Internacional de Sistemas *Fuzzy*, constituída, principalmente, por pesquisadores dos países mais avançados tecnologicamente.

Sistemas *fuzzy* foram inicialmente ignorados nos Estados Unidos porque eram associados com inteligência artificial, um campo que periodicamente se obscurecia, resultando numa falta de credibilidade por parte da indústria.

Ainda segundo NUNO E SOUZA (2003), os japoneses não tiveram este preconceito; o interesse em sistemas *fuzzy* foi demonstrado por Yasunobu e Miyamoto da Hitachi, que em 1985 apresentaram simulações que demonstraram a superioridade de sistemas de controle *fuzzy* para o caminho de ferro de Sendai. Suas idéias foram adotadas e sistemas *fuzzy* foram usados para controle de aceleração, e frenagem quando a linha foi inaugurada em 1987.

Outro evento em 1987 ajudou a promover o interesse em sistemas *fuzzy* foi o encontro internacional de pesquisadores de *fuzzy* em Tokyo naquele ano. Yamakawa demonstrou o uso de controle *fuzzy* em um experimento de um pêndulo invertido, um problema clássico de controle em que um veículo tenta manter um poste montado no seu topo por uma dobradiça vertical com movimentos de ida e volta.

Deste ano em diante, o uso de controle e sistemas *fuzzy* aumentou significativamente, com a utilização desta técnica em sistemas industriais, principalmente onde o processo de decisão admite uma certa tolerância em sua decisão (BORGES, 2003).

### 3.3.2 – CONJUNTOS *FUZZY*

Uma das mais importantes capacidades do especialista humano é sua habilidade em trabalhar efetivamente com informações imprecisas, incompletas e incertas. Boa parte dos problemas relacionados com a representação de conhecimento, resulta das dificuldades que se tem em expressar, com a precisão desejada, idéias sobre pensamentos, sensações ou percepções do mundo físico que nos rodeia. E justamente o tratamento de dados incertos é crucial para o sucesso dos programas de muitas máquinas inteligentes. Os conjuntos *fuzzy* são propostos para gerenciar tais informações, ou ainda variáveis lingüísticas (LIN, LING, et al., 1993).

Assim, a imprecisão a respeito de uma afirmação, é expressa através de um número que em vez de probabilidade exprime a possibilidade da afirmação ser correta.

O tratamento da imprecisão, pode ser necessário nas diferentes etapas do manejo do conhecimento, ou seja, na (AZEVEDO, BRASIL, et al., 2000):

- a) coleta da informação;
- b) definição dos elementos do conhecimento;
- c) combinação de elementos entre si, ou seja, imprecisão nas premissas;
- d) forma de obter conclusões, isto é, aplicação de uma regra de raciocínio
- e) avaliação de uma seqüência de regras ou estruturas, como é o caso da aplicação sucessiva de regras de raciocínio.

Na aquisição de informação, o engenheiro de conhecimento e o próprio especialista deparam-se com informações não facilmente classificáveis e, certamente pessoas diferentes discordarão na classificação destes dados. Na definição dos elementos de conhecimento é necessário recorrer a métodos estatísticos e probabilísticos para depurar índices e frequências.

Na combinação dos elementos de conhecimento entre si, permitindo certa conclusão, é onde a presença da imprecisão mais se acentua. Entra aí, a consideração dos eventos serem ou não independentes entre si e o quanto cada informação pesa sobre a conclusão. Os conjuntos *fuzzy* se transformam neste contexto, nos valores das palavras.

Já em termos numéricos, os conjuntos *fuzzy* representam uma generalização dos conjuntos *crisp*.

O conjunto clássico, tratado aqui como conjunto *crisp* é definido como a forma de divisão de indivíduos em um dado universo em dois grupos: membros (que certamente pertencem ao conjunto) e não membros (que não pertencem). Contudo, muitos conceitos de classificação comumente são empregados e expressos em linguagem natural descrevendo conjuntos que não apresentam esta característica. Exemplos são os conjuntos de pessoas altas, carros caros, números muito maiores que outros, dias ensolarados, etc. Podemos notar que estes conjuntos têm limites imprecisos que facilitam a transição gradual de pertencer a um grupo ou não pertencer, e vice-e-versa (KLIR E YUAN, 1995).

Já o conjunto *fuzzy* pode ser definido matematicamente por dotar cada possível indivíduo no universo com um valor representando sua grade de pertinência no conjunto. Esta grade corresponde ao grau com a qual o indivíduo é similar ou compatível com o conceito representado pelo conjunto *fuzzy*. Indivíduos podem então, pertencer ao conjunto em maior ou menor grau, conforme indicação de sua função de pertinência. Os valores desta função são freqüentemente representados por valores numéricos reais em intervalos entre 0 e 1. Como as funções de pertinência podem ainda ser indicadas pelos valores 0 e 1, os conjuntos

*crisp* equivalem-se a um caso restrito de um conceito mais geral de conjunto  $fuzzy$ , para qual somente dois valores de pertinência são permitidas.

### 3.3.2.1 – Definições Básicas e Terminologia

Seja  $X$  um espaço de objetos e  $x$  um elemento genérico de  $X$ . Um conjunto clássico  $A$ ,  $A \subseteq X$ , é definido como uma coleção de elementos ou objetos  $x \in X$ , tal que cada  $x$  pode pertencer ou não ao conjunto  $A$ . Para definir uma função característica para cada elemento  $x$  em  $X$ , nós podemos representar um conjunto clássico  $A$  por um conjunto de pares ordenados  $(x, 0)$  ou  $(x, 1)$ , os quais indicam  $x \in A$  ou  $x \notin A$ , respectivamente.

Como já mencionado anteriormente, um conjunto  $fuzzy$ , diferentemente do conjunto clássico acima mencionado, expressa o grau para o qual um elemento pertence a um conjunto. Permite valores entre 0 e 1, os quais denotam o grau de pertinência de um elemento em um dado conjunto.

Definição: Se  $X$ , é uma coleção de objetos, denotados genericamente por  $x$ , então, um conjunto  $fuzzy$   $A$  em  $X$ , é um conjunto de pares ordenados, tal que:

$$A = (x, \mu_A(x)) \quad | \quad x \in X \quad (3.6)$$

onde:

$A$ : conjunto  $fuzzy$ ;

$x$ : elemento pertencente ao universo de discurso  $X$ ;

$X$ : universo de discurso;

$\mu_A(x)$ : função de pertinência.

Para a construção de um conjunto  $fuzzy$  necessita-se da identificação de um universo de discurso e da especificação de uma função apropriada de pertinência. A especificação de funções de pertinência é subjetiva, o que significa que, quando especificadas para um mesmo conceito, por pessoas diferentes, podem variar consideravelmente. Esta subjetividade vem das diferenças individuais em perceber ou expressar conceitos abstratos e tem pouco a ver com a aleatoriedade.

Na prática, quando o universo de discurso  $X$  é um espaço contínuo, nós usualmente dividimos o conjunto completo  $X$  em vários conjuntos  $fuzzy$ . Estes conjuntos, usualmente apresentam nomes que correspondem a adjetivos que aparecem em nosso uso lingüístico diário, e também são chamados valores lingüísticos ou rótulos lingüísticos. Um conjunto  $fuzzy$  é unicamente especificado por sua função de pertinência, onde as regras e conclusões serão

obtidas em função deste valor, e não mais do valor propriamente dito da grandeza em questão.

A representação destes conjuntos vai depender do tipo da equação escolhida para cada função. As representações mais usuais de conjuntos  $fuzzy$ , de acordo com a sua função de pertinência, são mostradas abaixo:

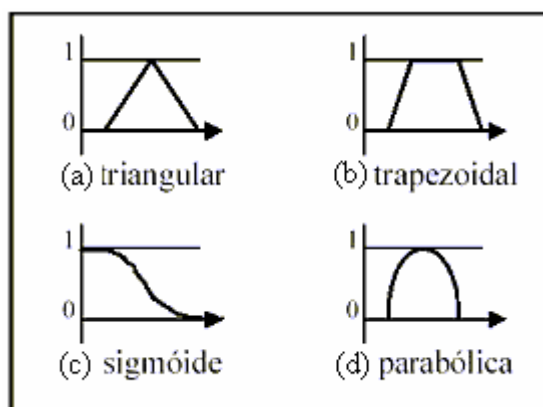


Figura 3.6 – Representação das funções de pertinência mais usuais.

Pode-se notar, pela representação acima, que as do tipo sigmóide e parabólica, utilizam apenas uma equação para obtenção do grau de pertinência em um determinado universo de discurso. Já a função triangular, vai utilizar duas funções e a trapezoidal, três equações.

### 3.3.3 – OPERAÇÕES COM CONJUNTOS *FUZZY*

Similarmente à teoria dos conjuntos, e a partir das definições apresentadas até aqui, a lógica  $fuzzy$  se desenvolve através da operação entre os conjuntos  $fuzzy$ . A seguir são apresentadas as principais operações com conjuntos  $fuzzy$  (operações básicas) (AZEVEDO, BRASIL, et al., 2000).

#### 3.3.3.1 – União

A união de dois conjuntos  $fuzzy$   $A$  e  $B$ , resulta em um conjunto  $fuzzy$   $C$  descrito como  $C = A \cup B$  ou  $C = A$  OU  $B$ , cuja função de pertinência está relacionada àquelas de  $A$  e  $B$  por:

$$\mu_C(x) = \max(\mu_A(x), \mu_B(x)) = \mu_A(x) \vee \mu_B(x) \quad (3.7)$$




Figura 3.7 – Representação gráfica da operação de união.

### 3.3.3.2 – Intersecção

A intersecção de dois conjuntos  $fuzzy$   $A$  e  $B$ , resulta em um conjunto  $fuzzy$   $C$  descrito como  $C = A \cap B$  ou  $C = A \text{ E } B$ , cuja função de pertinência está relacionada aquelas de  $A$  e  $B$  por:

$$\mu_C(x) = \min(\mu_A(x), \mu_B(x)) = \mu_A(x) \wedge \mu_B(x) \quad (3.8)$$




Figura 3.8 – Representação gráfica da operação de intersecção.

### 3.3.3.3 – Complemento

O complemento ou negação do conjunto  $fuzzy$   $A$ , denotado por  $\bar{A}(\neg A, NAOA)$ , pode ser entendido como o grau com o qual  $x$  não pertence a  $A$ , e é definido como:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (3.9)$$




Figura 3.9 – Representação gráfica da operação de complemento.

Como pode ser visualizado, estas operações são equivalentes às operações de conjuntos *crisp* quando o domínio de funções de pertinência estão restritas ao conjunto  $\{0, 1\}$ , ou seja, as operações básicas  $fuzzy$  são generalizações de operações dos conjuntos clássicos correspondentes. Contudo, estas não são as únicas generalizações.

Para cada uma das três operações, existe uma grande classe de funções as quais qualificam membros como generalizações dos conjuntos  $fuzzy$  de operadores clássicos. Funções que qualificam como intersecção e união  $fuzzy$  são implementados por uma família de operadores denominados *t-norms* e *t-conorms*, respectivamente.



Considerando que o complemento  $fuzzy$ , a interseção e união não são as únicas operações, contrariamente ao seu correspondente *crisp*, diferentes funções podem ser apropriadas para representar estas operações em diferentes contextos. Nota-se que, não somente as funções de pertinência dos conjuntos  $fuzzy$ , mas também operações com estes conjuntos, são dependentes do contexto. A capacidade de determinar funções de pertinência apropriadas e operações significativas no contexto de cada aplicação particular é crucial para tornar a teoria  $fuzzy$  útil.

### 3.3.4 – REGRAS FUZZY

Segundo AZEVEDO (2000), formalmente as regras  $fuzzy$  Se-Então, ou implicação  $fuzzy$ , admitem a seguinte forma:

$$Se\ x\ é\ A,\ Então\ y\ é\ B$$

Onde A e B são valores lingüísticos definidos pelos conjuntos  $fuzzy$  nos universos de discursos arbitrados às grandezas do problema. Assim,  $x\ é\ A$ , é o antecedente da regra e  $y\ é\ B$ , é chamado de conseqüente ou conclusão de uma regra.

A questão é como são manipulados os fatores de imprecisão em uma regra  $fuzzy$ . Na lógica booleana, a função de operadores booleanos E, OU e NÃO, fornece respostas do tipo 0 ou 1 e sim ou não. Na lógica  $fuzzy$ , os valores não são abruptos e suas respostas exibem uma distribuição de acordo com a função de pertinência.

Uma das formas mais usuais de combinação e operação com funções de pertinência, é do tipo obtido pelos operadores *Max/Min*. Basicamente, se considerarmos operação de união (OU), o resultado é igual ao maior valor de pertinência de todas analisadas na regra. Contrariamente, se realizamos operação de intersecção (E), a resposta é igual ao menor valor de pertinência considerado. Em operações de complemento será o valor que falta para aquele valor de pertinência chegar ao máximo, ou seja, à 1.

Explicadas as formas de operação das funções de pertinência, o problema agora seria como gerar tais regras  $fuzzy$ . Na maioria dos problemas, elas são geradas baseadas na experiência passada, onde deve-se conhecer a maioria das possíveis relações entrada-saída em termos  $fuzzy$ . Assim, as relações entrada-saída, ou regras são expressas facilmente com os estados Se-Então, tais como:

$$Se\ A\ E/OU\ B\ Então\ C$$

Onde E/OU são os operadores de união e intersecção lógica; A e B são as entradas acrescidas de um grau de pertinência; C corresponde a ação ou conclusão da regra.

Os graus de pertinência para um determinado conjunto de regras podem ser colocados somente na parte *Se* da regra, gerando através da combinação das mesmas o grau de pertinência da saída, que pode, dependendo do problema, ser considerado como um certo grau de confiabilidade da resposta final.

### 3.3.5 – ALGUMAS APLICAÇÕES DE LÓGICA *FUZZY* EM DIAGNÓSTICO PREVENTIVO DE TRANSFORMADORES

LIN, LING et al. (1993), utilizaram uma estrutura de lógica *fuzzy* associada a um sistema especialista no desenvolvimento de uma ferramenta para diagnóstico de falha em transformadores usando análise dos gases dissolvidos no óleo isolante (DGA). Baseado na experiência e em normas, criaram funções de pertinência; primeiro individualmente para cada gás, após, em relação aos limites de proporções de gases e por último em relação ao gás “chave”, e todas estas, função dos valores de gás gerado. De posse destas curvas de dados, foi criado o sistema especialista para o diagnóstico. As taxas de diagnósticos corretos, em novos casos registrados na literatura, foram de no mínimo 86,7%, obtidas na ocorrência de falha elétrica, chegando a 100% na identificação das condições de normalidade.

VARELLA, CHEIM et al. (2000) propuseram uma metodologia que combinasse diversos conjuntos *fuzzy*, utilizando-se de quatro conjuntos de pertinência. O primeiro, considerando o nível de gás gerado, dependente do histórico do equipamento e de sua família. O segundo levando em consideração o nível de relações gasosas geradas. O terceiro, que, utilizando-se de redes neurais, arbitra uma nota, conforme o grau de importância atribuída a falha e *fuzzyfica* esta nota em classificadores do tipo: “sem falha”, “falha leve”, “falha importante” e “falha grave”. E o último que, através do julgamento do especialista determina a influência do antecedente no consequente, aumentando ou diminuindo a pertinência dos conjuntos anteriores e fornecendo o diagnóstico final.

HUANG, YANG et al. (1997), propuseram um sistema *fuzzy* aliado a um algoritmo evolucionário. Baseado no método de Rogers, ou seja, trabalhando com três relações de gases, formaram um espaço padrão em três dimensões (uma relação para cada eixo), com conjuntos *fuzzy* de forma trapezoidal. Denotavam taxas pequenas, médias e grandes. O sistema de diagnóstico *fuzzy* era composto, assim, por 27 regras *fuzzy* e ainda 24 pontos da função de pertinência de forma trapezoidal para serem delimitados. Através dos exemplos, formava um padrão para cada tipo de falha. Com dados novos, tentava minimizar a função erro em relação a este padrão utilizando um algoritmo de programação evolucionária.

SU, LAI et al. (2000) desenvolveram uma ferramenta de diagnóstico capaz de diagnosticar múltiplas falhas incipientes existentes no transformador. Utilizaram três passos principais para o desenvolvimento do seu método  $fuzzy$ . Primeiramente gerando um vetor  $fuzzy$  contendo a função de pertinência dos códigos de taxas de gases da IEC, que passaram de representação binária, para graus de pertinência. Segundo, criando um conjunto  $fuzzy$  de forma trapezoidal e representaram-nas na forma de um vetor com as respectivas funções de pertinência para cada código: “baixo”, “médio” e “alto”. Finalmente, o último e o mais importante passo no desenvolvimento do sistema especialista, que combinava os vetores anteriormente descritos, atribuindo um peso a cada um deles e formando o vetor  $fuzzy$  com o diagnóstico. Vale salientar que os pesos referenciados acima eram determinados pela experiência prévia.

