



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA

FÁBIO ROCHA BARBOSA

**Monitoramento on-line e diagnóstico
inteligente da qualidade dielétrica do
isolamento líquido de transformadores de
potência**

FORTALEZA
2007

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

FÁBIO ROCHA BARBOSA

**Monitoramento on-line e diagnóstico
inteligente da qualidade dielétrica do
isolamento líquido de transformadores de
potência**

Dissertação apresentada à Coordenação do
Programa de Pós-Graduação em Engenharia
Elétrica do Centro de Tecnologia da
Universidade Federal do Ceará como parte
dos requisitos exigidos para a obtenção do
Grau de
Mestre em Engenharia Elétrica

Orientador: Prof. Dr. Otacílio da Mota Almeida

FORTALEZA
2007

FÁBIO ROCHA BARBOSA

Monitoramento on-line e diagnóstico inteligente da qualidade dielétrica do isolamento líquido de transformadores de potência

Esta Dissertação foi julgada adequada para obtenção do Título de Mestre em Engenharia Elétrica, Área de Concentração em Processamento da Energia, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Ceará.

Prof. Otacílio da Mota Almeida, Dr.
Orientador

Banca Examinadora:

Prof. Otacílio da Mota Almeida, Dr.
Presidente

Prof. Arthur Plínio, Dr.

Prof. José Almeida do Nascimento, Dr.

Fortaleza, 13 março de 2008

DEDICATÓRIA

À minha esposa, mulher da minha aliança,
que realmente sabe o que
significa ser companheira.
Aos meus pais, Paulo e Esmel,
por sempre me impulsionarem
com incentivos e amor.

AGRADECIMENTOS

Agradeço a todos que, diretamente e indiretamente, contribuíram para a minha formação propedêutica, técnica, na graduação e na pós-graduação.

Sei que seria de uma faculdade sobre-humana citar todos os nomes que deveriam encontrar-se nessas linhas, porém menciono o nome de minha esposa, Aratuza Rodrigues Rocha, que foi a pessoa que me fortaleceu e fortalece em tempos adversos, sendo minha adjuntora com todos os significados que tal palavra carrega.

Agradeço ao Prof. Otacílio da Mota Almeida pelo empenho e dedicação com que me orientou no desenvolvimento desse trabalho.

De certo que este projeto não teria o êxito esperado se não tivesse a massiva e valiosa participação do Prof. Márcio André Baima Amora e dos alunos Francisco Aldinei Pereira Aragão, Oliver Castro e Silva Nottingham e Paulo Roberto Oliveira Braga.

Agradeço à ENDESA, nas pessoas dos engenheiros Paulo Maisonnave e Rodrigo Vítor, pela coordenação e acompanhamento do projeto de P&D, contribuindo para a evolução da pesquisa através de seus conhecimentos técnicos e disponibilidade.

Obviamente, também quero mencionar minha atitude de gratidão para com o Deus de toda Sabedoria que tem me ensinado o equilíbrio com relação à razão e à fé. A Ele toda a honra e toda a Glória para todo o sempre.

RESUMO

Barbosa, F. R. **Monitoramento on-line e diagnóstico inteligente da qualidade dielétrica do isolamento líquido de transformadores de potência**. 2007. 210 f. Dissertação (Mestrado em Engenharia Elétrica)–Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2007.

O monitoramento e diagnóstico de falhas incipientes em transformadores de potência imersos em óleo estão diretamente relacionados à avaliação das condições do sistema de isolamento. Neste estudo, estabelece-se o conceito de monitoramento e diagnóstico, e em seguida técnicas de monitoramento *on-line* são discutidas. Um sistema de pré-diagnóstico é elaborado baseado na utilização de um dispositivo *on-line* de monitoramento classificar a gravidade da situação de falha detectada. Uma vez detectada uma situação de falha, módulos inteligentes de diagnóstico de falhas incipientes, via redes neurais e lógica *fuzzy*, podem ser utilizados para identificação da falha interna do equipamento. Para completar a verificação da qualidade dielétrica do líquido isolante, também é descrito um algoritmo inteligente, baseado em redes neurais, para diagnóstico do estado do óleo através das grandezas físico-químicas. A relação entre os atributos físico-químicos e as grandezas cromatográficas referente ao óleo mineral também foram averiguadas. Foi desenvolvida, então, a estimação dos gases dissolvidos através das características físico-químicas. Os módulos de monitoramento *on-line*, diagnósticos do estado do óleo e de falhas incipientes, além da estimação dos gases dissolvidos, perfazem um sistema computacional de auxílio à operação e manutenção.

Palavras-chave – Transformador de potência; Monitoramento e diagnóstico; Análise de gás dissolvido; Atributos físico-químicos; Rede neural; Sistema *fuzzy*.

ABSTRACT

BARBOSA, F. R. **Dielectric Quality On-line monitoring and intelligent diagnosis of liquid isolation of power transformers.** 2007. 210 f. Dissertation (Master in Electrical Engineering)–Technological Center, Federal University of Ceará, Fortaleza, Brazil, 2007.

O monitoramento e diagnóstico de falhas incipientes em transformadores de potência imersos em óleo estão diretamente relacionados à avaliação das condições do sistema de isolamento. Neste estudo, estabelece-se o conceito de monitoramento e diagnóstico, e em seguida técnicas de monitoramento *on-line* são discutidas. Um sistema de pré-diagnóstico é elaborado baseado na utilização de um dispositivo *on-line* de monitoramento classificar a gravidade da situação de falha detectada. Uma vez detectada uma situação de falha, módulos inteligentes de diagnóstico de falhas incipientes, via redes neurais e lógica *fuzzy*, podem ser utilizados para identificação da falha interna do equipamento. Para completar a verificação da qualidade dielétrica do líquido isolante, também é descrito um algoritmo inteligente, baseado em redes neurais, para diagnóstico do estado do óleo através das grandezas físico-químicas. A relação entre os atributos físico-químicos e as grandezas cromatográficas referente ao óleo mineral também foram averiguadas. Foi desenvolvida, então, a estimação dos gases dissolvidos através das características físico-químicas. Os módulos de monitoramento *on-line*, diagnósticos do estado do óleo e de falhas incipientes, além da estimação dos gases dissolvidos, perfazem um sistema computacional de auxílio à operação e manutenção.

Keywords – Power transformer; Fault diagnosis; Dissolved gas-in-oil analysis (DGA); Fuzzy System; Neural Networks.

LISTA DE FIGURAS

<i>Figura 2.1 - Formação dos gases em função da temperatura de decomposição</i>	24
<i>Figura 2.2 - Decomposição gasosa para a falha de sobreaquecimento no óleo</i>	36
<i>Figura 2.3 - Decomposição gasosa para a falha de sobreaquecimento na celulose</i>	36
<i>Figura 2.4 - Decomposição gasosa para a falha de descargas parciais (corona)</i>	37
<i>Figura 2.5 - Decomposição gasosa para a falha de descargas de alta energia (arco)</i>	37
<i>Figura 2.6 - Fluxograma de aplicação do método de Dörnenburg</i>	39
<i>Figura 2.7 - Interpretação gráfica do método de Dörnenburg</i>	39
<i>Figura 2.8 - Fluxograma de aplicação do método de Rogers</i>	41
<i>Figura 2.9 - Representação gráfica do método de Duval</i>	42
<i>Figura 2.10 - Representação gráfica do método de Rogers revisado pelo IEEE/IEC</i>	45
<i>Figura 3.1 - Distribuição das possíveis fontes de falhas em transformadores de potência</i>	51
<i>Figura 3.2 - Grau de importância dos parâmetros monitorados em um transformador de potência novo</i>	52
<i>Figura 3.3 - Grau de importância dos parâmetros monitorados em um transformador de potência em condição de sobrecarga</i>	52
<i>Figura 3.4 - Grau de importância dos parâmetros monitorados em um transformador de potência antigo</i>	53
<i>Figura 3.5 - Aparelhagem para extração de gases</i>	55
<i>Figura 3.6 - Cromatograma – Gráfico de análise cromatográfica</i>	56
<i>Figura 3.7 - Representação esquemática de um sistema de análise cromatográfica</i>	57
<i>Figura 3.8 - Comparação entre cromatogramas da amostra e de uma solução padrão</i>	59
<i>Figura 3.9 - Sensor óptico de ultra-som para medida de descargas parciais</i>	56
<i>Figura 3.10 - Centurion®</i>	57
<i>Figura 3.11 - GMM®</i>	58
<i>Figura 3.12 - Calisto®</i>	58
<i>Figura 3.14 - Sistema de circulação do Calisto®</i>	62

<i>Figura 3.15 - Hydran®</i>	62
<i>Figura 3.16 - True Gas®</i>	68
<i>Figura 3.17 - N-TCG-6C®</i>	74
<i>Figura 3.18 - PGA-200®</i>	84
<i>Figura 3.19 – Transfix®</i>	85
<i>Figura 3.20 – Big Dipper®</i>	87
<i>Figura 5.4 – Funções de pertinência dos conjuntos nebulosos para NGF</i>	89
<i>Figura 5.5 – Funções de pertinência dos conjuntos nebulosos para TGF</i>	90
<i>Figura 5.6 – Funções de pertinência dos conjuntos nebulosos para a saída</i>	91
<i>Figura 5.7 – Interface IHM do sistema de Diagnóstico de Falhas Incipientes</i>	95
<i>Figura 5.8 – Saída gráfica da Interface IHM do sistema de diagnóstico apresentando a evolução da concentração de H₂</i>	96

LISTA DE QUADROS

<i>Quadro 2.1 – Razões entre as concentrações dos gases</i>	34
<i>Quadro 2.2 – Faixas das razões definidas no método de Dörnenburg</i>	37
<i>Quadro 2.3 – Tabela de diagnóstico do método original de Rogers</i>	39
<i>Quadro 2.4 – Códigos do IEEE, IEC e ABNT para o método de Rogers revisado</i>	41
<i>Quadro 2.5 – Método de interpretação de Rogers revisado</i>	41
<i>Quadro 3.1 – Conjunto de regras para o sistema nebuloso 1</i>	53
<i>Quadro 3.2 – Conjunto de regras para o sistema nebuloso 2</i>	54
<i>Quadra 3.3 – Conjunto de regras para o sistema nebuloso 3</i>	55
<i>Quadra 5.1 - Base de regras do sistema nebuloso de decisão</i>	91

LISTA DE TABELAS

<i>Tabela 2.1 – Valores limites das concentrações dos gases para condição de normalidade</i> ..	37
<i>Tabela 4.1 – Classificação dos dados utilizados no treinamento quanto ao tipo de falha</i>	80
<i>Tabela 4.2 – Percentual médio de acerto das redes neurais</i>	80
<i>Tabela 5.1 – Percentuais dos gases em função da falhas (método do gás chave)</i>	89
<i>Tabela 5.2 – Dados da análise cromatográfica do transformador - caso 1</i>	92
<i>Tabela 5.3 – Dados da análise cromatográfica do transformador - caso 2</i>	93
<i>Tabela 5.4 – Ponderação realizada pelo módulo de decisão - caso 2</i>	93
<i>Tabela 5.5 – Dados da análise cromatográfica do transformador - caso 3</i>	94

LISTA DE ABREVIATURAS E SIGLAS

- ABNT: Associação Brasileira de Normas Técnicas
IEC: International Electrotechnical Commission
IEEE: Institute of Electrical and Electronics Engineers
DGA: Dissolved Gas-in Oil Analysis
RNA: Redes Neurais Artificiais
MLP: Multi-Layer Perceptron
RBF: Radial Basis Funtions
L1: Norma para determinação do nível crítico de normalidade
H₂: Hidrogênio
O₂: Oxigênio
N₂: Nitrogênio
CH₄: Metano
C₂H₆: Etano
C₂H₄: Etileno
C₂H₂: Acetileno
R1: Razão CH₄/H₂
R2: Razão C₂H₂/C₂H₄
R3: Razão C₂H₂/CH₄
R4: Razão C₂H₆/C₂H₂
R5: Razão C₂H₄/C₂H₆

DP: Descargas Parciais
FT: Falha Térmica
DADE: Descargas de Alta Densidade de Energia
NGG: Nível do Gás Gerado
PPM: Partes Por Milhão
NGF: Nível do Gás Final
TG: Taxa de Geração
TGF: Taxa de Geração Final

LISTA DE SÍMBOLOS

T_f	→	Temperatura do ponto quente produzido por uma falha
$h(\circ)$	→	Função de vizinhança
σ	→	Desvio padrão de um conjunto qualquer de dados
σ_j	→	Desvio padrão dos componentes do j-ésimo vetor
\mathcal{R}	→	Conjunto dos números reais
$\mu(\circ)$	→	Função de pertinência
T	→	Função do tipo T-norma
S	→	Função do tipo S-norma
X_j^i	→	Conjunto nebuloso da j-ésima entrada relacionado à i-ésima regra
ψ_i	→	Valor verdade da i-ésima regra
z	→	Centro de gravidade ou centróide
b	→	Polarização de um neurônio
ω	→	Pesos sinápticos de um neurônio
η	→	Taxa de aprendizagem
δ	→	Gradiente local de um neurônio
α	→	Coefficiente de momento
$\Phi(\circ)$	→	Função de ativação de um neurônio
$\Phi'(\circ)$	→	Derivada da função de ativação de um neurônio
$G(\circ)$	→	Função de ativação do tipo gaussiana
x_j^{norm}	→	Valor normalizado do j-ésimo vetor

- \bar{x}_j → Valor médio dos componentes do j-ésimo vetor
- x_j^{\min} → Valor mínimo dos componentes do j-ésimo vetor
- x_j^{\max} → Valor máximo dos componentes do j-ésimo vetor
- $N_{total}^{padrões}$ → Número total de padrões de saída
- $N_{errado}^{padrões}$ → Número de padrões de saída erroneamente classificados
- $\|V_1 - V_2\|$ → Distância Euclidiana entre os vetores V_1 e V_2

Capítulo 1

INTRODUÇÃO

Durante estes comentários introdutórios, a problemática envolvendo o mote do estudo será desenvolvida. A seção 1.1 discorre sobre a importância do monitoramento e análise das condições dielétricas e das situações de falas incipientes em transformadores de potência. Na seção 1.2 é explanada a metodologia utilizada na abordagem dos assuntos correlatos, bem como as motivações que levaram ao estudo em questão. O formato de apresentação da dissertação é mencionado na seção 1.3.

1.1 A IMPORTÂNCIA DO MONITORAMENTO E DIAGNÓSTICO DE TRANSFORMADORES DE POTÊNCIA

Sistemas para diagnóstico e monitoramento de equipamentos do sistema elétrico de distribuição e transmissão sem a necessidade de desligamentos (*on-site*) tem sido proposto em níveis de pesquisas com implementações práticas finais por agentes do setor elétrico, como fabricantes, transmissoras e distribuidoras (BENGTSON, 1996; KOVACEVIC; DOMINELLI, 2003). Neste contexto, as universidades e centro de pesquisas têm desenvolvido papéis importantes, principalmente em nível de pesquisa. Isto vem ocorrendo não somente no Brasil como também na maioria dos países desenvolvidos e em desenvolvimento (BENGTSON, 1996; KOVACEVIC; DOMINELLI, 2003; TENBOHLEN; FIGEL, 2000; LAZAREVICH, 2003; FREITAS, 2000). No Brasil, mais especificamente, o interesse por esta área tem sido acelerado nos últimos anos devido a mudanças estruturais no setor de energia elétrica que promovem a competição em todos os níveis, estabelecem índices mais rigorosos de qualidade técnica e de serviço (geralmente regulados por uma empresa reguladora). Um outro ponto a considerar relaciona-se às razões técnicas associadas ao envelhecimento natural de grande parte dos equipamentos instalados que devem, neste novo contexto, incrementar o desempenho e confiabilidade em condições inferiores à época de suas instalações (FREITAS, 2000; CAVALEIRO *et al.*, 2003; FERREIRA *et al.*, 1999).

Transformadores de potência de grande porte são equipamentos essenciais técnica e economicamente uma planta elétrica de transmissão e distribuição. Desta forma um grande esforço vem sendo empregado para garantir seu bom funcionamento no que concerne a evitar possíveis falhas que venham a ocorrer devido ao seu ciclo natural de vida ou regimes elétricos a que são submetidos. Atualmente encontram-se disponíveis ou está em desenvolvimento um considerável número de ferramentas para o monitoramento e diagnóstico das condições dos transformadores de potência imersos em óleo (BENGTSON, 1996; KOVACEVIC; DOMINELLI, 2003; TENBOHLEN; FIGEL, 2000; ZYLKA *et al.*, 2002; VARL, 2002; SAHA, 2003).

Os sistemas de monitoramento e diagnóstico de transformadores possuem, geralmente duas funções que, embora distintas por definição, evoluem e são utilizadas em conjunto. O monitoramento tem por fim a aquisição de um conjunto de dados relativos ao funcionamento do transformador e cuja coleta envolve modernas tecnologias em sensores, técnicas de aquisição de dados e dispositivos digitais ou analógicos utilizados. O diagnóstico, por sua vez, está mais relacionado à interpretação dos dados e pode ser realizado por um especialista ou por um software especialmente desenvolvido para este fim (KOVACEVIC; DOMINELLI, 2003). Atualmente observa-se a tendência da substituição do diagnóstico feito por um especialista por sistemas automáticos de diagnóstico que incorporam uma forte parcela de técnicas inteligentes para representar entre outros conhecimentos, aquele acumulado com a experiência de um especialista (FREITAS, 2000; HAYKIN, 2000; CHEN, 1996).

Nesse contexto, surge a necessidade de monitoramento e diagnóstico de falhas incipientes em transformadores de potência, através da análise dos gases dissolvidos no óleo do transformador (WANG, 2000; LIMA, 2004; MIRANDA; CASTRO, 2005; DURAISAMY *et al.*, 2007). Também, como verificação da qualidade dielétrica do líquido isolante, algoritmos inteligentes, baseado em redes neurais, são projetados para o diagnóstico do estado do óleo através das grandezas físico-químicas (WAHAB, 1999; MOKHNACHE; BOUBAKEUR, 2002; PARASKEVAS *et al.*, 2006). A relação entre os atributos físico-químicos e as grandezas cromatográficas referente ao óleo mineral também foram averiguadas (IMAMURA *et al.*, 2000).

Neste estudo, os módulos de monitoramento *on-line*, em conjunto com os algoritmos de diagnóstico e com a estimação foram projetados de modo a performarem uma estratégia integrada para promover o diagnóstico da qualidade dielétrica do isolante líquido do transformador. Os resultados apontam para o sucesso no que tange a implementação e utilização desses métodos em um programa de computador desenvolvido com o objetivo de promover a salvaguarda de um transformador monitorado (SHENK *et al.*, 2002).

1.2 METODOLOGIA

A evolução desse estudo permeia, em primeira instância, a revisão de diversos trabalhos e normas para interpretação e compreensão das informações provenientes das análises cromatográficas e os ensaios físico-químicos de óleos minerais. Em um segundo nível, são levadas em consideração as técnicas e os instrumentos para monitoramento *on-line* de transformadores e as melhores opções em termos de um compromisso técnico-econômico. Também é averiguada a aplicação dos métodos inteligentes no que tange ao desenvolvimento de um meio otimizado de obter diagnóstico confiável do transformador. Todos os resultados devem ser devidamente avaliados pra que haja a determinação dos métodos de melhor *performance*. Em uma fase adiante, os métodos de melhor desempenho são reunidos debaixo de uma plataforma computacional que gerencia o uso dos algoritmos de monitoramento, detecção e identificação das condições de falha, determinando, em tempo hábil, as recomendações cabíveis.

1.3 DISPOSIÇÃO GERAL DO DOCUMENTO

Esta dissertação possui oito capítulos. Este primeiro capítulo é composto da exposição dos conceitos introdutórios para uma melhor compreensão da problemática. No capítulo 2, o assunto discutido é a caracterização e análise do óleo isolante de transformadores. Este capítulo também menciona métodos de diagnóstico de falhas incipientes e análises físico-químicas, além de formas de quantificação da evolução de condições de falha nestes equipamentos. O capítulo 3 expõe o conceito de monitoramento *on-line* das condições do óleo isolante abrangendo desde a distribuição de falhas no transformador até os vários dispositivos e métodos de monitoramento disponíveis. Uma experiência de aplicação

de um dos monitores é descrita. O diagnóstico de falhas incipientes é desenvolvido no capítulo 4. Inicialmente, é apresentada a modelagem neural em todo o seu detalhamento e imediatamente após, a modelagem nebulosa é descrita detalhando a metodologia desta ferramenta. Porém, para uma melhor desenvoltura do texto, os detalhamentos básicos inerentes aos conceitos sobre redes neurais e sistemas *fuzzy* são colocados, respectivamente, nos apêndices A e B. Os resultados das estratégias inteligentes desenvolvidas são discutidos ao fim deste capítulo. O capítulo 5 aborda a importância dos atributos físico-químicos na definição das características dielétricas do óleo isolante e um algoritmo inteligente para efetuar o diagnóstico é desenvolvido, aplicado e seus resultados discutidos. O estudo da relação entre as grandezas físico-químicas e as cromatográficas é aprofundado no capítulo 6. Um método de busca exaustiva é utilizado para determinação das grandezas mais influentes e uma estratégia para estimação dos gases dissolvidos através dos resultados dos ensaios físico-químicos é desenvolvida. O capítulo 7 trata do projeto de um sistema computacional que comporta os módulos de monitoramento e diagnóstico, objetivando alcançar melhorias nos conceitos de operação e manutenção de transformadores de grande porte. O resultado final da composição do sistema é discutido. No capítulo 8 são levantados os comentários conclusivos e lançados os desenvolvimentos futuros.

Capítulo 2

ANÁLISE DO ÓLEO MINERAL ISOLANTE

Os possíveis problemas em um equipamento elétricos têm influências nos resultados das maiores dos testes possíveis neste, de sorte que apenas um conjunto de análises já permite um diagnóstico preciso na maioria das situações de falhas. No caso do transformador, as condições de funcionamento e integridade são refletidas diretamente no óleo isolante.

Os métodos mais estudados de diagnóstico aplicados para identificar falhas incipientes em transformadores de potência são: Avaliação físico-química, que determina o estado do óleo; e análise cromatográfica que verifica possíveis falhas no equipamento. Este dois tipos de análise podem definir procedimentos de operação e manutenção de um equipamento isolado a óleo, pois dão uma clara visão da qualidade do isolamento. Daí, uma análise eficiente e que produza resultados confiáveis merece enfoque.

A caracterização do sistema isolante do transformador e como este pode se degradar está descrita na seção 2.1 desta seção. A seção 2.2 caracteriza as falhas incipientes. O valor da avaliação físico-química é discutido na seção 2.3 Para interpretar os dados das análises cromatográficas devem-se associar os valores atuais das concentrações a uma determinada falha que produziu tal formação de gases. Os métodos convencionais de identificação de falhas através da taxa de geração e razões entre concentrações dos gases estão descritos na seção 2.4. Também é importante comentar formas de quantificar a evolução da formação de gases no interior do transformador. Estes comentários estão situados na seção 2.5 e sustenta o título de Nível de Gás Gerado e Taxa de Geração. Finalmente, as conclusões da seção são apresentadas na seção 2.6.

2.1 ÓLEO MINERAL ISOLANTE, CELULOSE E A FORMAÇÃO DE GASES EM TRANSFORMADORES.

O óleo mineral isolante aparece amplamente usado em equipamentos elétricos assumindo, basicamente, as funções de meio isolante e refrigerante. A primeira função evita o aparecimento e garante a extinção de arcos elétricos. A segunda realiza a refrigeração do equipamento dissipando o calor gerado. Seguem algumas propriedades físicas do óleo mineral (MILASCH, 1984):

- Cor: o óleo novo tem uma cor amarelo-pálida e é transparente. A cor muda e escurece na medida em que o óleo vai se deteriorando.
- Ponto de fulgor: é a menor temperatura na qual se formam vapores inflamáveis na superfície do óleo e são identificados pela formação de um lampejo quando em presença de uma chama.
- Ponto de fluidez: é a temperatura mais baixa na qual o óleo, em condições perfeitamente estabelecidas, escoar.
- Densidade: a densidade do óleo está, normalmente, em torno de 0,9 na temperatura de 15 °C.
- Viscosidade: é a resistência que o óleo oferece ao escoamento contínuo sem turbulência, inércia ou outras forças. A quantidade de calor que o óleo é capaz de transferir, por hora, do transformador para o meio ambiente depende desta propriedade.
- Ponto de anilina: é a temperatura em que há a separação da anilina de uma mistura de anilina e óleo. O ponto de anilina, de certa forma, está relacionado com a propriedade de dissolver materiais com os quais entra em contato e com seu conteúdo aromático.
- Tensão interfacial: na superfície de separação entre o óleo e a água forma-se uma força de atração entre as moléculas dos dois líquidos que é chamada de tensão interfacial, sendo medida em N/m. Uma diminuição da tensão interfacial indica, com bastante antecedência em relação aos outros métodos, o início da deterioração do óleo.

- Solubilidade da água no óleo: a água pode existir no óleo sob a forma dissolvida, não dissolvida (em suspensão) ou livre (depositada). A quantidade de água em solução no óleo depende da temperatura e do grau de refino. Quanto mais alta a temperatura, tanto maior a quantidade de água dissolvida no óleo, e quanto mais bem refinado for o óleo, tanto menor será a solubilidade da água.

Com relação às propriedades elétricas, segue (MILASCH, 1984):

- Rigidez dielétrica: é a tensão alternada na qual ocorre a descarga disruptiva na camada de óleo situada entre dois eletrodos e em condições perfeitamente determinadas. A rigidez dielétrica do óleo é pouco afetada pela água nele dissolvida. Por outro lado, a água livre em suspensão no óleo diminui acentuadamente sua rigidez dielétrica, sendo que em um óleo deteriorado, a água livre tem maior possibilidade de ficar em suspensão que no óleo novo. Outro fator que contribui para a redução da rigidez dielétrica são as partículas sólidas em suspensão (fibras celulósicas, carvão, poeira, etc.).
- Fator de potência: o fator de potência do óleo mineral isolante é igual ao cosseno do ângulo de fase ou o seno do ângulo de perdas do mesmo. Este aumenta de valor na medida em que a deterioração do óleo progride. O fator de potência nos informa uma idéia da quantidade de corrente que flui pelo óleo e que é uma medida de sua contaminação e de sua deterioração.

A composição química do óleo mineral é basicamente uma mistura de hidrocarbonetos em sua maioria, e de não-hidrocarbonetos, também chamados de heterocompostos, em pequena proporção uma vez que é extraído do petróleo. Estima-se em cerca de 2900 o número de compostos existentes no óleo isolante (MILASCH, 1984; SIEROTA, 1998).

A característica relevante do óleo pode ser uma propriedade intrínseca usada no projeto dos transformadores ou pode ser a concentração de um componente específico ou de uma impureza (ROUSE, 1998).

A dinâmica de formação de gases no interior de transformadores de potência imersos em óleo mineral tem sua origem nas solicitações elétricas e térmicas as

quais aqueles são submetidos e pode ser descrita por um modelo termodinâmico. Este modelo expressa a relação entre a taxa de formação dos gases e a temperatura nas proximidades do ponto onde ocorrem as falhas. Logo, tem-se uma associação direta entre uma dada série de concentrações de gases dissolvidos e uma determinada faixa de temperatura e, por consequência, a um determinado tipo de falha no transformador (IEEE, 1991; IEC 599, 1978).

2.1.1 Decomposição do óleo mineral

O óleo mineral isolante é obtido a partir do refino de uma fração dos hidrocarbonetos coletados durante a destilação do petróleo cru e suas características variam conforme sua procedência e tecnologia empregadas. Estes óleos são empregados no isolamento líquido dos transformadores de potência e apresentam decomposição de acordo com o tempo de envelhecimento. Sob a ação de esforços térmicos e elétricos no transformador ocorre a aceleração deste complexo processo de decomposição dos hidrocarbonetos. Como produto deste processo, tem-se a formação de hidrogênio ativo e fragmentos instáveis de hidrocarbonetos ou radicais livres advindos da quebra de algumas ligações químicas do tipo hidrogênio-carbono (H-C) ou carbono-carbono (C-C). Nessas condições de ambiente e pela ação catalítica de metais, como o cobre, são formados hidroperóxidos que são produtos instáveis e podem liberar oxigênio resultando no que se conhece por oxidação do óleo (MILASCH, 1984). Posteriormente são formados ácidos e outros produtos polares que são quimicamente ativos. Nesta fase existe um aumento de acidez e do fator de dissipação do óleo. Ocorre um aumento da tensão interfacial e um aumento da capacidade de dissolução de água. Um eventual aumento da quantidade de água dissolvida poderá ter influência na rigidez dielétrica. Em um momento de temperatura mais elevada, esses radicais livres podem se combinar para formar gases, hidrogênio molecular, metano, etano e até mesmo podem se recombinar para a formação de novas moléculas estáveis. Alguns agentes de degradação do óleo podem ter seus efeitos acentuados com a aplicação de um campo elétrico (ZIRBES, 2005)

Essas reações ocorrem sob um caráter estequiométrico, sendo completamente imprecisas as informações quanto aos compostos presentes no processo e as condições de energia do ambiente da reação. Portanto, torna-se impraticável o uso

da teoria cinética das reações químicas para uma previsão razoável da decomposição de tais hidrocarbonetos. Admitindo-se que todos os hidrocarbonetos do óleo são decompostos nos mesmos produtos e que estes estão em equilíbrio entre si. Fazendo-se uso, também, de constantes de equilíbrio conhecidas das reações de decomposição relevantes e considerando a aproximação de que a reação ocorre em um equilíbrio térmico de temperatura constante tem-se o modelo termodinâmico proposto por Halstead (1973) que permite calcular a pressão parcial de cada gás em função da temperatura, conforme figura 2.1. O modelo assim definido permite o cálculo da taxa de geração de cada gás a qualquer temperatura, levando a uma associação entre uma dada distribuição de concentração de gases e uma determinada falha característica em termos de temperatura e duração da falha. Devido as condições idealizadas, este modelo apresenta algumas limitações, sendo impossível identificar claramente a característica de formação dos gases quando duas ou mais falhas ocorrem simultaneamente no interior de um transformador (IEEE, 1991).