### 3.4 – CONCLUSÕES

Neste capítulo foram descritos diversos aspectos referentes às redes neurais e à sistemas de lógica  $fuzzy$ , técnicas estas, que serão utilizadas no desenvolvimento deste trabalho. Após breve descrição, seguido de seu histórico e caracterização, foram apresentados os aspectos pertinentes de cada técnica levando em consideração a aplicação no contexto geral de solução de problemas de engenharia. Finalmente, foram citadas algumas publicações referentes ao uso destas, ao problema proposto, ou seja, avaliação do estado do transformador através de análise dos gases dissolvidos no óleo.

Conforme apresentado, as redes neurais, principalmente a GRNN, mostram-se totalmente aplicáveis na solução do problema proposto, principalmente pela sua capacidade de auto-aprendizado. Baseando-se somente nos exemplos históricos que lhe são fornecidos, não necessitando do conhecimento dos especialistas, a rede neural é capaz de adquirir o conhecimento, não sendo necessário informar porque tal situação resultou em tal consequência ou decisão no passado. Também se caracteriza pela rápida implementação facilitando a sua utilização em problemas do tipo.

Já os sistemas  $fuzzy$  podem consistentemente trabalhar com regras que expressam as imprecisões e aproximações do mundo real. Através da experiência de especialistas ou de metodologias tradicionais já consolidadas na literatura, são formulados os conjuntos  $fuzzy$  que podem melhor interpretar os dados em função da natureza do problema.

## 4 DESCRIÇÃO DA METODOLOGIA PROPOSTA PARA AVALIAÇÃO DO ESTADO DO TRANSFORMADOR

### 4.1 – INTRODUÇÃO

Este capítulo descreve a metodologia proposta neste trabalho para a avaliação do estado e diagnóstico preventivo de transformadores. Para o tratamento dos dados de análise dos gases dissolvidos, e para melhor entendimento, o trabalho foi desenvolvido em módulos, como apresentado na figura 4.1.

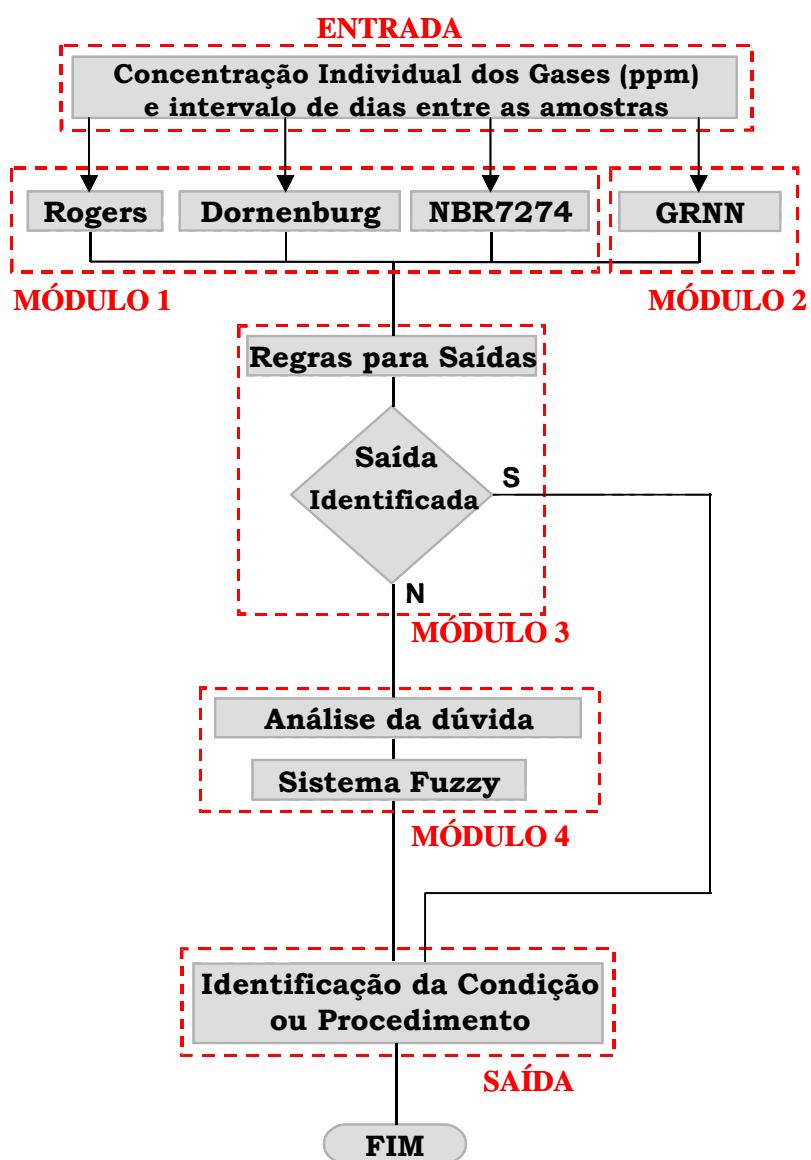


Figura 4.1 – Fluxograma do Método Proposto.

O funcionamento da ferramenta depende da informação, via usuário ou via arquivo, dos dados históricos da análise dos gases dissolvidos no óleo, que necessariamente devem conter as informações de geração dos seguintes gases em ppm: hidrogênio ( $H_2$ ), metano ( $CH_4$ ), acetileno ( $C_2H_2$ ), etileno ( $C_2H_4$ ) e etano ( $C_2H_6$ ), além do intervalo em dias entre as amostras. Na saída a ferramenta apresenta uma classificação para o isolamento entre: “NORMAL”, “FALHA ELÉTRICA”, “FALHA TÉRMICA”, “REAMOSTRAGEM SUGERIDA” ou “SEM DIAGNÓSTICO”. Vale salientar que todas estas técnicas foram implementadas computacionalmente no programa Matlab.

ZIRBES (2003), em sua dissertação de mestrado, já havia testado diferentes critérios de identificação de falhas através da análise dos gases dissolvidos no óleo, incluindo os critérios de Rogers e Doernenburg e também a NBR 7274. Em seu trabalho, ele também testa diferentes arquiteturas e tipos de redes neurais, comprovando ser a GRNN (*General Regression Neural Network*) a mais adequada e a que apresenta os melhores resultados na identificação das condições do equipamento, mesmo com poucos exemplos para treinamento. Vale salientar ainda que, no trabalho de ZIRBES (2003), estas técnicas foram todas testadas individualmente, e que, em função da eficiência de cada uma e de sua utilização pelos concessionários do setor elétrico, foram selecionadas e serviram como base e como ponto de partida no desenvolvimento dos módulos 1 e 2 deste trabalho.

O módulo 3 foi desenvolvido como um conjunto de regras, formadas logicamente, que leva em conta a interpretação das saídas dos módulos anteriores e conseqüente verificação de conclusões idênticas encontradas pelos critérios ou ainda algumas combinações que possam resultar em uma saída com certo nível de confiabilidade. Estas regras serão explicadas mais adiante e são apresentadas na Tabela 4.10.

O último módulo, ou módulo 4 que consiste no sistema *fuzzy*, teve como ponto de partida o trabalho de VARELLA, CHEIM, et al. (2000). No artigo de VARELLA, intitulado “Sistema de inferência *fuzzy* para diagnóstico de transformadores de potência”, as considerações acerca da concentração de gases e taxa de geração anormal, bem como os conjuntos *fuzzy* arbitrados para cada uma destas grandezas, foram determinadas em função da experiência dos seus autores. A combinação destes conjuntos na formação da resposta do programa não é apresentada, mas é baseada nos maiores valores obtidos para estas variáveis. A ferramenta desenvolvida nesta dissertação, baseia-se nas equações e os conjuntos *fuzzy* arbitrados pelos especialistas e apresentados no artigo de Varella. A principal alteração diz respeito a utilização dos valores encontrados na composição da saída. A ferramenta aqui descrita leva em conta as proporções relativas de gases formados na ocorrência de

determinadas falhas na determinação de alguns pesos que compõem o resultado final e que estão explicados no item 4.5.1 e 4.5.2.

Dessa forma, o texto que consta neste capítulo apresenta técnicas utilizadas amplamente para diagnóstico de falhas em transformadores, variando o enfoque em relação à disposição destas técnicas e também no que tange à união dos melhores resultados, com o objetivo de produzir uma ferramenta eficiente, que forneça ao usuário a indicação de manutenção antes da ocorrência de severa deterioração do isolamento e conseqüente dano ao equipamento.

Este capítulo apresenta-se assim dividido: no item 4.2, estão descritas as considerações acerca do Módulo 1, referente à aplicação dos critérios de identificação de falhas. No item 4.3, é apresentado o modelo de rede neural – Módulo 2 – utilizado no trabalho, bem como as características pertinentes ao treinamento da mesma. Já no item 4.4, são apresentadas as regras utilizadas no sistema decisor da ferramenta – Módulo 3. Aspectos referentes ao sistema de lógica *fuzzy* – Módulo 4 – e regras pertinentes ao seu uso são apresentados no item 4.5. Por fim, são apresentadas no item 4.6, algumas conclusões individualmente e em grupo da metodologia utilizada no desenvolvimento da ferramenta.

## **4.2 – MÓDULO 1 – UTILIZAÇÃO DAS NORMAS**

A partir da década de 50 e principalmente no final dos anos 60 e 70, apareceram na literatura diversos estudos de formação de gases em isolamentos de transformadores bem como foram sugeridos e aperfeiçoados diversos métodos de diagnóstico a partir da análise desses gases dissolvidos no óleo. Em linhas gerais, muitas destas publicações ainda são utilizadas e transformaram-se em normas e recomendações. Algumas alterações foram posteriormente sugeridas no que diz respeito aos valores limites para identificação de falhas e caracterização de condição de normalidade, mas mantiveram-se as bases pré-estabelecidas.

Neste trabalho, são utilizados dois critérios internacionais: de Rogers e Doernenburg, integrantes da norma IEEE C57.104 (1991); e a NBR7274 (1982) – Interpretação da Análise dos Gases de Transformadores em Serviço, baseada na IEC 599/78. Antes de falar especificamente de cada um, e da aplicação deles aos dados cromatográficos, vale salientar que para cada um destes três critérios, alguns diagnósticos correlacionados foram agrupados de modo a se obter somente as saídas consideradas pela ferramenta. A tabela com a relação de diagnósticos agregados é apresentada então para cada método na descrição correspondente.

#### 4.2.1 – MÉTODO CLÁSSICO DE ROGERS

Utiliza a filosofia de diagnóstico baseado em relações de concentrações de gases e limites de variação para estas relações. Utiliza quatro relações e cinco gases, no estabelecimento das condições do equipamento. A forma de apresentação do método é dividida em duas tabelas. Na Tabela 4.1, em função das faixas de valores obtidos para as relações gasosas, estabelece-se um código. E na Tabela 4.2, através da combinação destes códigos, é que se determina o diagnóstico final da amostra (IEEE C57.104, 1991).

RELAÇÃO DE GASES	FAIXA DE VARIAÇÃO	CÓDIGO
CH <sub>4</sub> /H <sub>2</sub>	< = 0.1	5
	> 0.1 , < 1	0
	> = 1 , < 3	1
	> = 3	2
C <sub>2</sub> H <sub>6</sub> /CH <sub>4</sub>	< 1	0
	> = 1	1
C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>	< 1	0
	> = 1 , < 3	1
	> = 3	2
C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>	< 0.5	0
	> = 0.5 , < 3	1
	> = 3	2

Tabela 4.1 – Tabela de definição dos códigos do método de Rogers.

CH <sub>4</sub> /H <sub>2</sub>	C <sub>2</sub> H <sub>6</sub> /CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>	Diagnóstico
0	0	0	0	Deterioração Normal
5	0	0	0	Descargas Parciais
1 / 2	0	0	0	Sobreaquecimento – abaixo de 150°C
1 / 2	1	0	0	Sobreaquecimento de 150°C – 200°C
0	1	0	0	Sobreaquecimento de 200°C – 300°C
0	0	1	0	Sobreaquecimento de condutores
1	0	1	0	Correntes de circulação nos enrolamentos
1	0	2	0	Correntes de circulação no núcleo e tanque, sobreaquecimento em conexões
0	0	0	1	Descarga contínua
0	0	1 / 2	1 / 2	Arco com alta energia
0	0	2	2	Descarga contínua de baixa potência
5	0	0	1 / 2	Descarga parcial envolvendo o papel

Tabela 4.2 – Tabela de diagnóstico do método de Rogers em função do código.

A Tabela 4.3 apresenta os diagnósticos correlacionados que foram agregados para efeito de saída na aplicação deste método:

SAÍDA CONSIDERADA	DIAGNÓSTICOS AGREGADOS
NORMAL	Deterioração normal.
FALHA ELÉTRICA	Descargas parciais, Descarga contínua, Arco com alta energia, Descarga contínua de baixa potência, Descarga parcial envolvendo o papel.
FALHA TÉRMICA	Sobreaquecimento – abaixo de 150°C, Sobreaquecimento – de 150°C-200°C, Sobreaquecimento – 200°C-300°C, Sobreaquecimento de condutores, Correntes de circulação nos enrolamentos, Correntes de circulação no núcleo e tanque, sobreaquecimento em conexões.

Tabela 4.3 – Agrupamento de Diagnósticos para o Método de Rogers.

#### 4.2.2 – MÉTODO DE DOERNENBURG

O método de Doernenburg original não define critérios para o estabelecimento de condições normais do isolamento, mas estabelece as condições de validade para aplicação do método de diagnóstico em função das concentrações individuais dos gases componentes das relações. O critério de identificação de falha do método de Doernenburg pode ser visualizado na Tabela 4.4 (IEEE C57.104, 1991), onde são apresentados os valores de relações gasosas que classificam o tipo de falha a que o equipamento está submetido.

TIPO DE FALHA	RELAÇÕES ENTRE CONCENTRAÇÕES DE GASES			
	Relações principais		Relações auxiliares	
	$\text{CH}_4/\text{H}_2$	$\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$	$\text{C}_2\text{H}_6/\text{C}_2\text{H}_2$	$\text{C}_2\text{H}_2/\text{CH}_4$
Ponto quente	>1	<0.75	>0.4	<0.3
Descarga parcial	<0.1	Não signif.	>0.4	<0.3
Outros tipos de descarga	<1 e >0.1	>0.75	<0.4	>0.3

Tabela 4.4 – Critério de identificação de falha de Doernenburg.

Já a Tabela 4.5 apresenta os dados de concentração de gases individualmente para a validação de aplicação do referido método. O critério estabelece que, para a utilização da Tabela 4.4, no mínimo um dos gases que compõe as relações principais tenha uma concentração superior ao dobro do valor da Tabela 4.5 e que para as relações auxiliares, pelo menos um dos gases tenha uma concentração superior ao constante na mesma tabela.



Tipos de gás	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>
Concentração ppm (v/v)	200	50	15	60	15

Tabela 4.5 – Tabela de concentração dos gases para validação do método de Doernenburg.

A IEEE C57.104-1991, recomenda a utilização do método de Doernenburg, porém alterando os valores apresentados para a validação da aplicação do método. Com esta alteração, apresentada na Tabela 4.6, o método de Doernenburg também passou a ser utilizado para identificações de condições de normalidade do transformador. Ou seja, se nenhuma das concentrações de gases que compõem as relações principais alcançar uma concentração superior ao dobro do valor da tabela e para as relações auxiliares, nenhuma destas concentrações seja maior ao constante na mesma tabela, o transformador apresenta condições de operação de normalidade.

Tipos de gás	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>
Concentração ppm (v/v)	100	120	65	50	35

Tabela 4.6 – Tabela de concentração dos gases para identificação de condição de normalidade para o método de Doernenburg, segundo a IEEE.

Da mesma forma que o método de Rogers, e mesmo possuindo menor quantidade de diagnósticos considerados, alguns destes foram agregados para que fossem contempladas as saídas consideradas pela ferramenta. A Tabela 4.7 apresenta o agrupamento dos diagnósticos similares para o método de Rogers.

SAÍDA CONSIDERADA	DIAGNÓSTICOS AGREGADOS
NORMAL	Quando os valores obtidos para as concentrações forem abaixo dos valores utilizados para validação.
FALHA ELÉTRICA	Descarga parcial, Outros tipos de descarga.
FALHA TÉRMICA	Ponto quente.

Tabela 4.7 – Agrupamento de Diagnósticos para o Método de Doernenburg.

#### 4.2.3 – MÉTODO PREVISTO NA NBR7274

A NBR7274 / 1982 – Interpretação da Análise dos Gases de Transformadores em Serviço (baseada na IEC 599/78), é apresentada na Tabela 4.8, e sugere a utilização de um método semelhante ao método de Rogers, variando alguns limites constantes das relações e

também algumas alterações na interpretação dos valores para o referido diagnóstico (ZIRBES, 2003).

$C_2H_2/C_2H_4$	$CH_4/H_2$	$C_2H_4/C_2H_6$	Diagnóstico
< 0.1	0.1 a 1.0	< 1.0	Envelhecimento Normal
< 0.1	< 0.1	< 1.0	Descarga parcial baixa energia
0.1 a 3.0	< 0.1	< 1.0	Descarga parcial alta energia
> 0.1	0.1 a 1.0	> 1.0	Arco – descarga baixa energia
0.1 a 3.0	0.1 a 1.0	> 3.0	Arco – descarga alta energia
< 0.1	> 1.0	< 1.0	Sobreaquecimento $150^\circ C < t < 300^\circ C$
< 0.1	> 1.0	1.0 a 3.0	Sobreaquecimento $300^\circ C < t < 700^\circ C$
< 0.1	> 1.0	> 3.0	Sobreaquecimento $t > 700^\circ C$

Tabela 4.8 – Interpretação da Análise de Gases conforme NBR7274.

Também para efeitos de comparação posterior, diagnósticos de mesma origem foram agrupados, resultando em três saídas possíveis, conforme mostrado na Tabela 4.9.

SAÍDA CONSIDERADA	DIAGNÓSTICOS AGREGADOS
NORMAL	Envelhecimento normal
FALHA ELÉTRICA	Descarga parcial baixa energia, Descarga parcial alta energia, Arco – descarga baixa energia, Arco – descarga alta energia
FALHA TÉRMICA	Sobreaquecimento $150^\circ C < t < 300^\circ C$ , Sobreaquecimento $300^\circ C < t < 700^\circ C$ , Sobreaquecimento $t > 700^\circ C$

Tabela 4.9 – Agrupamento de Diagnósticos para a NBR7274.

### 4.3 – MÓDULO 2 – REDE NEURAL

A rede neural utilizada para a análise dos dados de gases dissolvidos no óleo, foi do tipo GRNN, como já foi descrito no item 3.2.2.2. Resumidamente, um conjunto de dados com diagnóstico verificado é utilizado para treinamento da rede, outro conjunto é utilizado para a regulação do “spread” ou espalhamento e por fim são testados os dados em questão. Nos itens a seguir, são descritos os dados utilizados para essas funções no teste dos três conjuntos de dados considerados:

- Dados IEC: Para a verificação de diagnósticos corretos deste conjunto de dados, a rede neural foi treinada com uma parcela de dados do CEPEL, sendo que o “spread”, ou

espalhamento, da rede foi regulado heurísticamente com o teste da outra parcela de dados também do CEPEL;

- Dados CEPEL: Para este conjunto de dados, a rede neural foi treinada com uma parcela de dados da IEC, e o seu “spread” foi determinado heurísticamente com o restante destes dados;
- Dados Históricos: Para este conjunto de dados, a rede neural foi treinada com o conjunto de dados da IEC e seu “spread” foi determinado através de testes com os dados do CEPEL.

A rede neural foi implementada junto ao programa Matlab, que automaticamente realiza o seu treinamento e seu processamento interno, fornecendo como resposta final um vetor normalizado, representado pelo número de saídas consideradas. Quanto mais alto o valor representado neste vetor, mais próximo estará a amostra da saída correspondente. As regras utilizadas para a interpretação destes valores foram as seguintes: se um dos valores deste vetor é  $>0.7$ , ou se um deles (maior) apresenta diferença  $> 0.3$ , em relação aos outros, é considerada esta amostra pertencente a esta saída. Esse procedimento pode ser melhor entendido através da Figura 4.2. Vale salientar ainda, que as amostras que não satisfizeram estas condições, foram consideradas com saídas do tipo “SEM DIAGNÓSTICO”.

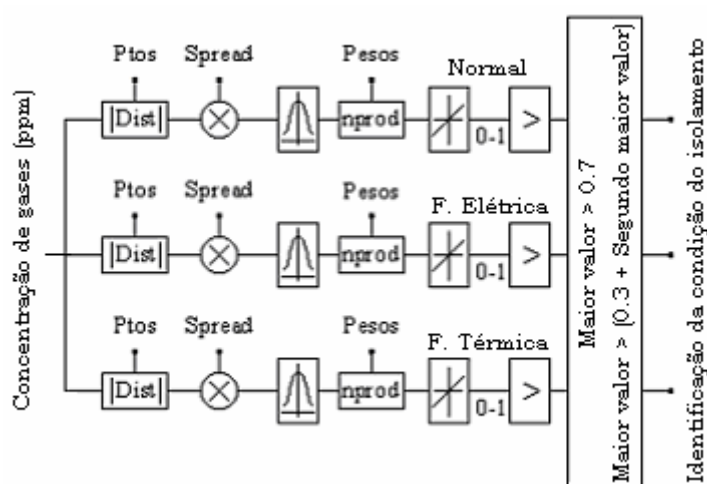


Figura 4.2 – Pesos utilizados para formulação – Falha Térmica.

#### 4.4 – MÓDULO 3 – REGRAS CONSIDERADAS PARA O SISTEMA DECISOR

De posse das saídas fornecidas pela aplicação dos módulos 1 e 2 aos dados de gases fornecidos como parâmetros de entrada, serão aplicadas algumas regras, que podem ou não

determinar a condição do equipamento em questão, identificando a falha à que está submetido, ou fornecendo ao usuário indicação de um procedimento posterior que deverá ser adotado. A Tabela 4.10 apresentada abaixo, não contempla todas as combinações possíveis de saídas obtidas, mas é considerado que as que não estão listadas devem passar por uma análise *fuzzy* para aí então fornecerem uma resposta.

SAÍDAS IGUAIS	COMPOSIÇÃO DA SAÍDA	RESPOSTA
4	MESMO DIAGNÓSTICO	PRÓPRIO DIAGNÓSTICO
3	3 FALHAS ELÉTRICAS + (1 NORMAL OU 1 SEM DIAGNÓSTICO)	FALHA ELÉTRICA
3	3 FALHAS TÉRMICAS + (1 NORMAL OU 1 SEM DIAGNÓSTICO)	FALHA TÉRMICA
3	3 NORMAIS + 1 SEM DIAGNÓSTICO	NORMAL
2	1 SEM DIAGNÓSTICO + 2 FALHAS ELÉTRICAS + 1 NORMAL	FALHA ELÉTRICA
2	1 SEM DIAGNÓSTICO + 2 FALHAS TÉRMICAS + 1 NORMAL	FALHA TÉRMICA
2	2 FALHAS ELÉTRICAS + 2 SEM DIAGNÓSTICO	FALHA ELÉTRICA
2	2 FALHAS TÉRMICAS + 2 SEM DIAGNÓSTICO	FALHA TÉRMICA
2	2 NORMAIS + 2 SEM DIAGNÓSTICO	NORMAL

Tabela 4.10 – Regras estipuladas para saídas conflitantes.

#### 4.5 – MÓDULO 4 – SISTEMA DE INFERÊNCIA *FUZZY*

Nos casos em que a análise pelo módulo 3 indique a necessidade de verificação pelo módulo *fuzzy*, que são todos os outros casos não constantes na Tabela 4.10, e que estão resumidos como tipos de dúvidas na Tabela 4.11, além dos níveis dos gases encontrados, serão consideradas as taxas de geração anormais destes gases.

TIPOS DE DÚVIDAS	DIAGNÓSTICOS ENCONTRADOS
TIPO 1	Condição de Normalidade + Indicação de Falha Elétrica + Indicação de Falha Térmica; Indicação de Falha Elétrica + Indicação de Falha Térmica;
TIPO 2	Condição de Normalidade + Indicação de Falha Elétrica;
TIPO 3	Condição de Normalidade + Indicação de Falha Térmica;

Tabela 4.11 – Tipos de Dúvidas considerados na Análise *Fuzzy*.

#### 4.5.1 – NÍVEL DE GÁS GERADO (NG)

Esta análise é feita baseada nos valores de gases combustíveis ( $H_2$ ,  $CH_4$ ,  $C_2H_6$ ,  $C_2H_4$  e  $C_2H_2$ ), comparados aos valores históricos obtidos para o mesmo equipamento (valores limites) e que apresentem condições de normalidade. Similarmente à VARELLA, CHEIM, et al. (2000), o nível de gás gerado é calculado então, para cada um dos cinco gases considerados, através da seguinte equação:

$$NG_i = \frac{CA_t_i}{CL_i} \quad (4.1)$$

Onde:

$CA_t_i$  = Concentração atual dos cinco gases em questão (ppm);

$CL_i$  = Valor histórico máximo de geração dos gases para uma condição de normalidade, para o transformador que está sob análise.

Os valores de NG obtidos para os cinco gases, em função do tipo de dúvida original apresentado na Tabela 4.11, são ponderados por pesos para a obtenção do nível de gás gerado final.

Estes pesos foram arbitrados conforme as proporções de gases formados na ocorrência de determinadas falhas, e foram obtidos a partir do método do gás “chave” (IEEE C57.104, 1991). Segundo esse método, existe a determinação qualitativa dos gases gerados que são típicos ou predominantes, sob várias temperaturas, em função do tipo de falha que está ocorrendo. As figuras 4.2, 4.3 e 4.4, apresentam as proporções relativas de gases na ocorrência de sobreaquecimento do óleo, corona no óleo e arco no óleo, respectivamente.

Levando em conta estas considerações, o nível de gás gerado final é expresso por:

$$NGF = \sum_1^5 P_i NG_i \quad (4.2)$$

Onde:

$P_i$  = Pesos arbitrados para os cinco gases em questão, advindos do método do gás “chave”, em função da dúvida encontrada pelos diagnósticos individualmente ( $\sum P_i = 1$ );

$NG_i$  = Níveis de gás gerados para os cinco gases em questão.

Na figura 4.2 são apresentados os pesos utilizados para cada gás, quando da ocorrência de dúvida do tipo 3 (Tabela 4.11), entre condição de normalidade e condição de falha térmica. Esta figura representa a proporção relativa de geração de gases na ocorrência de

sobreaquecimento do óleo. Nota-se pela figura que o nível de gás etileno ( $C_2H_4$ ) gerado terá uma contribuição muito mais expressiva na composição do nível de gás gerado final, podendo confirmar, se os valores forem elevados na amostra sob análise a ocorrência deste tipo de falha.

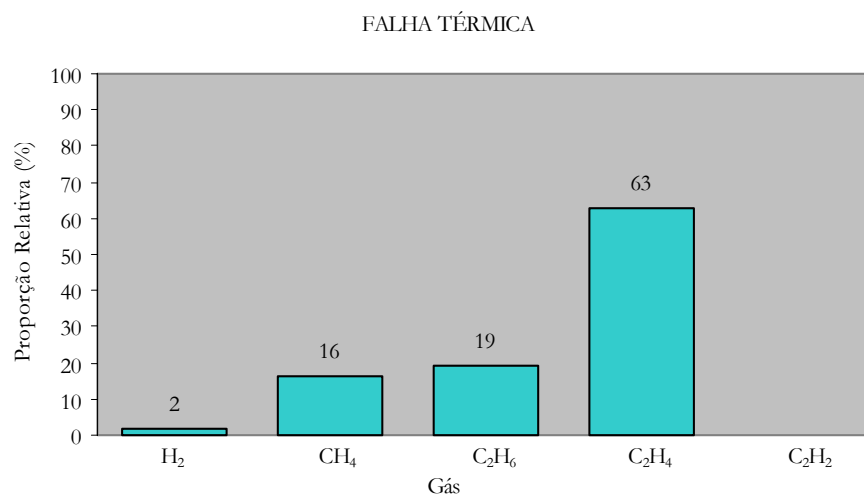


Figura 4.3 – Pesos utilizados para formulação – Falha Térmica.

O procedimento utilizado quando da dúvida entre condição de normalidade e falha elétrica (dúvida do tipo 2) é similar ao explicado anteriormente. A diferença é que existem, basicamente, dois tipos de falhas elétricas: Corona e Arco, que no nosso caso, são agrupadas. Os pesos utilizados foram obtidos simplesmente pela normalização da média aritmética entre os percentuais dos gases nesses dois tipos de falha elétrica. Assim, a ferramenta tenta incorporar as informações dos dois tipos, não priorizando nenhuma das duas falhas, embora o arco elétrico corresponda à uma falha mais crítica. As figuras 4.3 e 4.4 apresentam as proporções relativas de gases formados na ocorrência de corona, e também na ocorrência de arco elétrico.




Figura 4.4 – Proporção relativa dos gases para ocorrência de Corona no Óleo.

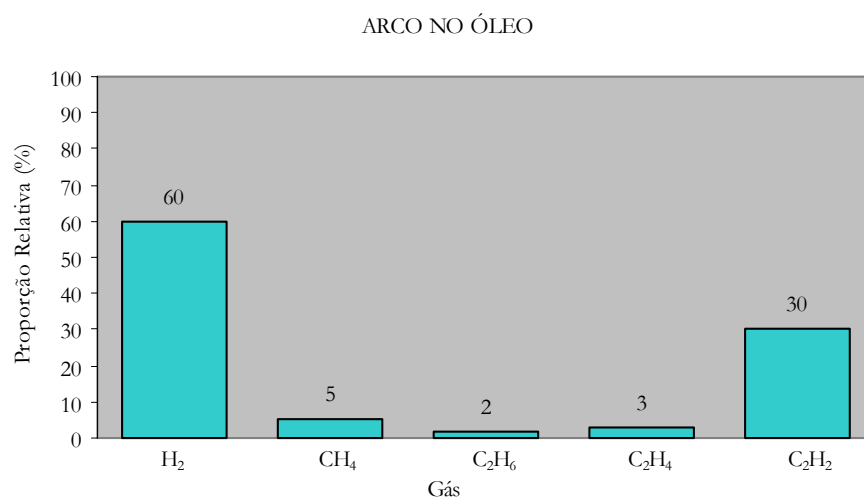


Figura 4.5 – Proporção relativa dos gases para ocorrência de Arco no Óleo.

Combinando as duas figuras anteriores, obtém-se os pesos utilizados para as dúvidas envolvendo falha elétrica, como pode ser visualizado na figura 4.5.

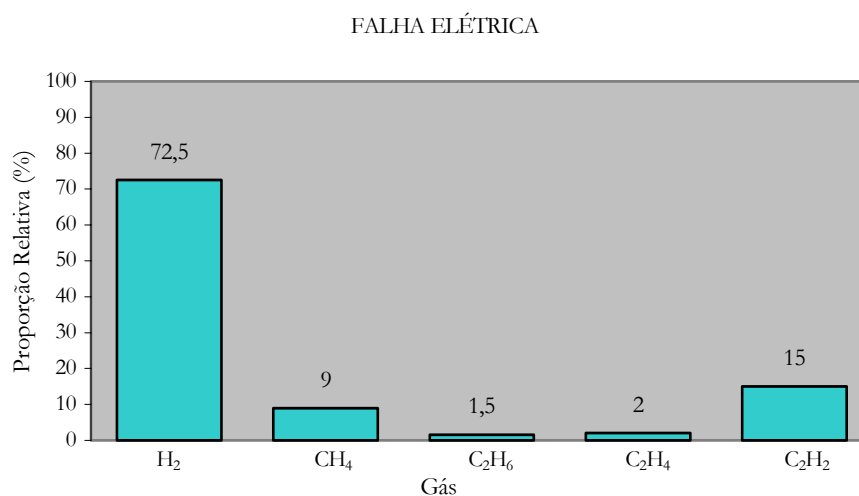


Figura 4.6 – Pesos utilizados para formulação – Falha Elétrica.

Depois de todas essas considerações acerca dos pesos utilizados em diagnósticos conflitantes e obtenção do nível de gás gerado final, calcula-se a pertinência, ou seja, o grau com o qual as amostras são similares ou compatíveis com o conceito representado pelo conjunto em todos os conjuntos *fuzzy* arbitrados e apresentados na figura 4.6 (normal, alto e muito alto). Estes conjuntos foram formados através da experiência de especialistas na área e, como já mencionado anteriormente, tiveram inspiração no trabalho de VARELLA, CHEIM, et al. (2000).




Figura 4.7 – Conjuntos *fuzzy* de Nível de Gás Gerado Final (NGF).

#### 4.5.2 – TAXA DE GERAÇÃO

Baseando-se na taxa de crescimento da formação de gases combustíveis ao longo dos meses, é calculado a Taxa de Geração percentual. Esta taxa mostra a evolução de crescimento no período de um mês, e, similarmente à VARELLA, CHEIM, et al. (2000), é dada pela seguinte equação:

$$TG_i = \frac{(CA_{t_i} - CA_{n_i}) * 30 * 100\%}{IT * CA_{n_i}} \quad (4.3)$$

Onde:

$CA_{t_i}$  = Concentração atual (ppm);

$CA_{n_i}$  = Concentração anterior (ppm);

$IT$  = intervalo de tempo entre as concentrações (em dias).