Os principais gases formados a partir da decomposição do óleo mineral de transformadores submetidos à falhas incipientes são:

- i)* Combustíveis: hidrogênio (H_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4), acetileno (C_2H_2), monóxido de carbono (CO);
- ii)* Não-combustíveis: dióxido de carbono (CO_2).

Outros gases não-combustíveis tais como oxigênio (O_2) e nitrogênio (N_2) ou hidrocarbonetos com C_3 e C_4 também podem encontrar-se dissolvidos no óleo, no entanto, por não serem produtos relevantes da deterioração do óleo, um diagnóstico satisfatório pode ser estabelecido sem levá-los em consideração (ABNT 1982; MILASCH, 1984).

A figura 2.1 apresenta graficamente a relação entre os gases gerados e a temperatura nas proximidades de uma falha.

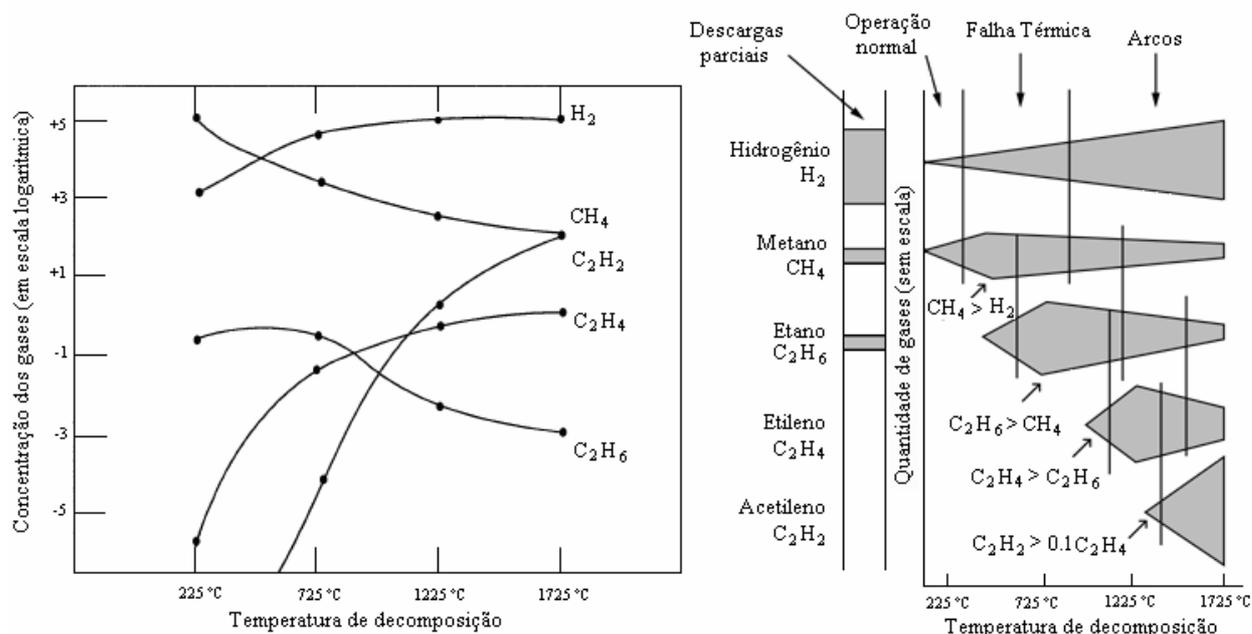


Figura 2.1 – Formação dos gases em função da temperatura de decomposição. a) pressão x temperatura. b) concentração dos gases x temperatura

Através de uma simples observação pode-se constatar que, para baixas temperaturas, a quantidade de hidrogênio gerado é relativamente grande, porém menor que o metano, ambos com baixo peso molecular. Um aumento de temperatura pode fazer com a produção de hidrogênio ultrapasse a geração de metano modificando a relação entre os gases. Assim, esta relação se torna importante para a discriminação entre falhas de baixa intensidade térmica. Também, a análise revela que a formação de acetileno torna-se apreciável somente quando a falha leva a produção de pontos quentes de temperatura muito elevada (>1000 °C), portanto a presença de acetileno é, em geral, associada à falhas de descargas de alta energia (arcos elétricos). Estes exemplos ilustram satisfatoriamente o uso do gráfico acima.

2.1.2 Decomposição da celulose

O isolamento de papel impregnado é formado por papel celulósico e óleo isolante e cada um deles possui seu processo natural de degradação de acordo com seu

envelhecimento. No entanto, este processo de degradação pode ser modificado e até acelerado pela interação dos componentes deste dispositivo de isolamento.

Os principais materiais celulósicos empregados na isolação de transformadores são: 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 (MILASCH, 1984).

As propriedades elétricas mais importantes deste tipo de material isolante são a constante dielétrica, o fator de dissipação e rigidez dielétrica (KHALIFA, 1990). Esta última mantém o isolamento entre alta e baixa 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 isolação com tensões elevadas permite a avaliação da extensão das descargas parciais na isolação (MILASCHI, 1984; MORAIS, 2004).

Em termos da decomposição térmica da isolação celulósica, há produção de óxidos de carbono (CO e CO_2) e algumas moléculas de hidrogênio (H_2) e metano (CH_4) devido ao óleo mineral impregnado. A relação existente entre a taxa de produção dos gases é exponencial em relação à temperatura e proporcional ao volume do material que se encontra nesta. Assim, é possível que um grande volume aquecido a uma temperatura moderada tenha o mesmo efeito de um pequeno volume a alta temperatura. Do exposto, o volume de óleo de um transformador aparece como um parâmetro importante para se determinar os limiares de produção normal de gases no interior de transformadores (IEEE, 1991).

A degradação da celulose é também fonte de oxigênio, portanto, auxilia o processo de oxidação do óleo (MILASCH, 1984). A oxidação dos óleos minerais afeta largamente as propriedades físico-químicas agravando o desempenho do mesmo e conseqüentemente do equipamento em serviço. Os principais produtos da oxidação

dos óleos minerais isolantes são polares e podem formar gomas, isto é, borras, que diminuem a transferência de calor, causando entupimentos e formação de depósitos sólidos. Estes aspectos apontam para a necessidade de interromper ou retardar a oxidação do óleo em uso para aumentar sua vida útil e seu desempenho, reduzindo assim o custo de manutenção do equipamento (MELO, 2005).

Diante do exposto, é verídica a afirmação de que há um grande interesse de pesquisadores no enorme leque de temas que envolva desenvolvimento e aperfeiçoamento de técnicas para diagnóstico de envelhecimento da isolação de transformadores, identificação dos produtos de degradação e a identificação antecipada da ocorrência de falhas. Como prova disto, um pequeno sumário das técnicas, seus níveis de desenvolvimento, campo de aplicação e a utilização de cada uma delas no âmbito da engenharia são demonstrados na tabela 2.1 (VAN BOLHUIS, GULSKI *et al.*, 2002).

Tabela 2.1 - Principais técnicas utilizadas na estimativa do envelhecimento e degradação do sistema isolante de transformadores.

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 furfúricos em transformadores.	Concessionárias e laboratórios.	Sim
Medição da tensão de estabelecimento (RVM)	Quantidade de água e envelhecimento do papel isolante.	Sob pesquisa.	Algumas concessionárias e laboratórios.	Não
Tângente delta	Perdas dielétricas no sistema isolante.	Conhecida. Instrumentos portáteis têm sido desenvolvidos para este fim.	Algumas concessionárias e fabricantes de transformadores, como controle de qualidade.	Tângente 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.	Conhecida.	Principalmente concessionárias. Pode ser usada <i>off-line</i> em testes periódicos.	Não
Tângente 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

2.2 FALHAS INCIPIENTES EM TRANSFORMADORES DE POTÊNCIA

Os isolamentos sofrem redução de sua capacidade ao longo do tempo, mesmo quando submetidos às condições normais de projeto. Quando submetido a condições mais severas, 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. A recuperação de um isolamento nestas condições nem sempre é possível e os custos envolvidos são geralmente elevados. Os processos que atuam no sentido de acelerar a redução de capacidade do isolamento, quando em sua fase bem inicial, são denominados de falhas incipientes. Estas falhas são normalmente recuperáveis com um custo reduzido (ZIRBES, 2005).

As falhas incipientes podem ser classificadas em termos dos esforços térmicos, onde sobreaquecimentos são atores principais, e elétricos, relacionados à descargas internas no equipamento.

2.2.1 Falhas térmicas

Quando submetidos a temperaturas 150 °C e 500 °C, reconhecidamente tidas como baixas temperaturas, os óleos minerais utilizados para isolamento sofrem decomposição em relativamente grandes quantidades de gases molecularmente leves, tais como hidrogênio (H₂) e metano (CH₄) e apenas traços de gases molecularmente pesados, tais como etileno (C₂H₄) e etano (C₂H₆). À medida que a temperatura se eleva na vizinhança da falha ocorre o aumento da produção de gases molecularmente mais pesados. Inicialmente, a taxa de produção de etano se eleva mais rapidamente seguida pelo etileno. Entretanto, quando uma falha promove o aumento substancial da temperatura se manifesta a produção de acetileno (C₂H₂). Daí, a presença deste gás indicar para especialistas uma condição extrema dentro do equipamento, considerada como o maior nível de alarme em se tratando de falhas incipientes.

Como explicitado anteriormente, a decomposição térmica da celulose e outros isolamentos sólidos produzem óxidos de carbono (CO e CO₂) em quantidades relevantes já em temperaturas muito baixas. Portanto, a relação entre monóxido (CO) e dióxido de carbono (CO₂) carrega em si a importância de indicar a decomposição térmica da celulose em termos quantitativos. Sendo assim, o IEEE Std. C57.104-1991 utiliza-se da razão CO₂/CO e estabelece que sete (7,0) é um valor típico para a ela. De forma mais geral, uma razão CO₂/CO na faixa de 3,0 a 10,0 é considerada normal. Também, de modo semelhante, a norma IEC 599 propõe a avaliação da degradação da celulose através do monitoramento dos óxidos de carbono, no entanto, utiliza a razão CO/CO₂, sendo definida uma faixa de valores (0,07 < CO/CO₂ < 0,30) para esta razão quando sob condição normal de envelhecimento.

Em uma situação da celulose sob temperatura extremamente alta, como sob arcos elétricos, a razão CO/CO₂ aproxima-se de 1:1, pois a geração de monóxido de carbono (CO) aumenta muito rapidamente em comparação à produção de dióxido de

carbono (CO₂). Porém, em uma situação de leve sobrecarga ou problemas de ventilação, onde ocorre leve sobreaquecimento, o CO₂ cresce muito mais rapidamente que o CO, portanto a taxa de CO/CO₂ fica na faixa de 1:20 a 1:10.

2.2.2 Falhas elétricas

Quando há a ocorrência de descargas de baixa intensidade de energia, como descargas parciais ou arcos intermitentes de baixa intensidade ou descargas de alta intensidade de energia, como arcos elétricos é bastante provável decomposição do óleo devido à temperatura que pode ser atingida por estas falhas. Na persistência da falha ou na maior duração da mesma a temperatura do óleo pode se elevar acima de 1500°C.

Para descargas elétricas de baixa intensidade de energia, tais como, as descargas parciais ou corona e arcos intermitentes de baixa energia, a produção de hidrogênio apresenta-se elevada, com pequena quantidade de metano e apenas possíveis traços de acetileno. À medida que a intensidade de energia das descargas aumenta, e, conseqüentemente, aumenta a temperatura na vizinhança da falha, ocorre uma significativa aceleração da produção de etileno e acetileno. Quando a quantidade de gases dissolvidos é elevada e ocorrer uma alteração na temperatura que modifique o valor da solubilidade de saturação, os gases antes dissolvidos podem ser liberados na forma de bolhas. A existência de bolhas de gases não dissolvidos altera a condição de rigidez dielétrica, levando a uma ruptura do isolamento. As descargas podem se processar nessas bolhas gasosas envolvidas pelo óleo ou por partes impregnadas de óleo. A causa principal da decomposição é o bombardeamento iônico das moléculas de óleo.

No caso da intensidade das descargas elétricas atingirem valores de alta energia, ou seja, a formação de descargas contínuas, como arcos elétricos, a produção de acetileno torna-se relevante uma vez que a temperatura se eleva entre 800 e 2800°C. Possíveis causas de formação destes pontos quentes são: centelhamentos promovidos por más conexões ou interrupção de correntes no comutador; descargas de contorno ou arcos de potência decorrentes da ruptura dielétrica do óleo entre os enrolamentos, entre espiras ou entre espiras e massa (LIMA, 2005).

2.3 ANÁLISE FÍSICO-QUÍMICA DO ÓLEO ISOLANTE

Como já citado, o óleo mineral isolante é obtido a partir de petróleo e este pode ser classificado em naftênico ou parafínico, sendo designado tipo A o primeiro e tipo B o último (NBR 5356, 1993).

Tendo em vista a presença de um elevado número de componentes em diferentes quantidades em sua composição, a caracterização de um óleo mineral para a 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 composição e por apresentarem reflexos em sua utilização. Assim, o estabelecimento de limites para esses parâmetros tem como objetivo alcançar uma uniformidade de comportamento como isolante e referências de qualidade para sua utilização (ZIRBES, 2005).

A análise das características físico-químicas, um indicativo importante da boa adequação do óleo isolante, bem como seus valores limites, procedimentos e metodologias para medição são padronizados por entidades tais como ABNT, IEC e ASTM. Através destes determinados ensaios pode-se acompanhar a evolução de algumas características e determinar se o óleo isolante continua adequado para o uso ou não. Pois estes componentes sofrem mudanças ao longo do tempo de operação do transformador, modificando assim a capacidade de transferir calor e a própria estabilidade do óleo, que é sempre submetido aos campos elétricos advindos da operação do equipamento. Tais modificações podem elevar o valor de temperatura e o surgimento de água no óleo.

As características mais utilizadas como determinante da boa adequação do óleo isolante, em termos da sua capacidade de isolação e refrigeração, são: aparência, densidade máxima, viscosidade, ponto de fluidez, ponto de fulgor, índice de neutralização, tensão interfacial, cor, teor de água, rigidez dielétrica, fator de potência, dentre outros. Vale salientar que valores fora dos limites pré-estabelecidos indicam necessidade de tratamento termo-vácuo, substituição ou regeneração do óleo mineral. A tabela 2.2 demonstra alguns valores padrões estabelecidos para o óleo tipo A, a título de exemplo conforme NBR 5356 (1993).

Tabela 2.2 - Especificação para o óleo mineral isolante Tipo "A"

CARACTERÍSTICAS	UNIDADES	VALORES		MÉTODOS
		MÍN	MÁX	
APARÊNCIA	-	O óleo deve ser claro, limpo e isento de material em suspensão		VISUAL
CLORETOS	-	AUSENTE		NBR-5779
COR	-	-	1,0	ABNT-MB-351
DENSIDADE A 20/4° C	-	0,861	0,900	NBR-7148
ENXOFRE CORROVISO	-	NÃO CORROSIVO		ABNT-899
ESTABILIDADE À OXIDAÇÃO				NBR-10504
- ÍNDICE DE NEUTRAL. (IAT)	mg KOH/g	-	0,40	
- BORRA	% massa	-	0,10	
- FATOR DE PERDAS DIELETR. A 90° C	%	-	20	
FATOR DE PERDAS DIELETRICAS	%			NBR-12133
A 25° C		-	0,05	
A 90° C		-	0,40	
A 100° C		-	0,50	
ÍNDICE DE NEUTRAL. (IAT)	mg KOH/g	-	0,03	ABNT-MB-101
PONTO DE ANILINA	°C	63	84	ABNT-MB-299
PONTO DE FLUIDEZ	°C	-	39	ABNT-MB-820
PONTO DE FULGOR	°C	140	-	ABNT-MB-50
RIGIDEZ DIELETRICA	KV			NBR-6869
- ELETRODO DE DISCO		30	-	NBR-10859
- ELETRODO VDE		42	-	
RIGIDEZ DIELETRICA A IMPULSO (ELETRODOS AGULHA/ESFERA)	KV	145	-	ASTM-D-3300
SULFATOS	-	AUSENTE		NBR-5779
TENDÊNCIA A EVOLUÇÃO DE GASES	µl/min	NEGATIVO		ASTM-D-2300 MÉTODO B
TENSÃO SUPERFICIAL A 25° C	mN/m	40	-	NBR-6234

TEOR DE CARBONO AROMÁTICO	%	ANOTAR	ASTM-D2140
TEOR DE INIBIDOR DE OXIDAÇÃO DBPC/DBP	% massa	- 0,08	NBR-12134
TEOR DE PCB	mg/kg	NÃO DETECTÁVEL	ASTM-D-4059
VISCOSIDADE A 20° C	mm ² /s	- 25,0	ABNT-MB-293
40° C	(cST)	- 11,0	
100° C		- 3,0	
TEOR DE ÁGUA	mg/kg (ppm)	- 35	NBR-10710

Diante do exposto, é de extrema vantagem a utilização das assertivas acima expostas para uma adequada manutenção e uma conseqüente extensão na vida útil do transformador, pois qualquer detecção anormal permite a intervenção planejada no equipamento e evita desligamentos desnecessários atuando como um redutor de perdas econômicas.

2.4 MÉTODOS DE INTERPRETAÇÃO DA ANÁLISE DOS GASES DISSOLVIDOS

Com uma análise dos gases dissolvidos no óleo isolante do transformador remete a uma avaliação profunda da atual realidade do sistema de isolamento do equipamento. Para tanto, vários métodos de análise dos gases dissolvidos (DGA) têm sido desenvolvidos e empregados nos parques elétricos de todo o mundo gerando um ambiente de confiança na metodologia à medida que esta logra êxito com o passar dos anos. Com isso, formou-se um campo de conhecimento acerca de DGA que abrange experiência na aplicação das técnicas mais convencionais por mais de trinta anos, haja vista que todas as suas etapas básicas, envolvendo a coleta das amostras (sem necessidade de desligamento do equipamento) e a análise cromatográfica são amplamente documentadas e até padronizadas por normas internacionais, tais como as normas: NBR 7070 (ABNT, 1981), IEC 599 (IEC, 1978) e IEEE C57.104 (IEEE, 1991). Daí a principal razão do grande sucesso e do interesse para o desenvolvimento de novas técnicas que este tipo de análise tem atraído diante do exigente cenário de manutenção e proteção a que estão submetidos os parques elétricos atuais.

A base das técnicas de DGA é o processo de cromatografia laboratorial a que a amostra do óleo isolante do transformador é submetida. Esta tem por produto uma estratificação das concentrações dos gases dissolvidos no óleo e a partir destes valores quantificadores aplica-se uma técnica de interpretação destes dados. Estes dados podem ser expressos a partir das concentrações individuais de cada gás, através de razões entre as concentrações dos gases ou ainda como porcentagens em relação à concentração total de gases combustíveis.

O processo de falha está intrinsecamente 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, são possíveis 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).

A interpretação de uma análise individual pode não ser muito efetiva, pois, mais de uma falha podem estar ocorrendo ao mesmo tempo ou ainda um tipo de falha pode progredir para outro, tal como ocorre com alguns problemas elétricos que têm origem em problemas térmicos. Portanto, é de fundamental importância estabelecer uma base de dados para servir como valores de referência. De forma tal que, se torna possível determinar a evolução temporal das concentrações dos gases, tomando-se como base os valores históricos. Isso é implementado através de coletas periódicas de amostras de óleo, análise cromatográfica para determinar as concentrações dos gases e formação de um banco de dados com o histórico do transformador (LIMA, 2005).

A questão do intervalo entre as análises reflete a dependência entre as condições de perigo de falha no equipamento. Quanto maior for o indicativo de suspeita de falha no equipamento menor será o período de tempo para uma nova coleta e uma nova

análise para que se possa observar o horizonte de evolução da falha suspeita e se estabelecer as devidas providências a serem tomadas. Entretanto, o conceito de necessidade de monitoramento ganha força como advento de sensores que mantêm uma nova análise da situação interna dos gases dissolvidos em intervalos de até 15 minutos. O início desse monitoramento também pode fazer grande diferença uma vez que o óleo de um transformador novo pode conter teores de gases que indiquem erroneamente uma situação de alarme com relação a falhas incipientes. Diante disso, não seria anormal o conselho de se iniciar o monitoramento ainda na fábrica ou no ato de instalação da nova unidade a fim de se conhecer todas as características inerentes à fabricação e ao bom funcionamento do transformador incluindo seu sistema de isolamento.

A aplicação das técnicas de DGA exige a observação de uma seqüência de ações para a obtenção de um diagnóstico satisfatório e eficiente. Primeiramente, detectar a geração de algum gás que exceda os limites normais aplicando, nesse caso, os critérios apropriados para a identificação da anormalidade a que está submetido o equipamento. Em segundo lugar, avaliar o impacto desta anormalidade na disponibilidade de operação do transformador para, então, recomendar uma ação efetiva que se coadune com o nível de falha confirmada, resguardando a unidade de um desenvolvimento da falha ainda incipiente e de até retiradas de serviço inoportunas (IEEE, 1991).

2.4.1 Métodos Convencionais

As várias técnicas para interpretação da análise cromatográfica, visam diagnosticar a condição atual do sistema de isolamento do transformador. Dentre os métodos mais conhecidos figuram: gás chave (PUGH; WAGNER, 1961, IEEE, 1991), triângulo de Duval (DUVAL, 1989) e os métodos das razões de Dörnenburg (DÖRNENBURG; GERBER, 1967) e Rogers (ROGERS, 1978). Tais métodos encontram-se padronizados nas normas de interpretação das análises cromatográficas: IEEE-Std.C57.104 (IEEE, 1991), IEC-60599 (IEC, 1999) e NBR-7274 (ABNT, 1982).

Os métodos do gás principal e das razões requerem que um nível mínimo das concentrações dos gases, conhecido como norma L1, seja excedido para que

possam ser corretamente aplicados. Os valores da norma L1 são apresentados na tabela 2.3.

Tabela 2.3 - Valores limites das concentrações dos gases para condição de normalidade.

Gás	H₂	CH₄	C₂H₂	C₂H₄	C₂H₆	CO
Norma L1 (ppm)	100	120	35	50	65	350

2.4.1.1 Método do Gás Chave (Key Gas Method)

O método do gás chave faz uso do valor percentual dos gases para diagnosticar falhas incipientes em transformadores. Este método teve sua formulação básica desenvolvida a mais de quatro décadas e se fundamenta nas quantidades relativas de cada gás gerado mediante os esforços térmicos e/ou elétricos a que estão submetidos o transformador (PUGH, 1961; WAGNER, 1961). É importante salientar que a degradação da celulose também pode ser observada através deste método uma vez que o óleo isolante do transformador, seja sozinho, seja impregnado no papel isolante, está em contato, praticamente, com todas as partes do equipamento vulneráveis a defeitos. Sendo assim, perante uma situação de falha, onde é observado um aumento da temperatura na região e uma conseqüente produção de gases, há uma probabilidade elevada de que os gases sejam encontrados dissolvidos neste óleo envolvente no interior do transformador.

De acordo com o exposto, a essência do método direciona a formalizar uma base qualitativa a partir do conhecimento da temperatura onde um gás é predominantemente gerado e correlacionar esta temperatura, e conseqüentemente o gás, a uma determinada falha. Daí o nome do método se chamar gás chave. O gás predominante seria o gás chave ou principal.

Os estudos que formam a base deste método foram desenvolvidos por Pugh e Wagner (1961). Posteriormente, Griffin (1988) realizou uma revisão do método e trabalhou questões relativas a aplicação do método.

As figuras 2.2, 2.3, 2.4 e 2.5 indicam as proporções relativas dos gases principais para quatro tipos gerais de falhas (IEEE, 1991).

Falha Térmica no óleo – Gás Chave: Etileno: O produto principal desta decomposição é o etileno, mas também é gerada uma menor quantidade de metano, hidrogênio e etano. Traços de acetileno podem ser formados se a falha for muito severa, isto é, temperaturas muito elevadas, ou envolver problemas com contatos elétricos.

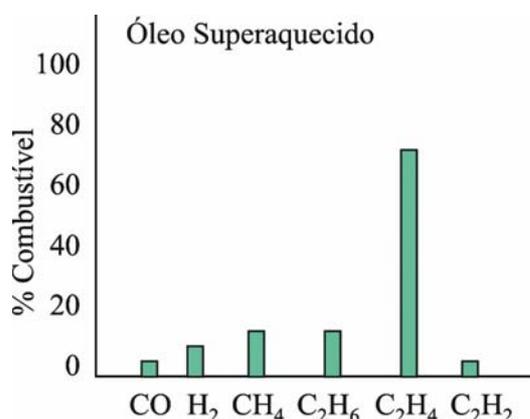


Figura 2.2 – Decomposição gasosa para a falha de sobreaquecimento no óleo.

Falha Térmica na celulose – Gás Chave: Monóxido de Carbono: Grandes quantidades de dióxido e monóxido de carbono são liberados da celulose superaquecida. Hidrocarbonetos gasosos, como metano e etileno, serão formados se a falha envolver uma estrutura impregnada em óleo.

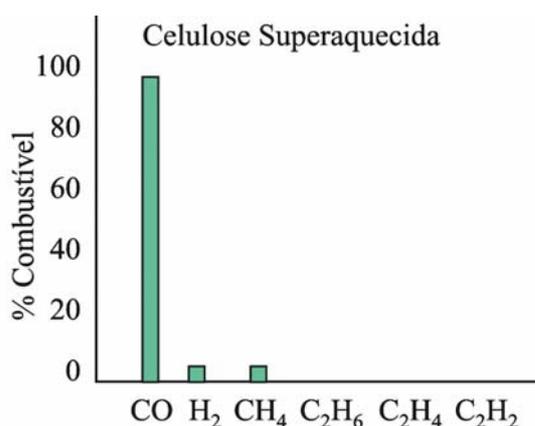


Figura 2.3 – Decomposição gasosa para a falha de sobreaquecimento na celulose.

Falha Elétrica de baixa energia ou Corona – Gás Chave: Hidrogênio: Essas descargas elétricas produzem hidrogênio e metano, com pequenas quantidades de

etano e etileno. Quantidades comparáveis de dióxido e monóxido de carbono também podem ser formadas caso a falha envolva a celulose.

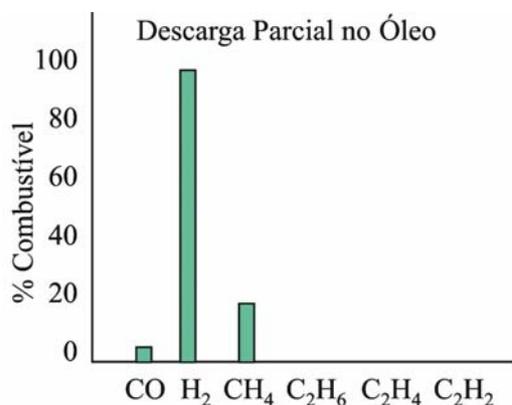


Figura 2.4 – Decomposição gasosa para a falha de descargas parciais (corona).

Falha Elétrica de alta energia ou Arco – Gás Chave: Acetileno: Grandes quantidades de hidrogênio e acetileno são produzidas, com pequenas quantidades de metano e etileno. Dióxido e monóxido de carbono também podem ser formados caso a falha envolva a celulose. O óleo e a celulose poderão ser carbonizados.

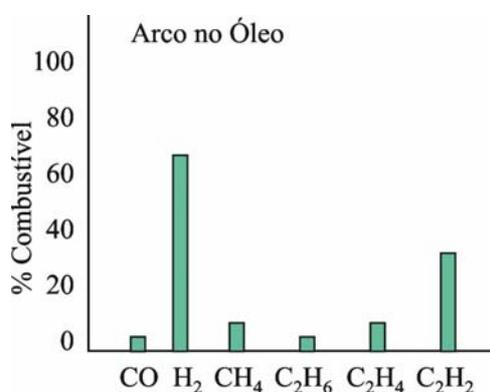


Figura 2.5 – Decomposição gasosa para a falha de descargas de alta energia (arco).