Depois do cálculo desta taxa para todos os gases combustíveis, é adotado o procedimento similar ao apresentado anteriormente, onde são utilizados pesos na formação da taxa de geração anormal final que, levando em conta a dúvida existente, vai dar uma maior importância àqueles gases que possam estar envolvidos em determinada falha. A distribuição dos pesos no cálculo desta taxa também leva em conta as proporções relativas apresentadas pelo método do gás “chave” (IEEE C57.104, 1991).

Assim, a taxa de geração anormal final é expressa por:

$$TGF = \sum_1^5 P_i TG_i \quad (4.4)$$



Onde:

$P_i$  = Pesos arbitrados para os cinco gases em questão advindos do método do gás “chave”, em função da dúvida encontrada pelos diagnósticos individualmente;

$TG_i$  = Taxas de geração anormal de gás encontrados para os cinco gases em questão.

Depois de calculada a taxa de geração anormal final, o valor é “fuzzyficado” e é calculada a sua pertinência em todos os conjuntos  $fuzzy$  arbitrados (aceitável, importante e perigoso). Os conjuntos  $fuzzy$ , similares aos utilizados por VARELLA, CHEIM, et al. (2000), para a obtenção da pertinência dos dados, em função da taxa de geração anormal dos gases, são mostrados na figura 4.7.




Figura 4.8 – Conjuntos  $fuzzy$  de Taxa de Geração Anormal Final (TGF).

As regras  $fuzzy$  estipuladas são apresentadas na Tabela 4.11 e obedecem ao formato especificado no capítulo anterior, sendo que a combinação dos antecedentes, ou seja, dos conjuntos  $fuzzy$  de nível de gás gerado final e taxa de geração anormal final; através destas regras, fornece como conseqüente, ou saída, três possíveis condições: “SEM FALHA”, “FALHA PROVÁVEL” e “FALHA CERTA”.

<b>REGRA 1</b>	<b>REGRA 2</b>
SE NGF é normal E TGF é aceitável ENTÃO A saída do sistema é “SEM FALHA”	SE NGF é normal E TGF é importante ENTÃO A saída do sistema é “SEM FALHA”
<b>REGRA 3</b>	<b>REGRA 4</b>
SE NGF é normal E TGF é perigoso ENTÃO A saída do sistema é “FALHA PROVÁVEL”	SE NGF é alto E TGF é aceitável ENTÃO A saída do sistema é “SEM FALHA”

<b>REGRA 5</b>	<b>REGRA 6</b>
SE NGF é alto E TGF é importante ENTÃO A saída do sistema é “FALHA PROVÁVEL”	SE NGF é alto E TGF é perigosa ENTÃO A saída do sistema é “FALHA CERTA”
<b>REGRA 7</b>	<b>REGRA 8</b>
SE NGF é muito alto E TGF é aceitável ENTÃO A saída do sistema é “FALHA PROVÁVEL”	SE NGF é muito alto E TGF é importante ENTÃO A saída do sistema é “FALHA CERTA”

**REGRA 9**

SE NGF é muito alto E TGF é perigosa ENTÃO  
A saída do sistema é “FALHA CERTA”

Tabela 4.12 – Regras estipuladas para o Sistema *Fuzzy*.

Resumidamente, estas regras podem ser representadas de acordo com a Tabela 4.12, apresentada abaixo:

TAXAS	NGF NORMAL	NGF ALTO	NGF MUITO ALTO
TGF ACEITÁVEL	SF	SF	FP
TGF IMPORTANTE	SF	FP	FC
TGF PERIGOSA	FP	FC	FC

Tabela 4.13 – Resposta do Sistema *Fuzzy*.

Onde:

SF: indica a condição “SEM FALHA”;

FP: indica a condição “FALHA PROVÁVEL”;

FC: indica a condição “FALHA CERTA”.

Vale salientar que, como as regras estabelecidas (Tabela 4.11) são baseadas em operadores lógicos do tipo “E”, baseado nas formas mais usuais de combinação e operação de conjuntos *fuzzy*, a resposta do sistema *fuzzy* para as nove saídas consideradas e mostradas na Tabela 4.12 é apresentada com o menor valor de pertinência de todos os conjuntos dos antecedentes analisados na regra (em nosso caso, NGF e TGF).

Posteriormente, como estas nove saídas representam somente três possíveis: “sem falha”, “falha provável” e “falha certa”, os valores de pertinências são novamente combinados, sendo que agora, o valor utilizado será o maior obtido dentre as saídas iguais.

Finalmente, a ferramenta utiliza-se de alguns testes com os valores de pertinência (valores maiores que 0,49), como mostrado na figura 4.8, retorna ao tipo de dúvida encontrada, e, em função desta, indica a condição obtida para a amostra. O procedimento que diz respeito a todo processo de combinação dos valores de pertinências encontrados pode ser melhor entendido através da figura 4.8.

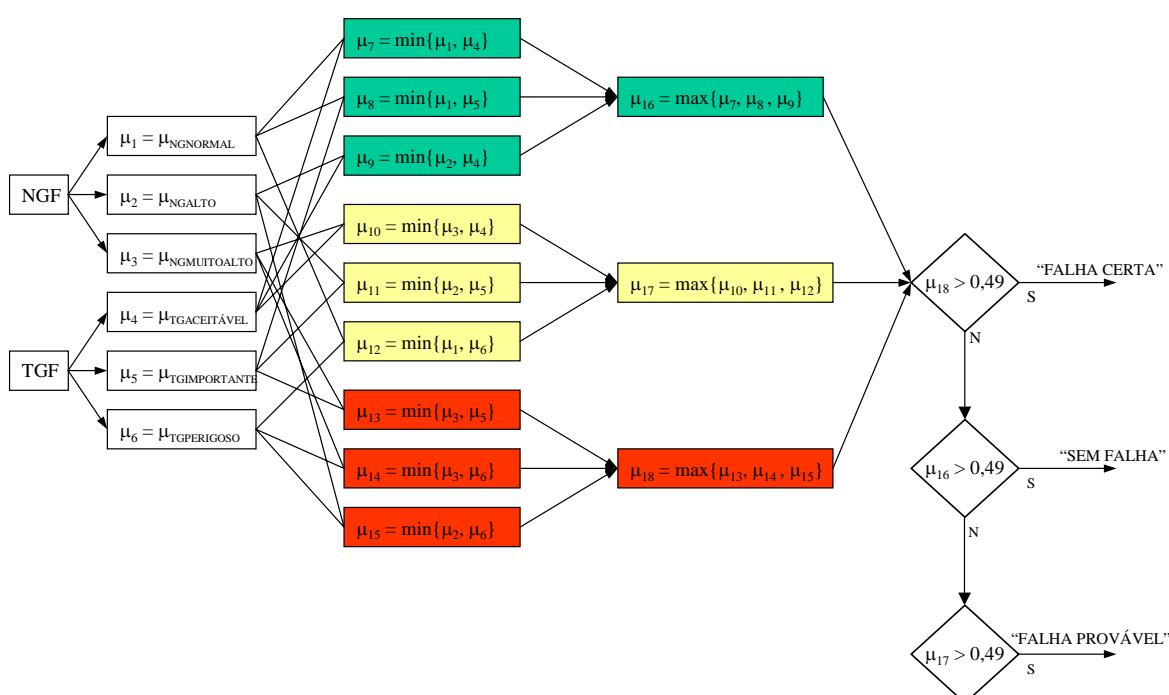


Figura 4.9 – Operações com os valores de pertinências dos conjuntos  $fuzzy$ .

Se a dúvida for do tipo 2, entre condição de normalidade e condição de falha elétrica, e se a saída do sistema  $fuzzy$  apresenta um valor de pertinência em relação ao conjunto “falha certa” ( $\mu_{18} > 0,49$ ), a ferramenta fornece ao usuário, para a amostra em questão, a condição de falha elétrica. Do contrário, se a saída do sistema  $fuzzy$  apresenta um alto valor de pertinência para o conjunto “sem falha” ( $\mu_{17} > 0,49$ ), a ferramenta apresenta como saída, a condição de normalidade. Como última hipótese, se o sistema  $fuzzy$  apresentar alto valor de pertinência para o conjunto “falha provável” ( $\mu_{186} > 0,49$ ), a ferramenta sugere reamostragem, para verificação da condição. Todas estas considerações são válidas igualmente na ocorrência de dúvidas do tipo 3, podendo a ferramenta indicar a condição de falha térmica, condição de normalidade ou reamostragem.

Se a dúvida for do tipo 1, entre condição de normalidade, condição de falha elétrica, e condição de falha térmica, o procedimento é um pouco mais complexo. Primeiramente serão calculados os níveis de gases gerados e as taxas de gerações levando em conta os pesos arbitrados em dúvidas do tipo 2 e 3, e já explicados no item 4.5. Posteriormente são encontrados os valores de pertinência para os conjuntos  $fuzzy$  arbitrados, para cada tipo de dúvida (2 e 3) individualmente. Essas duas saídas  $fuzzy$ , uma que leva em conta os pesos arbitrados para falha elétrica e outra que leva em conta os pesos arbitrados para falha térmica, são recombinadas, de modo a fornecerem a saída final da análise  $fuzzy$ . A combinação das saídas  $fuzzy$  na ocorrência de dúvidas do tipo 1, podem ser visualizadas na Tabela 4.13.

COMBINAÇÃO FINAL DAS SAÍDAS PARA DÚVIDAS DO TIPO 1		FALHA ELÉTRICA		
		SF	FP	FC
F A L H A  T É R M I C A	SF	CN	RS	FE
	FP	RS	RS	FE
	FC	FT	FT	RS

Tabela 4.14 – Combinações consideradas na ocorrência de dúvidas do tipo 1.

Onde:

CN: condição de normalidade;

RS: reamostragem sugerida;

FE: falha elétrica;

FT: falha térmica.

Vale salientar ainda que, nas combinações consideradas em dúvidas do tipo 1, não existem mais valores de pertinência, já que agora estamos combinando somente saídas lógicas, obtidas na utilização dos pesos arbitrados na ocorrência de falha elétrica, com a saída obtida na utilização dos pesos arbitrados na ocorrência de falha térmica.

## 4.6 – CONCLUSÕES

Neste capítulo foram apresentados os aspectos pertinentes à ferramenta desenvolvida para a análise dos gases dissolvidos no óleo na identificação de falhas incipientes. Primeiramente foi apresentado um fluxograma simplificado do processo como um todo, de

modo a facilitar a compreensão da metodologia proposta, bem como as publicações que motivaram o desenvolvimento deste trabalho. Posteriormente foram apresentados os critérios e a norma utilizada na formação do módulo 1, seguido das considerações referentes ao desenvolvimento de uma rede neural artificial do tipo GRNN, correspondente ao módulo 2. Na seqüência foram apresentadas as regras utilizadas no processo de decisão da metodologia, e que corresponde ao módulo 3.

A principal contribuição desta proposta consiste na abordagem do sistema  $fuzzy$ . Levando em conta o nível de gás gerado, a taxa de geração anormal de gases, a dúvida encontrada pelos métodos anteriores e o método do gás “chave”, a ferramenta torna-se capaz de fornecer uma resposta, com maior confiabilidade, unindo os melhores resultados não somente dos métodos tradicionais já consolidados na literatura técnica e utilizados pelas empresas do setor elétrico, bem como das técnicas de inteligência artificial.

## 5 APLICAÇÃO DA METODOLOGIA E ANÁLISE DOS RESULTADOS

### 5.1 – INTRODUÇÃO

Neste capítulo será discutido o emprego da metodologia descrita no capítulo anterior para a avaliação do estado e diagnóstico preventivo do transformador, e serão apresentados os resultados obtidos quando da utilização da ferramenta desenvolvida. Para o estudo das técnicas de classificação de falhas utilizadas neste trabalho, serão utilizados três conjuntos de dados de análises de gases dissolvidos no óleo, a saber:

IEC (Anexo A): Esta publicação apresenta vários conjuntos de dados referentes a diferentes equipamentos, organizados pelo seu tipo, e pelo tipo de falha encontrada. Para efeito de estudo, foi escolhido o conjunto de transformadores sem conexão com comutadores sob carga, totalizando 52 amostras, distribuídas em 16 amostras com diagnóstico de normalidade, 22 amostras com diagnóstico de falha elétrica e 14 amostras com diagnóstico de falha térmica, conforme anexo A. A opção por utilizar somente um tipo de transformador, desconsiderando os demais, é para manter maior uniformidade dos dados e permitir uma real comparação de desempenho dos métodos de diagnóstico, embora estes métodos não apresentem nenhuma restrição quanto a sua aplicação a um tipo específico. Os dados de formação de gases com diagnósticos de falhas de mesma origem foram agrupados para que contemplassem as saídas consideradas pela ferramenta em desenvolvimento. Estes diagnósticos foram determinados através de medições específicas e inspeções visuais feitas por especialistas. Vale salientar também que esse conjunto de dados foi testado somente na aplicação do Módulo 1, referente às normas, e do Módulo 2, referente à rede neural, já que são dados de diversos transformadores, não constituindo o histórico de equipamentos.

CEPEL (Anexo B): Neste conjunto constam dados da análise de gases dissolvidos para transformadores de vários níveis de tensão, desde 13.8kV a 230kV (ZIRBES, 2003). Estão incluídos dados de transformadores sem e com comutadores de tensão sob carga, embora o último tipo seja em número reduzido. Este grupo totaliza 224 amostras, distribuídas em 83 amostras com diagnóstico de normalidade, 61 amostras com diagnóstico de falha elétrica e 80 amostras com diagnóstico de falha térmica, conforme o anexo B. Também para este conjunto de dados, os diagnósticos foram obtidos através de medições específicas e inspeções visuais feitas por especialistas, e serão testados somente nos módulos 1 e 2 da ferramenta, já que também não se constituem em dados históricos de um equipamento.

Dados Históricos (Anexo C): Este conjunto de dados foi obtido junto a uma grande empresa do setor elétrico brasileiro. Constitui-se em um banco de dados extenso com amostras de diferentes transformadores e diagnósticos determinados por especialistas. Em função do volume de dados, foram selecionados 20 transformadores com dados históricos, totalizando 212 amostras, distribuídas em 180 amostras com condições normais, 10 amostras com diagnóstico de falha elétrica e 22 amostras com diagnóstico de falha térmica, conforme o anexo C, para análise do desempenho da ferramenta como um todo, abrangendo além das normas e rede neural, as regras do sistema decisor e a análise *fuzzy* que leva em conta o nível de gás gerado e a taxa de geração anormal de gases. Vale salientar que no teste de diagnósticos corretos para os dados históricos, a primeira amostra de cada transformador, foi considerada com condição de normalidade, para que a análise *fuzzy* tivesse a referência necessária, independente do diagnóstico obtido pelo especialista.

Como os mecanismos de diagnóstico foram desenvolvidos em módulos, a divisão e medida de diagnósticos corretos também serão fornecidas dessa forma. O item 5.2 está destinado a uma análise dos resultados obtidos na aplicação do Módulo 1, referente às normas propriamente ditas, aliada a um estudo dos principais tipos de erros encontrados. O item 5.3 apresenta os aspectos pertinentes e os resultados obtidos na aplicação de redes neurais – Módulo 2 – na identificação das condições atuais dos transformadores. Já no item 5.4, é apresentado o diagnóstico conjugado de normas e de redes neurais, fornecendo ao usuário uma resposta com maior índice de confiabilidade (quando da ocorrência de diagnósticos idênticos), bem como a identificação dos diagnósticos conflitantes. Finalmente, no item 5.5, é apresentado os resultados das saídas de regras *fuzzy*, referente ao Módulo 3, bem como a união destes aos diagnósticos conflitantes anteriores e posterior diagnóstico final. As conclusões referentes a este capítulo serão apresentadas no item 5.6.

## **5.2 – MÓDULO 1 – RESULTADOS – APLICAÇÃO DAS NORMAS**

Neste item são apresentados os resultados referentes à aplicação das normas, descritas no item 4.2, aos dados obtidos junto à IEC, CEPEL e conjunto de dados históricos. Separadamente, é apresentada a percentagem de diagnósticos corretos e análise dos tipos de erros ocorridos quando foi aplicado o método clássico de Rogers, método de Doernenburg e para o método previsto no projeto de revisão da NBR 7274.

Para um melhor entendimento e comparação dos resultados obtidos para cada um dos métodos previstos, eles tiveram seus diagnósticos agrupados, como já mostrado no capítulo anterior, de acordo com a natureza da falha, de forma a fornecerem ao usuário, somente três saídas possíveis: Normal, Falha Elétrica e Falha Térmica.

### 5.2.1 – MÉTODO CLÁSSICO DE ROGERS

Para os dois primeiros conjuntos de dados testados, e para as saídas consideradas, as taxas de diagnósticos corretos podem ser visualizadas na Tabela 5.1. Podemos notar nessa tabela que o método de Rogers não apresentou resultados satisfatórios na identificação de condições de normalidade do equipamento. Já para a identificação de falhas elétricas e falhas térmicas, o método apresentou bons resultados para o conjunto de dados da IEC, e resultados razoáveis para o conjunto de dados do CEPEL.

Método	DADOS IEC Diagnósticos Corretos (%)			DADOS CEPEL Diagnósticos Corretos (%)		
	Normal	F. Elétrica	F. Térmica	Normal	F. Elétrica	F. Térmica
Rogers	---	86.36	64.28	4.82	52.46	40.00

Tabela 5.1 – Dados de diagnósticos corretos por conjunto de dados.

Os resultados obtidos para os dados históricos também são apresentados em uma tabela semelhante, mostrando a percentagem de diagnósticos corretos em função de cada condição considerada pela ferramenta, e são listados na Tabela 5.2.

Para o conjunto de dados históricos, podemos notar que o método de Rogers mostrou-se ineficiente, já que o índice obtido com a utilização desse critério, foi muito baixo.

Método	DADOS HISTÓRICOS Diagnósticos Corretos (%)		
	Normal	F. Elétrica	F. Térmica
Rogers	1.67	40.00	40.91

Tabela 5.2 – Dados de diagnósticos corretos para o conjunto de dados históricos.

Através da análise dos diagnósticos errôneos de cada método, é possível visualizar os reflexos de cada um desses erros no contexto geral da operação do equipamento. Esse estudo, torna-se de suma importância, pois poderá identificar, por exemplo, a ocorrência de um diagnóstico incorreto, onde é identificada a condição de normalidade e na realidade está ocorrendo uma condição de falha, que é mais significativo que um diagnóstico onde é identificado uma falha e na realidade o equipamento está operando normalmente.



Para esta análise, e para os outros métodos apresentados na sequência, foi usada a Tabela 5.3, que classifica os tipos de erros encontrados, de forma semelhante à utilizada por ZIRBES (2003).

<b>TIPOS DE DIAGNÓSTICOS</b>	<b>DESCRIÇÃO</b>
E1	Diagnóstico incorreto de condição normal para uma condição de falha
E2	Diagnóstico incorreto de condição de falha para uma condição de normalidade
E3	Diagnóstico incorreto, existe a falha, mas pertence à outra origem (térmica/elétrica)
E4	Sem diagnóstico e apresenta uma condição de normalidade
E5	Sem diagnóstico e apresenta uma condição de falha

Tabela 5.3 – Identificação dos tipos de diagnósticos errôneos.

Após a qualificação dos tipos de erros, foi feita essa análise para o método de Rogers, com relação aos três conjuntos de dados considerados. Essa análise está listada na Tabela 5.4. Nota-se que para o critério, os principais tipos de erros verificados são os do tipo E2, E4 e E5, sendo o E5, de maior incidência, mostrando que o método não possui bons resultados na identificação de falhas, sejam elas elétricas ou térmicas.

<b>DADOS IEC</b>					<b>DADOS CEPEL</b>					<b>DADOS HISTÓRICOS</b>				
E1	E2	E3	E4	E5	E1	E2	E3	E4	E5	E1	E2	E3	E4	E5
---	29.17	---	37.50	33.33	0.64	28.21	4.49	22.44	44.23	---	32.49	0.50	57.86	9.15

Tabela 5.4 – Distribuição percentual dos diagnósticos incorretos para o método de Rogers.

### 5.2.2 – MÉTODO DE DOERNENBURG

O método de Doernenburg original, como já mencionado no capítulo anterior, não estabelece critérios para o estabelecimento de condições normais do isolamento, mas estabelece as condições de validade para aplicação do método de diagnóstico em função das concentrações individuais dos gases componentes das relações. Para a obtenção dos resultados

de diagnósticos corretos, e necessariamente para identificação das condições de normalidade, foi utilizada a recomendação da norma IEEE C57.104-1991.

A distribuição percentual de diagnósticos corretos obtidos para dois conjuntos de dados em análise – IEC e CEPEL – são apresentadas na Tabela 5.5. Pode-se notar, que o método de Doernenburg apresenta no geral, percentagem de diagnósticos corretos em níveis razoáveis.

Método	DADOS IEC Diagnósticos Corretos (%)			DADOS CEPEL Diagnósticos Corretos (%)		
	Normal	F. Elétrica	F. Térmica	Normal	F. Elétrica	F. Térmica
Doernenburg	43.75	72.73	71.43	85.54	42.62	50.00

Tabela 5.5 – Dados de diagnósticos corretos por conjunto de dados.

Os resultados obtidos na aplicação do critério de Doernenburg, aos dados históricos estão listados na Tabela 5.6. Os valores obtidos apresentaram-se acima dos esperados, mas possuem uma explicação lógica, que será comentada no final do capítulo, quando da análise da ferramenta como um todo.

Método	DADOS HISTÓRICOS Diagnósticos Corretos (%)		
	Normal	F. Elétrica	F. Térmica
Doernenburg	95.00	---	36.36

Tabela 5.6 – Dados de diagnósticos corretos para o conjunto de dados históricos.

Também para este método, foram observados e qualificados os principais tipos de erros de diagnósticos encontrados, para os três conjuntos de dados, como pode ser visto na Tabela 5.7. No final do capítulo também ficará claro o porquê dos erros obtidos pelo método serem em sua maioria do tipo E1, onde é identificada a condição de normalidade, e o equipamento está operando sob falha.

DADOS IEC					DADOS CEPEL					DADOS HISTÓRICOS				
E1	E2	E3	E4	E5	E1	E2	E3	E4	E5	E1	E2	E3	E4	E5
36.84	31.58	---	15.79	15.79	54.32	8.64	3.70	6.17	27.17	63.89	8.33	2.78	11.11	13.89

Tabela 5.7 - Distribuição percentual dos diagnósticos incorretos para o método de Doernenburg.

### 5.2.3 – MÉTODO PREVISTO NA REVISÃO DA NBR 7274

Este método está baseado na IEC 599/78. Prevê a utilização de três relações gasosas e cinco gases. Também para efeitos de comparação posterior e para o cálculo do percentual de diagnósticos corretos, diagnósticos de mesma origem foram agrupados, resultando em três saídas possíveis. Com esta simplificação, e para os conjuntos de dados da IEC e do CEPEL, foram obtidos os resultados apresentados na Tabela 5.8. Os valores obtidos nos mostram que a NBR7274, apresenta os mesmos problemas do método que lhe serviu como base, que foi o método de Rogers, obtendo taxas de identificação de condições de normalidade nulas, ou muito pequenas.

Método	DADOS IEC Diagnósticos Corretos (%)			DADOS CEPEL Diagnósticos Corretos (%)		
	Normal	F. Elétrica	F. Térmica	Normal	F. Elétrica	F. Térmica
NBR 7274	---	86,36	78,57	10,84	55,73	61,25

Tabela 5.8 – Dados de diagnósticos corretos por conjuntos de dados.

Para os dados históricos analisados posteriormente, a taxa de diagnósticos corretos obtidos pela NBR7274, também não apresentou bons resultados, como pode ser visualizado na Tabela 5.9.

Método	DADOS HISTÓRICOS Diagnósticos Corretos (%)		
	Normal	F. Elétrica	F. Térmica
NBR 7274	12.22	70.00	45.45

Tabela 5.9 – Dados de diagnósticos corretos para o conjunto de dados históricos.

A análise dos diagnósticos errados obtidos pela aplicação da norma aos dados IEC e CEPEL, também é apresentada na Tabela 5.10.

DADOS IEC					DADOS CEPEL					DADOS HISTÓRICOS				
E1	E2	E3	E4	E5	E1	E2	E3	E4	E5	E1	E2	E3	E4	E5
---	31.82	---	40.91	27.27	6.06	24.24	5.30	31.82	32.58	---	27.75	1.16	63.58	7.51

Tabela 5.10 – Distribuição percentual dos diagnósticos incorretos para a NBR7274.

### 5.3 – MÓDULO 2 – RESULTADOS – REDE NEURAL

Neste item são apresentados os resultados referentes à aplicação de uma rede neural artificial do tipo GRNN, já descrita no item 3.2.6.5. A Tabela 5.11, mostra a distribuição percentual de diagnósticos corretos para os dois primeiros conjuntos de dados, por tipos de falhas consideradas. No geral, a rede apresentaria diagnósticos corretos com taxas superiores a 50%, mas esta taxa não se apresenta satisfatória quando da análise individualizada para as três condições de saída consideradas.

Método	DADOS IEC Diagnósticos Corretos (%)			DADOS CEPEL Diagnósticos Corretos (%)		
	Normal	F. Elétrica	F. Térmica	Normal	F. Elétrica	F. Térmica
Rede Neural	37.50	87.50	28.58	63.86	70.49	45.00

Tabela 5.11 – Dados de diagnósticos corretos por conjuntos de dados.

Para os dados históricos e para a rede neural com as características anteriormente descritas, a taxa de diagnósticos corretos obtida é mostrada na Tabela 5.12. A rede apresentou novamente a alternância de bons e maus resultados em função da identificação das condições de normalidade, falha elétrica e falha térmica. Vale salientar que para os três conjuntos de dados analisados, as taxas de diagnósticos corretos obtidos não podem ser diretamente comparados, já que não foram utilizados os mesmos dados na implementação da rede neural (conjunto de treinamento, *spread*, etc...), como já descrito no item 4.3.

Método	DADOS HISTÓRICOS Diagnósticos Corretos (%)		
	Normal	F. Elétrica	F. Térmica
GRNN	75.59	30.00	50.00

Tabela 5.12 – Dados de diagnósticos corretos para o conjunto de dados históricos.

Também para a análise do desempenho da rede neural, foram observados e qualificados os tipos de erros encontrados pela ferramenta. A análise de erros para os três conjuntos de dados é apresentada na Tabela 5.13. Observando esta tabela podemos visualizar que a rede neural apresenta a taxa de diagnósticos errôneos de forma mais distribuída, em comparação com os erros ocorridos na utilização dos critérios anteriores.

DADOS IEC					DADOS CEPEL					DADOS HISTÓRICOS				
E1	E2	E3	E4	E5	E1	E2	E3	E4	E5	E1	E2	E3	E4	E5
21.05	15.79	---	36.84	26.32	45.56	25.55	14.44	6.67	7.78	20.31	54.69	1.56	17.19	6.5

Tabela 5.13 – Distribuição percentual dos diagnósticos incorretos para a NBR7274.

#### 5.4 – MÓDULO 3 – DIAGNÓSTICO CONJUGADO DE NORMAS E REDE NEURAL

Neste item, serão apresentados os resultados obtidos na aplicação das normas e redes neurais aos conjuntos de dados considerados, e conseqüente determinação da porcentagem de amostras com diagnósticos verificados em um primeiro momento, quando da aplicação das regras já apresentadas na Tabela 4.10.

Também é verificada a porcentagem de amostras que deveriam passar ao próximo módulo da ferramenta, que consiste no sistema *fuzzy*, embora essa análise fique restrita somente aos dados históricos. Estes resultados são apresentados na Tabela 5.14.

Pode-se notar na Tabela 5.14 que para todos os conjuntos de dados, a distribuição percentual de diagnósticos corretos poderia alcançar valores acima de 85%, desde que, com os dados históricos dos equipamentos, pudessem ser verificadas corretamente as suas condições de operação.

DADOS IEC		DADOS CEPEL		DADOS HISTÓRICOS	
Diagnósticos Corretos (%)	Análise <i>Fuzzy</i> (%)	Diagnósticos Corretos (%)	Análise <i>Fuzzy</i> (%)	Diagnósticos Corretos (%)	Análise <i>Fuzzy</i> (%)
69.23	25	45.09	40.63	35.38	58.49

Tabela 5.14 – Distribuição percentual dos diagnósticos – Normas e Rede Neural.

Também pode-se notar, pelos valores apresentados na Tabela 5.14, que, para os critérios utilizados, muitas vezes as suas interpretações apresentam diagnósticos conflitantes, sendo uma tarefa complexa a determinação daquela que apresenta os melhores resultados. Essa constatação também serve de justificativa e incentivo à utilização destes de forma conjugada, a fim de se extrair o que cada uma tem de melhor em seus processos de identificação.

## 5.5 – MÓDULO 4 – RESULTADOS – LÓGICA FUZZY

Para a análise do mecanismo de inferência *fuzzy*, e conseqüente validação final da ferramenta, foram utilizados somente os dados históricos, já que essa formulação leva em conta a evolução dos níveis de gás gerados ao longo do tempo, bem como a taxa de geração anormal, necessária à esta análise.

Os níveis percentuais de acertos da ferramenta em função da saída considerada podem ser visualizados na Tabela 5.15.

Método	DADOS HISTÓRICOS Diagnósticos Corretos (%)		
	Normal	F. Elétrica	F. Térmica
Ferramenta	85.56	50.00	63.63

Tabela 5.15 – Dados de diagnósticos corretos para o conjunto de dados históricos.

Para a análise comparativa, foram obtidas as taxas de diagnósticos corretos para todos os métodos utilizados individualmente e que já foram apresentadas, bem como a taxa de diagnósticos corretos alcançados pela ferramenta como um todo. Estes valores, que não estão mais divididos em função da condição considerada, e sim do próprio conjunto de dados, podem ser visualizados na Tabela 5.16.

DIAGNÓSTICOS CORRETOS OBTIDOS PARA OS DADOS HISTÓRICOS(%)				
Rogers	Doernenburg	NBR7274	GRNN	Ferramenta
7.08	83.02	18.40	69.81	81.60

Tabela 5.16 – Distribuição percentual dos diagnósticos corretos.

De posse dos resultados apresentados na Tabela 5.16, podemos notar que a ferramenta teve desempenho considerado satisfatório, com mais de 80% dos casos identificados de forma correta, e com confiabilidade igualmente alta, já que estes níveis foram obtidos após a utilização de todos os critérios previamente determinados e explicados, bem como após uma análise *fuzzy* levando em conta os dados históricos do equipamento.

Faz-se mister salientar ainda que as taxas de diagnósticos corretos da ferramenta, podem apresentar melhores resultados. A taxa de reamostragens sugeridas chegou à 12,26% dos dados totais. Considerando que com as novas amostras, a ferramenta chegasse às conclusões necessárias e à indicação correta da condição do equipamento, os resultados poderiam alcançar em torno de 94% de diagnósticos acertados.

Outro comentário pertinente é a análise da alta taxa de diagnósticos corretos obtidos pelo critério de Doernenburg. O critério de Doernenburg original, como já foi mencionado anteriormente, não possui em suas relações critérios para definição de condições de normalidade para o equipamento. Segundo sugestão da IEEE, a não validade do método, ou seja, quando determinados limites de geração de gases não forem alcançados, o método vai fornecer como diagnóstico a operação normal do equipamento. Sendo assim, e para os dados em questão, esses limites por muitas vezes não foram atingidos, fazendo com que a resposta deste critério, aplicado individualmente, fosse na maioria dos casos, a condição de normalidade.

Considerando também que em torno de 85% das amostras analisadas apresentava diagnóstico “normal”, verificada pela opinião do especialista, fica explicado o porquê da alta taxa de diagnósticos corretos obtidos por este critério. Também torna-se importante dizer, que para aproximadamente 15% de amostras que apresentavam falhas, o critério de Doernenburg identificou somente 25% delas, como mostra a Tabela 5.6. Isso mostra a perspectiva de que o critério não teria boas taxas de diagnósticos corretos se as amostras se apresentassem em maior número com condições de falha.

Também para uma análise mais detalhada da ferramenta desenvolvida foram escolhidos dois transformadores, dentre os vinte analisados, e mostrados dados históricos de geração de gases para estes equipamentos, bem como as datas em que foram obtidas estas amostras, a resposta dos métodos individualmente e uma resposta geral da ferramenta após a análise *fuzzy* correspondente. Todos estes dados são apresentados na Tabela 5.17 e 5.18.

Convém informar ainda que os diagnósticos obtidos pelos métodos e pela ferramenta como um todo são representados por letras nas Tabelas 5.17 e 5.18, as quais representam as seguintes condições:

- A*: sem diagnóstico;
- B*: condição de normalidade do equipamento;
- C*: equipamento operando sob falha elétrica;
- D*: equipamento operando sob falha térmica;

De posse desta codificação, podemos então analisar os resultados obtidos por cada critério aplicado individualmente e também a análise da resposta final da ferramenta, comparações estas feitas em relação ao diagnóstico obtido por um especialista.