2.4.1.2 Método das razões de Dörnenburg (Dörnenburg Ratio Method)

O uso de razões entre as concentrações dos gases para indicar a ocorrência de uma determinada falha foi desenvolvida através de um processo empírico baseado na experiência de diversos engenheiros especialistas e pesquisadores mediante várias experimentações em transformadores no intuito de aperfeiçoar tais métodos. Eles buscam identificar uma falha correlacionando-a com cada uma das razões em determinadas faixas e, em geral, associando-a a uma dada codificação. Essa

metodologia foi inicialmente proposta por Dörnenburg (DÖRNENBURG; GERBER, 1967) e posteriormente confirmada por Rogers (ROGERS, 1978). A maioria das teorias de diagnóstico baseada no princípio de degradação térmica se embasam nas razões, apresentadas no quadro 2.1.

Quadro 2.1 - Razões entre as concentrações dos gases.

Razão	$\frac{CH_4}{H_2}$	$\frac{C_2H_2}{C_2H_4}$	$\frac{C_2H_2}{CH_4}$	$\frac{C_2H_6}{C_2H_2}$	$\frac{C_2H_4}{C_2H_6}$
Notação	R1	R2	R3	R4	R5

O método de Dörnenburg utiliza as razões R1, R2, R3 e R4 para indicar uma determinada falha dentre três tipos gerais sugeridos: sobreaquecimento, descargas de baixa energia (corona) e descargas de alta energia (arco) e exige níveis relevantes dos gases, como os da norma L1, em todas as razões para que o diagnóstico possa ser considerado válido.

As faixas das razões R1, R2, R3 e R4 definidas no método de Dörnenburg e a respectiva falha associada são apresentadas no quadro 2.2.

Quadro 2.2 – Faixas das razões definidas no método de Dörnenburg.

Falha Incipiente	R1	R2	R3	R4
Decomposição Térmica	>1,0	<0,75	<0,3	>0,4
Corona (descargas de baixa energia)	<0,1	-----	<0,3	>0,4
Arcos (descargas de alta energia)	>0,1 e <1,0	>0,75	>0,3	<0,4

O fluxograma apresentado na figura 2.6 ilustra o procedimento para aplicação do método de Dörnenburg. A figura 2.7 ilustra o método de forma gráfica, onde há uma percepção clara de regiões, onde não é estabelecida nenhuma associação com qualquer diagnóstico de falha. Logo, para alguns casos onde os valores das razões levem a estas regiões, o diagnóstico não poderá ser efetuado a contento. Este problema é conhecido por problema de “não-decisão”.

O problema da “não-decisão” é característica dos métodos convencionais, uma vez que as normas apresentam apenas algumas combinações típicas das razões. Quando um caso se configura fora dessas combinações típicas, outros métodos necessitam ser utilizados.

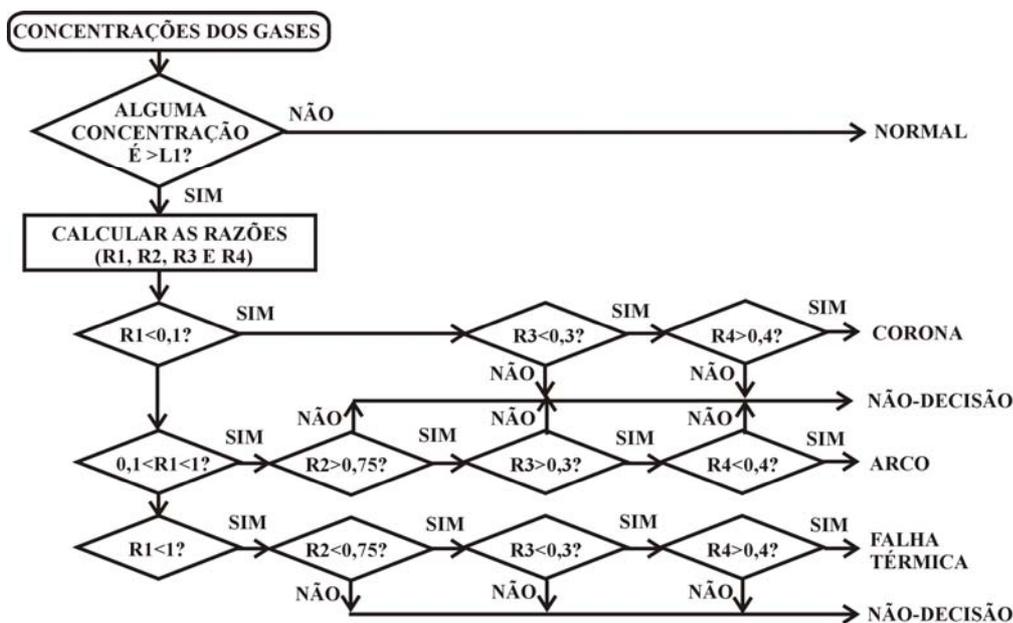


Figura 2.6 – Fluxograma de aplicação do método de Dörnenburg.

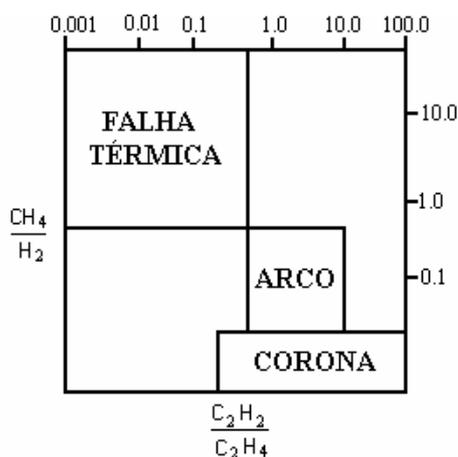


Figura 2.7 – Interpretação gráfica do método de Dörnenburg.

2.4.1.3 Método das razões de Rogers (Rogers Ratio Method)

O método das razões de Rogers segue o mesmo procedimento geral utilizado no método de Dörnenburg, exceto pelo fato que as razões utilizadas são: R1, R2 e R5 e C_2H_6/CH_4 . Este método passou por vários testes para ser validação, aperfeiçoando e otimizando a correlação existente entre a análise dos gases e os resultados das inspeções dos transformadores. No entanto, tal como o método de Dörnenburg, o método de Rogers pode apresentar o problema da “não-decisão”.

O método original de Rogers utiliza o quadro 2.3 para realizar o diagnóstico. Nesta tabela o valor 0 indica que o atual valor da razão é menor que 1.0 e 1 indica uma razão acima de 1.0. A figura 2.8 ilustra o procedimento passo-a-passo para aplicação do método de Rogers.

Quadro 2.3 – Tabela de diagnóstico do método original de Rogers.

CH_4/H_2	C_2H_6/CH_4	C_2H_4/C_2H_6	C_2H_2/C_2H_4	Diagnóstico
0	0	0	0	Se $CH_4/H_2 \leq 0.1 \Rightarrow$ Descargas parciais Caso contrário \Rightarrow Deterioração normal
1	0	0	0	Falha térmica de baixa temperatura (menor que 150 °C) envolvendo óleo e/ou a celulose
1	1	0	0	Falha térmica na faixa de 150-200 °C envolvendo óleo e/ou a celulose
0	1	0	0	Falha térmica na faixa de 200-300 °C envolvendo óleo e/ou a celulose
0	0	1	0	Falha térmica na faixa de 100-200 °C envolvendo óleo e sobreaquecimento generalizado do isolamento sólido
1	0	1	0	Falha térmica de alta temperatura com circulação de corrente entre tanque e núcleo por mau contato nas conexões
0	0	0	1	Descargas de média densidade de energia envolvendo o óleo isolante.
0	1	0	1	Problemas com o comutador de tap promovendo circulação de correntes
0	0	1	1	Descarga de alta energia (arco com potencial) envolvendo óleo isolante.

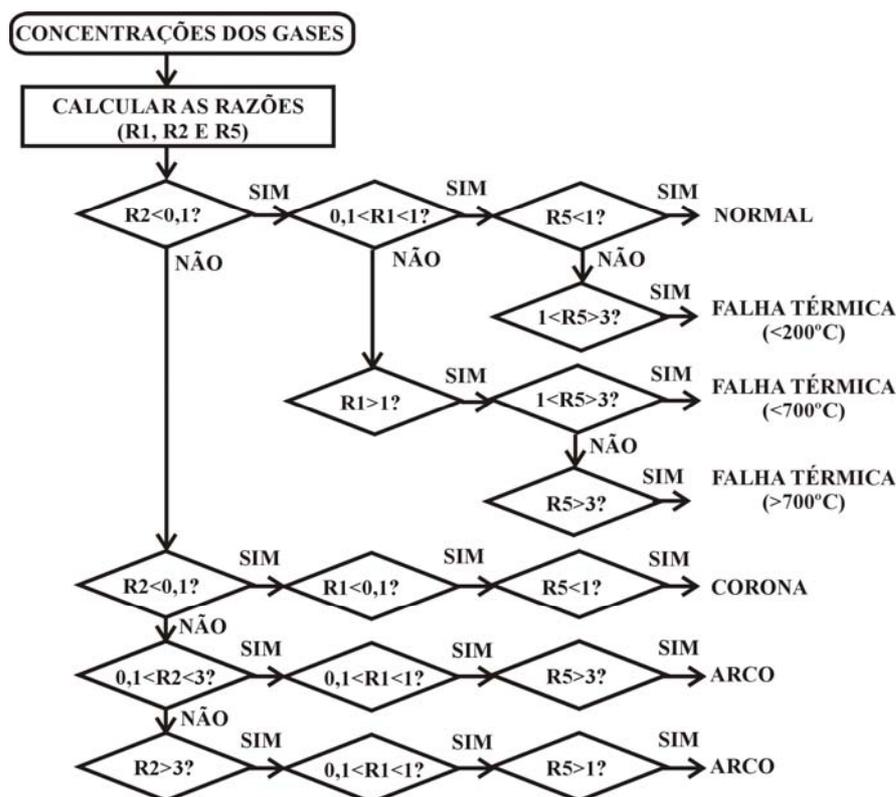


Figura 2.8 – Fluxograma de aplicação do método de Rogers.

2.4.1.4 Triângulo de Duval (Duval's Triangle)

Este método foi desenvolvido por Michel Duval em 1974 e está descrito no apêndice B do IEC 60599 (IEC, 1999) e é também apresentado e utilizado em outras experimentações (DUVAL 2001, 2002). O procedimento de aplicação deste método se inicia com o cálculo das percentagens dos gases metano (CH₄), etileno (C₂H₄) e acetileno (C₂H₂) em relação a soma das concentrações destes gases gerados em p.p.m. (CH₄+C₂H₄+C₂H₂). Uma vez obtidos os percentuais (%CH₄, %C₂H₄, %C₂H₂), estes servem como coordenadas para identificação de um ponto em um sistema de coordenadas triangulares. O famoso triângulo de Duval é geograficamente subdividido em zonas que representam as falhas. Quando na combinação da concentração de gases forem estabelecidas as coordenadas do triângulo, na verdade é determinada a zona que associa aquela combinação de concentrações dos gases, a um padrão de falha que apresenta essa característica de produção de gases.

O Triângulo de Duval assim como os demais métodos de diagnóstico, deve ser aplicado quando há suspeita de falha, através de um método de detecção de falha como o monitoramento da taxa de crescimento da concentração total dos gases combustíveis, por exemplo. Na tentativa de ser ter uma melhor panorâmica da atual situação interna do equipamento, no que diz respeito à formação dos gases, faz uso do valor das concentrações dos gases de análises anteriores, quando disponíveis, para utilizar a subtração entre os valores atuais e anteriores das concentrações como entrada para o método. No entanto, essa transformação deve ser utilizada com cautela, pois, se a diferença entre as concentrações for muito pequena haverá um comprometimento da interpretação dos dados. A figura 2.9 ilustra de forma gráfica o método de Duval, bem como a composição das coordenadas e as zonas das respectivas falhas.

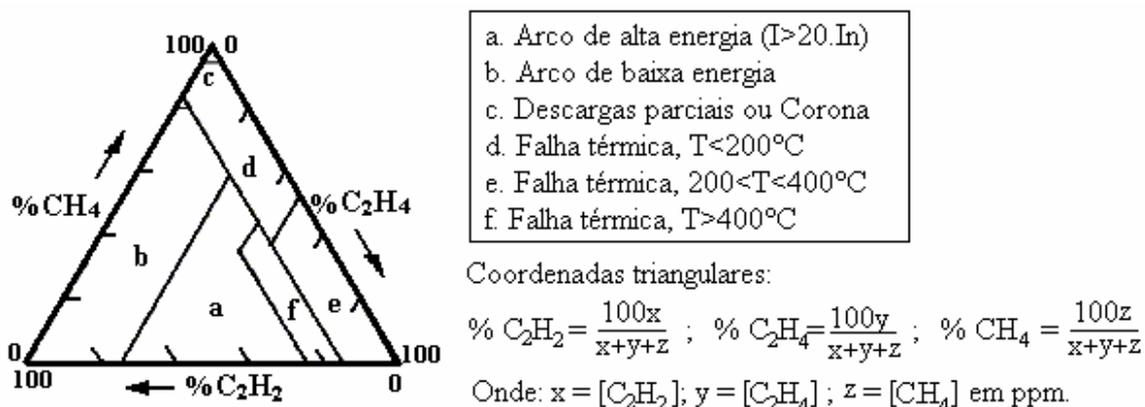


Figura 2.9 – Representação gráfica do método de Duval.

2.4.1.5 As normas do IEEE, IEC e ABNT

As normas do IEEE, IEC e ABNT são padronizações de métodos largamente utilizados e estas passam por muitas experimentações, evoluções e aperfeiçoamentos e levam em consideração muitos resultados de avaliação por especialistas para se consolidarem como referência (DUVAL, 2005; MIRANDA, 2005). Os métodos convencionais até aqui apresentados formam a base para estas padronizações. Consideram-se aqui como métodos convencionais aqueles cujo diagnóstico está associado a intervalos para concentrações dos gases e/ou das razões entre estas. Tendo em vista que estes métodos já foram descritos nas

subseções anteriores, nesta subseção serão realizados apenas alguns comentários sobre esses padrões.

O IEEE C57.104, o IEC 599 e a ABNT NBR-7274, por exemplo, apresentam uma revisão do método das razões de Rogers. Ao aperfeiçoar o método de Rogers, o IEEE/IEC/ABNT excluiu a utilização da razão C_2H_6/CH_4 , pois, esta razão não era utilizada para identificação da falha, mas somente para indicar o intervalo de temperatura da decomposição. Dessa forma, esta revisão do método utiliza as razões R1, R2 e R5 descritas no quadro 2.1. Os quadros 2.4 e 2.5 apresentam o método de Rogers revisado e a figura 2.10 ilustra este método graficamente (LIMA, 2005).

Quadro 2.4 – Códigos do IEEE, IEC e ABNT para o método de Rogers revisado.

Intervalos das razões	Códigos		
	R2	R1	R5
<0.1	0	1	0
0.1-1	1	0	0
1-3	1	2	1
>3	2	2	2

Quadro 2.5 – Método de interpretação de Rogers revisado.

Falha característica	Códigos			Exemplos típicos
	R2	R1	R5	
Condição normal (sem falha)	0	0	0	Envelhecimento normal.
Descargas parciais de baixa densidade de energia	0	1	0	Descargas nas bolhas de gás resultantes de impregnação incompleta, supersaturação ou alta umidade.
Descargas parciais de alta densidade de energia	1	1	0	Como caso anterior, porém provocando perfuração da isolação sólida.
Descargas de energia reduzida	1	0	0	Centelhamento contínuo no óleo devido a más conexões. Ruptura dielétrica do óleo.
Descargas de alta energia	1	0	0	Descargas e alta potência, arcos, ruptura dielétrica do óleo entre espiras ou entre espira e massa. Corrente de interrupção no seletor.
Falha térmica de baixa temperatura (<150 °C)	0	1	0	Aquecimento generalizado dos condutores.

Falha térmica de baixa temperatura (150-300 °C)	0	1	0	Sobreaquecimento local do núcleo devido a concentrações de fluxo. Pontos quentes de temperatura crescente, desde pequenos pontos no núcleo, sobreaquecimento do cobre, maus contatos até pontos quentes devido a correntes de circulação entre núcleo e carcaça.
Falha térmica na faixa de 300-700 °C	0	0	1	
Falha térmica de alta temperatura (>700 °C)	1	0	1	

Acerca desta tabela cabem alguns comentários (WANG, 2000):

1. Para a proposta desta tabela, há uma tendência para a razão C_2H_2/C_2H_4 se elevar de um valor entre 0.1 e 3.0 para acima de 3.0, e para a razão C_2H_4/C_2H_6 de um valor entre 0.1 e 3.0 para acima de 3.0 tanto quanto a falha desenvolve em intensidade.
2. No caso dos gases se originarem, principalmente da decomposição do isolamento sólido tem-se o uso da razão C_2H_4/C_2H_6 .
3. A condição de falha é normalmente indicada pelo incremento da concentração de gases. A razão CH_4/H_2 é normalmente 1.0 e seu valor atual é dependente de muitos fatores tais como a temperatura do óleo e sua qualidade.
4. Um aumento no valor de C_2H_2 pode indicar um ponto quente de temperatura maior que 1000°C.

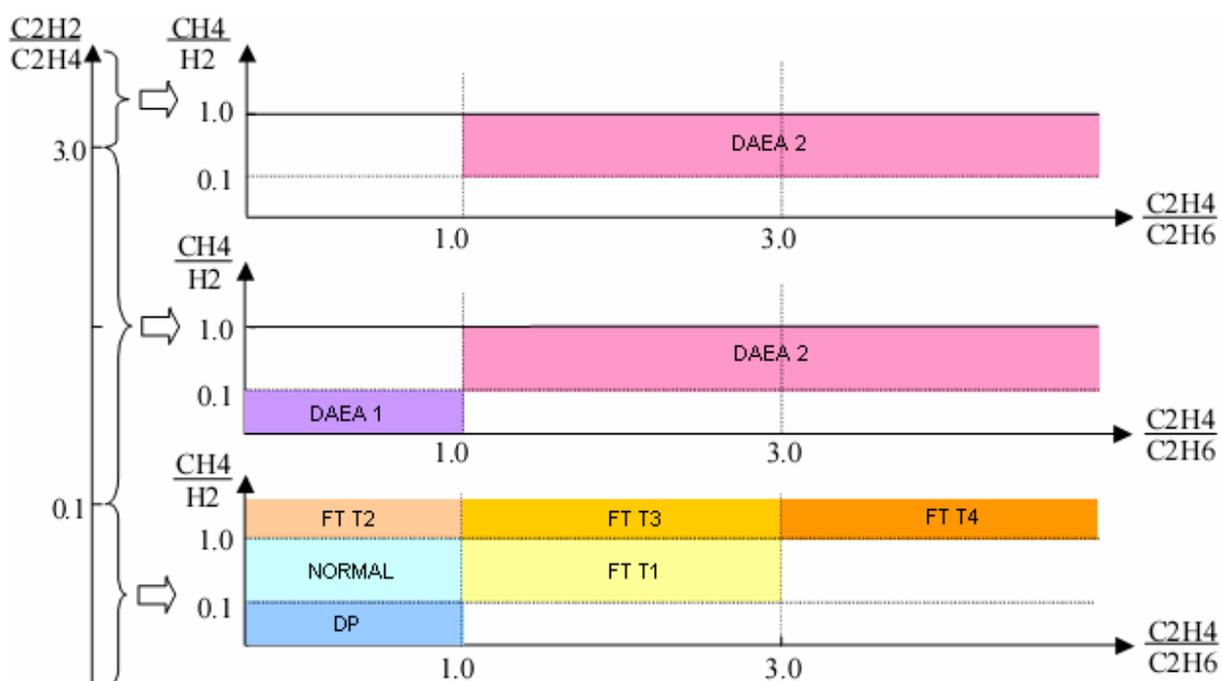


Figura 2.10 - Representação gráfica do método de Rogers revisado pelo IEEE/IEC.

2.4.2 Métodos que utilizam técnicas de inteligência artificial

Muito se tem visto em pesquisas na aplicação de técnicas de Inteligência Artificial no diagnóstico de falhas incipientes (DUKARM, 1993; ZANGH, 1996; HUANG, 1997; WANG, 2000; MORAIS, 2004; LIMA 2005; ALMEIDA *et al.*, 2007). São muitos os fatores que contribuem para tanto, dentre eles, a facilidade na aplicação das técnicas, uma vez que estas são amplamente dominadas, a disponibilidade de dados, visto que os métodos de DGA são aplicados com sucesso há décadas, e o desenvolvimento de tecnologias que ajudam na implementação das pesquisas desenvolvidas. Tudo isto conduz a um ambiente de confiabilidade do diagnóstico e, conseqüentemente, a uma garantia do investimento feito.

Nesse contexto, as pesquisas abrangem Sistemas Especialistas, métodos com Lógicas *Fuzzy* e aproximações através de Redes Neurais Artificiais e resultam em diagnósticos consistentes vislumbrando um cenário de aperfeiçoamento de técnicas e até nascimento de novos conhecimentos. Tais técnicas podem ser utilizadas individualmente ou até em conjunto formando sistemas híbridos que podem gerar resultados esplendorosos (MIRANDA, CASTRO, 2005; LIMA *et al.*, 2006; ALMEIDA *et al.*, 2007; DURAISAMY *et al.*, 2007).

No caso de sistemas especialistas, a formação da base de regras é proveniente dos métodos convencionais já mostrados neste trabalho. Entretanto, também são adicionadas algumas regras advindas da experiência de especialistas na área como forma de acurar o resultado final do diagnóstico (LIN *et al.*, 1993; WANG *et al.*, 1998).

A aplicação de Redes Neurais em casos de reconhecimento de padrões já é amplamente difundida. As características de adaptação e generalização dos resultados fazem com que o processo de diagnóstico de falhas incipientes seja altamente eficiente neste método de inteligência artificial (GUARDADO *et al.*, 2001; ALMEIDA *et al.*, 2007).

O uso de lógica *fuzzy* apresenta a característica de aproveitamento de informações históricas na elaboração do diagnóstico e levam em consideração as incertezas existentes no processo alcançando resultados em ocasiões de duplo diagnósticos que os métodos convencionais não atingiriam (SU *et al.*, 2000 ; LIMA *et al.*, 2004).

2.5 NÍVEL DE GÁS GERADO (NGG E NGF) E TAXA DE GERAÇÃO (TG E TGF)

O cálculo do Nível de Gás Gerado (NGG) considera os valores das concentrações dos gases combustíveis (H₂, CH₄, C₂H₆, C₂H₄, C₂H₂ e CO), em relação aos valores históricos, tidos como normais, para aquele tipo de equipamento. A equação 2.1 demonstra como se processa o cálculo para o nível de gás gerado para cada um dos gases considerados (VARELLA *et al.*, 2000; MORAIS, ROLIM, 2004):

$$NGG_i = \frac{CA_{t_i}}{CL_i} \quad (2.1)$$

onde, CA_{t_i} representa a concentração atual (ppm) e CL_i o limite histórico máximo do gás para uma condição de normalidade (norma L1, por exemplo).

O Nível do Gás Gerado Final é obtido, para os gases em questão, por meio de um somatório ponderado dos valores de NGG. Esta ponderação utiliza os valores percentuais dos gases quando da ocorrência de uma falha sob suspeita, conforme definido no método do gás chave (IEEE Std C57.104, 1991). Assim, para cada falha sob suspeita há uma definição dos percentuais dos gases predominantes conforme as figuras 2.2, 2.3, 2.4 e 2.5.

Portanto, a equação 2.2 traz uma definição para o nível de gás gerado final (NGF):

$$NGF = \sum_{i=1}^6 P_i NGG_i \quad (2.2)$$

onde NGG_i representa o nível de gás gerado para cada gás e P_i são os percentuais dos gases advindos do método do gás chave, em função do tipo da falha.

A Taxa de Geração (TG), de cada um dos seis gases combustíveis, transmite um significado da evolução na geração do referido gás dentro de um período entre a amostra atual e uma amostra anterior. A equação 2.3 demonstra como se processa o cálculo da taxa de geração para cada um dos gases considerados (VARELLA *et al.*, 2000; MORAIS, ROLIM, 2004):

$$TG_i(\%) = \frac{(CA_{t_i} - CA_{n_i}) \cdot 30}{I \cdot CA_{n_i}} \cdot 100 \quad (2.3)$$

onde CA_{t_i} representa a concentração atual em ppm, CA_{n_i} a concentração anterior em ppm e I o intervalo em dias entre as coletas.

De forma similar ao processo anterior, a taxa de geração final (TGF) é calculada através de uma soma ponderada da taxa de formação de cada um dos gases combustíveis utilizando os percentuais oriundos do método do gás chave, levando-se em conta o diagnóstico preliminar da falha. Este procedimento vai dar uma maior importância àqueles gases que possam estar envolvidos na falha do diagnóstico preliminar.

$$TGF = \sum_{i=1}^6 P_i TG_i \quad (2.4)$$

onde P_i representa os percentuais dos gases advindos do método do gás chave (função do diagnóstico preliminar) e TG_i a taxa de geração encontrada para cada um dos seis gases.

É de suma importância mencionar que uma evolução na taxa de geração de gases combustíveis superior a 10% por dia pode indicar que a unidade tem uma falta interna ativa. Da mesma forma, para um total de gases combustíveis dissolvidos no óleo que exceda 720 p.p.m., há um forte indício de falha incipiente (IEEE, 1991).

2.6 CONCLUSÕES

No que diz respeito a um equipamento de expressiva importância para parques elétricos, é de suma relevância o ato de monitorar as condições de envelhecimento e degradação do isolamento de um transformador. O empenho nesse quesito pode ser o diferencial em salvaguardar o equipamento em situações críticas ou sofrer uma perda talvez irreparável. Daí a importância de ensaios físico-químicos que fornecem a real situação do estado do óleo isolante no que tange às suas faculdades de isolamento e refrigeração, servindo de base para o acompanhamento da unidade gerando um clima de maior segurança e eficiência em manutenção.

Tratando-se de análise dos gases dissolvidos, que tem sua base firmada em um modelo termodinâmico consolidado por seu desenvolvimento e uso através de décadas, observa-se um horizonte propício para o crescimento das investigações dos fenômenos internos nos transformadores aliando métodos consagrados e de comprovada eficiência com teorias e tecnologias inovadoras como os métodos de inteligência artificial e de monitoramento.

A análise dos gases dissolvidos no óleo, apesar de seu esplendoroso sucesso na realização do diagnóstico de falhas incipientes em transformadores, carece de avanços no que diz respeito a problemas de não decisão do diagnóstico e conservadorismo no que tange aos procedimentos referentes às situações de falha. Também se pode observar a necessidade de evolução nos métodos a respeito de uma unidade na linguagem de interpretação de resultados quando se usa vários métodos para diagnóstico a partir de cromatografia.

Diante do que foi discutido, o conhecimento de métodos convencionais para identificação de falhas incipientes será aplicado no desenvolvimento de um módulo do sistema de diagnóstico de falhas aliado a um esquema de monitoramento *on-line* que irá coletar os dados do equipamento para alimentar o sistema de informações em tempo real. Paralelo a isso, será ainda implementado um sistema de estimação dos gases dissolvidos em função das grandezas físico-químicas. Tal idéia visa diminuir o tempo de resposta na tomada de decisão quanto a uma condição de falha, uma vez que se está tratando de equipamentos de alta prioridade de proteção e continuidade de operação. Também, tem-se o objetivo de se solucionar

inconsistências normativas através de aplicações de técnicas que rendam maior confiabilidade aos diagnósticos de falha.

Capítulo 3

MONITORAMENTO ON-LINE DAS CONDIÇÕES DO ÓLEO MINERAL ISOLANTE

A questão de monitorar um equipamento ventila a idéia de se obter informações preciosas no que tange a previsibilidade de sinistros, possibilitando a implementação de mecanismos ou manobras de proteção. Aqui, o monitoramento tem por fim a aquisição de um conjunto de dados relativos ao funcionamento do transformador e cuja coleta envolve modernas tecnologias em sensores, técnicas de aquisição de dados e dispositivos digitais ou analógicos utilizados. Nesse contexto, surge a necessidade de monitoramento e diagnóstico de falhas incipientes em transformadores de potência, através da análise dos gases dissolvidos no óleo do transformador.

A distribuição das falhas dentre as regiões componentes de um transformador é estudada na seção 3.1 deste capítulo. A seção 3.2 caracteriza o método tradicional de monitorar falhas incipientes em equipamentos isolados a óleo. Porém, com os avanços dos estudos nessa área, é necessário se fazer uma comparação entre os vários equipamentos de monitoramento de falhas incipientes disponíveis, isso é discutido na seção 3.3. A seção 3.4 explana a aplicação prática de um equipamento comercial para monitoramento on-line. E então, seguem alguns comentários conclusivos na seção 3.5.

3.1 DISTRIBUIÇÃO DE FALHAS EM TRANSFORMADORES.

Os últimos avanços no desenvolvimento da tecnologia de sensores permitem que praticamente todos os parâmetros de um transformador sejam monitorados, estabelecendo que o critério para a escolha de quais parâmetros monitorar tenda a ser o custo e não a técnica. Para se avaliar o grau de sucesso do projeto de um sistema de monitoramento e diagnóstico é importante equilibrar eficiência e custos, mediante a identificação de quais parâmetros são relevantes e do uso de técnicas que reduzam a necessidade de um largo número de sensores aliado à utilização de softwares baseados em técnicas inteligentes.