Como pode ser visualizado na Tabela 5.17, que corresponde aos dados cromatográficos de um transformador da ITEL, o método de Rogers aplicado individualmente possui baixa taxa de diagnósticos corretos, identificando somente uma

condição de falha térmica e uma condição de normalidade. O critério de Doernenburg, para este transformador, confirma as afirmações feitas anteriormente, e como os níveis de gases gerados são pequenos, fornece em todas as suas saídas o diagnóstico de condição de normalidade. O projeto de revisão da NBR 7274, baseada no critério de Rogers, tem o seu desempenho melhorado em relação ao próprio método de Rogers, identificando mais duas condições de normalidade corretamente. Já a GRNN, apresenta uma alta taxa de acerto na identificação das condições, apresentando somente um erro de diagnóstico. Onde existia a condição de normalidade ela apresentou como saída a ocorrência de falha térmica. Finalmente a ferramenta como um todo apresenta respostas satisfatórias. As respostas do método geral serão exploradas na seqüência através da análise de uma amostra apenas deste transformador.

A amostra destacada em amarelo na Tabela 5.17 (referente ao transformador 6 do Anexo C), através das regras aplicadas à análise individual dos critérios, indica que estes dados devem ser submetidos ao sistema  $fuzzy$ , com dúvida do tipo 3. Dúvidas deste tipo avaliam principalmente a formação do gás etileno. Observando então o valor de gás etileno gerado em relação à amostra anterior notamos que houve redução destes valores, e o nível de gás gerado final, indicará em seu conjunto  $fuzzy$ , pertinência maior ao conjunto “NORMAL”. Com relação à taxa de geração anormal, os valores serão negativos e indicará em seu conjunto  $fuzzy$ , pertinência maior ao conjunto “ACEITÁVEL”. A resposta do sistema  $fuzzy$ , já apresentada na Tabela 4.12, na combinação destes dois conjuntos (normal e aceitável) confirma à ferramenta a condição de normalidade.

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico	Fabricante: ITEL			Rogers	Dornenb.	NBR7274	GRNN	Geral
						Data	$\Delta t$	Procedimento					
110	15	5	28	0	Normal	02/01/83			3	1	1	1	1
69	18	5	22	0	Normal	29/02/84	423		3	1	1	1	1
140	160	410	84	1	Normal	10/06/85	467		3	1	3	3	3
55	65	300	55	2	F. Térmica	22/01/86	226	OLEO FILTRADO	3	1	3	3	3
230	23	100	38	0	Normal	03/12/86	315		0	1	0	1	1
210	22	12	17	0	Normal	07/11/88	705		1	1	1	1	1
270	26	9	17	0	Normal	03/07/90	603		2	1	2	1	1

Tabela 5.17 – Dados correspondentes a um determinado equipamento e diagnósticos obtidos.

O outro transformador escolhido, para uma análise mais detalhada, é um transformador de fabricação da SIEMENS (referente ao transformador 9 do Anexo C). Analisando os critérios de diagnóstico de forma individual, notamos novamente a baixa taxa de acerto do método de Rogers, que neste caso foi nula, apresentando em sua maior parte indicações do tipo sem diagnóstico. O método de Doernenburg, como também já comentado anteriormente, permaneceu com altas taxas de acerto em função dos níveis de gás gerado serem baixos e também em função dos diagnósticos obtidos por especialistas apresentarem



somente condições de normalidade. O projeto de revisão da NBR 7274, também apresenta baixas taxas de acerto e muitas amostras sem diagnóstico. A GRNN, apresenta um comportamento melhor em relação aos demais critérios, mas que não chega a ser satisfatório. A ferramenta como um todo mostra uma alta taxa de diagnósticos corretos e também será melhor explicada em função da amostra assinalada em amarelo na Tabela 5.18.

Para esta amostra, Rogers não encontrou resposta, Doernenburg apresenta condição de normalidade, a NBR 7274, apresentou condição de falha elétrica e a rede neural, igualmente à Doernenburg, apresentou condição de normalidade. A ferramenta como um todo apresentou, desta forma, dúvida do tipo 2 (condição de normalidade e falha elétrica), e o processamento do sistema *fuzzy* deu maior peso aos valores gerados de hidrogênio, e somente estes serão comentados. Para o nível de gás gerado, a concentração atual deve ser comparada com o maior valor obtido de geração de hidrogênio com condição de normalidade. Esta comparação é feita então entre os valores 11 (concentração atual) e o valor 25 (maior valor de concentração com condição de normalidade), fornecendo valores pequenos e menores que 1 e maior pertinência ao conjunto “NORMAL”. Já para a taxa de geração anormal, o valor atual 11, deve ser comparado com o anterior, que apresente condição de normalidade, que é 12 e que também vai gerar valores pequenos e maior pertinência ao conjunto “ACEITÁVEL”. Similarmente ao exemplo apresentado anteriormente, a resposta do sistema *fuzzy*, na combinação destes dois conjuntos (normal e aceitável) confirma novamente à ferramenta a condição de normalidade.

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico	Fabricante: SIEMENS			Rogers	Dornenb.	NBR7274	GRNN	Geral
						Data	Δt	Procedimento					
13	2	0	0	0	Normal	24/08/83			2	1	0	0	1
13	2	0	1	0	Normal	09/05/84	259		2	1	0	0	1
9	4	2	0	0	Normal	24/07/86	806	ÓLEO TRATADO	0	1	2	0	1
11	2	1	1	0	Normal	28/01/87	188		3	1	0	1	1
8	2	5	1	0	Normal	15/03/88	412		0	1	0	1	1
2	1	2	0	0	Normal	27/09/88	196		0	1	2	0	1
4	2	4	8	0	Normal	25/01/89	120		3	1	0	1	3
10	3	7	1	0	Normal	27/02/91	763		0	1	0	3	1
9	4	6	1	0	Normal	11/02/92	349		0	1	0	3	1
13	5	7	15	0	Normal	06/04/93	420		3	1	1	1	1
25	5	8	14	0	Normal	27/01/94	296		3	1	1	1	1
12	6	10	8	0	Normal	01/02/95	370		0	1	0	1	1
11	5	3	1	0	Normal	13/11/96	651		0	1	2	1	1

Tabela 5.18 – Dados correspondentes a um determinado equipamento e diagnósticos obtidos.

Somente a título de ilustração, a figura 5.1 apresenta ainda a saída do programa desenvolvido. Os resultados apresentados foram obtidos no teste de dados de uma amostra qualquer.

```

-----
|
|          SISTEMA DE MONITORAMENTO E DIAGNOSTICO DE TRANSFORMADORES
|          ANALISE DOS GASES DISSOLVIDOS NO OLEO ISOLANTE
|
| Desenvolvido por: Diego Roberto Moraes
| Orientadora: Jacqueline Gisele Rolim
| Laboratorio de Sistemas de Potencia - LABSPOT
|
| Saida do Programa para as amostras analisadas
|
| Condicao Normal
| Falha Termica
| Falha Termica
| Falha Eletrica
| Falha Eletrica
| Falha Eletrica
| Falha Eletrica
| Provavel Ocorrencia de Falha - Reamostragem Sugerida
| Condicao Normal
| Provavel Ocorrencia de Falha - Reamostragem Sugerida
| Condicao Normal
| Condicao Normal
| Condicao Normal
-----

```

Figura 5.1 – Interface que representa a saída do programa desenvolvido.

## 5.6 – CONCLUSÕES

Neste capítulo foram apresentados os resultados obtidos na aplicação da ferramenta aos três conjuntos de dados considerados.

Mostrou-se a ineficiência das normas e redes neurais quando aplicadas individualmente a determinadas amostras, em comparativo com o diagnóstico obtido pela ferramenta como um todo. Essa comparação indicou resultados amplamente satisfatórios na aplicação de mais de um critério, além de é claro, apresentar um diagnóstico com maior confiabilidade.

A análise *fuzzy* também mostrou-se altamente aplicável ao problema, pois não permite que a ferramenta analise as amostras estaticamente, pelos critérios já consolidados, mas em função do comportamento da evolução dos gases ao longo do tempo.

Também comprovou-se que, com a utilização dos métodos de forma conjunta, as deficiências individuais dos critérios, representadas pela qualificação dos erros, são supridas pelos melhores resultados dos demais, fornecendo ao usuário uma boa taxa de diagnósticos corretos.

Outro item relevante na análise dos resultados da ferramenta é a existência de um fator de incerteza nos próprios dados utilizados para validação, já que o diagnóstico dado como correto foi determinado por um especialista e não confirmado por inspeção no transformador.

## 6 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

### 6.1 – CONCLUSÕES

Este capítulo tem como objetivo apresentar as principais conclusões referentes ao trabalho descrito nesta dissertação. Como já referenciado durante o trabalho, com a desregulamentação do setor elétrico, aumentou-se a necessidade de redução dos custos de manutenção bem como da redução do número de desligamentos dos equipamentos, levando a indústria a mover-se dos tradicionais programas de manutenção baseadas no tempo, para programas de manutenção baseados nas condições. Em vez de intervenção em intervalos regulares, a manutenção é somente requerida quando as condições do equipamento assim indicam. Se existe o problema, o transformador pode ser reparado ou substituído antes de sua falha.

Neste contexto, as técnicas de monitoramento e identificação de falhas incipientes em transformadores ganharam novos impulsos, no que se refere ao seu desenvolvimento. Métodos tradicionais constantes em normas ou publicações, e ainda utilizados por concessionárias mostram-se pouco eficazes para fornecerem diagnósticos confiáveis aos operadores do sistema, e é aí que se encaixa o desenvolvimento de técnicas de inteligência artificial associadas a este propósito.

Este trabalho de dissertação tentou, dessa forma, agrupar em uma mesma ferramenta, normas utilizadas pelas concessionárias do setor elétrico, aliadas à técnicas de redes neurais e sistemas de lógica *fuzzy* referenciadas na literatura. O objetivo da ferramenta foi suprir as deficiências dos métodos convencionais, quando utilizados de forma isolada.

O primeiro passo do processo de diagnóstico consistiu na utilização de forma conjunta do método de Rogers, do método de Doernenburg, do projeto de revisão da NBR 7274 e da GRNN, obtendo-se um vetor de saídas. De posse desse vetor, algumas regras foram aplicadas para a combinação destes diagnósticos e os conflitantes foram submetidos à análise *fuzzy*, que consistiu na principal contribuição deste trabalho.

Individualmente, os métodos de Rogers, de Doernenburg e o previsto na NBR 7274, foram implementados, e para os três conjuntos de dados considerados, não apresentaram boas taxas de diagnósticos corretos. Apesar do desempenho insatisfatório, estes critérios são comumente utilizados e possuem grande aceitação nas empresas do setor elétrico, e por isso não devem ser desconsiderados.

A rede neural, mesmo que tenha sido aplicada de forma paralela com os métodos tradicionais e diferentemente destes, apresentou, quando aplicada individualmente, bons resultados. Mostra-se altamente aplicável ao problema proposto, baseando-se somente nos

exemplos históricos que lhe foram fornecidos durante o processo de aprendizado. Assim, é importante a qualidade dos dados utilizados e de sua representatividade para a condição em que serão utilizados.

A análise *fuzzy* levou em conta a taxa de geração anormal de gases e o nível de gás gerado em seu processo de decisão. Aplicada de forma individual poderia fornecer somente algum subsídio para uma investigação mais detalhada, como por exemplo o disparo de alarmes indicando a evolução significativa da geração de algum gás encontrado no óleo isolante.

A análise da ferramenta como um todo, denota aspectos importantes, a saber:

- o comportamento e diferentes tipos de transformadores, com diferentes projetos, condições de manutenção, condições de operação, tempos de operação, influem significativamente na concentração dos gases no óleo e, portanto na análise de diagnóstico;
- verificou-se que com a união de uma ou mais técnicas de diagnósticos, pode-se obter resultados com maior confiabilidade, sendo supridas as deficiências individuais de cada metodologia;
- o desempenho da ferramenta poderia ser aperfeiçoado com a disponibilidade de um maior número de dados históricos para o treinamento da GRNN, e também através da incorporação de algumas regras heurísticas para ajudar na resolução dos casos de diagnósticos inconsistentes entre os métodos.

Vale ressaltar ainda que a incerteza contida nos processos de obtenção de dados de geração de gases, aliados às diferenças entre os transformadores, como: classes de tensão, volume de óleo, aspectos construtivos, fatores ambientais envolvidos, dentre outros, impossibilitam o desenvolvimento de uma ferramenta que chegue a 100% de identificação de casos de forma acertada.

## **6.2 – SUGESTÕES PARA TRABALHOS FUTUROS**

Como sugestões para uma continuidade deste trabalho propõe-se:

- obtenção de um maior volume de dados com diagnósticos confirmados, para a avaliação do desempenho da ferramenta na identificação destas condições, bem como para a avaliação do desempenho dos critérios aplicados individualmente;
- buscar alternativas viáveis para inserir a “gravidade” dos defeitos na saída do diagnóstico, seja ela através da alteração do sistema fuzzy, ou ainda incorporando de alguma forma o conhecimento de especialistas na área;
- utilização dos dados históricos e desenvolvimento da metodologia especificamente para famílias de transformadores;
- desenvolvimento de modelos que levem em conta a presença da umidade no óleo isolante e o efeito da temperatura em seu processo de degradação.

## ANEXO A

### Dados da IEC TC10

Neste anexo são apresentados os dados utilizados para os testes das metodologias convencionais, e que também foram utilizados para treinamento da rede neural. Os grupos de dados representam uma parte de um banco de dados da IEC TC10. Para a apresentação dos mesmos, eles foram divididos em função da natureza das condições estabelecidas em inspeção e testes realizados por especialistas.

Dados de concentração de gases referentes aos estados identificados com a condição de normalidade (valores de concentração dos gases em ppm).

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
134	134	***	45	157
100	200	20	200	200
***	225	3	110	225
105	125	10	166	71
100	50	15	50	65
100	70	10	170	70
***	224	5	112	224
200	50	3	200	50
150	***	15	100	200
125	100	20	150	100
200	3	***	200	50
100	70	10	170	70
95	280	10	150	250
60	40	3	60	50
84	79	56	166	52
66	111	15	110	90

\*\*\* - Os valores de concentração não detectáveis foram substituídos pelo valor de 0.4 ppm para os cálculos das relações.

Dados de concentração de gases referentes aos estados identificados com a condição de falha correspondente a descargas de baixa energia (valores de concentração dos gases em ppm).

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
305	100	541	161	33
1230	163	692	233	27
645	86	317	110	13

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
95	10	39	11	***
595	80	244	89	9
1790	580	619	336	321
1330	10	182	66	20

\*\*\* - Os valores de concentração não detectáveis foram substituídos pelo valor de 0.4 ppm para os cálculos das relações.

Dados de concentração de gases referentes aos estados identificados com a condição de falha correspondente a descargas de alta energia (valores de concentração dos gases em ppm).

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
440	89	757	304	19
545	130	239	153	16
7150	1440	1760	1210	97
755	229	460	404	32
1570	1110	1830	1780	175
3090	5020	2540	3800	323
1820	405	634	365	35
260	215	277	334	35
75	15	26	14	7
60	5	21	21	2
1500	395	323	395	28
20000	13000	57000	29000	1850
3700	1690	3270	2810	128
2770	660	763	712	54
1170	255	325	312	18

Dados de concentração de gases referentes aos estados identificados com a condição de falha térmica com temperatura inferior à 700°C (valores de concentração dos gases em ppm).

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
1270	3450	8	1390	520
3420	7870	33	6990	1500
48	610	***	10	29
12	18	***	4	4
66	60	***	7	2
14	44	1	7	124

\*\*\* - Os valores de concentração não detectáveis foram substituídos pelo valor de 0.4 ppm para os cálculos das relações.

Dados de concentração de gases referentes aos estados identificados com a condição de falha térmica com temperatura superior à 700°C (valores de concentração dos gases em ppm).

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
8800	64064	***	95650	72128
6709	10500	750	17700	1400
290	966	57	1810	299
2500	10500	6	13500	4790
400	940	24	820	210
6	2990	67	26076	29990
290	1260	8	820	231
107	143	2	222	34

\*\*\* - Os valores de concentração não detectáveis foram substituídos pelo valor de 0.4 ppm para os cálculos das relações.

## ANEXO B

### Dados do CEPEL para transformadores

Neste anexo são apresentados os dados utilizados para os testes das metodologias convencionais, e que também foram utilizados para treinamento da rede neural. Os grupos de dados representam uma parte de um banco de dados do CEPEL, que diz respeito a transformadores com e sem contato com comutador sob carga (OLTC) e transformadores de distribuição. Para a apresentação dos mesmos, eles foram divididos em função da natureza das condições estabelecidas em inspeção e testes realizados por especialistas.

Dados de concentração de gases referentes aos estados identificados com a condição de normalidade (valores de concentração dos gases em ppm).