Considerando um transformador de potência imerso em óleo com *taps* para mudança de cargas (OLTC), a figura 3.1 apresenta a distribuição estatística das falhas nos componentes do transformador (BENGTSSON, 1996). Da figura 3.1 pode-se observar que as principais fontes de falhas correspondem ao OLTC e enrolamentos (incluindo o sistema de isolamento). Para o OLTC os principais parâmetros a serem monitorados são a vibração e a temperatura, enquanto para o enrolamento e sistema de isolamento, os principais parâmetros a serem monitorados são as concentrações de gases dissolvidos no óleo, a temperatura e o nível de descargas parciais (PD). Deve ser observado que, independente da fonte de falha a ser considerada, a temperatura constitui um importante parâmetro a ser monitorado.

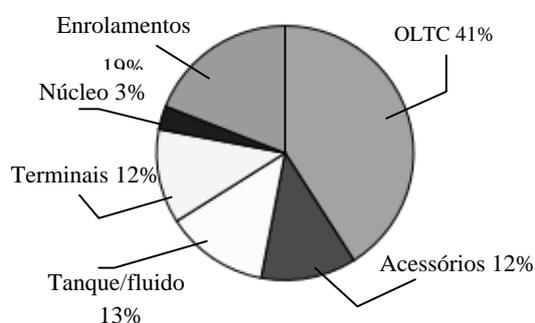


Figura 3.1. Distribuição das possíveis fontes de falhas em transformadores de potência.

Também, algumas pesquisas realizadas entre especialistas, os dois parâmetros mais importantes a serem monitorados em um transformador seriam a temperatura do ponto quente no interior do mesmo e os gases dissolvidos no óleo isolante. Para transformadores de recente instalação e que podem ser submetidos a situações de sobrecarga, o parâmetro mais importante a ser monitorado seria a temperatura do ponto quente, pois este parâmetro tem influência direta na vida útil do mesmo. No decorrer de vários períodos de utilização de um transformador, o parâmetro mais significativo a ser observado passa a ser a análise dos gases dissolvidos no óleo isolante, permitindo o monitoramento de falhas incipientes no equipamento. Essas conclusões podem ser observadas nas figuras de 3.2 a 3.4 (LUMASENSE, 2007).

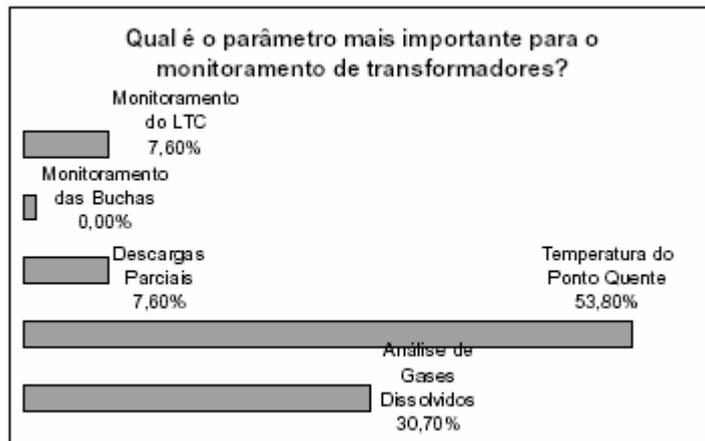


Figura 3.2. Grau de importância dos parâmetros monitorados em um transformador de potência novo.

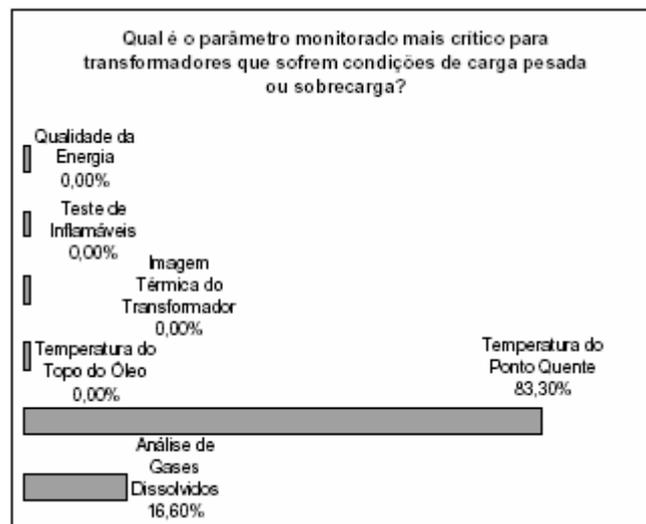


Figura 3.3. Grau de importância dos parâmetros monitorados em um transformador de potência em condição de sobrecarga.

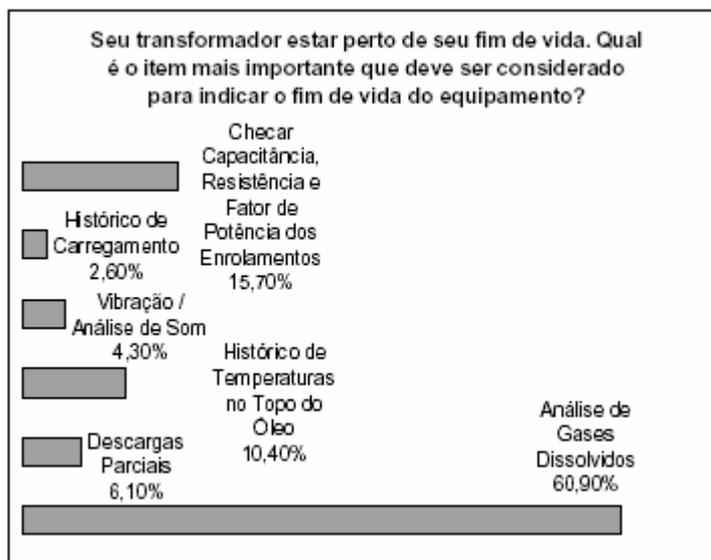


Figura 3.4. Grau de importância dos parâmetros monitorados em um transformador de potência antigo.

Devido a esta ênfase dada pelos especialistas em manutenção de equipamentos elétricos, é muito importante o estudo apurado das ferramentas de monitoramento de transformadores.

3.2 MÉTODO TRADICIONAL DE MONITORAMENTO

A manutenção preditiva é uma técnica de manutenção que consiste em acompanhar, periodicamente, as características e propriedades dos diversos componentes de um sistema e proceder a uma intervenção quando verificado que se encontra na iminência de falhar (NEPOMUCENO, 1999). Como não é possível realizar inspeção direta dos componentes de transformadores elétricos isolados a óleo sem a sua retirada de operação, se faz necessário o uso dos princípios da manutenção preditiva e possibilitar o acompanhamento periódico e sistemático, por exemplo, dos gases dissolvidos no seu líquido isolante no intuito de antecipar-se à falhas quando estas ainda estiverem em fase incipiente.

Este acompanhamento pode ser efetuado através de cromatografia laboratorial exercida sobre uma amostra do óleo isolante. Esta análise configura um método tradicional de monitoramento. Entretanto, estudos avançados e desenvolvimento de técnicas e equipamentos permitem o acompanhamento *on-line* ou em tempo real de gases dissolvidos no óleo.

A cromatografia trata-se de um método físico-químico de separação dos componentes de uma mistura, identificando, assim, quais os elementos presentes na amostra ensaiada. As falhas incipientes podem ser classificadas em termos dos esforços térmicos, onde sobreaquecimentos são atores principais, e elétricos, relacionados à descargas internas no equipamento. Neste ambiente, tais descargas geram gases que podem se dissolver no óleo passando a pertencer a sua composição. Dessa forma, podem ser identificados no processo de cromatografia.

A análise cromatográfica dos gases dissolvidos no óleo é feita em três etapas: a amostragem do óleo, a extração dos gases da amostra de óleo e a análise dos gases extraídos da amostra no cromatógrafo de gases, responsável pela identificação e quantificação de cada gás dissolvido no óleo (ABNT, 1981; MILASCH, 1984).

Na etapa de amostragem, alguns cuidados são necessários para se obter uma amostra do líquido isolante que realmente esteja em circulação e tenha contato com a parte ativa do equipamento. Este deve estar em condições normais de operação.

A norma NBR 7070 padroniza o procedimento de amostragem de óleo isolante de transformadores. A seguir encontram-se algumas considerações sobre a amostragem:

- Na amostragem em equipamento energizado, todas as providências envolvendo segurança devem ser observadas;
- É aconselhável a seringa de vidro com torneira de três vias como recipiente para coleta da amostra;
- Para enchimento da seringa, a própria pressão da coluna de óleo do transformador é aproveitada, evitando puxar o êmbolo da seringa. Pois, este procedimento pode provocar uma diminuição da pressão interna da mesma, podendo provocar a defasagem parcial do óleo, tornando a amostra não mais representativa do óleo em circulação no transformador;
- A tomada de amostra deve ser adequadamente realizada na válvula inferior de amostragem, por questões de facilidade e segurança. Entretanto, qualquer outro lugar em que se possa obter uma amostra do óleo que está em circulação na parte ativa pode ser utilizada;

A figura 3.5 mostra um sistema para a extração de gases presentes na amostra recolhida do transformador (ABNT, 1981).

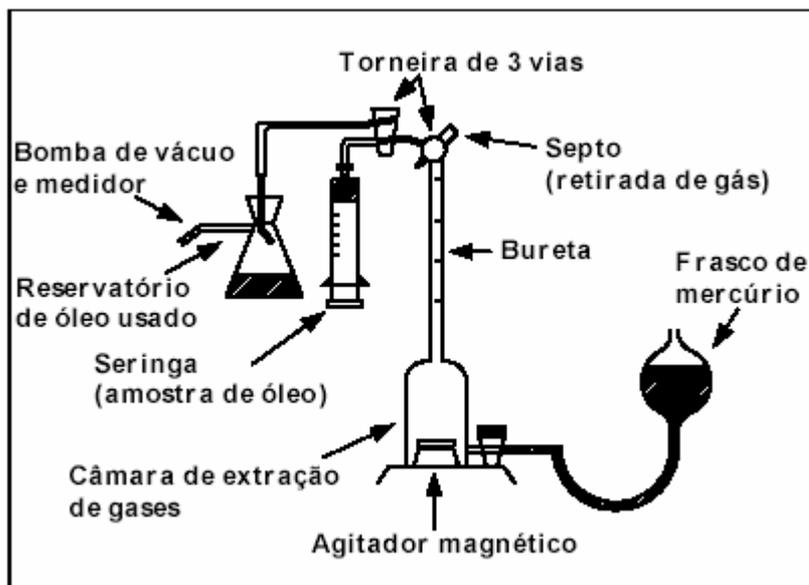


Figura 3.5 - Aparelhagem para extração de gases

Uma fração dos gases extraídos da amostra é analisada em cromatógrafo para a identificação e devida quantificação. Os resultados obtidos são avaliados de acordo com os métodos estabelecidos de diagnóstico, apresentados no capítulo 2.

3.2.1 Cromatógrafo

O cromatógrafo processa o reconhecimento e avaliação dos gases componentes da amostra, provendo um gráfico. Neste gráfico, há identificação dos referidos gases dissolvidos bem como o grau de concentração respectivo de cada gás. Também, é indicado o tempo de retenção e a área do pico conforme figura 3.6.

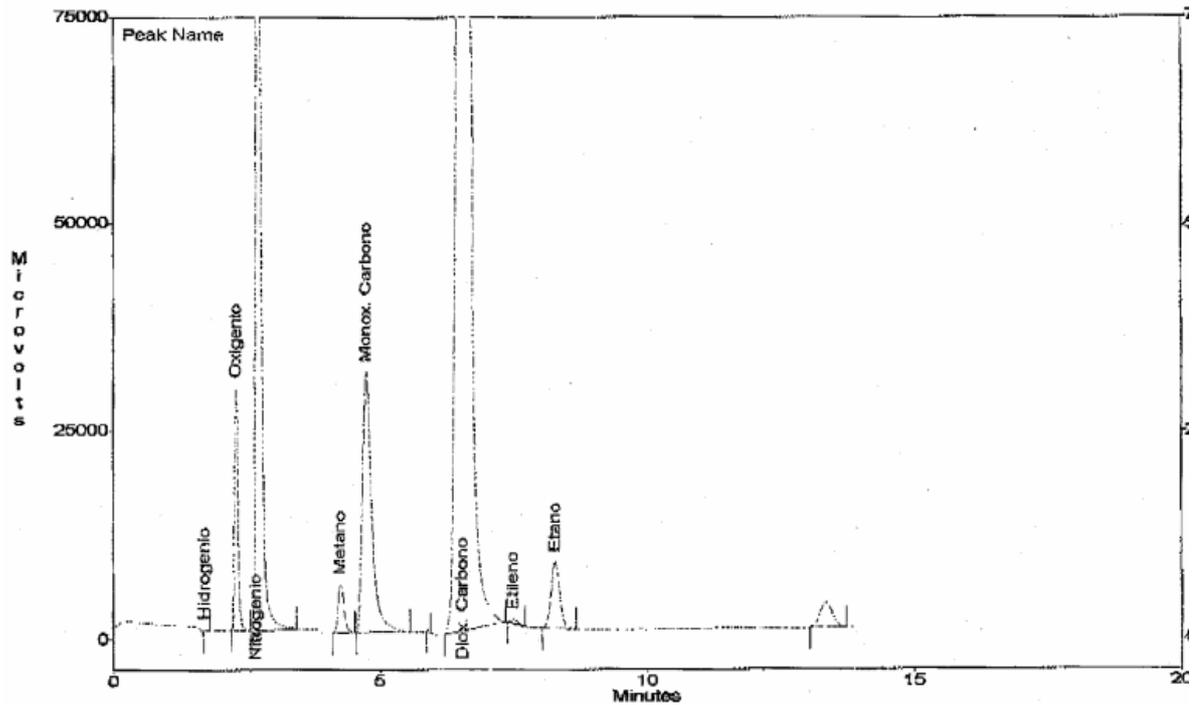


Figura 3.6 - Cromatograma – Gráfico de análise cromatográfica

As unidades fundamentais de um cromatógrafo, apresentadas na figura 3.7, são:

- 1: Fonte do gás de arraste;
- 2: Controlador de vazão e regulador de pressão;
- 3: Sistema de injeção da amostra;
- 4: Coluna cromatográfica;
- 5: Sistema de detecção;
- 6: Registrador;
- 7: Termostato para injetor (a), coluna(b) e detector (c).

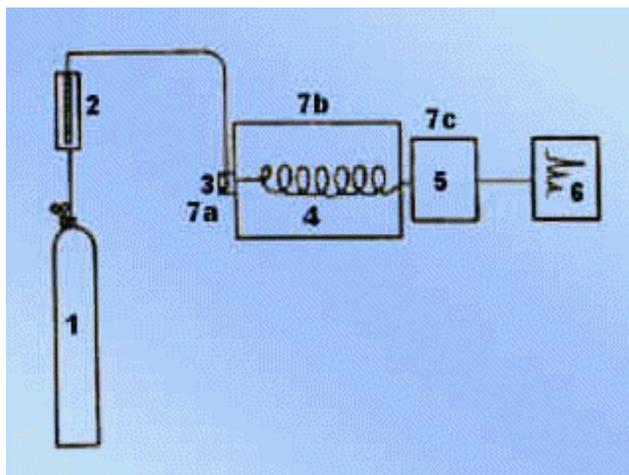


Figura 3.7 - Representação esquemática de um sistema de análise cromatográfica

Um cilindro contendo o gás sob alta pressão serve como fonte do gás de transporte ou de arraste, cuja função é levar as moléculas, da amostra a ser separada, do ponto de injeção até o detector, passando pela coluna cromatográfica onde a separação irá ocorrer. Este gás é a fase móvel e não deve interagir com a fase estacionária e nem com a amostra (inerte). Os gases mais usados como fases móveis são: nitrogênio, hélio, hidrogênio e argônio.

É desejável que a vazão do gás de arraste seja constante durante a análise sob pena de prejudicar a análise da amostra por provocar variações nas áreas dos picos e no tempo de retenção. As válvulas dos cilindros servem como reguladores de pressão. Quando a temperatura da coluna é mantida constante durante toda a análise, a pressão também permanece constante, e, neste caso, uma válvula de agulha serve para manter a vazão constante. (BAUGH, 1993).

A injeção de gases é feita através de seringa ou de válvulas. Algumas vezes usa-se a injeção de gases em solução. A injeção de amostras líquidas pode ser feita usando-se micro-seringas e, mais raramente, válvulas. Sólidos são geralmente dissolvidos em um solvente adequado e analisados sob a forma de solução; porém, também existem dispositivos para a vaporização e injeção diretamente do sólido. Apesar de não possibilitar a mesma exatidão apresentada pela válvula de injeção, as seringas são úteis para a maioria dos propósitos, além de baratas e altamente versáteis, isto é, permitem grande flexibilidade quanto ao volume a ser injetado (NOGUEIRA, 2004).

A quantidade de amostra injetada não deve ultrapassar a capacidade da coluna, determinada pela quantidade de fase estacionária. Falhas na técnica de injeção podem causar assimetria nos picos.

A amostra deve entrar na coluna na forma de um segmento estreito, caso contrário, pode ocorrer alargamento dos picos.

As colunas, tubos longos contendo a fase estacionária, efetivamente permitem a separação dos constituintes da amostra. Podem ser de aço inox, vidro, sílica fundida ou teflon, no entanto, o material constituinte não pode reagir com a amostra nem com a fase estacionária.

As colunas típicas utilizadas na cromatografia gasosa são: coluna recheada e capilar. Na primeira e mais comum, as colunas, de aço inox ou vidro são preenchidas integralmente com as partículas da fase estacionária, um sólido ativo.

De acordo com o aparelho, as colunas variam de formato, mas na maioria das vezes elas são espirais por ocuparem menos espaço e podem medir de 1 a 3m.

Porém, as colunas capilares podem ter comprimento de 10 a 100m e apresentam maior eficiência na eliminação de alargamento de bandas devido a irregularidades no enchimento mediante a baixíssima espessura.

Detectores são dispositivos que transformam em sinais elétricos as variações na composição do gás de arraste. Alguns tipos freqüentemente utilizados são:

- Detector por condutividade térmica;
- Detector por ionização de chama;
- Detector por captura de elétrons;
- Detector fotométrico de chama;
- Detector de condutividade eletrolítica.

A temperatura do detector é importante para que se evitem condensações da amostra, o que pode provocar alargamento dos picos (CARDOSO, 2005).

3.2.2 Análises qualitativa e quantitativa

A análise qualitativa se refere à identificação individual dos elementos componentes da amostra e se dá através da comparação do tempo de retenção, decorrido entre a injeção da amostra e o máximo pico cromatográfico, de um padrão como tempo de retenção da amostra. Se um composto conhecido possui o mesmo tempo de retenção que um dado elemento na amostra, trata-se da mesma substância, processo exemplificado na figura 3.8 (CARDOSO, 2005):

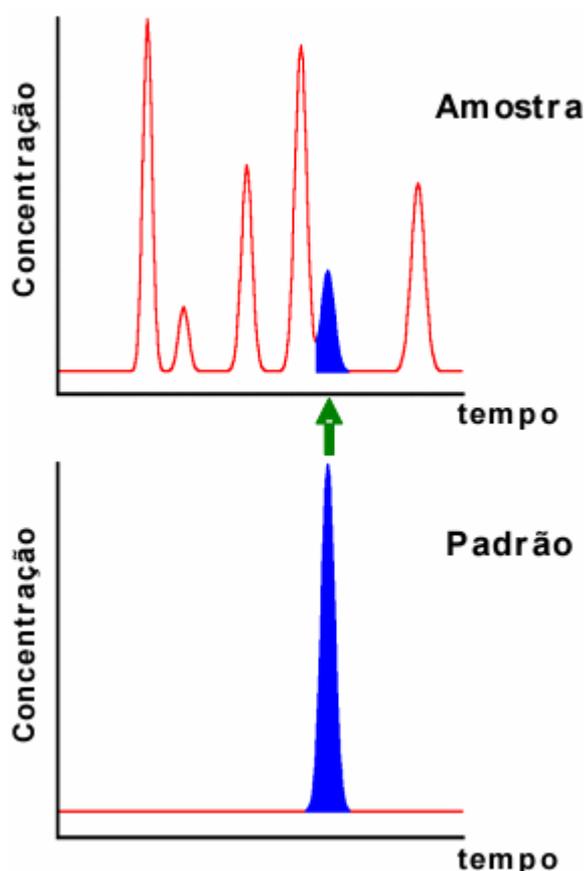


Figura 3.8 - Comparação entre cromatogramas da amostra e de uma solução padrão

Entretanto, a cromatografia gasosa é uma técnica eminentemente quantitativa, uma vez que a área dos picos registradas no gráfico da cromatografia é proporcional à massa do composto injetado. Assim, aplica-se alguma técnica de medição de área, ou integradores eletrônicos para se obter a quantidade do elemento componente da amostra.

Finalmente, uma análise cromatográfica permite saber a identificação e a respectiva concentração dos compostos dissolvidos no óleo do transformador. Com isso, esta

técnica se revela como uma ferramenta que permite uma inspeção das condições internas do equipamento, sem o inconveniente da retirada da unidade de serviço. Sistemáticamente, pode monitorar a evolução dos gases dissolvidos e formar uma base histórica de dados sobre o desenvolvimento das possíveis falhas. Isto propicia um adequado projeto do plano de manutenção da unidade.

3.3 EQUIPAMENTOS DE MONITORAMENTO

Equipamentos para monitoramento de transformadores devem ser eficientes, de custo justificável, fáceis de instalar em campo e de baixa taxa de manutenção. A necessidade da utilização de sistemas de monitoramento tem sua importância se for considerado que grandes quantidades de unidades de transformação instaladas nos parques elétricos atuais foram fabricadas há décadas (KOVACEVIC; DOMINELLI, 2003). Certamente, a idade do parque elétrico provoca um impacto no planejamento de manutenção alavancando as instalações de equipamentos de monitoramentos e diagnósticos em transformadores. Tal atitude visa salvaguardar um dos mais importantes equipamentos das subestações de possíveis falhas gerais causadas por elevados valores de parâmetros intrínsecos ao seu funcionamento, tais como a temperatura, o nível de descargas parciais, o carregamento e o nível de umidade do isolamento. O monitoramento destas grandezas tem-se tornado uma estratégia eficaz e vantajosa.

3.3.1 Monitores de Temperatura

As medidas de temperatura do transformador são úteis para a modelagem do comportamento térmico do equipamento e do ponto quente do enrolamento. Ainda é amplamente utilizada a forma de medida indireta que é realizada através da passagem de uma corrente de valor conhecido através de uma carga, que tem um elemento resistivo como indicador, e localizada em um ponto distante da região de alta tensão do transformador (KOVACEVIC; DOMINELLI, 2003; CAVALEIRO *et al.*, 2003). Existe uma correlação direta entre a temperatura do enrolamento e o tempo de vida útil do transformador. Logo, dispor de informações precisas sobre os parâmetros térmicos é de suma relevância para uma projeção maximizada desta vida útil. Vale a pena salientar que o sistema isolante pode perder suas características dielétricas diante da exposição prolongada ao calor excessivo

antecipando a ocorrência de falhas. Porém, este método convencional de medição indireta de temperatura apresenta deficiência em seus resultados que causam incertezas na modelagem térmica do transformador, não representando fielmente o comportamento real do equipamento.

Com o incentivo de erradicar tais inconvenientes pesquisas se aprofundam na implementação da medição direta de temperatura mediante a aplicação de sensores de fibra óptica. Dessa forma, tem-se acesso a uma informação importante não somente para manutenção e proteção, mas para operação do transformador, uma vez o ponto quente do enrolamento de um transformador é um parâmetro limitador da sua capacidade de carga.

Atualmente sensores de temperatura baseado em dispositivos opto-eletrônicos podem ser instalados nos enrolamentos dos transformadores em fase de manufatura, e são geralmente configurados para a medida em um único ponto ou em configurações distribuída no interior. Muitas técnicas de medidas de temperatura utilizando fibras ópticas têm sido cada vez mais aplicada para medida de cargas térmicas em transformadores (SARAVOLAC, 1994). Em termos de monitoramento on-line, a exatidão obtida é suficiente: $\pm 1^{\circ}\text{C}$ para sensores pontuais e $\pm 1^{\circ}\text{C/m}$ para sistemas distribuídos de medição (BETTA *et al.*, 2000).

Dois princípios são comumente usados na concepção dos sensores de fibra óptica de temperatura: Variação do tempo de decaimento da fluorescência do fósforo em função da temperatura e variação do espectro de luz do cristal de arsênio-gálio em função da temperatura. O primeiro princípio é comercialmente utilizado pela Luxtron enquanto o segundo pela ABB (SARAVOLAC, 1994). A grande vantagem da fibra como medidor de temperaturas internas em transformadores de potência é que esta apresenta ausência de susceptibilidade magnética praticamente não interferindo no processo normal do equipamento monitorado (TEUNISSEN *et al.*, 2002).

Porém, a idéia de aplicação imediata e em larga escala ainda é contraditada pelo ainda substancial custo do uso desta tecnologia, embora este parâmetro venha sofrendo um decrescente muito rápido ultimamente. Também, ainda há a necessidade de se desenvolver métodos de instalação que privilegiem as características mecânicas da fibra.

3.3.2 Monitores de Descargas Parciais

Outra causa de falhas em transformadores é o rompimento do dielétrico. Este tipo de falha interna do transformador é frequentemente precedida de descargas parciais. A caracterização de padrões de descargas parciais é outra importante fonte de investigação do estado do isolamento do transformador (LAZAREVICH, 2003). O monitoramento de PD é efetivo para detecção de falhas, pois um incremento no nível de descargas parciais pode significar o comprometimento do sistema de isolamento. Por essa característica, é bastante desejável o monitoramento deste parâmetro visando um julgamento em tempo hábil das condições internas da unidade evitando perdas financeiras consideráveis (ZHU *et al.*, 1991; WARD; LINDGREN, 2000).

As descargas parciais ocorrem dentro do tanque e produzem uma onda sonora e de pressão que é transmitida através do óleo, além de um pulso elétrico. Daí os princípios que regem a detecção de DP: acústica e elétrica.

A detecção acústica se dá através de sensores de emissão acústica instalados na parede do transformador. Com a ocorrência de uma DP, inicia-se uma emissão de ondas acústicas em todas as direções do tanque. Nota-se que essa é uma técnica de detecção não intrusiva, porém, o sinal detectado, por ter valor extremamente baixo, pode ser influenciado por distúrbios como ruídos magnéticos, vibração mecânica entre outros. Para evitar erros e medidas ineficazes, a emissão acústica de DP e as interferências devem ser distinguidas através do seu espectro de frequência mediante a aplicação de técnicas de processamento digital de sinais.

Seguindo a tendência de desenvolvimento de sensores opto-eletrônicos, novas técnicas de medida de descargas parciais através de sensores de ultra-som de fibra óptica vêm sendo desenvolvidas (LAZAREVICH, 2003). Um sistema exemplo proposto e desenvolvido pelo CPT - Center for Photonics Technology of Virginia University, é composto de uma sonda acústica opto-eletrônica e de um processador digital de sinais (DSP). Para a transmissão do sinal da sonda até o DSP utiliza-se uma fibra óptica, conforme a figura 3.9.

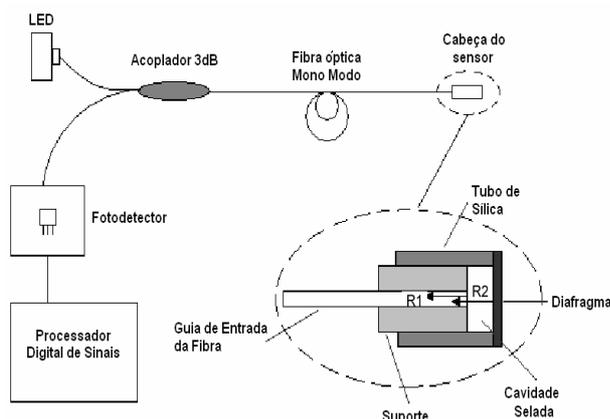


Figura 3.9 - Sensor óptico de ultra-som para medição de descargas parciais.

No sensor, o feixe luminoso proveniente de um diodo *laser* incide no acoplador e é transmitido pela fibra até a cabeça do sensor (ampliada em detalhes). O guia da fibra e o diafragma são colados juntos ao suporte cilíndrico. O feixe de luz incidente é parcialmente refletido (4%) na face do sensor enquanto a outra porção do feixe propaga-se para o espaço interior da cavidade atingindo até a superfície interna do diafragma. A superfície do diafragma é revestida por uma fina camada de ouro de forma que toda a porção de luz incidente seja refletida (96%). Com esta montagem, o sinal óptico, recebido pelo fotodetector, é uma função do comprimento da cavidade selada e é imune à contaminações externas (WARD, 2000).

3.3.3 Monitores de Gases Dissolvidos no Óleo

As condições de problemas mais internos no transformador podem ser detectadas na análise do óleo. Um programa de manutenção no qual o DGA é realizado em períodos anuais, dificilmente acompanha a curva de tendência da formação dos gases. Interessante seria uma diminuição do período de amostragem para promover um acompanhamento da evolução desses gases interno ao transformador. Na realidade, mesmo com a análise em períodos menores que o previsto em normas, um ano, a informação da evolução do estado interno entre as amostras fica na obscuridade. Este ponto de vista tem levado a desenvolvimentos tecnológicos no sentido de viabilizar o DGA em tempo real (ALMEIDA *et al.*, 2007) mesmo que simplificado, ou seja, com monitoramento da formação de alguns gases em particular, como por exemplo o gás carbônico, hidrogênio, furfuraldeído e umidade entre outros. A possibilidade de realizar DGA em tempo real apóia-se no grande

esforço que vem sendo atualmente empregado no desenvolvimento de sistemas de sensores eficientes, modulares, e de custo viável. O sensor de hidrogênio, por exemplo, como principal indicador de descargas parciais e arco, foi um dos primeiros sensores a ser desenvolvido e utilizado em sistemas de monitoramento em tempo-real.

O acompanhamento em tempo real da condição do óleo de transformadores acarreta benesses como a certeza de operar o transformador com o rendimento máximo, detectar os primeiros sinais de falha, reduzir as paradas não agendadas e as falhas do equipamento, e aumentar a vida útil do transformador (CARDOSO, 2005).

Os sistemas de medição que monitoram as condições do óleo isolante podem ser agrupados em três classes: monitores de qualidade do óleo; monitores de gases combustíveis e monitores multi-gás (CARGOL, 2005).

3.3.3.1 Centurion®-WEIDMANN

O Centurion® é um sistema de monitoramento de qualidade do óleo desenvolvido pela Weidmann-ACTI Inc. Seu projeto visa ser uma solução de custo acessível para monitoramento da qualidade de óleo isolante não somente em transformadores, mas em todos os tipos de dispositivos que usem este meio isolante.



Figura 3.10 – Centurion® (WEIDMANN-ACTI, 2005)

Pela sua concepção, o Centurion® não extrai gases do óleo. Sua atuação é na verificação da rigidez dielétrica diagnosticando o grau de pureza do óleo. Porém, em contradição aos métodos padronizados, como ASTM D877, D1816 e IEC 60156, de natureza destrutiva, o Centurion® usa métodos especiais que evitam a danificação do óleo. Este método não-destrutivo de avaliação das características dielétricas é a grande vantagem deste monitor.

O Centurion® apresenta, em sua caracterização do dielétrico, sensibilidade a umidade, partículas metálicas e carbono entre outras impurezas, além de alguma degradação do óleo (queima). Também, como muitos dos mecanismos que geram gases dissolvidos produzem variações da rigidez dielétrica do óleo, qualquer mudança sensibilizada pelo Centurion® pode indicar uma necessidade de análise de DGA em uma amostra de óleo.

As características principais do Centurion® são (WEIDMANN, 2003):

- Monitoramento: Rigidez Dielétrica Relativa.
- Sensibilidade: Umidade; Contaminação de carbono, metais e outros.
- Tempo de Resposta: Seleccionável (padrão: 6h).
- Temperatura do óleo: 0 – 100°C.
- Comunicação: RS – 232.

3.3.3.2 GMM® – Tree Tech

A Tree Tech é a desenvolvedora do sistema de medição GMM® para monitoramento de hidrogênio dissolvido em óleo isolante usados em transformadores e aparelhagens de alta tensão. O dispositivo emite alarmes caso o nível pré-estabelecido de hidrogênio seja ultrapassado, ou a taxa de geração do mesmo seja incrementada. Estes alarmes são importantes como monitoramento de falhas em estágio inicial uma vez que o hidrogênio está presente na maioria dos tipos de falhas em transformadores. Assim, o disparo de um alarme do GMM® pode indicar a eminência de uma situação de falha que pode ser confirmada e identificada através

de ma análise de DGA. Além do hidrogênio, o GMM® também monitora a temperatura e umidade relativa do óleo e, indiretamente, disponibiliza as taxas de evolução do hidrogênio e do teor de água.

O GMM® é composto por dois módulos: GMM® – medidor e GMM® – MMI, conforme mostrado na figura 3.11.



Figura 3.11 - GMM® (TREE TECH 2005)

O módulo medidor é acoplado à válvula de óleo do transformador para por em contato com o óleo as membranas para a extração do hidrogênio dissolvido no óleo e os sensores para a medição das grandezas a serem monitoradas. Esta conexão com o equipamento ativo é feita por intermédio de adaptador composto de câmara contendo o sistema de extração de gases (membranas), uma válvula de escape de ar e amostragem de óleo, um equalizador de pressão, o circuito de alimentação e o sistema de comunicação serial, padrão RS – 485, para a conexão com o módulo de interface GMM® – MMI ou rede de comunicação (TREE TECH, 2004).

O módulo de interface foi desenvolvido para disponibilizar as informações de leitura localmente através de dois displays ou remotamente pelas duas saídas de corrente, configuráveis por software. Além disso, as informações também podem transitar por duas saídas seriais, sendo uma reversível (RS 232 ou RS 485), para a conexão com

o GMM® – medidor. Para as sinalizações das condições de alarme, O GMM® - MMI possui seis LED's, oito contatos configuráveis NA / NF e um relógio interno.

Durante o modo normal de trabalho o GMM® – MMI indica em tempo real e de forma seqüencial: concentração de hidrogênio, temperatura do óleo, teor de água e taxas de evolução de hidrogênio e do teor de água. Porém, todos os cálculos das tendências e valores históricos podem ser armazenados em memória volátil.

A seguir, são apresentadas as principais características técnicas do GMM® da Tree Tech (TREE TECH, 2004):

- Monitoramento: Hidrogênio e Umidade.
- Faixa de medição (H₂): (0 a 2000) ppm (volume / volume).
- Incerteza de medição (H₂): ± 5 % da leitura ± 20 ppm.
- Faixa de medição (umidade): (0 a 100) %.
- Incerteza de medição (umidade): ± 2 %.
- Resolução: 1 ppm (µmol / mol).
- Saída analógica: Duas saídas configuráveis.
- Temperatura ambiente: (-10 a + 100) oC.
- Temperatura do óleo: (-10 a + 100) oC.
- Pressão de óleo: ± 1 MPa.
- Comunicação: RS - 232 e RS - 485.

3.3.3.3 Calisto® – Morgan Schaffer

O Calisto® foi desenvolvido pela empresa canadense Morgan Schaffer com o intuito de monitorar continuamente a concentração de hidrogênio e de água dissolvidos no óleo do transformador para aplicação em manutenção preditiva. A baixa solubilidade

do hidrogênio no óleo e alta difusibilidade facilita a detecção mesmo em baixas concentrações antecipando alertas de falhas. Esta informação ganha peso de importância ao se tratar de transformadores críticos onde apenas um leve aumento da produção de hidrogênio pode significar um indício de falha grave. O sensor é mostrado na figura 3.12.



Figura 3.12 - Calisto® (MORGAN SCHAFFER, 2004a)

A presença de água dissolvida no óleo afeta consideravelmente as propriedades dielétricas do isolante. Logo, o monitoramento desta grandeza resulta em uma estratégia de alargar o tempo de vida útil do equipamento.

O Calisto® apresenta imunidade a interferências oriundas de variações da temperatura do óleo e ambiente, que afetam consideravelmente a solubilidade e difusão dos gases. Isto se deve ao eficiente condicionamento termoeletrônico deste dispositivo. Assim, o fabricante garante uma detecção de alto desempenho, especialmente em baixas concentrações.

Uma necessidade inerente dos monitores de proposta *on-line* é manter o sensor em contato contínuo com uma amostra representativa. No caso do Calisto® um pequeno sistema de circulação forçada do óleo responde a essa questão baseado em uma bomba de circulação interna de 60 ml/min, conforme visto na figura 3.13.



Figura 3.14 - Sistema de circulação do Calisto® (MORGAN SCHAFFER 2004a)

Uma vez em contato com o Calisto®, a extração dos gases de falha do óleo é feita por meio de uma ponta de prova especialmente projetada, baseada em múltiplos tubos capilares de teflon, que é permeável aos gases. Esses se difundem na ponta de prova em sua própria taxa específica até que um equilíbrio seja alcançado. A partir daí, toda mudança na concentração do gás no óleo começará imediatamente a modificar o equilíbrio na ponta de prova. Para o hidrogênio, 50% do valor de uma mudança na sua concentração será medida na ponta de prova dentro de aproximadamente 60 minutos. A concentração de hidrogênio é medida por um sensor de condutividade térmica. No equilíbrio, a condutividade térmica da amostra da ponta de prova reflete diretamente sua composição.

As principais características técnicas do Calisto® são apresentadas abaixo:

- Monitoramento: Hidrogênio e Umidade.
- Faixa de medição (H₂): (0 a 50000) ppm.
- Incerteza de medição (H₂): ± 5% da leitura ± 5 ppm.
- Faixa de medição (umidade): (0 a 100) %.
- Incerteza de medição (umidade): ± 2 %.
- Resolução (H₂): 5 ppm (μ mol / mol).
- Tempo de resposta (H₂): 60 minutos (para uma variação de 50%).
- Tempo de resposta (umidade): 5 minutos (para uma variação de 90%).

- Saída analógica: (4 a 20) mA.
- Temperatura do óleo: (-40 a + 120) o C.
- Pressão de óleo: Pleno vácuo até 275 kPa .
- Comunicação: Duas saídas RS 232.

3.3.3.4 Hydran® MII-GE

O Hydran® MII é um sistema contínuo de medição *on-line* e inteligente da concentração de gases dissolvidos em óleo e umidade fabricado pela GE Energy Services do Canadá.

Sendo um sensor de dupla função, o Hydran® MII consiste em um invólucro metálico diretamente conectado à válvula de saída de óleo do transformador, tendo como princípio de funcionamento uma membrana permeável a gases seletivos em conjunto com detectores de gases combustíveis e filmes capacitivos para medição de umidade. Neste módulo, há também o sistema de controle da diferença de temperatura da câmara do dispositivo que promove a circulação do óleo através dos elementos sensores e o microprocessamento de controle do instrumento. O Hydran® também possui os contatos para níveis de alarme flexíveis parametrizados via software, além do alarme de falha do sistema. No mais, saídas analógicas podem ser acopladas para uso conjunto com sistemas de monitoramento de temperatura, por exemplo. Um display e um teclado alfanumérico permitem o controle do sistema de medição sem a necessidade do uso de um computador externo (GE ENERGY SERVICES, 2005). A figura 3.15 mostra o Hydran® MII em sua aparência externa.



Figura 3.15 – Hydran® (GE ENERGY SERVICES, 2005)

A unidade de comunicação do Hydran® MII possui uma saída RS-232 para a conexão a um computador externo ou modem e uma RS-485 para a comunicação com outros dispositivos Hydran®. Este módulo também indica a leitura realizada pelos sensores Hydran® e da atuação dos alarmes.

O sensor do Hydran® MII é seletivo para Umidade Relativa (%) e Hidrogênio (H_2), Monóxido de Carbono (CO), Acetileno (C_2H_2), Etileno (C_2H_4) os quais são gases primários gerados em falhas de isolamento do transformador. Entretanto, a leitura do Hydran® não estratifica as concentrações destes gases, mas apenas dispõe uma soma ponderada dos quatro gases a que é sensível de acordo como segue (GE ENERGY SERVICES, 2005): Hidrogênio (H_2): 100% de concentração; Monóxido de Carbono (CO): $(18 \pm 3)\%$ da concentração; Acetileno (C_2H_2): $(8 \pm 2)\%$ da concentração e Etileno (C_2H_4): $(1,5 \pm 0,5)\%$ da concentração.

O Hydran® MII permite registro histórico de dados dos eventos com amostragem configurável.

As características técnicas do Hydran® MII são apresentadas abaixo (GE ENERGY SERVICES, 2005):

- Monitoramento: Umidade e Total de gases dissolvidos.
- Sensibilidade: Umidade Relativa (%); Hidrogênio (H_2), Monóxido de Carbono (CO), Acetileno (C_2H_2), Etileno (C_2H_4).
- Faixa de medição: Gás: 0 – 2000 p.p.m.; Umidade: 0 – 100%.

- Precisão: Gás: \pm (10% da leitura + 25p.p.m.); Umidade: \pm 2%.
- Resolução: 1 p.p.m. ($\mu\text{mol} / \text{mol}$).
- Tempo de Resposta: Gás: 10 minutos (Variação 90%); Umidade: 2 h (80%).
- Temperatura do óleo: -50 – 90°C
- Pressão de óleo: (0 a 700) kPa.
- Comunicação: RS – 232 e RS – 485.

3.3.3.5 True Gas® – Serveron

O True Gas®, fabricado pela Serveron, empresa norte-americana, se propõe como um cromatógrafo acoplado ao transformador. É um instrumento do tipo análise multi-gás que examina a amostra do óleo isolante disponibilizando as leituras de oito tipos de gases de falha, ou seja, uma informação completa para aplicação de métodos de DGA. Como opcional, pode-se introduzir as leituras de temperatura ambiente, do óleo e umidade e ainda, correlacioná-las com o carregamento do transformador. As amostras são realizadas com o intervalo selecionável pelo usuário entre 2 e 12h (padrão: 4h), fazendo um acompanhamento praticamente on-line da situação do transformador. A figura 3.16 mostra o dispositivo instalado em campo.



Figura 3.16 - True Gas® (SERVERON CORPORATION, 2005a)

O True Gas® apresenta sensibilidade a: hidrogênio (H₂), oxigênio (O₂), metano (CH₄), etano (C₂H₆), acetileno (C₂H₂), etileno (C₂H₄), monóxido de carbono (CO) e dióxido de carbono (CO₂).

A concepção deste tipo de monitor *on-line* considera a seguinte constituição (SERVERON CORPORATION, 2005b):

- extrator de gases montado diretamente no transformador;
- cromatógrafo acoplado ao transformador;
- tanque de verificação com concentrações conhecidas e rastreáveis de cada gás de falha, apropriado para a verificação em campo do desempenho do instrumento;
- microcontrolador e memórias não voláteis capazes de armazenar um ano de dados, modem industrial integrado e indicadores de status externos;
- True Gas software, capaz de direcionar a conexão do modem ao instrumento para download de todos os dados a um computador remoto.

As características técnicas do True Gás® são apresentadas a seguir (SERVERON CORPORATION, 2005c):

- Monitoramento: Oito gases dissolvidos no óleo (opcionais: temperatura ambiente e do óleo, umidade).
- Hidrogênio (H₂): (10 a 2000) ppm (volume / volume). ± 10% da leitura.
- Acetileno (C₂H₂): (5 a 500) ppm. ± 10% da leitura ± 1 ppm.
- Etileno (C₂H₄): (7 a 2000) ppm. ± 10% da leitura ± 1 ppm.
- Monóxido de Carbono (CO): (5 a 2000) ppm. ± 10% da leitura ± 1 ppm.
- Metano (CH₄): (50 a 2000) ppm. ± 10% da leitura.
- Etano (C₂H₆): (10 a 2000) ppm. ± 10% da leitura.

- Oxigênio (O₂): (10 a 1400) ppm. ± 10% da leitura.
- Dióxido de carbono (CO₂): (5 a 7000) ppm. ± 10% da leitura ± 1 ppm.
- Temperatura do Óleo: 15 - 55 °C.
- Período de Amostragem: 4 h.

3.3.3.6 N-TCG-6C® e PGA-200® – Mitsubishi

A Mitsubishi Electric Power Products fornece analisadores *on-line* de gases dissolvidos (*on-line* DGA) para monitoramento do nível de gases combustíveis presentes no óleo isolante. Este tipo de equipamento pode ser fornecido como parte de um novo transformador, ou geralmente, pode ser instalado em algum transformador existente sem a interrupção na operação.

As vantagens do N-TCG-6C® é a economia de custos de manutenção e tempo devido ao uso do ar atmosférico como gás de transporte e a interface de comunicação largamente aplicável a sistemas com vários monitores.

Como características principais do N-TCG-6C® da Mitsubishi, vale salientar o monitoramento do Total de Gases Combustíveis (TCG) e seis gases componentes resultante de medições automáticas dos gases extraídos diretamente do óleo. O método de extração evita contaminação externa, pelo uso do processo de degasificação e sem perda do óleo amostrado. O óleo circula através dos esforços de uma bomba de óleo e é despejado em uma câmara de vácuo. Daí os gases são extraídos da amostra na unidade de extração. O tempo estimado para a extração é em torno de 30 minutos. A figura 3.17 mostra um modelo N-TCG-6C® instalado.



Figura 3.17 – N-TCG-6C® (MITSUBISHI, 2007a)

Na detecção, os gases extraídos são carregados através da coluna de separação dos gases e do sensor composto por quatro semicondutores com filamento de platina. O sistema mantém o tempo de medição em aproximadamente 15 minutos.

Sua interface de comunicação dispõe de porta RS – 232 e RS – 485 para interligação a computadores locais e remotos.

Na versão portátil, o PGA-200® (Portable Dissolved Gas Analyzer) , também da Mitsubishi, aperfeiçoa a ação de manutenção e reduz custos devido a sua mobilidade.

A sua operação, após preparação da amostra do óleo, é extremamente fácil, pois toda a seqüência é controlada por um microprocessador.

O PGA-200® necessita de uma amostra muito pequena do óleo, cerca de 50ml e produz um resultado de análise que fornece o Total dos Gases Combustíveis e seis tipos de gases em um tempo de 10 minutos para medição. A figura 3.18 mostra o PGA-200®.



Figura 3.18 – PGA-200® (MITSUBISHI, 2007a)

Seguem as características técnicas do PGA-200® (MITSUBISHI, 2007a):

- Monitoramento: Sete gases dissolvidos e Total de gases dissolvidos.
- Sensibilidade: Hidrogênio (H₂), Monóxido de Carbono (CO), Acetileno (C₂H₂), Etileno (C₂H₄), Metano (CH₄), Etano (C₂H₆), Dióxido de Carbono (CO₂).
- Precisão: ±30% da leitura.
- Tempo de Resposta: 10 minutos.
- Volume de amostra: 50 ml.
- Temperatura ambiente de trabalho: 0 – 40°C
- Comunicação: RS – 232 e RS – 485.

3.3.3.7 Transfix® - Kelman

O Transfix® é o representante da Kelman entre a nova geração de monitores *on-line* de gases dissolvidos no óleo. Ele visa dar uma percepção essencial das condições internas dos transformadores monitorados.

Seu extenso uso prova a disponibilização confiável de informações e representa uma ferramenta valiosa no gerenciamento de manutenção. Ele mede nitrogênio (N₂), umidade e as concentrações de oito gases dissolvidos, utilizando a técnica de Espectroscopia Foto-Acústica, sem a necessidade de gases de arraste e expressa os valores das concentrações de cada gás de forma individual e em unidades de partes por milhão (p.p.m.). A figura 3.19 mostra o Transfix® instalado em um transformador.



Figura 3.19 – Transfix® (Kelman, 2007a)

O processo de Espectroscopia Foto-Acústica não necessita de gases de arraste ou calibração de gases. O efeito fotoacústico é obtido em uma célula fechada, preenchido pela amostra, no qual existe uma janela de vidro. Um feixe de luz modulada atravessa a janela, atinge a amostra e por ela é absorvida. É gerado, então, o sinal fotoacústico que é captado por um microfone no interior da célula. Este sinal é enviado para um amplificador, o qual só amplifica as componentes do sinal que possuem a mesma frequência de modulação do sinal de referência,

eliminando, portanto, sinais espúrios e indesejáveis. O sinal amplificado pode ser processado e analisado.

Neste processo, luzes espalhadas pela amostra, que constitui um sério problema nas demais técnicas de espectroscopia ótica, não provocam nenhum problema relevante, uma vez que apenas luz absorvida pela amostra é convertida no sinal desejado.

Há opções de comunicação remota através de dois canais separados, além de conexão local USB e Ethernet. Ainda, possui módulos para conexão RS – 232, RS – 485 e *modems* PSTN e *wireless*.

Os níveis de alarme são configuráveis local e remotamente através do *software* monitor podendo ser baseados no nível dos gases ou variação da taxa de crescimento, TDCG e umidade.

Abaixo, são apresentadas as características técnicas do Transfix® (Kelman, 2007a):

- Monitoramento: oito gases dissolvidos e Umidade Relativa.
- Sensibilidade: Umidade Relativa (%); Hidrogênio (H₂), Monóxido de Carbono (CO), Acetileno (C₂H₂), Etileno (C₂H₄), Metano (CH₄), Etano (C₂H₆), Dióxido de Carbono (CO₂); Oxigênio (O₂).
- Precisão: ± 5%.
- Freqüência de amostragem: variável (1 por hora - 1 por dia).
- Temperatura do óleo: -50 – 120°C
- Comunicação: RS – 232, USB, PSTN Modem, GSM.

3.3.3.8 Big Dipper® – Techno Chem

O Big Dipper® é um analisador portátil de gases dissolvidos fabricado pela empresa chinesa Techno Chem o qual pode efetuar medições de gases de falhas em óleo de transformador ou outros fluidos dielétricos em menos de 5 minutos. Desenvolvido

para uso em campo, também pode ser aplicado como contínuo analisador on-line em projetos de laboratório.

Este tipo de monitor emprega laser espectroscópico ao invés de fotometria infravermelha ou sensores eletroquímicos frequentemente usados em outros tipos de monitores. Uma vista frontal do Big Dipper® é demonstrada na figura 3.20.



Figura 3.20 – Big Dipper® (TechnoChem, 2007a)

O fotômetro a laser é uma nova tecnologia na análise de gases. A largura da linha de espectro no fotômetro a laser é usualmente abaixo de nanômetros tornando possível uma absoluta, qualitativa e quantitativa distinção de um único gás dentre os co-existentes que tenham energias de absorção muito próximas. Comparativamente, a linha de infravermelho é da ordem de 0,15 micrômetros (usualmente com filtros), ou seja, dificuldades para alta resolução devido a interferência entre os gases analisados. O tempo de vida do laser é maior que 10000 horas em trabalho contínuo. Não é necessário nenhum tipo de calibração por um longo período e nem manutenção com filtros e outros aparatos.

Na amostragem, o Big Dipper® foi projetado para utilizar o espaço de gás sobre o óleo (câmara de expansão), ou seja, não precisa de uma amostra do óleo. Porém, caso não seja possível o contato do conector de amostra com o espaço de gases sobre o óleo no transformador, amostras do óleo podem ser extraídas para um recipiente apropriado. O conector pode ser colocado em contato com o recipiente e após 5 minutos para o equilíbrio, o instrumento faz a detecção através desta amostra.

Os dados das análises podem ser armazenados em memórias e depois acessados por vários meios. Há suporte para RS – 232, RS – 485, impressora e USB para memórias removíveis.

Para cada recarga da bateria, o instrumento tem seu funcionamento garantido por mais de 24 horas.

Seguem as características técnicas do Big Dipper® (TechnoChem, 2005a):

- Monitoramento: Oito gases dissolvidos, Total de Gases Combustíveis, Umidade Relativa, Temperatura, Pressão e contaminantes.
- Sensibilidade: Umidade Relativa (%); Temperatura (°C); Pressão (kgf/cm²); Hidrogênio (H₂), Monóxido de Carbono (CO), Acetileno (C₂H₂), Etileno (C₂H₄), Metano (CH₄), Etano (C₂H₆), Dióxido de Carbono (CO₂); Oxigênio (O₂); Hexafluoreto de Enxofre (SF₆).
- Tempo de Resposta: 1 minuto (90% de variação).
- Tempo de medição: 5 minutos (*warm up*)
- Amostragem: Sem amostragem do óleo.
- Precisão: Hidrogênio= ±10%, Temperatura e pressão= ± 0,5%, demais= ± 2%.
- Temperatura ambiente de trabalho: -10 – 60°C
- Comunicação: RS – 232, RS – 485 e USB.

3.4 MONITORAMENTO ON-LINE DOS GASES DISSOLVIDOS EM TRANSFORMADORES

Três dispositivos para monitoramento do desenvolvimento das condições do óleo isolante para diagnóstico de falhas incipientes, modelo HYDRAN® MII da GE, foram instalados em três transformadores de potência de 140MVA, pertencente à CGTF - Central Geradora Termelétrica de Fortaleza, do grupo ENDESA.

Este modelo de monitor, conforme citado na subseção anterior, efetua a medição do total da concentração de gases dissolvidos, além de umidade, para monitoramento em tempo-real. Estes dados são disponibilizados pelo equipamento em intervalos mínimos de 15 minutos, com garantia de sensibilidade de Hidrogênio (H_2), Monóxido de Carbono (CO), Acetileno (C_2H_2) e Etileno (C_2H_4). O total dos gases dissolvidos é a soma das sensibilidades a esses gases.

A partir da instalação do equipamento foi elaborado um algoritmo para o fornecimento de um pré-diagnóstico utilizando as informações do total dos gases gerados no período monitorado e à tendência de queda ou subida da taxa de geração desses gases. Logo, tem-se o acompanhamento das unidades durante o período compreendido entre duas análises laboratoriais do óleo isolante.

O Guia de Interpretação de DGA do IEEE apresenta um algoritmo que leva em consideração o patamar do total dos gases dissolvidos no óleo isolante de um transformador e a tendência de evolução deste valor (IEEE, 1991). Uma vez que o sensor utilizado não permite a estratificação dos valores dos gases gerados individualmente, de forma a se fazer uma análise cromatográfica completa on-line, toma-se esse algoritmo sugerido acima para implementar um pré-diagnóstico que consiga mostrar qualitativamente a produção de gases dissolvidos no óleo e a tendência de evolução dessa produção. Assim, pode-se classificar, em até quatro níveis, a condição de trabalho da unidade monitorada, sendo uma condição normal, duas intermediárias e a última, crítica.

A partir deste pré-diagnóstico, pode-se disponibilizar uma série de procedimentos condizentes com a classificação feita indo de continuidade normal da operação até retirada de funcionamento da unidade para análise mais detalhada do óleo, ou seja, cromatografia laboratorial.

Tratando-se a cromatografia como um procedimento relativamente caro e observando a desvantagem de que a unidade não tem uma cobertura de monitoramento entre os intervalos de retirada do óleo para este tipo de análise, o pré-diagnóstico se configura como uma oportunidade de se resguardar o transformador durante o citado período e de se estabelecer a otimização do tempo em que a cromatografia é realmente necessária.

3.5 ANÁLISE DOS RESULTADOS

Os métodos de acompanhamento da quantidade de gás dissolvido em óleo e os sistemas de medição descritos neste capítulo nos apresentaram as ferramentas disponíveis para a elaboração de um sistema de monitoramento *on-line* das condições de isolamento de transformadores de potência.

Como visto as tecnologias empregadas nestes processos de monitoramento são variadas e a aplicação de cada uma delas fica a cargo de estudos que revelem quais as características mais interessantes em relação ao custo do equipamento.

Há de se avaliar que, geralmente, estes recursos, em menor ou maior grau, podem ser a diferença na administração de ativos de uma companhia que tem sua cadeia produtiva dependente da continuidade do serviço de um transformador, por exemplo.

Junto destes monitores, normalmente há uma avaliação das grandezas medidas através de técnicas de interpretação implementadas em *software*. O propósito sempre é emitir um alerta que antecipe uma falha em fase ainda incipiente, rendendo à manutenção preditiva uma ferramenta para administrar a extensão da vida útil dos equipamentos isolados a óleo.

Uma experiência de monitoramento *on-line* foi descrita e um algoritmo alternativo foi estabelecido como intuito de providenciar procedimentos diante de possíveis situações de falha. O algoritmo de pré-diagnóstico desenvolvido apresentou resultados satisfatórios em relação aos transformadores com o equipamento de monitoramento *on-line* instalado, inclusive reduzindo os insumos com seguro das unidades monitoradas, significando um reconhecimento da eficácia deste tipo de proteção.

Capítulo 4

DIAGNÓSTICO DE FALHAS INCIPIENTES EM TRANSFORMADORES UTILIZANDO INTELIGÊNCIA ARTIFICIAL

Os sistemas nebulosos e as redes neurais artificiais podem ser projetados para identificar padrões em processos lineares, não-lineares e variantes no tempo. Pois, no universo da inteligência artificial, tanto os sistemas nebulosos como as redes neurais são considerados aproximadores universais. Os estudos para desenvolver módulo de diagnóstico baseado em Redes Neurais Artificiais (RNA) e Sistemas Nebulosos (*Fuzzy*) são descritos neste capítulo.

Primeiro, são apresentadas as arquiteturas, o método de treinamento e as principais características das redes neurais desenvolvidas para o módulo do sistema que utiliza este método de diagnóstico. As redes neurais empregadas são do tipo supervisionadas e alimentadas adiante (*feed-forward*): *perceptron* de múltiplas camadas (MLP). Na realização das etapas de treinamento e validação foram utilizados dois algoritmos de treinamento (*Adaptative Back-Propagation* e *Levenberg-Marquardt*) alimentados pela base de dados do apêndice C. Depois, o restante deste capítulo propõe três classificadores de padrões, utilizando sistemas nebulosos com diferentes bases de conhecimento, para identificar falha incipiente em transformadores de potência imersos em óleo. É discutida a definição das bases de conhecimento, os padrões de entrada e saída e a possível construção de diagnóstico em conjunto entre os sistemas nebulosos.