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
22	6	4	6	5
36	5	***	20	6
180	11	***	27	18
18	3	***	15	***
100	62	***	7	12
12	6	***	25	1
12	13	1	58	18
30	6	***	***	5
120	42	***	46	80
64	48	49	160	26
1600	2200	74	2700	430
48	20	120	130	21
7	2	***	2	1
32	6	***	7	5
33	25	63	16	7
23	6	***	2	3
9	5	***	17	4
140	110	74	250	36
14	200	***	41	520
10	24	3	24	12
47	35	11	78	49
34	5	***	5	3
17	4	***	11	2
7	8	***	3	13
59	16	***	12	14
150	54	***	9	61
82	61	8	35	130
82	20	74	33	16



H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
40	62	1	11	51
20	3	***	5	2
19	9	***	7	20
13	10	***	55	3
290	16	***	12	24
14	3	***	12	3
11	79	***	14	130
49	14	1	24	12
8	3	***	4	2
610	1800	270	6300	960
1	***	***	***	***
5	***	1	1	1
62	28	260	180	30
4	1	4	2	***
3	1	1	1	***
4	2	1	1	1
23	8	1	8	9
11	23	***	36	9
19	140	***	20	330
75	92	26	250	240
35	8	***	3	3
22	19	***	40	75
30	8	1	200	96
15	2	6	48	3
62	11	***	59	8
20	29	130	77	5
22	4	***	8	12
20	40	***	62	5
8	4	***	4	9
23	30	***	86	14
61	310	330	3000	570
88	6	***	15	23
350	350	5	860	290
28	6	2	5	4
9	4	***	15	3
21	8	***	17	25
69	43	***	20	32
50	50	5	66	36
430	2300	10	3000	1900
25	3	***	2	1
16	3	***	4	10
110	8	***	10	4
1	1	***	***	***
52	3	***	4	3
430	2300	10	3000	1900
7	***	***	***	***
14	38	***	22	55
51	97	***	3	110
48	29	***	20	17

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
30	76	***	48	220
600	1800	130	3800	520
24	3	***	8	4
16	1	***	1	1
48	12	***	18	14
56	6	10	7	5

\*\*\* - Os valores de concentração não detectáveis foram substituídos pelo valor de 0.4 ppm para os cálculos das relações.

Dados de concentração de gases referentes aos estados identificados com a condição de falha por sobreaquecimento (valores de concentração dos gases em ppm).

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
25	18	1	39	33
590	8400	710	62000	92000
310	1200	5	1200	320
260	100	26	2200	210
150	340	14	1400	220
1700	1600	***	2100	440
980	1800	22	3200	460
1	1800	5	6100	3400
29	440	***	180	2900
130	220	***	87	1700
87	430	***	190	570
42	320	***	840	820
4800	39000	20	70000	19000
300	1400	9	2100	720
64	840	37	5100	800
430	450	***	2000	1000
380	280	***	330	280
460	570	38	720	100
150	380	49	2300	320
46	960	***	1000	720
420	800	***	370	100
99	480	***	220	2600
290	110	***	14	320
47	74	***	100	150
200	1200	75	2700	800
190	820	***	1500	780
51	53	***	29	200
45	900	3	8700	7900
28	320	13	1200	250

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
170	1200	24	5200	940
280	160	39	1000	610
6	2	***	7	5
30	520	***	1000	310
1600	55000	9300	74000	42000
44	95	***	13	33
420	1400	7	1500	640
34	41	***	5	69
19	4	1	20	6
610	1900	33	14000	2400
67	9	22	7	9
57	46	***	14	58
17	3	1	4	9
110	2	3	15	2
66	38	***	39	120
6000	14000	47	19000	18000
410	90	***	36	53
410	11	30	330	300
2500	3200	220	5300	620
12	5	1	4	3
64	160	***	68	1200
4	19	***	20	1
7	22	***	32	35
450	250	510	300	130
82	13	***	8	23
20	11	1	14	14
110	46	***	9	52
1400	460	***	310	940
1400	3500	3600	7900	2500
13	290	13	4100	2400
220	750	7	1200	300
250	430	9	700	120
36	250	***	410	130
27	130	1	280	110
2200	120	***	5	63
23	5	1	8	6
54	3300	***	3000	2200
11	8	6	39	11
580	880	160	1100	190
300	250	32	560	160
470	2800	***	4300	1400
440	3600	96	6500	1500
61	240	1	320	130
12	110	1	660	190
1000	1200	1200	2000	140
45	240	18	1100	260
57	29	***	190	220
85	160	2	38	270
32	51	***	51	52

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
72	27	140	220	26
260	650	3	950	220

\*\*\* - Os valores de concentração não detectáveis foram substituídos pelo valor de 0.4 ppm para os cálculos das relações.

Dados de concentração de gases referentes aos estados identificados com a condição de falha por descargas elétricas (valores de concentração dos gases em ppm).

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
3800	1100	1700	1300	300
550	67	240	89	30
78	580	1200	1500	130
5800	560	4700	830	31
430	40	480	68	13
3800	1700	4200	1300	200
6600	3300	6200	4200	620
4500	2100	1300	3000	250
7200	7200	1100	7700	3800
5000	2000	5500	3100	1900
1500	110	910	91	140
20000	1700	11000	6600	940
7	4	60	94	49
2100	210	1200	230	160
770	86	370	170	29
540	26	280	21	11
1500	640	1700	810	50
1900	1700	5300	2900	130
2400	770	1900	850	68
530	260	250	210	14
16	3	5	2	4
36	67	380	290	110
250	20	200	31	5
2600	660	810	750	47
49	4	***	1	3
200	240	100	380	74
970	240	1100	390	18
1200	2500	120	3700	710
500	160	240	140	48
630	670	1700	1100	81
110	860	1800	1500	200
200	110	230	150	12
94	5	20	25	4
4000	1200	4400	1900	130

H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
230	120	740	220	14
6600	2300	3400	3500	210
11000	1300	4600	1400	140
9	2	52	5	1
51	6	11	6	1
16000	9400	22000	17000	1400
7	2	***	1	1
97	12	21	25	2
150	38	110	54	5
35	110	540	380	150
32	32	29	47	5
79	100	230	83	410
20000	6400	10000	7100	2600
1300	8400	5500	2200	5900
1100	140	350	2	14
200	6	8	8	5
39	4	15	4	***
6000	1900	2700	2400	280
81	21	29	46	11
14	7	22	15	1
19	***	***	4	***
380	250	1000	590	34
67	6	***	21	15
15000	10000	23000	21000	2200
4700	240	300	120	***
170	98	140	45	220
210	65	190	100	22

\*\*\* - Os valores de concentração não detectáveis foram substituídos pelo valor de 0.4 ppm para os cálculos das relações.

## ANEXO C

### Dados Históricos de transformadores

Neste anexo são apresentados os dados utilizados para os testes de todas as metodologias individualmente, bem como utilizados para os testes da ferramenta como um todo. Para a apresentação dos mesmos, eles estão divididos em função de cada transformador, contendo, além dos dados de geração de gases, as datas em que foram obtidas estas amostras e o diagnóstico obtido, através da opinião de um especialista, para esta mesma amostra.

TRANSFORMADOR 1	FABRICANTE: EMS	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		6	17	16	6	***	Normal	28/10/85	
		10	9	14	10	***	Normal	07/12/88	
		80	34	19	15	***	Normal	13/10/89	
		7	75	16	9	***	Normal	18/12/91	
		49	34	32	18	***	Normal	19/02/93	
		81	47	27	16	***	Normal	01/03/94	
		39	41	29	16	2	Normal	05/06/95	
		73	45	29	23	***	Normal	09/01/97	
		2800	940	940	100	590	Falha Elétrica	17/02/97	
		52	2	15	17	***	Normal	10/04/97	Óleo Trocado 03/97
46	12	9	2	***	Normal	06/06/97			

TRANSFORMADOR 2	FABRICANTE: BROWN BOVERI	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		590	40	16	31	***	Falha Térmica	19/08/81	
		320	30	19	27	***	Normal	21/12/81	
		290	16	15	28	***	Falha Térmica	11/11/82	
		610	17	15	18	***	Normal	23/09/83	
		230	20	12	17	***	Normal	13/02/84	
		410	10	10	10	***	Normal	01/07/86	
		550	9	8	17	***	Normal	09/07/87	
		64	3	4	4	***	Normal	06/12/88	Óleo Filtrado 08/88
		7	10	19	2	***	Normal	05/12/95	
		64	7	47	6	***	Normal	25/02/97	
		39	18	76	6	***	Normal	08/10/97	
		54	12	88	6	***	Normal	22/06/98	

TRANSFORMADOR 3	FABRICANTE: BROWN BOVERI	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		15	110	290	47	13	Falha Térmica	04/05/79	
		380	100	450	64	20	Falha Térmica	26/10/79	
		390	90	410	60	28	Falha Térmica	30/10/79	
		8	2	3	***	***	Normal	06/11/79	Degasagem 01/11/79
		89	8	10	8	***	Falha Térmica	29/04/80	
		51	16	17	11	***	Normal	25/05/81	
		9	14	10	13	***	Normal	28/07/82	
		6	4	12	3	***	Normal	20/05/83	
		3	2	5	5	***	Normal	04/10/84	
		10	3	6	3	***	Normal	18/09/85	
		83	3	6	5	***	Normal	26/05/87	
		9	2	3	3	***	Normal	27/09/88	
		110	7	3	6	***	Normal	13/09/89	
		110	13	22	8	***	Normal	18/10/90	
		39	11	21	8	***	Normal	30/07/92	
		50	9	15	12	***	Normal	30/09/93	
770	16	14	18	***	Normal	05/06/95			
53	11	8	12	***	Normal	01/04/96			

TRANSFORMADOR 4	FABRICANTE DESCONHECIDO	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		42	3	6	***	6	Falha Elétrica	06/05/79	
		6	3	5	***	***	Normal	28/05/79	
		19	3	9	***	***	Normal	16/08/79	
		33	3	21	***	***	Normal	04/10/79	
		11	7	19	***	***	Normal	28/04/80	
		16	32	23	40	***	Falha Térmica	17/02/81	
		10	7	21	***	***	Normal	03/09/81	
		12	8	19	***	***	Normal	15/02/82	
		19	6	9	***	***	Normal	13/05/82	
		29	2	16	1	***	Normal	11/01/83	
		27	5	12	2	***	Normal	13/02/84	
		35	3	3	3	***	Normal	08/06/89	
		18	3	80	***	***	Falha Elétrica	08/06/89	
		18	2	3	5	***	Normal	27/12/89	
		37	7	8	4	***	Normal	26/11/92	
		60	5	7	4	***	Normal	02/12/93	
		16	2	5	1	***	Normal	14/03/94	
		37	3	2	3	***	Normal	26/06/95	
34	4	4	1	***	Normal	10/10/96	Óleo Trocado 03/97		
33	3	6	***	***	Normal	09/12/97			

TRANSFORMADOR 5	FABRICANTE: ITEL	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		220	15	6	26	***	Falha Térmica	17/05/83	
		84	8	13	4	11	Falha Elétrica	04/05/84	
		170	14	7	26	***	Normal	08/06/84	
		100	10	8	24	***	Normal	27/09/85	
		190	17	8	28	***	Normal	03/09/86	
		250	36	19	42	***	Normal	11/03/88	
		260	13	10	17	***	Normal	20/07/90	
		320	10	11	11	***	Normal	06/02/92	
		260	14	12	21	***	Normal	06/04/93	
		200	8	12	12	***	Normal	01/12/94	
		17	5	7	3	***	Normal	01/03/96	Óleo Regenerado 11/95
		16	0	6	2	***	Normal	07/04/97	Óleo Trocado 11/96
5	7	24	3	***	Normal	20/07/98			

TRANSFORMADOR 6	FABRICANTE: ITEL	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		110	15	5	28	***	Normal	02/01/83	
		69	18	5	22	***	Normal	29/02/84	
		140	160	410	84	1	Normal	10/06/85	
		55	65	300	55	2	Falha Térmica	22/01/86	Óleo Filtrado 02/96
		230	23	100	38	***	Normal	03/12/86	
		210	22	12	17	***	Normal	07/11/88	
		270	26	9	17	***	Normal	03/07/90	

TRANSFORMADOR 7	FABRICANTE: ITEL	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		29	110	53	290	10	Normal	02/03/83	
		26	51	52	530	5	Normal	17/08/84	
		64	180	65	770	5	Normal	10/10/86	
		620	2200	2000	1100	13	Falha Térmica	05/08/87	
		790	2400	1900	1100	13	Falha Térmica	05/08/87	
		410	510	600	150	26	Falha Térmica	14/08/87	
		350	580	740	180	29	Falha Térmica	14/08/87	
		460	670	770	200	18	Falha Térmica	27/08/87	
		350	780	760	260	5	Falha Térmica	21/10/87	
		2200	890	980	310	490	Normal	05/01/88	
		13000	2000	3300	950	4600	Falha Elétrica	19/08/88	
		180	2700	4200	1600	12	Normal	26/08/88	
		930	2700	3200	1700	17	Falha Térmica	07/12/88	
		8600	2200	3100	1300	1100	Falha Elétrica	15/02/89	
480	2200	2700	1600	10	Falha Térmica	31/03/89			
430	2300	3000	1900	10	Falha Elétrica	03/07/89			



TRANSFORMADOR 8	FABRICANTE: SIEMENS	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		13	2	***	***	***	Normal	24/08/83	
		15	3	1	1	***	Normal	09/05/84	
		14	3	1	1	***	Normal	24/07/86	Óleo Tratado 21/07/86
		11	2	3	1	***	Normal	28/01/87	
		9	5	22	2	1	Normal	15/03/88	
		11	3	7	3	***	Normal	01/02/90	
		11	4	8	13	***	Normal	27/02/91	
		8	3	8	1	2	Normal	11/02/92	
		10	3	6	1	***	Normal	06/04/93	
		13	4	8	2	***	Normal	27/01/94	
		10	4	10	***	***	Normal	01/02/95	
7	13	2	1	***	Normal	13/11/96			

TRANSFORMADOR 9	FABRICANTE: SIEMENS	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		13	2	***	***	***	Normal	24/08/83	
		13	2	***	1	***	Normal	09/05/84	
		9	4	2	***	***	Normal	24/07/86	Óleo Tratado 21/07/86
		11	2	1	1	***	Normal	28/01/87	
		8	2	5	1	***	Normal	15/03/88	
		2	1	2	***	***	Normal	27/09/88	
		4	2	4	8	***	Normal	25/01/89	
		10	3	7	1	***	Normal	27/02/91	
		9	4	6	1	***	Normal	11/02/92	
		13	5	7	15	***	Normal	06/04/93	
		25	5	8	14	***	Normal	27/01/94	
12	6	10	8	***	Normal	01/02/95			
11	5	3	1	***	Normal	13/11/96			

TRANSFORMADOR 10	FABRICANTE: SIEMENS	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		11	2	***	***	***	Normal	24/08/83	
		16	3	***	1	***	Normal	09/05/84	
		7	2	1	1	***	Normal	24/07/86	Óleo Tratado 21/07/86.
		10	2	1	1	***	Normal	28/01/87	
		7	2	5	1	***	Normal	15/03/88	
		9	3	5	12	***	Normal	25/01/89	
		9	4	6	6	***	Normal	01/02/90	
		10	2	9	***	***	Normal	27/02/91	
		10	4	8	10	***	Normal	11/02/92	
		12	6	8	13	***	Normal	06/04/93	
		15	7	8	24	***	Normal	27/01/94	
10	4	8	9	***	Normal	01/02/95			
6	6	2	2	***	Normal	13/11/96			

TRANSFORMADOR 1	FABRICANTE: ASEA	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		71	24	14	6	14	Falha Elétrica	05/08/82	Óleo Tratado 01/82
		200	150	96	160	95	Normal	09/06/83	
		21	6	38	30	13	Normal	08/05/85	
		22	8	11	9	***	Normal	28/06/95	
		130	270	800	160	120	Falha Térmica	22/05/98	

TRANSFORMADOR 12	FABRICANTE: ITEL	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		64	7	7	8	***	Normal	07/04/93	
		34	8	11	27	5	Falha Térmica	01/12/94	
		19	5	5	7	4	Normal	27/04/95	
		160	14	4	15	***	Normal	04/03/96	
		25	5	***	***	***	Normal	08/04/97	
14	7	8	2	***	Normal	17/07/98	Óleo Regenerado 12/97		

TRANSFORMADOR 13	FABRICANTE: TOSHIBA	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		95	13	5	69	***	Falha Elétrica	19/08/83	
		480	37	8	84	***	Falha Elétrica	15/10/84	
		330	10	3	26	***	Normal	13/03/86	
		320	10	5	17	***	Normal	19/08/87	
		23	5	2	2	***	Normal	31/07/97	Óleo Filtrado 06/96
		14	6	7	3	***	Normal	05/11/97	
8	5	10	3	***	Normal	24/04/98			

TRANSFORMADOR 14	FABRICANTE: ITEL	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		19	9	4	17	***	Normal	11/11/88	
		7	9	7	8	***	Normal	20/07/90	
		55	11	23	13	***	Normal	06/02/92	
		26	16	18	12	***	Normal	07/04/93	
		61	10	17	12	***	Normal	01/12/94	
		260	8	20	9	***	Normal	04/03/96	
		370	7	120	8	***	Normal	07/04/97	Óleo Regenerado 09/96
17	12	120	7	***	Normal	20/07/98			

TRANSFORMADOR 15	FABRICANTE: TRAF0	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		64	70	16	230	***	Falha Térmica	17/05/83	
		130	46	28	160	***	Normal	04/05/84	
		170	67	10	130	***	Normal	14/12/84	
		180	22	6	84	***	Normal	27/09/85	
		180	20	6	64	***	Normal	03/09/86	
		270	21	8	41	***	Normal	11/03/88	
		310	9	8	11	***	Normal	10/02/92	
		290	11	11	8	***	Normal	07/04/93	
		220	7	10	10	***	Normal	01/12/94	
		130	8	7	3	***	Normal	04/03/96	
		5	2	***	***	***	Normal	01/04/97	
17	7	8	2	***	Normal	20/07/98	Óleo Regenerado 11/97		

TRANSFORMADOR 16	FABRICANTE: TRAF0	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		59	37	6	120	***	Normal	17/05/83	
		140	24	5	65	***	Normal	11/12/84	
		150	28	10	81	***	Normal	27/09/85	
		170	18	6	64	***	Normal	03/09/86	
		240	20	8	39	***	Normal	11/03/88	
		370	10	10	19	***	Normal	10/02/92	
		230	7	5	3	***	Normal	06/04/93	
		280	10	13	6	6	Falha Térmica	01/12/94	
		310	10	10	3	3	Normal	27/04/95	
		320	7	10	9	***	Normal	04/03/96	
		11	***	***	***	***	Normal	09/04/97	Óleo Regenerado 01/97
71	7	6	2	***	Normal	20/07/98	Óleo Regenerado 11/97		

TRANSFORMADOR 17	FABRICANTE: WEG	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		190	37	33	2	***	Falha Térmica	08/07/93	
		120	26	29	6	***	Normal	03/08/93	
		15	10	19	1	42	Falha Elétrica	18/11/93	
		5	1	1	***	2	Normal	14/03/94	Óleo Trocado 01/94
		15	2	4	2	1	Normal	08/06/94	
		14	3	4	2	***	Normal	05/10/94	
		3	2	4	***	***	Normal	05/12/95	
2	5	3	***	***	Normal	09/01/97			

TRANSFORMADOR 18	FABRICANTE: H. LINE	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		32	11	33	8	***	Normal	21/12/83	
		100	1200	1300	370	580	Falha Térmica	09/05/85	
		74	590	1200	300	690	Falha Térmica	13/05/85	
		9	7	58	22	21	Normal	20/05/85	
		30	11	68	22	24	Falha Térmica	14/08/85	
		55	26	87	25	210	Falha Elétrica	12/11/85	
		28	14	74	18	130	Normal	10/12/85	
		1	1	16	6	24	Normal	11/12/85	
		57	5	12	3	***	Normal	14/01/86	Óleo Filtrado 12/85
		23	5	13	5	12	Falha Elétrica	17/02/86	
		22	5	9	4	***	Normal	20/05/87	
		15	4	3	3	***	Normal	27/01/89	
110	9	3	2	***	Normal	21/03/90			

TRANSFORMADOR 19	FABRICANTE: DESCONHECIDO	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		180	10	1	11	***	Normal	16/05/83	
		200	13	7	25	***	Normal	14/12/84	
		140	24	12	20	***	Normal	08/10/85	
		250	35	6	13	***	Normal	03/09/86	
		160	7	8	9	***	Normal	10/03/88	
		210	19	20	14	2	Falha Térmica	19/09/88	
		110	5	5	7	***	Normal	20/02/90	
		140	4	6	3	***	Normal	07/02/92	
		170	5	7	2	***	Normal	07/04/93	
		80	4	6	5	***	Normal	01/12/94	
		110	4	3	2	***	Normal	04/03/96	
		69	5	3	***	***	Normal	08/04/97	
17	5	5	2	***	Normal	21/07/98	Óleo Regenerado 07/97		

TRANSFORMADOR 20	FABRICANTE: DESCONHECIDO	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
		220	12	11	24	***	Falha Térmica	16/05/83	
		120	11	7	15	***	Normal	11/12/84	
		310	15	7	12	***	Normal	08/10/85	
		220	12	6	15	***	Normal	03/09/86	
		230	12	9	12	***	Normal	11/03/88	
		340	21	17	10	***	Falha Térmica	05/05/88	
		210	7	8	7	***	Normal	20/07/90	
		190	5	7	7	***	Normal	07/02/92	
		90	4	5	3	***	Normal	06/04/93	
		170	6	9	5	***	Normal	02/12/94	
		170	6	6	2	***	Normal	04/03/96	
		170	6	9	7	***	Normal	09/04/97	
12	5	5	7	***	Normal	22/07/98	Óleo Regenerado 07/97		

\*\*\* - Os valores de concentração não detectáveis foram substituídos pelo valor de 0.4 ppm para os cálculos das relações.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AZEVEDO, F. M.; BRASIL L. M.; OLIVEIRA R. C. L.; 2000. Redes Neurais com Aplicações em Controle e em Sistemas Especialistas, Florianópolis : Brookstore.
- BARONI, P.; GUIDA, G.; MUSSI, S.; 1995. Distributed and Uncertain Reasoning in a Knowledge-Based System for Preventive Diagnosis of Power Transformers, *IEEE International Conference on Systems, Man and Cybernetics*, vol. 2, p. 1801-1806.
- BARONI, P.; GUIDA, G.; MUSSI, S.; 1997. State Assessment and Preventive Diagnosis of Power Transformers: a Knowledge-based Approach. *Engineering Intelligent Systems*, vol. 5, nº 2, p. 91-105.
- BARRETO J. M.; 1999. Inteligência Artificial no Limiar do Século XXI, 2ª ed., Florianópolis : J. M. Barreto.
- BORGES, P. S. S.; 2003. Lógica Fuzzy e suas Aplicações. IX Ciclo de Cursos e Palestras da Engenharia Elétrica. Apostila de Curso. 28p.
- CARDOSO JR., Ghendy; 2003. *Estimação da Seção em Falta em Sistemas Elétricos de Potência via Redes Neurais e Sistemas Especialistas Realizada em Nível de Centro de Controle*. Florianópolis. Tese (Doutorado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina.
- COSTA, S.; BRANDÃO JR., A. F.; 2001. Monitoramento de Transformadores de Potência com Base nas Condições. *Eletricidade Moderna*, p. 152-162.
- DARVENIZA, M.; SAHA, T. K.; HILL, D. J. T. et al.; 1998. Investigations into Effective Methods for Assessing the Condition of Insulation in Aged Power Transformers. *IEEE Transaction on Power Delivery*, vol. 13, nº 4, p. 1214-1223.
- DUKARM, J. J.; 1993. Transformer Oil Diagnosis Using Fuzzy Logic and Neural Networks. *Conference in Electrical and Computer Engineering, Canadian*, vol. 1, p. 329-332.
- DUVAL, M.; 1989. Dissolved Gas Analysis: It Can Save Your Transformer. *IEEE Electrical Insulation Magazine*, vol. 5, nº6, p. 22-27.
- DUVAL, M.; DE PABLO, A.; 2001. Interpretation of Gas-In-Oil Analysis Using New IEC Publication 60599 and IEC TC 10 Databases. *IEEE Electrical Insulation Magazine*, vol. 17, nº 2, p. 31-41.
- DUVAL, M.; 2002. A Review of Faults Detectable by Gas-in-Oil Analysis in Transformers. *IEEE Electrical Insulation Magazine*, vol. 18, nº 3, p. 8-17.
- DUVAL, M.; 2003. New Techniques for Dissolved Gas-in-Oil Analysis. *IEEE Electrical Insulation Magazine*, vol. 19, nº 2, p. 6-15.

- FARROKHY, M.; RAFIEE, M.; 2001. Evaluation of Used and Repaired Power Transformers Using Neural Networks. *Transmission and Distribution Conference and Exposition, IEEE/PES*, vol. 1, p. 143-146.
- FAUSETT, L.; 1994. *Fundamentals of Neural Networks*. New Jersey: Prentice Hall Inc.
- FREITAS, A. A. C.; SOUZA, A N.; SILVA, I. N.; 2002. Aplicação de Redes Neurais na Estimativa da Temperatura Interna de Transformadores de Distribuição Imersos em Óleo. *Revista Controle e Automação*, vol. 13, nº 3, p. 266-274.
- GUARDADO, J. L.; NAREDO, J. L.; MORENO, P. et al.; 2001. A Comparative Study of Neural Network Efficiency in Power Transformers Diagnosis Using Dissolved Gas Analysis. *IEEE Transactions on Power Delivery*, vol. 16, nº 4, p. 643-647.
- HAN, Y.; SONG, Y. H.; 2003. Condition Monitoring Techniques for Electrical Equipment – A Literature Survey. *IEEE Transaction on Power Delivery*, vol. 18, nº 1, p. 4-13.
- HAYKIN, S.; 2001. *Redes Neurais: Princípios e Prática*. 2ª ed. Porto Alegre : Bookman.
- HUANG, Y. C.; YANG, H. T.; HUANG, C. L.; 1997. Developing a New Transformer Fault Diagnosis System through Evolutionary Fuzzy Logic. *IEEE Transactions on Power Delivery*, vol. 12, nº 2, p. 761-767.
- IEEE Std C 57.104-1991. *IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers*.
- JAEGER, N. A. F.; JAEGER, C. P.; KATO, H. et al.; 1998. An On-Line Real-Time Relative Dissipation Factor Monitoring System. *Electrical and Computer Engineering, Canadian Conference, IEEE*, vol. 2, p. 493-496.
- KELLY, J. J.; 1980. Transformer Fault Diagnosis by Dissolved-Gas Analysis. *IEEE Transaction on Industry Applications*, vol. IA-16, nº 6, p. 777-782.
- KELLY, J. J.; MYERS, D. P.; 1993. Transformer Life Extension through Proper Reinhibiting and Preservation of the oil insulation. *IEEE Transactions on Industry Applications*, vol. 31, nº 1, p. 55-60.
- KHALIFA, M.; 1990. *High-Voltage Engineering: Theory and Practice*. USA : Marcel Dekker Inc.
- KLIR, G. J.; YUAN B.; 1995. *Fuzzy Sets and Fuzzy Logic: Theory and Applications*. New Jersey: Prentice Hall Inc.
- LIN, C. E.; LING, J. M.; HUANG, C. L.; 1993. An Expert System for Transformer Fault Diagnosis Using Dissolved Gas Analysis. *IEEE Transaction on Power Delivery*, vol. 8, nº1, p. 231-238.
- LOESCH, C.; SARI, S. T.; 1996. *Redes Neurais Artificiais – Fundamentos e Modelos*, Editora da FURB, Blumenau.
- MILASCHI, M.; 1984. *Manutenção De Transformadores em Líquido Isolante*. Editora Edgard Blücher LTDA.

- MIN, L.; HUA, R.; 1988. Analytical Investigation for Causes of Instability of Dissipation Factor of Insulating Oil. *Second International Conference on Properties and Applications of Insulating oil*, vol. 1, p. 74-77.
- MYERS, C.; 1998. Transformers- Conditioning Monitoring by Oil Analysis Large or Small; Contentment or Catastrophe. *Power Station Maintenance: Profitability Through Reliability*. Conference Publication n° 452, IEE, p. 53-58.
- NUNO, M. D. S.; SOUZA, B. C. T.; 2003. Fuzzy Controls in Mechatronics. Trabalho de Graduação. Universidade de Coimbra. 10p.
- SCHIMIDT, W.; 1979. Materiais Elétricos – Isolantes e Magnéticos. Vol. II. Edgard Blücher.
- SEN, P. K.; PANSUWAN S.; 2001. Overloading and Loss-of-Life Assessment Guidelines of Oil-Cooled Transformers. *Rural Electric Power Conference*. p. B4/1-B4/8.
- Sistema de Monitoramento SITRAM, SIEMENS, Informe Técnico 2001.
- SOKOLOV, V.; BULGAKOVA, V.; BERLER, Z.; 2001. Assessment Of Power Transformer Insulation Condition. *Electrical Insulation Conference and Electrical manufacturing & Coil Winding Conference*. p. 605-613.
- SOKOLOV, V.; BERLER, Z.; RASHKES, V.; 1999. Effective Methods of Assessment of Insulation System Conditions in Power Transformers: A View Based on Practical Experience. *Electrical Insulation Conference and Electrical manufacturing & Coil Winding Conference*. p. 659-667.
- SPARLING, B. D.; 2001. Transformer Monitoring Moving Forward from Monitoring to Diagnostics. *Transmission and Distribution Conference and Exposition, IEEE/PES*, vol. 2, p. 960-963.
- SU, Q.; LAI, L. L.; AUSTIN, P.; 2000. A Fuzzy Dissolved Gas Analysis Method for the Diagnosis of Multiple Incipient Faults in a Transformer. *Proceedings of the 5<sup>th</sup> International Conference on Advances in Power system Control, Operation and Management, APSCOM 2000*, Hong Kong, p. 344-348.
- TAFNER, M. A.; XEREZ, M.; FILHO, I. W. R.; 1996. Redes Neurais Artificiais – Introdução e Princípios de Neurocomputação, Eko.
- THOMAS, P.; SHUKLA, A. K.; 2001. Ageing Studies on Paper-oil to Asses the Condition of Solid Insulation used in Power Transformers. *IEEE 7<sup>th</sup> Internation Conference on Solid Dielectrics*, Eindhoven, the Netherlands, p. 69-72.
- TOMSOVIC, K.; TAPPER, M.; INGVARSSON T.; 1993. A Fuzzy Information Approach to Integrating Different Transformer Diagnostic Methods. *IEEE Transactions on Power Delivery*, vol. 8, n° 3, p. 1638-1646.
- VAN BOLHUIS, J. P.; GULSKI, E.; SMIT, J. J.; 2002. Monitoring and Diagnostic of Transformer Solid Insulation. *IEEE Transactions on Power Delivery*, vol. 17, n° 3, p. 528-536.

- VARELLA, V.; CHEIM, L.; DUPONT, C.; 2000. Sistema de Inferência Fuzzy para Diagnóstico de Transformadores de Potência. In: *VII SEPOPE – Symposium of Specialists in Electric Operational and Expansion Planning*. Curitiba – Paraná.
- XU, W.; WANG, D.; ZHOU, Z. et al.; 1997. Fault Diagnosis of Power Transformers: Application of Fuzzy Set Theory, Expert Systems and Artificial Neural Networks. *IEEE Proc.-Sci. Meas. Technology*, vol. 144, n° 1, p. 39-44.
- WANG, M.; VANDERMAAR, A. J.; SRIVASTAVA, K. D.; 2002. Review of Condition Assessment of Power Transformers in Service. *IEEE Electrical Insulation Magazine*, vol. 18, n° 6, p. 12-26.
- WANG, M. H.; 2003. A Novel Extension Method for Transformer Fault Diagnosis. *IEEE Transaction on Power Delivery*, vol. 18, n° 1, p. 164-169.
- WANG, Z.; LIU, Y.; GRIFFIN, P. J.; 1998. A Combined ANN and Expert System Tool for Transformer Fault Diagnosis. *IEEE Transactions on Power Delivery*, vol. 13, n° 4, p. 1224-1229.
- WANG, Z.; 2000. Artificial Intelligence in OLTC Fault Diagnosis Using Dissolved Gas-In-Oil Information. *Power Engineering Society Summer Meeting, IEEE*, vol. 4, p.2422-2427.
- YANG, H. T.; LIAO, C. C.; 1999. Adaptive Fuzzy Diagnosis System for Dissolved Gas Analysis of Power Transformers. *IEEE Transactions on Power Delivery*, vol. 14, n° 4, p. 1342-1350.
- YANG, H. T.; LIAO, C. C.; CHOU, J. H.; 2001. Fuzzy Learning Vector Quantization Networks for Power Transformer condition Assessment. *IEEE Transaction on Dielectrics and Electrical Insulation*, vol. 8, n° 1, p. 143-149.
- ZIRBES, Roberto; 2003. *Metodologias para Avaliação e Diagnóstico do Estado de Isolamentos de Papel Impregnado com Óleo Mineral*. Florianópolis. Dissertação (Mestrado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina.
- ZHANG, Y.; DING, X.; LIU, Y. et al.; 1996. An Artificial Neural Network Approach to Transformer Fault Diagnosis. *IEEE Transactions on Power Delivery*, vol. 11, n° 4, p. 1836-1841.