Portanto, o capítulo está dividido como segue. Na seção 4.1 apresenta-se o processo de definição das características da RNA aplicada no diagnóstico de falhas através de dois algoritmos de treinamento. Na seção 4.2 desenvolve-se a modelagem nebulosa, comparando-se três bases de conhecimento, utilizada para realizar o diagnóstico de falhas incipientes. A seção 4.3 analisa os resultados obtidos com os sistemas quando submetidos a testes com a base de dados apresentada no Apêndice C. As conclusões do capítulo são apresentadas na seção 4.4.

4.1 DIAGNÓSTICO DE FALHAS INCIPIENTES UTILIZANDO REDES NEURAIS ARTIFICIAIS

Desde que todos os fenômenos relacionados ao diagnóstico de falhas em transformadores são caracterizados por imprecisões, incertezas nas medidas e não-linearidades não modeladas, métodos convencionais, combinados com métodos baseados em inteligência computacional e em especial, os sistemas nebulosos e neurais podem ser empregados de forma eficiente para diagnósticos automáticos de falhas (LIMA *et al.*, 2006).

Visando a resolução da problemática do diagnóstico de falhas incipientes, as redes neurais foram utilizadas como classificadores de padrões devendo apresentar como resposta de diagnóstico a classe à qual pertence um determinado vetor n -dimensional de entrada.

Entre as principais características das redes neurais é mencionada a capacidade de realizar um mapeamento não-linear entre as entradas e saídas, conservando o fluxo de sinal sempre adiante, são *feed-forward*. E, em geral, os neurônios de uma camada são totalmente conectados aos da seguinte, conforme ilustrado na figura 4.1.

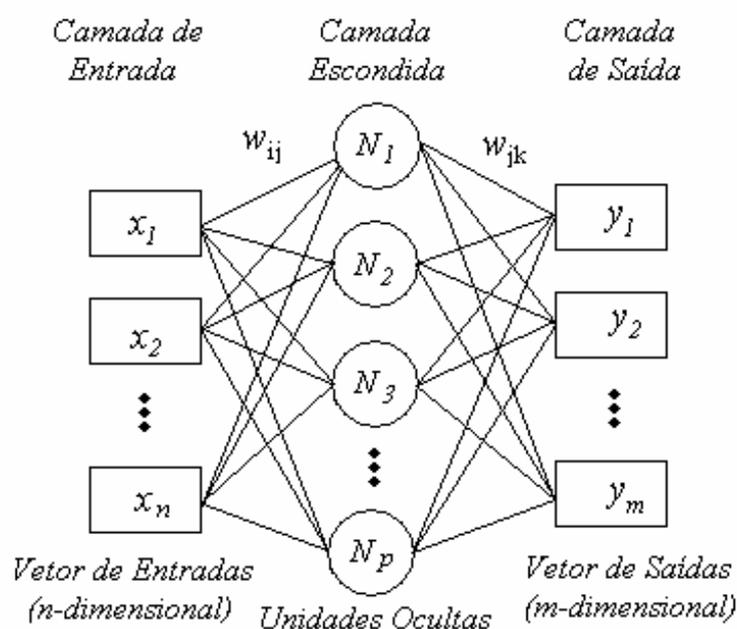


Figura 4.1 – RNA feed-forward totalmente conectada.

Supõe-se que as relações entre o vetor de entrada (X) e o vetor de saída (Y) são definidas pela natureza física do problema, e estas relações podem ser representadas por um número limitado de pares de entrada-saída que são as amostras de dados. Estas suposições são de fundamental importância, principalmente para analisar se uma determinada amostra é realmente representativa para um dado sistema. O número de neurônios da camada de entrada é, logicamente, igual à quantidade de atributos de entrada (dimensão do vetor de entrada, n). Com relação à camada de saída, um único neurônio pode ter sua saída escalonada exatamente no número de padrões a classificar ou pode ser definida uma quantidade de neurônios igual ao número de classes que se deseja identificar (dimensão do vetor de saída, m). No primeiro caso, o vetor de saída possui um único elemento que coloca em sua saída um único valor que representa a classe em resposta a um vetor de entrada na rede. No segundo caso, cada neurônio da camada de saída representa uma classe ou um tipo de falha incipiente que responde com um vetor de saída formado pelos valores individuais de cada neurônio de saída quando um padrão é introduzido na entrada da rede. A determinação da classificação vem da identificação do neurônio que apresentou maior valor de saída sendo a classe solidária a este neurônio o diagnóstico da rede. Este último tipo de estratégia de classificação se chama regra do vencedor leva tudo (LIMA, 2004).

Assim, as entradas são descritas por atributos quantitativos, ou seja, os valores numéricos dos gases dissolvidos, enquanto a saída desejada é um atributo qualitativo, o diagnóstico das falhas.

A aplicação de redes neurais no diagnóstico de falhas apresenta duas fases. A primeira fase é o processo de treinamento, durante o qual um conjunto de amostras de dados é fornecido à rede. Nesta fase, os pesos dos neurônios da rede são ajustados iterativamente para “memorizar” as relações de entrada-saída. A segunda fase é um processo de teste ou validação, durante o qual um conjunto de amostras é apresentado à rede, e saídas são calculadas através dos valores dos pesos memorizados pela rede (MOTA *et al.*, 2007).

Para a implementação deste módulo de diagnóstico foi projetada uma estrutura de rede neural Perceptrons de Múltiplas Camadas (*Multi-Layer Perceptrons* – MLP) com dois métodos de treinamento: *Adaptive Back-Propagation* e Levenberg-Marquardt.

4.1.1 Perceptrons de Múltiplas Camadas – MLP

Em termos de aplicações em reconhecimento de padrões, A MLP é talvez a rede neural mais popular (RAYKIN, 1994). O seu poder computacional de aprender através da experiência mediante treinamento faz a sua fama de eficiente nestas aplicações. Entretanto, esta mesma característica também é responsável por não demonstrar diretamente o conhecimento do comportamento interno da rede, a não ser pelo uso de técnicas especiais de extração de conhecimento (MIRANDA; CASTRO, 2005).

A princípio, a análise de uma MLP, traz um confronto com uma distribuição de unidades não-lineares sob um emaranhado de neurônios altamente conectados, inclusive em camadas escondidas tornando o processo de aprendizagem menos transparente ou difícil de ser visualizado. Em um sentido mais amplo, o desenvolvimento do processo de aprendizagem vai direcionando os neurônios da camada oculta a representarem as características mais relevantes dos padrões apresentados à interface de entrada.

Sua constituição pode ser definida, conforme mostra a figura 4.1, por uma camada de entrada, onde os retângulos indicam os neurônios que perfazem a interface de entrada (X), uma ou mais camadas intermediárias ou escondidas, representada pelos círculos e uma camada de saída, onde os retângulos indicam os neurônios que perfazem a interface de saída (Y). As setas denotam cada conexão e esta mantém uma associação com um peso sináptico (w_{ij}) que pondera a referida entrada i do neurônio j . A relação existente entre entrada e saída de um neurônio j é descrita através da equação 4.1.

$$y_j^{(l)} = \Phi(v_j^{(l)}) = \Phi\left(\sum_{i=0}^p w_{ij}^{(l)} x_{ij}^{(l)}\right) \quad (4.1)$$

onde l identifica a camada ($l > 0$, a camada de saída é a terceira camada), y_j é a saída do j -ésimo neurônio, v_j é a soma de pesos dos neurônios de entrada, x_{ij} é a i -ésima entrada do neurônio (p entradas da camada anterior e a polarização), w_{ij} é o peso da i -ésima entrada para o j -ésimo neurônio, e $\Phi(\cdot)$ denota a função de ativação do neurônio.

Para o modelo de um neurônio, o valor da saída deste é calculado a partir da utilização da soma das entradas ponderadas pelos seus respectivos pesos sinápticos. Este somatório é usado como argumento para uma função de ativação $\Phi(v)$ não-linear. Assim, a função logística da equação (4.2) e a função tangente hiperbólica da equação (4.3) são as formas mais utilizadas por serem simétricas e preservarem características de saturação e monotonicidade na faixa dinâmica.

$$\Phi(v) = \frac{1}{1 + \exp(-av)} \quad (4.2)$$

$$\Phi(v) = \tanh(av) = \frac{1 - \exp(-av)}{1 + \exp(-av)} \quad (4.3)$$

onde $\exp(\cdot)$ é a função exponencial, v ($-\infty < v < \infty$) é o argumento da função de ativação (somatório ponderado das entradas menos a polarização), a ($a > 0$) é o parâmetro que determina a inclinação da transição suave da sigmóide.

A função de ativação pode assumir qualquer forma, porém deve obedecer ao pré-requisito de ser contínua e suave. Esta ressalva é importante quando se aplica o algoritmo de retro-propagação do erro que carece da informação da derivada da função de ativação. Com isto, observar que esta função seja totalmente diferenciável se torna uma exigência básica para a correta escolha da função de ativação. Assim, as derivadas das funções logística e tangente hiperbólica são apresentadas, respectivamente, nas equações 4.4 e 4.5, por estas possuírem suas derivadas contínuas.

$$\Phi'(v) = a \cdot \Phi(v) \cdot [1 - \Phi(v)] \quad (4.4)$$

$$\Phi'(v) = a \cdot [1 + \Phi(v)] \cdot [1 - \Phi(v)] \quad (4.5)$$

4.1.2 Definição da arquitetura MLP

Na busca da definição da arquitetura de MLP mais adequada à aplicação em diagnóstico de falhas incipientes há de se considerar que este problema se refere a um mapeamento não-linear complexo, uma vez que as entradas e saídas são ambas

multivariáveis e não há uma relação linear entre elas até o presente momento. Tomando esta consideração como orientação para a melhor estrutura de MLP e lembrando que uma MLP de três camadas, com apenas uma camada escondida, tem a capacidade de aproximar qualquer função contínua e limitada, com determinada precisão (CYBENKO, 1989; HECHT-NIELSEN, 1990), independente de sua complexidade, é possível definir esta quantidade de camadas para a MLP a ser desenvolvida. Com relação ao algoritmo de treinamento, o extremo sucesso das aplicações da retro-propagação do erro evidencia que esta estratégia pode ser aconselhável aqui. Com esta estrutura definida espera-se que uma MLP seja capaz de modelar com suficiente precisão o problema do diagnóstico de falhas. No projeto do adequado vetor de entradas que alimenta a rede neural, inicialmente foram utilizados os valores diretos das concentrações dos gases hidrogênio (H_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4), acetileno (C_2H_2), monóxido de carbono (CO) e dióxido de carbono (CO_2), oriundos dos relatórios das análises cromatográficas em exposição no Apêndice C. No entanto, outro teste foi feito utilizando as razões das concentrações dos gases conforme definido no método revisado de Rogers padronizado pelas normas do IEEE/IEC/ABNT R1, CH_4/H_2 , R2, C_2H_2/C_2H_4 e R5, C_2H_4/C_2H_6 . O desempenho da rede, quando utilizadas as razões entre as concentrações dos gases ou as concentrações diretas será verificado. Entretanto, no caso da classificação de falhas envolvendo a celulose, é necessário se considerar a relação definida CO_2/CO , denotada aqui por R6 (IEC 60599, 1978; KAN; MIYAMOTO, 1995; WANG, 2000). Assim, três tipos de vetores de entrada foram utilizados: *i*) sete entradas, com aplicação direta das concentrações dos gases; *ii*) três entradas, com aplicação das razões R1, R2 e R5 e *iii*) quatro entradas, utilizando as razões R1, R2, R5 e R6, conforme respectivamente mostrados nas equações 4.6, 4.7 e 4.8.

$$X = \begin{pmatrix} x_0 \\ x_1 \\ \vdots \\ x_6 \end{pmatrix} \quad (4.6)$$

$$X = \begin{pmatrix} x_0 \\ x_1 \\ x_2 \end{pmatrix} \quad (4.7)$$

$$X = \begin{pmatrix} x_0 \\ x_1 \\ x_2 \\ x_3 \end{pmatrix} \quad (4.8)$$

Também foi definida a polarização (*bias*) para todos os neurônios, sendo esta de valor inicial 1.

Com relação à saída da rede neural, para cada padrão de falha foi associado um valor numérico, logo, o único neurônio de saída apresenta o diagnóstico através deste tipo de código. O diagnóstico via rede neural apresenta estas possibilidades: falha térmica de baixa temperatura (1), falha térmica de alta temperatura (2), descargas de baixa energia (3), descargas de alta energia (4), degradação da celulose (5) e normal (6).

Para finalizar a abordagem acerca das camadas da MLP, é importante salientar que as camadas escondidas são de suma relevância no desempenho da rede através do número de camadas e da quantidade de neurônios em cada uma delas. Entretanto, há de se observar o compromisso na definição destes parâmetros, pois uma quantidade de neurônios insuficiente deixa a MLP simples demais para a resolução do problema, o que é conhecido por *underfitting*. Por outro lado, um número exacerbado de unidades escondidas conduz a rede a absorver detalhes irrelevantes das amostras fornecidas na etapa de treinamento prejudicando a capacidade de generalização da rede, o que pode ser chamado de *overfitting*.

No intuito de se definir a melhor topologia para a MLP sugerida, em termos do número de camadas escondidas e seus respectivos neurônios comparou-se o percentual de acerto das diversas configurações em uma série de simulações. Os resultados mais promissores advieram de uma composição com apenas uma

camada escondida fortalecendo o que é defendido em Cybenko (1989) e Hecht-Nielsen (1990).

A função de ativação tangente hiperbólica foi utilizada nos neurônios da camada escondida e a função linear no neurônio de saída. O critério de parada do treinamento é realizado através do monitoramento do índice de acerto no conjunto de dados de validação para cada época de treinamento. Portanto, com o objetivo de não permitir que a rede aprenda detalhes demais do conjunto de treinamento (*overtraining*), neste projeto, o treinamento é interrompido quando o erro de validação subir por 5 validações consecutivas ou quando é atingido o número máximo de épocas possíveis, neste caso, de 30.000 épocas.

Com a dificuldade de convergência durante as simulações, foi verificada a importância de se realizar o pré-processamento dos dados mediante normalização, uma vez que as dimensões dos valores das entradas são amplamente diferentes. Assim, a normalização foi efetuada de forma a ter média igual a 0 e desvio padrão igual a 1, redimensionando o domínio dos dados para os limites adequados para garantir uma convergência.

Para evitar que os pesos da MLP tendessem para alguma classe de padrão a série de dados de treinamento foi organizada de forma tal que cada classe apresentasse quantidades aproximadamente iguais de amostras.

4.1.3 Algoritmos de treinamento MLP - *Back-Propagation* e *Adaptive Back-Propagation*

O treinamento de uma MLP utilizando o algoritmo de retro-propagação do erro (*error back-propagation*) foi essencialmente desenvolvido e popularizado por Rumelhart *et al.* (1986). O principal objetivo do algoritmo *Back-Propagation* (BP) é determinar e ajustar um vetor de pesos sinápticos que minimize o erro quadrático, entre a saída desejada e a atual saída da rede, em um dado conjunto de amostras durante a etapa de treinamento. Para tanto, utiliza-se de manipulações com o gradiente da função deste erro no que se convencionou denominar de regra delta generalizada, RDG (KOVACS, 2002).

Durante o processo de treinamento, ocorre a necessidade de se ajustar os pesos sinápticos dos neurônios das camadas ocultas que, por definição, não possuem contato com a saída da rede. Na verdade, esses neurônios carecem que um parâmetro seja definido de forma a atribuir um valor relacionado ao erro calculado que permita a correta atualização dos pesos. Para isso, o erro obtido na saída retrocede em direção à entrada através das camadas escondidas atualizando os parâmetros de todos os neurônios de cada camada, daí o nome retro-propagação (*back-propagation*).

O algoritmo *Back-Propagation* pode ser compreendido sob a ótica de duas etapas. A primeira é a etapa de propagação adiante, também conhecida como alimentação direta que se refere ao cálculo das saídas dos neurônios de cada camada e a determinação do erro da saída da MLP. Como nesta etapa os pesos sinápticos da MLP são fixos, a equação 4.1 é utilizada para obtenção das saídas dos neurônios das camadas escondidas e de saída da MLP. A segunda etapa é a propagação reversa ou retro-propagação do erro, onde todos os pesos sinápticos são ajustados de modo a minimizar o erro na saída. A seguir é apresentado o processo de treinamento passo a passo:

Passo 1: Os parâmetros iniciais do algoritmo de treinamento são ajustados heurísticamente, tais como a taxa de aprendizagem e os pesos sinápticos. Estes últimos são ajustados preferencialmente para pequenos valores aleatórios, geralmente, no intervalo [0,1].

Passo 2: Estabelece-se um critério de parada para o treinamento. Pode-se determinar um número máximo de épocas de treinamento e/ou um patamar de erro satisfatório atingido.

Passo 3: É apresentado um par entrada-saída e calcula-se a saída das camadas da rede utilizando a equação 4.1. Calcula-se o erro na última camada e atualiza-se o erro quadrático médio (*EQM*):

$$e_j(t) = d_j(t) - y_j(t) \quad (4.9)$$

$$EQM \leftarrow EQM + \frac{1}{m} \left[\sum_{j=1}^m e_j^2(t) \right] \quad (4.10)$$

onde e_j representa o sinal de erro do neurônio j na camada de saída, ou seja, diferença entre a saída desejada d_j e a saída atual y_j , m é o número de neurônios da camada de saída e t é o número da iteração de treinamento dentro da época atual.

Assim o sinal de entrada é propagado até a saída (propagação direta).

Passo 4: Cálculo dos gradientes locais (retro-propagação do erro):

$$\delta_j^{(l)}(t) = \begin{cases} e_j^{(l)} \Phi' \left(v_j^{(l)}(t) \right) \rightarrow \text{camada de saída} \\ \Phi' \left(v_j^{(l)}(t) \sum_k \delta_k^{(l+1)}(t) w_{kj}^{(l+1)}(t) \right) \rightarrow \text{camada escondida} \end{cases} \quad (4.11)$$

onde $\Phi'(\cdot)$ denota a derivada da função de ativação, δ é o gradiente local e w_{kj} é o peso da ligação entre o k -ésimo neurônio da camada $l+1$ e o j -ésimo neurônio da camada l .

Passo 5: Ajusta-se o valor dos pesos:

$$w_{ji}^{(l)}(t+1) = w_{ji}^{(l)}(t) + \alpha w_{ji}^{(l)}(t-1) + \eta \delta_j^{(l)}(t) y_i^{(l-1)}(t) \quad (4.12)$$

onde w_{ij} é o peso da i -ésima entrada para o j -ésimo neurônio, η é o parâmetro da taxa de aprendizagem, α é o coeficiente de momento, t é o número da iteração dentro da época atual e l identifica a camada cujo os pesos estão sendo atualizados.

Passo 6: Retorna ao passo 3 até a apresentação de todos os dados do conjunto de treinamento (época).

Passo 7: Ao final de uma época, verificar o critério de parada definido no passo 2 e determinar o encerramento ou não do treinamento.

Como o algoritmo *Back-Propagation* convencional é um procedimento local, ele é susceptível aos problemas de convergência e aprisionamento em mínimos locais. Também, a existência de regiões muito planas no universo de erro pode prejudicar a velocidade de convergência, pois isto significa um valor de gradiente pequeno. E a

velocidade de convergência está diretamente relacionada com a taxa de aprendizagem, que em suma, define o tamanho do passo que se dará em cada interação. Por consequência, uma taxa de aprendizagem muito alta pode fazer o algoritmo oscilar e se tornar instável. Porém, uma taxa de aprendizagem muito baixa pode levar o algoritmo a uma convergência demasiadamente lenta. Para dirimir estes problemas foram utilizadas algumas modificações, tais como: utilização do coeficiente de momento e adaptação da taxa de aprendizagem. A primeira permite que a rede seja imune a pequenas características da superfície de erro, dificultando o aprisionamento em mínimos locais rasos. Já a segunda, permite uma taxa de aprendizagem variável debaixo de um compromisso de manter o passo de aprendizagem tão amplo o possível quanto estável. Tal algoritmo é conhecido como *Adaptative Back-Propagation*.

A taxa de aprendizagem é iniciada em 0,3 e a constante de momento de 0,7, escolhas baseadas no extensivo estudo de Zhang (1996). Inicialmente, a saída da rede e o erro são calculados. Baseado na taxa de aprendizagem inicial, novos pesos e *biases* são calculados para uma nova atualização da saída e do erro. Porém, a estratégia de atualização da taxa de aprendizagem a cada época de treinamento é: se o erro quadrático médio da época atual exceder em 4% o anterior, então o coeficiente de aprendizagem é decrementado em 30% e os novos valores dos pesos e *biases* são descartados. Se o erro quadrático médio da época atual é inferior ao da anterior então a taxa de aprendizagem é multiplicada por 1,05.

Esta estratégia incrementa a taxa de aprendizagem, mas somente o bastante para que a rede aprenda sem aumentar a taxa de erro. A utilização deste método de treinamento proporcionou uma redução do tempo de treinamento, pois possibilita uma convergência mais rápida quando comparado ao *Back-Propagation* convencional (PATEL; KHUBCHANDANI, 2004). A figura 4.2 apresenta o fluxograma do algoritmo de treinamento *Back-Propagation*.

4.1.4 – Algoritmo de Treinamento Levenberg-Marquardt

Conforme visto, o desempenho do algoritmo de treinamento *Back-Propagation* é amplamente sensível à configuração do coeficiente de aprendizagem e utiliza somente a primeira derivada da função de erro. Uma alternativa para o algoritmo

Back-Propagation é o treinamento baseado no método de Levenberg-Marquardt, LM (Levenberg 1944, Marquardt, 1963). Este método envolve o uso da derivada segunda da função a ser minimizada acelerando a convergência. Na verdade, trata-se de um aperfeiçoamento do método de Gauss-Newton, que é uma variante do método de Newton.

O método de Newton usa a informação da derivada parcial de segunda ordem do índice de desempenho utilizado para corrigir os pesos permitindo que, além da informação do gradiente sejam usadas, também, informações da curvatura do erro (RANGANATHAN, 2004).

Apesar de convergir rapidamente, o método de Newton se torna complicado e custoso devido à computação de matriz Hessiana, formada pelas derivadas segundas. Porém, o método das secantes, conhecido como Quasi-Newton se baseia no método de Newton, mas não requer o cálculo direto da matriz Hessiana, utilizando uma aproximação (GONÇALVES *et al*, 2005).

No algoritmo de LM, quando a função de *performance* apresenta a forma de uma soma de quadrados, como no caso do treinamento das redes *feed-forward*, então a matriz Hessiana pode ser aproximada conforme a equação 4.13, a seguir:

$$H(\bar{w}) = J^T(\bar{w})J(\bar{w}) \quad (4.13)$$

onde \bar{w} é a representação dos pesos e *biases* e J é a matriz Jacobiana que contem as primeiras derivadas dos erros da rede com respeito aos pesos e *biases*.

Daí, o gradiente pode ser obtido mediante a equação 4.14:

$$g(\bar{w}) = J^T(\bar{w})e(\bar{w}) \quad (4.14)$$

onde g é o gradiente e e é o vetor de erros da rede.

O problema é que a matriz Hessiana, conforme definida na equação 4.13, pode não ter inversa. A modificação de Levenberg-Marquardt propõe uma solução adicionando a parcela μI à matriz Hessiana, onde μ é um escalar, conhecido como

tamanho de passo adaptativo e I é a matriz identidade resultando na equação 4.15 para atualização dos pesos e *biases* (HAGAN *et al.*, 1994; JAZAYERI *et al.*, 2007).

$$\bar{w}_{k+1} = \bar{w}_k - [J^T(\bar{w})J(\bar{w}) + \mu I]^{-1} J^T(\bar{w}) e(\bar{w}) \quad (4.15)$$

onde k é a época atual de treinamento.

Dessa forma, quando o escalar μ é próximo de zero o método LM comporta-se em no método de Gauss-Newton. Porém, quando o escalar μ assume valores elevados, o comportamento é semelhante ao de um método de descida mais íngreme, como o *Back-Propagation*. Os métodos de Newton são mais precisos numa região próxima de um erro mínimo, ou seja, próxima à convergência. Porém, no caso do aumento do valor do índice de *performance*, então seguir o gradiente descendente deve ser a melhor escolha. Assim, μ é decrementado a cada época bem sucedida (com redução do índice de *performance*) e incrementado apenas a cada época que poderia levar o índice de *performance* a aumentar. Isto resulta em uma função de *performance* sempre reduzida a cada época de treinamento.

Seguem os passos para o algoritmo de treinamento Levenberg-Marquardt:

Passo 1: São ajustados os parâmetros iniciais do algoritmo de treinamento, como o valor inicial do escalar μ , e suas taxas de decréscimo e acréscimo.

Passo 2: Estabelece-se um critério de parada para o treinamento podendo ser um valor satisfatório da função de *performance* ou número de épocas de treinamento, ou ainda um valor de gradiente pré-determinado.

Passo 3: É apresentado um par entrada-saída e calcula-se a saída das camadas da rede utilizando a equação 4.1. Calcula-se o erro na última camada e atualiza-se o índice de *performance* (*EQM*), conforme 4.9 e 4.10:

Passo 4: Cálculo da Matriz Hessiana, gradiente e atualização dos pesos, conforme 4.13, 4.14 e 4.15, respectivamente:

Passo 5: Recomputa-se a função de performance. Se este valor é menor que o obtido no passo 1, então μ é reduzido através da taxa de redução pré-definida e retorna ao passo 3. Caso contrário, μ é incrementado e retorna ao passo 4:

Passo 6: verificação do critério de parada definido no passo 2 e determinar o encerramento ou não do treinamento.

Em nossa aplicação, o valor inicial de μ é 0,01, baseado em estudos de Hagan (1994), e será atualizado dependendo da distância de uma solução ótima. A taxa de decremento de μ adotada é 0,1 enquanto a de incremento é definida em 10.

Devido a essa característica de acelerar a convergência minimizando rapidamente a função de *performance* o algoritmo LM vem sendo comparado e obtendo substancial vantagem sobre outras estratégias ou até utilizada em conjunto para a obtenção de resultados ótimos (RAO; TRIPATHY, 1980; JAZAYERI et al., 2007).

4.2 DIAGNÓSTICO DE FALHAS INCIPIENTES UTILIZANDO SISTEMAS NEBULOSOS

Para se projetar um um sistema de diagnóstico baseado em lógica nebulosa, é necessário contornar duas dificuldades importantes: a definição das funções de pertinência (FP) e a especificação de uma base de regras utilizando o conhecimento empírico do comportamento do sistema (CHEN, 1996; HESK; NEPORENT, 1999; WANG, 2000; LIMA *et al.*, 2004).

4.2.1 Base de Conhecimento

Na concepção da base de conhecimento para o desenvolvimento do módulo de sistemas nebulosos foi estabelecido um profundo estudo acerca das padronizações que regem os métodos de interpretação da análise de gases dissolvidos no óleo e, conseqüentemente, determinam as linhas de pensamento acerca do diagnóstico de falhas incipientes. Também há de se considerar que os métodos padronizados por IEC, IEEE E ABNT, por exemplo, são guias de interpretação e necessitam de experiência no seu uso e passam por revisões periódicas, além de não abordarem todas as possibilidades de situações de falhas, como discorrido no capítulo 2 deste trabalho. Decorrente disso, três níveis de abrangência sobre diagnóstico de falhas

incipientes se tornaram alvo deste estudo para que fosse possível identificar quais razões de gases são relevantes e quantificar seus valores típicos determinando a base de regras e o universo de discurso das variáveis. Os três métodos que constituem a base de conhecimento geraram três sistemas nebulosos e são:

- Método de Rogers revisado com adição de regras empíricas (WANG Z., 2000);
- Método de Tsuchie (TSUCHIE, 2002).
- Método Aperfeiçoamento do critério IEC 60599 (MIRANDA; CASTRO, 2005).

No desenvolvimento do primeiro sistema, o método de Rogers revisado define a classificação dos padrões de falhas em função de três razões entre as concentrações dos gases, a saber, R1, R2 e R5. Para uma representação nebulosa destas razões, aproveita-se a definição da norma de três faixas de valores para cada uma das três entradas. Assim, a representação nebulosa é: Pequena (P), Média (M) e Grande (G), conforme ilustrado na figura 4.2, que transforma em um plano o espaço de características das entradas, e no quadro 4.1 (WANG Z., 2000).

R2		R5		
		R1	P	M
P	P	DP	---	---
	M	NORMAL	FT T1	---
	G	FT T2	FT T3	FT T4
M	P	DAEA_1	---	---
	M	---	DAEA_2	DAEA_2
	G	---	---	---
G	P	---	---	---
	M	---	DAEA_2	DAEA_2
	G	---	---	---

Quadro 4.1 – Conjunto de regras baseado no método de Rogers revisado.

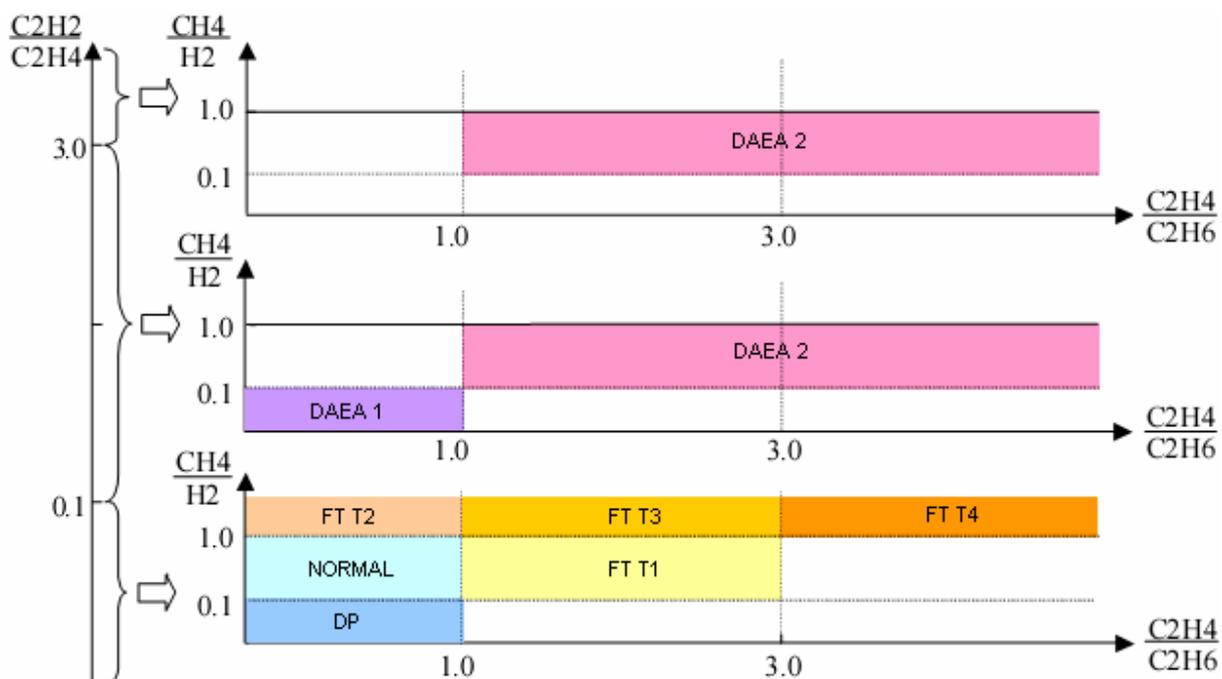


Figura 4.2 – Representação gráfica do método de Rogers revisado.

Os padrões de saída possíveis são, pelo quadro 4.1: Normal (condição de degradação e envelhecimento normal do sistema de isolamento), Descargas Parciais – DP (descargas de baixa densidade de energia), Falha Térmica em quatro níveis de sobreaquecimento FT T1 ($T < 150^\circ\text{C}$), FT T2 ($150^\circ\text{C} < T < 300^\circ\text{C}$), FT T3 ($300^\circ\text{C} < T < 700^\circ\text{C}$) e T4 ($T > 700^\circ\text{C}$) e Descargas de Alta Densidade de Energia ou Arcos-DAEA (dois níveis de densidade de energia para os arcos 1 e 2).

Conforme facilmente demonstrado na figura 4.2 e no quadro 4.1, há regiões entre combinações das variáveis de entrada onde não existe qualquer associação a um padrão de falha. Chamados de casos de não-decisão, este problema significa a existência de zonas onde não há uma forma de ter certeza acerca do diagnóstico inerente ao próprio método de Rogers revisado. Isso ocorre porque este método contempla apenas alguns casos tidos como típicos, porém não prevê que algumas das combinações das razões dos gases podem ocorrer na prática. Por esta razão, o sistema nebuloso desenvolvido utilizando esta base de conhecimento não será capaz de identificar a falha em determinadas situações, pois não é possível garantir a existência de que pelo menos uma regra seja sempre disparada para qualquer combinação de entradas do sistema.

Uma solução possível para este problema de não-decisão é a adição de algumas regras empíricas ao método de Rogers, de modo a que todas as combinações possíveis de entrada apresentem um diagnóstico (WANG Z., 2000). Entretanto, a adição de regras deve manter a consistência da base de regras, garantindo a inexistência de contradições entre premissas e conclusões.

Esta solução foi aplicada no primeiro sistema projetado. Desse modo, eliminando as situações de não-decisão, o sistema é capaz de realizar um diagnóstico para todos os valores assumidos pelas variáveis de entrada (R1, R2, R5), significando uma base de regras completa, conforme quadro 4.2.

Na figura 4.3 pode-se notar que a zona de indicação de descargas de alta densidade de energia ou arcos foi aumentada e agora possui quatro faixas distintas para classificação desse tipo de falha.

R2				
P	R1	R5		
		P	M	G
	P	DP	DP	DP
	M	NORMAL	FT T1	FT T1
	G	FT T2	FT T3	FT T4
M	P	DAEA_1	DAEA_1	DAEA_1
	M	DAEA_2	DAEA_2	DAEA_2
	G	DAEA_2	DAEA_2	DAEA_2
G	P	DAEA_1	DAEA_1	DAEA_1
	M	DAEA_2	DAEA_2	DAEA_2
	G	DAEA_2	DAEA_2	DAEA_2

Quadro 4.2 – Conjunto de regras para o sistema nebuloso 1.

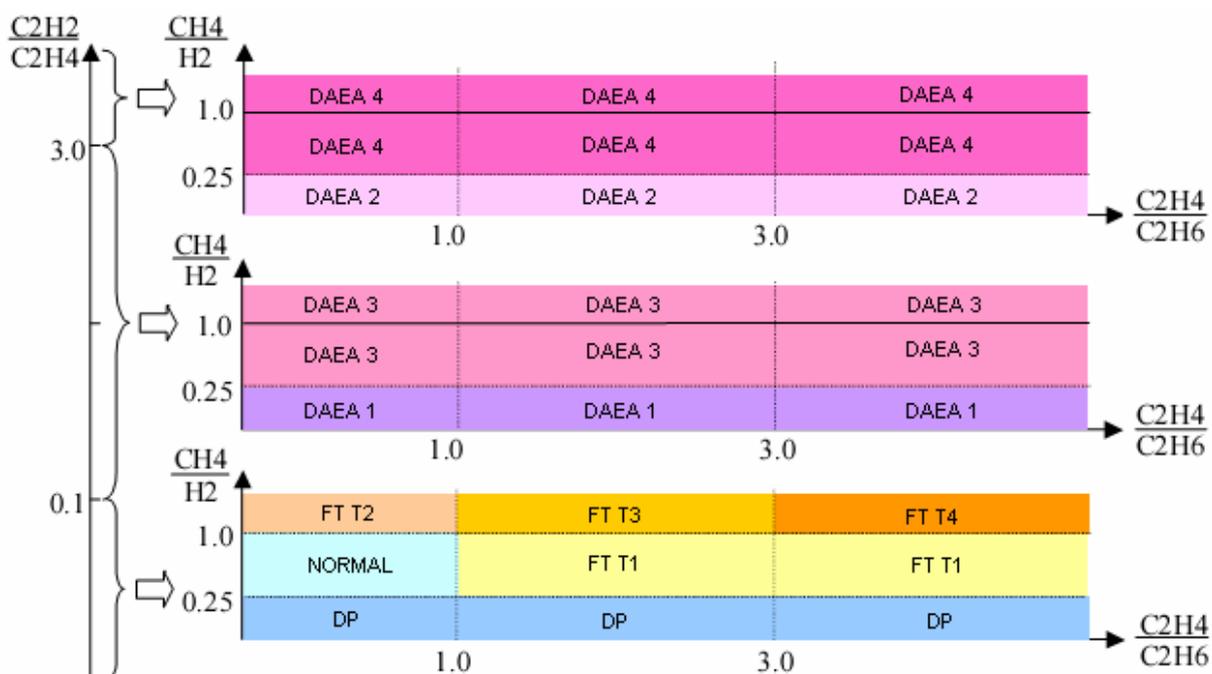


Figura 4.3 – Representação gráfica do método de Rogers revisado com adição de regras empíricas.

Uma modificação que vale a pena salientar é a fronteira inferior da faixa da razão R1 (CH_4/H_2) que era 0,1 e agora é 0,25, apenas com o intuito de melhor diferenciar diagnósticos de descargas parciais, sobreaquecimentos e normais.

No segundo sistema, a base de regras foi originada do estudo de um novo método apresentado por Tsuchie (2002). O grande diferencial desse estudo é a abordagem do diagnóstico através de apenas duas razões entre os gases dissolvidos, C_2H_2/C_2H_6 e C_2H_4/C_2H_6 , sendo que a segunda não é definida pelos padrões da norma IEC 60599. Para a configuração do sistema nebuloso, as variáveis de entrada são determinadas pelos valores destas razões, conforme ilustrado na figura 4.4 e quadro 4.3 e os quatro conjuntos nebulosos para essas entradas são definidos como: Muito Pequeno (MP), Pequeno (P), Médio (M) e Grande (G). A saída apresenta as seguintes possibilidades de diagnóstico: Falha Térmica de Baixa Temperatura – FTBT ($T < 300^\circ C$), Falha Térmica de Média Temperatura – FTMT ($300^\circ C < T < 700^\circ C$), Falha Térmica de Alta Temperatura – FTAT ($T > 700^\circ C$), Descargas Parciais - DP (descargas de baixa densidade de energia ou corona), Descargas de Média Densidade de Energia - DMDE e Descargas de Alta Densidade de Energia - DADE (arcos) (LIMA, 2004).

$\frac{C_2H_2}{C_2H_6}$	$\frac{C_2H_4}{C_2H_6}$			
	MP	P	M	G
MP	FTBT	FTMT	FTAT	FTAT
P	DP	FTMT+D P	FTAT	FTAT
M	DMDE	DMDE	DMDE	DADE
G	DADE	DADE	DADE	DADE

Quadro 4.3 – Conjunto de regras para o sistema nebuloso 2.

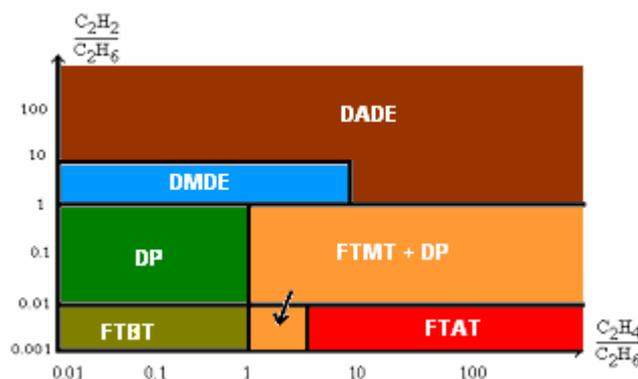


Figura 4.4 – Representação gráfica do método de Tsuchie.

Vê-se aqui uma separação das descargas de energia em três níveis, além de uma região de sobreposição de diagnósticos, no caso, falha térmica de média temperatura e descargas parciais, sugerindo uma possível transição evolutiva ou concomitância entre as falhas.

No que tange ao terceiro sistema desenvolvido, a base de regras foi originada de um aperfeiçoamento da tabela IEC 60599, mediante os estudos de Miranda e Castro (2005). No trabalho citado, a melhoria da tabela IEC 60599 foi conseguida através de extração, através de técnicas *fuzzy*, do conhecimento adquirido por uma rede neural treinada para efetuar a classificação dos padrões de falhas incipientes em transformadores de potência. De acordo com as conclusões dos autores do referido trabalho, algumas regras jamais serão ativadas e podem ser excluídas da base de regras sem incorrer nos problemas de não-decisão. O quadro 4.4 demonstra a

tabela aperfeiçoada IEC 60599 que serve de base de conhecimento para o sistema nebuloso 3. Como estrada deste sistema, permanecem as razões R1, R2 e R5. Em termos do conjunto nebuloso de entrada, a configuração dos padrões seguem: Extremamente Pequeno (EP), Muito Pequeno (MP), Pequeno (P), Médio (M), Grande (G). Para a saída do diagnóstico, as possibilidades são: Falha Térmica de Baixa Temperatura – T1 ($T < 300^{\circ}\text{C}$), Falha Térmica de Alta Temperatura – T2 ($T > 300^{\circ}\text{C}$), Descargas Parciais - DP (descargas parciais ou corona) e dois níveis de Descargas de Energia e Arcos - D1 (baixa densidade) e D2 (alta densidade).

Case	$\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$	CH_4/H_2	$\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$
PD			
	<0.1	<0.1	>2.6 or <0.36
	<0.1	0.1-0.36	<0.1 or >1.06
	0.1-0.36	<0.1	<0.1
	0.1-0.36	0.36-2.6	>2.6
	0.36-1.06	<0.36	<0.36
	0.36-1.06	1.06-2.6	1.06-2.6
	1.06-2.6	<0.36	<0.36
	1.06-2.6	0.36-1.06	0.36-1.06
	>2.6	<0.1	<0.1
	>2.6	0.1-0.36	<0.36
	>2.6	0.36-1.06	0.36-1.06
D1			
	<0.1	<0.1	1.06-2.6
	0.1-0.36	<0.36	>1.06
	0.1-0.36	<0.1	0.36-1.06
	0.36-1.06	0.36-1.06	1.06-2.6
	0.36-1.06	1.06-2.6	>2.6
	1.06-2.6	<0.1	>0.36
	1.06-2.6	0.1-0.36	0.36-2.6
	1.06-2.6	0.36-2.6	1.06-2.6
	>2.6	<0.1	>0.1
	>2.6	0.1-0.36	>0.36
	>2.6	0.36-1.06	>1.06
	>2.6	1.06-2.6	<0.1 or 1.06-2.06
D2			
	0.36-1.06	<0.36	>1.06
	1.06-2.6	0.36-1.06 or 1.06-2.6	>2.6
	0.36-1.06	0.36-1.06	>2.6
	>2.6	1.06-2.6	>2.6
T1			
	<0.1	0.36-1.06	0.1-1.06
	<0.1	>1.06	<1.06
	0.1-0.36	0.36-1.06	0.1-1.06
	<0.36	>1.06	<1.06
	0.36-1.06	1.06-2.6	0.1-0.36
T2			
	<0.1	0.1-0.36	0.1-0.36
	<0.1	0.36-1.06	<0.1 or >1.06
	<0.1	>1.06	>1.06
	0.1-0.36	0.36-1.06	<0.1 or 0.36-1.06
	0.1-0.36	>2.6	>1.06
	0.36-1.06	>2.6	<1.06

Quadro 4.4 – Conjunto de regras para o sistema nebuloso 3.

4.2.2 Funções de Pertinências

Existe a possibilidade de utilização de funções de pertinência triangulares, trapezoidais e gaussianas com variações de precisão nos resultados, segundo os estudos de Duraisamy (2007). A opção selecionada para os sistemas nebulosos desenvolvidos foi o uso de funções de pertinência triangulares para os conjuntos nebulosos médios e trapezoidais para os pequenos e grandes, para as variáveis de entrada. Alguns testes foram realizados para se obter o melhor ajuste dos parâmetros das funções de pertinência chegando aos formatos demonstrados na figura 4.5, para o primeiro sistema nebuloso. As funções de pertinência para os demais sistemas são semelhantes.

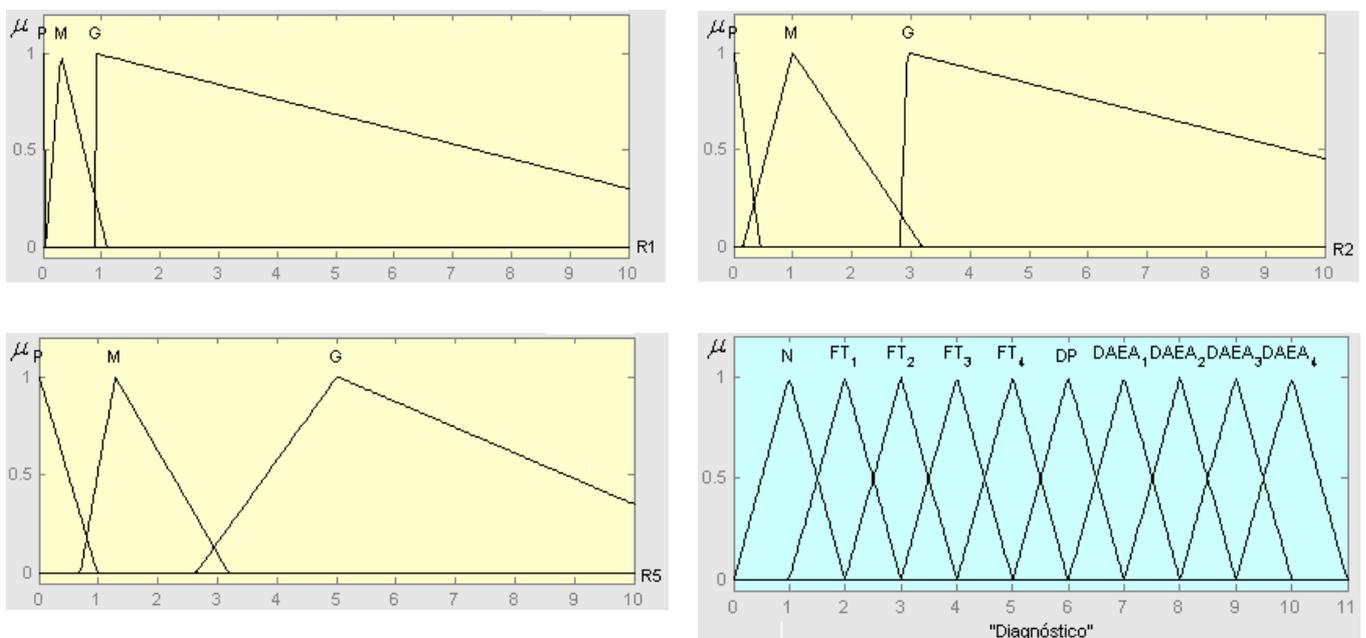


Figura 4.5 – Função de pertinência das entradas R1, R2 e R5 e saída “Diagnóstico” para o primeiro sistema nebuloso.

Para os três sistemas nebulosos propostos utilizou-se funções de pertinência triangulares para os padrões de saída, conforme figura 4.5. A saída de diagnósticos está organizada em uma sequência crescente de temperatura e níveis de densidade de energia. A análise de situações de falhas que envolvam celulose ocorre por meio de regras especiais incorporadas ao algoritmo de diagnóstico (WANG, 2000).

4.2.3 Sistema de Inferência e Matching

A implicação de Mandani é implementado na máquina de inferência, com o objetivo de formular o mapeamento das entradas para a saída através da lógica *fuzzy* (MANDANI, 1975; ZADEH, 1973). Baseado nesse mapeamento e envolvendo as funções de pertinência e a base de regras do sistema, o diagnóstico é definido na saída do sistema.

O termo conseqüente de uma regra é uma série *fuzzy* representada por uma função de pertinência que pondera apropriadamente as características lingüísticas atribuídas a ele. O conseqüente é reformatado usando uma função associada com o termo antecedente. Assim, a entrada do processo de implicação, aplicado em cada regra, é um número oriundo do termo antecedente e a saída é uma série *fuzzy*.

No intuito da tomada de decisão baseada nas regras de cada sistema, estas devem ser combinadas de algum modo. A operação de *matching*, ou agregação das saídas é o processo em que todas as séries *fuzzy* das saídas do processo de implicação são ajustadas em uma única série *fuzzy* representativa do diagnóstico final. A operação de *matching* possibilita calcular o grau de similaridade entre os padrões de falha e o conjunto nebuloso de saída da máquina de inferência, através do cálculo da área de sobreposição. O diagnóstico apresenta a falha com maior índice de similaridade.

4.2.4 Processo de desnebulização (defuzificação)

A entrada do processo de desnebulização ou defuzificação é uma série *fuzzy*. É evidente que o sistema *fuzzy* facilita a avaliação das regras, porém, a saída desejada para cada variável normalmente é numérica. Dessa forma, a desnebulização identifica o domínio das variáveis de saída do diagnóstico estabelecendo um alicerce para a obtenção do valor aproximado da temperatura ou da densidade de energia associada às falhas térmicas e elétricas, respectivamente. O método de desnebulização utilizado foi o do centro de gravidade ou centróide, o qual retorna o centro da área sob a curva.

A figura 4.6 demonstra o diagrama de blocos dos sistemas nebulosos implementados.

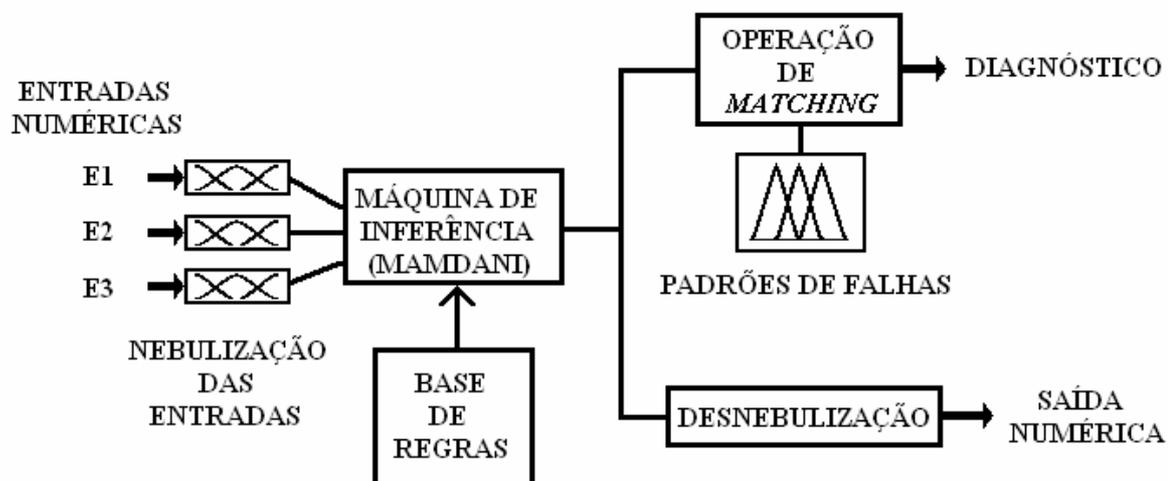


Figura 4.6 – Diagrama de blocos dos sistemas nebulosos implementados.

4.3 ANÁLISE DOS RESULTADOS

Para realização das etapas de treinamento, validação e testes das redes neurais desenvolvidas, bem como dos testes dos sistemas nebulosos propostos foram utilizadas amostras do banco de dados de análises cromatográficas dispostas no Apêndice C.

O conjunto total de dados é formado por 354 amostras selecionadas de modo que se tenha o número equilibrado de amostras para cada tipo de falha, bem como situações de normalidade.

No projeto da rede neural, os conjuntos de treinamento, validação e teste apresentam, respectivamente, 184, 100 e 70 amostras. Foi considerada como saída desejada para o processo de treinamento o diagnóstico fornecido no laudo técnico do especialista responsável pela análise dos gases dissolvidos no óleo.

A rede foi treinada com três formatos para os vetores de entrada. O primeiro, com sete concentrações dos gases, não alcançou resultados superiores a 40% de acertos entre os dados de treinamento e 5% de diagnóstico correto no processo de validação errando completamente os dados de teste. Assim, o foco do estudo se deu sobre os resultados utilizando o segundo formato e o terceiro formato de vetores de entrada, conforme definido na subseção 4.1.2. A tabela 4.1 apresenta os valores do percentual de acerto para a MLP treinada pelo algoritmo *Adaptive Back-Propagation* (identificado por ABP) e a MLP treinada via algoritmo Levenberg-

Marquardt (identificado por LM) em função do número de neurônios utilizados na camada escondida nos conjuntos de dados de treinamento, validação e teste.

Tabela 4.1 – Percentual de acerto das redes neurais.

Vetores de Entradas	Algoritmo de Treinamem.	Nº de Neurônios na Camada Escondida	Épocas de Treinam.	Diagnóstico Correto (%)		
				Treinamento	Validação	Teste
R1, R2 e R5	ABP	5	30.000	89,67	89,00	95,00
	LM	5	402	100,00	100,00	100,00
R1, R2, R5 e R6	ABP	5	30.000	86,41	85,00	82,86
	LM	5	184	100,00	100,00	100,00
R1, R2 e R5	ABP	15	30.000	90,21	88,00	87,50
	LM	15	175	100,00	98,00	97,14
R1, R2, R5 e R6	ABP	15	30.000	85,87	68,00	80,00
	LM	15	68	100,00	99,00	100,00
R1, R2 e R5	ABP	25	30.000	95,10	89,00	82,50
	LM	25	31	100,00	94,00	95,71
R1, R2, R5 e R6	ABP	25	30.000	80,43	63,00	68,57
	LM	25	21	100,00	99,00	100,00

Os melhores resultados apresentados conduzem a níveis de 100% de acerto no diagnóstico, considerando o conjunto total de dados. É importante ressaltar que em alguma generalização esporádica, poderá haver disparate entre o diagnóstico dado através das redes neurais e o diagnóstico real no transformador, pois não se pode garantir que o conjunto de dados representa todas as possibilidades de valores das razões utilizadas como entrada da rede. Também, não há como certificar que o resultado do laudo técnico do especialista, utilizado como alvo de treinamento das redes (baseado na IEC 599 e na ABNT NBR-7274) esteja completamente correto para todos os casos.

A tabela 4.1 também demonstra a velocidade superior de convergência do algoritmo de treinamento Levenberg-Marquardt em comparação com o *Adaptative Back-*

Propagation. Além disso, para um menor número de neurônios na camada escondida, é possível chegar a percentuais de acerto de diagnóstico melhores com a opção de treinamento otimizado Levenberg-Marquardt, devido a sua estratégia de acelerar a convergência e evitar mínimos locais. Assim, é possível utilizar uma rede de menor complexidade e manter um nível ótimo de eficiência no diagnóstico abrindo oportunidades para implementações em sistemas embarcados e estudos de aplicações em tempo real.

Também, o uso da razão R6 é indiferente para o diagnóstico representado pela rede neural no que concerne a identificação de casos envolvendo celulose. Haja vista que o nível de acerto para as redes com utilização desta razão é praticamente o mesmo para as redes que não contemplam R6, a menos de uma convergência mais veloz.

Com relação aos sistemas nebulosos, o conjunto de dados de testes apresenta 70 amostras, conforme o conjunto de teste das redes neurais. A tabela 4.2 apresenta os resultados obtidos com os sistemas propostos.

Tabela 4.2 – Percentual de acerto dos sistemas nebulosos.

Sistema Fuzzy	Diagnóstico Correto (%)
Sistema 1 – Rogers revisado + Regras	72,86
Sistema 2 – Tsuchie	71,43
Sistema 3 – IEC 599 Aperfeiçoada	75,71

O sistema 1, com base de regras originado do método de Rogers revisado e com adição de regras empíricas, apesar de quase 28% de erros, não apresentou casos de não-decisão. Na realidade, mais de 70% dos erros se deve à incapacidade de classificação de falhas do tipo descargas parciais.

Para o sistema nebuloso 2, baseado no método de Tsuchie, mais de 40% dos erros foram acerca da classificação de descargas parciais. No entanto, a maior parte dos erros, cerca de 57%, se deve à classificação das falhas térmicas apresentando, em geral, uma temperatura de falta em uma faixa superior à temperatura apresentada no laudo técnico.

Na análise dos resultados do sistema 3, verifica-se um desempenho superior aos outros dois métodos anteriores. Porém, este sistema nebuloso tem, em seus resultados, uma característica conservadora, pois a maioria das classificações de falha de temperatura por parte do especialista é vista pelo sistema como ocorrência de descarga parcial em mais de 55% do total de erros. Além disso, das 70 amostras apresentadas, duas não ativaram regra alguma, gerando situação de não-decisão que, por conseguinte, foram classificadas erroneamente.

Contudo, em situações críticas de falhas, envolvendo alta temperatura de sobreaquecimento e descargas de alta energia, os sistemas oferecem resultados seguros.

Entretanto, de acordo com os resultados obtidos, também é possível concluir que a integração dos sistemas 1 e 2 pode fornecer um diagnóstico de ampla eficiência. Quando efetuado, conseguiu-se percentual de acerto de 81,43%, superando os três sistemas nebulosos de diagnóstico isolados. Atuando em conjunto, os dois sistemas somente erraram classificações de descargas parciais.

A tabela 4.3 estabelece uma comparação em termos de eficiência de diagnóstico entre os métodos inteligentes desenvolvidos de melhor desempenho, o critério padrão IEC 599 e a falha real no equipamento amostrado. A tabela 4.4 contém 6 exemplos de amostras utilizadas na comparação de eficiência entre os métodos desenvolvidos. O diagnóstico via rede neural é representado pela MLP, vetor de entrada com quatro razões (R1, R2, R5 e R6) e treinamento Levenberg-Marquardt, com 5 neurônios na camada escondida. Enquanto o diagnóstico *fuzzy* é figurado pelo sistema conjugado, formado pelos sistemas 1, Rogers revisado com adição de regras e 2, método de Tsuchie.

Tabela 4.3 – Comparação entre os métodos de diagnósticos.

Amostra	Critério IEC	Diagnóstico Sistema Fuzzy	Diagnóstico Redes Neurais	Diagnóstico Real
1	Falha Térmica Baixa Temperatura	Falha Térmica Baixa Temperatura	Falha Térmica Baixa Temperatura	Falha Térmica Baixa Temperatura

Amostra	Critério IEC	Diagnóstico Sistema Fuzzy	Diagnóstico Redes Neurais	Diagnóstico Real
	150-300°C			
2	Falha Térmica de Média Temperatura 300-700°C	Falha Térmica Alta Temperatura	Falha Térmica Alta Temperatura	Falha Térmica Alta Temperatura
3	Falha Térmica Baixa Temperatura	Falha Térmica Baixa Temperatura	Descargas Parciais	Descargas Parciais
4	Descarga de Baixa Energia	Descarga de Alta Energia	Descarga de Alta Energia	Descarga de Alta Energia
5	Normal	Sobreaquecimento na Celulose	Sobreaquecimento na Celulose	Sobreaquecimento na Celulose
6	Sem Classificação	Normal	Normal	Normal

Tabela 4.4 – Exemplos das amostras testadas.

Amostra	H ₂	CH ₄	CO	CO ₂	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂
1	24	120	690	2616	38	64	0
2	30	225	678	3374	168	76	0
3	58	83	1325	6201	16	24	0
4	1569	216	241	1455	184	13	1539
5	55	50	995	3951	10	21	0
6	5	0,6	6	90	2	0,1	0

4.4 CONCLUSÃO

Neste capítulo, foram propostas e projetadas três redes neurais, treinadas com métodos diferentes com o objetivo de se implementar um dos módulos do sistema de diagnóstico de falhas incipientes em transformadores de potência utilizando a análise de gases dissolvidos em óleo.

O diagnóstico de falhas incipientes via redes neurais apresentou um percentual elevado de acerto. As falhas, que se deseja identificar, foram separadas em seis tipos: térmica de baixa temperatura, térmica de alta temperatura, descargas de baixa energia e descargas de alta energia, degradação da celulose e condição de normalidade.

A comparação entre dois métodos de treinamento, *Adaptative Back-Propagation* e Levenberg-Marquardt, foi realizada na tentativa de se atingir níveis de eficiência mais elevados no diagnóstico. O primeiro método de treinamento utiliza manipulações do gradiente da função de erro para reduzir tal função. A aplicação da constante de momento e da taxa de aprendizagem variável é uma estratégia para uma convergência mais rápida em relação ao *Back-Propagation* convencional. Já o método de Levenberg-Marquardt é reconhecidamente uma otimização das estratégias de treinamento com característica de convergência muito rápida. Isso é possível pelo uso da derivada segunda carregando informações da curvatura da superfície de erro e não somente do gradiente, traços de aperfeiçoamento dos métodos de Newton.

O treinamento com método de Levenberg-Marquardt apresentou resultados superiores ao *Adaptative Back-Propagation* sendo o indicado para protagonizar a constituição do módulo neural de diagnóstico de falhas incipientes.

Com relação aos três sistemas nebulosos propostos para realização do diagnóstico de falhas incipientes a diferença básica entre eles foi a definição da base de regras de cada sistema nebuloso. Cada base de conhecimento foi construída a partir do conhecimento dos métodos de interpretação dos resultados das análises dos gases dissolvidos em óleo. Estes métodos, Rogers revisado com adição de regras empíricas, Tsuchie e um aperfeiçoamento da tabela IEC 60599, definem as variáveis de entrada dos sistemas *fuzzy*, estabelecem o universo de discurso e as funções de pertinência das variáveis através dos limiares das regiões de falha, quando representadas graficamente.

Há de se comentar que a adição de regras especiais para detecção de situações de falhas envolvendo celulose proporciona um caráter abrangente aos sistemas desenvolvidos, uma vez que o problema da não-decisão foi superado.

Finalmente, os sistemas inteligentes são de fato uma alternativa de diagnóstico automático de falhas incipientes em transformadores de potência. Sua superioridade quando comparados aos métodos tradicionais se sobressai. Porém, além da detecção e identificação da falha, a localização da mesma (ponto quente) também se configura como uma informação importante para a proteção integral do equipamento. Assim, em complemento à detecção e identificação realizada pela análise dos gases dissolvidos no óleo, a localização das regiões de falha pode ser alcançada através de métodos acústicos ou de sensoriamento utilizando a tecnologia de fibras ópticas.

Capítulo 5

DIAGNÓSTICO DO ESTADO DO ÓLEO ISOLANTE

Além da análise dos gases dissolvidos no óleo isolante, também ocorre a necessidade de se verificar em que condições de isolamento está este óleo. Mesmo que não haja indicação de falhas incipientes através de gases dissolvidos, alguns testes em uma amostra do óleo podem revelar se a integridade dielétrica e refrigeradora do mesmo ainda se mantém em níveis de segurança. Essas análises, bem como a emissão das suas conclusões, são fortemente dependentes de métodos padronizados que necessitam da experiência humana gerenciando seu uso. Diante disso, há uma necessidade de se aplicar estudos envolvendo inteligência artificial na avaliação da qualidade do óleo isolante. Neste capítulo, discorre-se sobre o projeto de soluções inteligentes para o julgamento da qualidade do óleo isolante.

A priori, o desenvolvimento do diagnóstico inteligente do estado do óleo isolante acontece através do uso de redes neurais artificiais. Para isto, duas redes serão aplicadas na solução do problema. Mediante o uso dos dados contidos no apêndice C, o método de Levenberg-Marquardt (LM) constará como algoritmo de treinamento de uma rede neural MLP. Este método é idêntico ao apresentado no capítulo 4. Depois, uma rede neural do tipo função de base radial (RBF) será introduzida na discussão visando, por meio de comparação dos resultados alcançados pelos métodos, estabelecer o de melhor desempenho como o algoritmo a ser incluído na ferramenta computacional inteligente de monitoramento e diagnóstico do óleo isolante de transformadores de potência.

O presente capítulo será organizado dessa forma: A seção 5.1 levanta o estudo do conceito da análise e diagnóstico do estado do óleo isolante através das características físico-químicas. A seção 5.2 apresenta-se o processo de definição das características da rede neural RBF, bem como um breve comentário da MLP, uma vez que esta última já foi devidamente detalhada no capítulo anterior. Nas seções 5.3 e 5.4, respectivamente, os resultados obtidos são analisados os comentários conclusivos são expostos.

5.1 DIAGNÓSTICO DO ESTADO DO ÓLEO ISOLANTE DE TRANSFORMADORES DE POTÊNCIA

Como dito anteriormente neste trabalho, o óleo isolante tem provado ser um meio eficiente como sistema de isolamento e refrigeração de transformadores de potência. Por isso, o efeito do envelhecimento do óleo nas suas propriedades físicas, químicas e elétricas tem ganhado enfoque e muitos testes de avaliação da qualidade do sistema de isolamento têm sido elaborados. A deterioração das características do óleo sob determinadas condições de trabalho representa um cenário alarmante no que tange a geração de falhas que podem retirar a unidade de serviço se evoluídas.

5.1.1 Importância do Estado do Óleo Isolante

À medida que o transformador envelhece, seu sistema de isolamento pode perder as características dielétricas a ponto de não mais suportar eventos sistemáticos que o agridam, tais como faltas de curto-circuito e/ou sobretensões transientes. O papel dos procedimentos de manutenção ganha importância diante deste cenário. Tradicionalmente, os procedimentos de manutenção preventiva mantêm suas rotinas paralelamente associadas a teste e avaliações regulares dos equipamentos. Porém, com o avanço das técnicas de gerenciamento de manutenção, há um maior enfoque na redução de custos de manutenção e equipamentos de reposição. Tal estratégia pode significar, em muitos casos, redução de capacidade de reserva e aumento da média de carregamento em um parque elétrico. Tal fato pode agravar uma possível condição de falha pré-existente em um equipamento sob essas condições acelerando a perda de vida útil ou até mesmo antecipando eventos destrutivos caso não seja mitigado o avanço da falha.

Entretanto, uma estratégia para melhorar as condições de manutenção tem sido a mudança dos programas baseados no tempo para as rotinas baseadas nas condições. Enquanto aquela é efetuada em intervalos regulares, esta é somente executada em situações em que a condição de operação do equipamento requer intervenção. Para tanto, há uma exigência de implementação de ferramentas confiáveis de monitoramento e diagnóstico para avaliação das condições internas dos transformadores. Estes sistemas de monitoramento e diagnóstico concebem um ambiente de crédito a manutenção que intervém no ato do aparecimento de

qualquer indício de sinistro na unidade. Isto também significa proteção em períodos onde não haveria manutenção programada (WANG M. *et al*, 2002).

Portanto, para garantir a continuidade do fornecimento de energia e uma adequada manutenção com conseqüente extensão da vida útil do transformador, o correto e preciso diagnóstico da qualidade do óleo isolante torna-se uma ferramenta eficiente na prevenção de falhas em transformadores.

5.1.2 Características Físico-Químicas do Óleo Isolante

Uma coletânea de testes físicos, químicos e elétricos exerce a caracterização das mudanças nas propriedades elétricas, no nível de contaminação e no grau de deterioração do óleo isolante. Para uma análise adequada do estado e qualidade do óleo alguns procedimentos são padronizados e seguem normas estabelecidas, conforme mostrado na tabela 5.1 (IMAMURA, 2000; CARGOL, 2005). Os resultados das análises físico-químicas indicam o real estado do óleo utilizado como isolante, possibilitando a orientação de procedimentos para regeneração ou até mesmo substituição do óleo.

Tabela 5.1 – Normas aplicadas aos ensaios físico-químicos no óleo isolante.

Ensaio	Normas Aplicadas
Cor	ABNT- MB – 351 / ASTM D-1500
Densidade	NBR-7148 / ASTM D-1298
Tensão Interfacial	NBR-6234 / ASTM D-971
Teor de Água	NBR-5755 e 10710 / ASTM D1533
Índice de Acidez Total	NBR-14248 / ASTM D-974
Rigidez Dielétrica	IEC 156 / NBR 6869 e 10859 / ASTM D-877 e D-1816
Fator de Perdas a 90°C	IEC-247
Estabilidade à Oxidação	NBR-10504
Viscosidade Cinemática	NBR-10441 / ABNT – MB – 293
Ponto de Anilina	ABNT - MB – 299
Ponto de Fulgor e Combustão	ABNT – MB – 50
Grau de Polimerização em Papel Isolante	NBR-8148

A perda dielétrica de um sistema isolante pode ser compreendida como a potência dissipada pelo isolamento quando da aplicação de uma tensão alternada. Esta perda dielétrica é mensurável de forma que um bom isolante apresenta valor de perda muito baixo. Entretanto, alguns fatores podem provocar um aumento no valor da perda dielétrica, tais como: o envelhecimento natural do isolante, contaminação por umidade ou substâncias químicas, além de danos físicos provenientes de esforços elétricos ou outras forças externas (CHU, 1999).

Um material é considerado dielétrico quando apresenta capacidade de armazenamento de energia sob a aplicação de um campo elétrico externo. A descrição das propriedades dielétricas inerentes a este material é feita através da permissividade complexa. Na aplicação da tensão externa, o material dielétrico sofre polarização que varia com a faixa de frequência. Em baixas frequências, dominam as polarizações iônicas e dipolares provendo aumento de temperatura. Isto, por sua vez intensifica o processo de transporte de carga originando novas componentes de corrente agindo diretamente nas propriedades elétricas. Em se tratando de líquidos isolantes, a polarização é influenciada pelos contaminantes presentes (ZAENGL, 2003).

Um dielétrico submetido a uma tensão alternada apresenta uma corrente resultante que pode ser decomposta em duas componentes. A permissividade complexa está relacionada a estas componentes. A corrente de carregamento, responsável pela interação entre o material e o campo elétrico no armazenamento de energia, tem íntima ligação com a parte real da permissividade, também chamada de constante dielétrica, enquanto a corrente de perda, representativa do efeito de dissipação, consiste na parte imaginária, denominada fator de perda. O fator de perda mede o quanto dissipativo é um material para um determinado campo elétrico externo.

A permissividade complexa normalmente é descrita sob a forma de permissividade relativa, de valor adimensional, que compara a permissividade complexa do material com a permissividade do espaço livre ($8,854 \times 10^{-12}$ F/m). A figura 5.1 mostra, em um diagrama de vetores, a permissividade complexa relativa (ϵ_r^*), sua componente real (ϵ_r') e a imaginária (ϵ_r''). O vetor resultante (ϵ_r^*) forma um ângulo δ com respeito ao eixo real. A tangente de perda ($\tan \delta$), ou fator de dissipação, representa a perda

relativa do material denotada pela razão da energia dissipada pela energia armazenada (PARASKEVAS *et al.*, 2006).

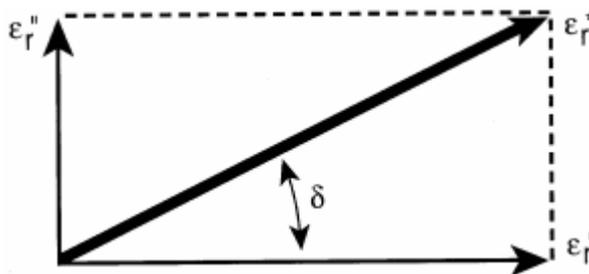


Figura 5.1 – Diagrama vetorial da permissividade relativa complexa.

Nos estudos de Paraskevas *et al.* (2006), sobre a resposta do dielétrico em função da frequência e da temperatura (espectroscopia dielétrica dependente da temperatura) são tecidos alguns comentários sobre o fator de dissipação em algumas condições de óleos isolantes.

Condição 1 - Óleos de alto isolamento: Apresentam condições satisfatórias para a continuidade do uso:

- Valor do fator de dissipação ($\tan \delta$) muito baixo para as frequências de operação e independente da temperatura;
- Permissividade complexa termicamente estável.

Condição 2 - Óleos com baixas perdas: Necessitam de acondicionamento através de desidratação ou filtragem para garantir o uso confiável e prolongado:

- Nas frequências de operação, apresenta valores do fator de dissipação ($\tan \delta$) maiores que os óleos de alto isolamento, mas com certa dependência da temperatura;
- Estabilidade térmica reduzida para os valores da permissividade complexa.

Condição 3 - Óleos com altas perdas e/ou instabilidade térmica: Apresentam condição precária de operação necessitando de inspeção frequente. Exigem acondicionamento, se possível, ou descarte, dependendo de averiguações econômicas.

- Fator de dissipação ($\tan\delta$) muito elevado com ampla dependência da temperatura;
- Alta instabilidade térmica da permissividade complexa.

A tabela 5.2 apresenta os resultados dos ensaios físico-químicos efetuados por Paraskevas *et al.* (2006) em amostras classificadas segundo as condições de óleo descritas anteriormente. Baseado nos resultados destes testes, algumas conclusões podem ser evidenciadas acerca da relação entre as grandezas físico-químicas ensaiadas e o estado do óleo.

Tabela 5.2 – Médias e desvios padrões dos resultados dos ensaios físico-químicos comparados com os valores normalizados.

Ensaio Físico-químico	Limites (ASTM)	Condição do Óleo		
		1	2	3
Rigidez Dielétrica (kV)	26 mín. (D877)	31,48±5,9	28,70±6,9	27,49±7,24
Tensão Interfacial (dinas /cm)	24 mín. (D971)	34,60±6,18	24,33±3,8	20,13±3,65
Acidez (mg KOH /oil g)	0,2 máx. (D974)	0,10±0,016	0,124±0,048	0,19±0,091
Teor de Água (ppm)	35 máx. (D1533)	13,4±7,5	14,6±7,7	17,4±11,0
Densidade Relativa	0,840-0,9 (D1298)	0,8718±0,0011	0,8720±0,0087	0,8752±0,0098
Cor	0,5-8 (D1500)	1,37±0,56	2,13±0,71	3,19±0,83

Apesar do patamar de normalidade padronizado, tabela 5.2, não ter sido ultrapassado por nenhum dos conjuntos de dados, há uma forte tendência de queda no valor da rigidez dielétrica à medida que aumenta o valor do fator de dissipação e a instabilidade térmica da permissividade.

Também é observada uma tendência de decréscimo da tensão interfacial em direção às amostras de condição deteriorada, as quais apresentaram valores reprováveis.

O índice de acidez cresce em proporção direta ao fator de perdas e à instabilidade térmica, ou seja, amostras na condição 3 apresentam níveis de acidez elevados em comparação com as outras condições de amostras, muito próximas do limiar da norma.

A densidade relativa também apresenta comportamento de crescimento com relação ao aumento do valor de $\tan\delta$. Importante observar que mesmo dentro da faixa de

normalidade sugerida as amostras da condição 3 apresentam alta taxa de elevação em comparação com as outras duas condições.

O índice de cor também sofre incremento em relação à deterioração do óleo, mas deve ser enfatizado que esta medida não é totalmente confiável como indicador da qualidade do óleo.

Outro ponto que merece enfoque é a influência do envelhecimento do óleo sobre a degradação das características dielétricas do óleo. Ou seja, quanto maior o tempo de operação do isolante, menor a probabilidade da amostra estar em boa qualidade dielétrica. Podendo a estabilidade do óleo, inclusive, ser agravada por decorrência de oxidação e *stress* elétrico, influenciando no acréscimo do fator de dissipação (FERGUSON *et al.*, 2002).

Em suma, através dos resultados destes estudos, temos um claro cenário que revela a íntima ligação da degradação do óleo com os parâmetros físico-químicos. Em vista disso, é possível utilizar os valores dos resultados de ensaios físico-químicos para formular uma classificação em termos de qualidade do óleo isolante de equipamentos elétricos.

Por depender da aplicação de muitas normas em vários resultados de ensaios para se obter uma avaliação da qualidade do óleo, a tarefa de diagnosticar o estado do líquido isolante do transformador pode se tornar uma tarefa árdua na falta de experiência na manipulação destas padronizações.

Visando a resolução desta problemática, foram desenvolvidas redes neurais aplicadas ao diagnóstico da qualidade do óleo isolante de transformadores através dos resultados de análises físico-químicas devendo apresentar como resposta de diagnóstico um determinado procedimento referente ao estado do óleo analisado.

5.2 APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NO DIAGNÓSTICO DO ESTADO DO ÓLEO ISOLANTE

A aplicação das Redes Neurais Artificiais no diagnóstico da qualidade do óleo isolante visa utilizar o comportamento inteligente destes mecanismos proveniente das interações entre as unidades de processamento. Os desenvolvimentos teóricos referentes ao projeto de redes neurais estão devidamente descritos no Apêndice A.

Baseada nos princípios de projetos de Redes Neurais Artificiais discutidos no capítulo 4 deste trabalho, a aplicação para a classificação de amostras de óleo isolante quanto à qualidade dielétrica do óleo foi desenvolvida. No entanto, além de utilizar redes do tipo MLP com algoritmos de treinamento *Adaptive Back-Propagation* e Levenberg-Marquardt, foi introduzida a implementação de uma outra estrutura de rede neurais baseadas em funções de base radial, *Radial Basis Function* (RBF).

5.2.1 Projeto de Perceptrons de Múltiplas Camadas – MLP

Uma vez que as particularidades dos *perceptrons* de múltiplas camadas já foram amplamente comentadas no capítulo anterior, há necessidade apenas de relatar detalhes do projeto desse tipo de solução neuro-computacional com relação às propriedades do diagnóstico do estado do óleo isolante.

Redes MLP aplicadas a este tipo de diagnóstico têm alcançado resultados promissores utilizando uma arquitetura do tipo três camadas, com apenas uma camada escondida. Também, percebe-se certo fracasso do uso de treinamento de *back-propagation* convencional neste tipo de aplicação. Entretanto, de forma próxima, os resultados do uso do algoritmo *adaptive back-propagation* e Levenberg-Marquardt rendem crédito no projeto de soluções inteligentes na classificação de amostras de óleo isolante quanto à sua qualidade (MOKHNACHE; BOUBAKEUR, 2002).

Na definição do vetor de entrada da rede neural, no objetivo de se obter resultados relevantes e confiáveis no diagnóstico, foram levados em consideração os resultados de qualificação do óleo citados na subseção 5.1.2 (PARASKEVAS *et al.*, 2006). Assim, as características físico-químicas consideradas de influência na qualidade do óleo isolante e utilizadas para a formação do vetor de entrada para o projeto das redes neurais são: acidez, rigidez dielétrica, teor de água, tensão interfacial, densidade e fator de potência do óleo (informação complementar ao fator de perda). Dessa forma, o vetor de entrada da rede é determinado utilizando seis neurônios na camada de entrada, conforme demonstrado na equação 5.1. Os dados foram normalizados de forma a terem média igual a 0 e desvio padrão igual a 1,

redimensionando o domínio dos dados para os limites adequados para garantir a convergência. Os dados originais estão devidamente demonstrados no Apêndice C.

$$X = \begin{pmatrix} x_0 \\ x_1 \\ \vdots \\ x_5 \end{pmatrix} \quad (5.1)$$

O papel da saída da rede neural projetada é providenciar uma classificação da qualidade do óleo isolante sob a forma do procedimento a ser executado em cada padrão de diagnóstico. Os laudos dos especialistas nas análises físico-químicas foram tomados como alvo de saída durante o processo de treinamento das redes. De acordo com estes laudos, o diagnóstico pode ser: recondicionamento por termo-vácuo, regeneração por filtragem, reamostragem imediata, reamostragem em um ano. Estas também foram as possibilidades de diagnóstico fornecidas pela rede neural através de código associado aos procedimentos, representado por valor numérico entre 1 e 4, posto em sua saída. Para tanto, apenas um único neurônio na saída é necessário.

Para os neurônios da camada escondida, a função de ativação utilizada foi tangente hiperbólica. A função linear foi escolhida para o neurônio de saída. Também foi definida a polarização (*bias*) para todos os neurônios, sendo esta de valor inicial 1.

O índice de acerto no conjunto de dados de validação é monitorado, pois o treinamento é interrompido quando o erro de validação subir por 5 validações consecutivas. Outro critério de parada do treinamento é o alcance do número máximo de épocas possíveis, neste caso, de 30.000 épocas.

Para evitar que os pesos da MLP tendessem para alguma classe de padrão a série de dados de treinamento foi organizada de forma tal que cada classe apresentasse quantidades aproximadamente iguais de amostras.

5.2.2 Algoritmo de treinamento Adaptive Back-Propagation

Como já visto no capítulo 4, o algoritmo *Adaptive Back-Propagation* faz uso do coeficiente de momento visando acelerar a convergência do erro do algoritmo *back-propagation*. Também, evitando oscilações do algoritmo, que podem surgir por uma taxa de aprendizagem mal configurada, este algoritmo estabelece uma taxa de aprendizagem variável, porém garantindo que o passo de aprendizagem seja amplo e o algoritmo permaneça estável.

As configurações do algoritmo de treinamento, aproveitando as configurações do capítulo 4, seguem:

- Escolha de uma taxa de aprendizagem inicial em 0,3 e a constante de momento em 0,7;
- Decremento da taxa de aprendizagem em 30% e taxa de incremento estabelecido em 5%;
- O máximo incremento da taxa de desempenho é 4%. Um erro quadrático médio acima desse percentual em relação ao da época anterior decreta o coeficiente de aprendizagem. Caso seja inferior, ocorre o incremento.

5.2.3 – Algoritmo de Treinamento Levenberg-Marquardt

Conforme já visto, também no capítulo 4, o método envolve o uso da derivada segunda da função de desempenho acelerando a convergência, mediante a introdução do passo adaptativo e de algumas manipulações no método de Newton. O objetivo é que a função de *performance* seja sempre reduzida a cada época de treinamento ou utilizando o método de Newton, ou utilizando o gradiente descendente de acordo com a conveniência.

A configuração do passo adaptativo desse algoritmo tem seu valor inicial em 0,01, com taxa de incremento igual a 10 e decremento definida em 0,1, de acordo com o ajuste do algoritmo para o diagnóstico de falhas incipientes.

5.2.4 Projeto de Redes de Função de Base Radial - RBF

As Redes de Função de Base Radial, RBF, consistem de uma camada de neurônios com função de ativação do tipo gaussiana, conforme figura 5.2 e equação 5.2, posicionados no espaço vetorial de entrada. A saída é obtida através da aplicação do somatório ponderado das unidades de saída que por sua vez estão totalmente conectadas com a camada de base radial.

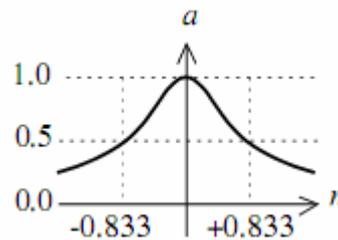


Figura 5.2 – Função de base radial.

$$a = e^{-n^2} \quad (5.2)$$

onde n é o argumento da função.

A camada de entrada de uma RBF tem o papel de servir como canal de absorção de dados para o interior da rede. A camada oculta, conhecida como camada de base radial, aplica uma transformação não-linear da entrada para o espaço interno da rede através de um conjunto de funções que constroem uma base arbitrária para os padrões de entrada. A camada de saída, geralmente do tipo linear, apresenta uma resposta pertinente ao vetor disposto na entrada da rede.

A camada oculta e a camada de saída de uma RBF suportam várias configurações de projeto, como uma rede auto-organizável do tipo SOM (Self Organized Mapping) e Perceptrons Simples, por exemplo. E ainda podem apresentar alguns variantes para seu algoritmo, como as Redes de Regressão Generalizada (GRNN) e as Redes Neurais Probabilísticas (PNN).

A função de ativação de um neurônio em uma rede RBF é diferente de outros neurônios. Cada neurônio escondido possui uma função de base não-linear $G(\cdot)$ que utiliza como argumento a distância euclidiana entre o vetor de entrada X e o centro das funções de base radial C , que representam os pesos dos neurônios escondidos

v , multiplicada pelo *bias*. Assim, calcula-se a ativação v do neurônio escondido i por meio da expressão 5.2 e então a saída h do neurônio escondido i é calculada mediante a aplicação da equação 5.3, como segue:

$$v_i = \|X - C_i\|b_i \quad (5.3)$$

$$h_i = G(v) = \exp\left(-\frac{v^2}{2\sigma_i^2}\right) \quad (5.4)$$

onde o parâmetro σ define a largura ou abertura da função de ativação gaussiana $G(\cdot)$ e b é o *bias*.

Cada neurônio da camada escondida apresenta uma região centrada em C_i no espaço de entrada com dimensão determinada pelo parâmetro σ , que por sua vez é responsável pelo grau de suavidade da função de base radial. Esta região é o campo receptivo (*receptive field*).

Do exposto, podemos inferir que o valor da saída do neurônio escondido i é diretamente dependente do quanto o vetor de entrada X se aproxima do centro C_i . No caso da distância entre o vetor de entrada e o peso do neurônio diminuir, a saída sofre incremento. Quando há a coincidência entre o vetor de entrada e o centro do neurônio, ou seja, $X=C_i$, ocorrerá a saída máxima do neurônio, $h_i=1$.

Para estabelecer a saída da rede y , considerando camada de saída linear, é calculada uma combinação ponderada das funções de base radial para o neurônio j da camada de saída:

$$y_j = \sum_{i=1}^p [w_{ij} \cdot G(\|X - C_i\|b_i)] \quad (5.5)$$

onde p é o número de unidades escondidas da rede.

5.2.5 Definição da Arquitetura RBF

As RBF exigem maior número de neurônios que as MLP e possuem melhores resultados quando um número maior de dados é disponível, porém, a custo de um tempo de projeto e treinamento muito menor significando sua grande vantagem.

Isto se deve ao fato de o projeto de uma RBF poder se reduzir a um problema de ajuste de curva em um espaço de alta dimensionalidade. Entende-se esta característica potencial da RBF através da compreensão, em termos qualitativos, do teorema de Cover, onde um problema de classificação de padrões disposto não-linearmente em um espaço de alta dimensão tem maior probabilidade de ser linearmente separável do que em um espaço de baixa dimensionalidade (LIMA, 2005). Daí, em uma RBF convencional, a quantidade de neurônios de base radial é igual à dimensão do vetor de entrada. O resultado é que existe uma camada de funções de base radial onde cada neurônio funciona como um detector de diferenças entre o vetor de entrada e os pesos destes neurônios.

Nesse contexto, o *bias* passa a ter sua importância. O *bias* permite que a sensibilidade da função de base radial seja ajustada. No caso do *bias* assumir um valor 0,1 para um neurônio, sua saída deveria ser 0,5 para qualquer vetor de entrada que diste 8,326 ($0,8326/b$) do vetor de pesos. Em outras palavras, ele determina qual a largura da área no espaço de entrada a qual o neurônio responde. Um valor otimizado para configuração de *bias* deve levar em consideração uma largura da função radial que ofereça uma resposta eficiente dos neurônios para regiões sobrepostas do espaço de entrada. Entretanto, este alargamento não pode ser tão grande a ponto de que provocar uma resposta eficiente de cada neurônio à mesma área do espaço de entrada.

Para o treinamento, os dados são apresentados com uma saída correspondente a um dado vetor de entrada que ativa todas as funções gaussianas em algum nível. As conexões ponderadas propagam as respostas das funções locais para as unidades de saída, onde é realizado o somatório ponderado que origina a saída. A comparação entre a saída atual e a saída desejada fornece o erro apresentado pela rede para este padrão em um dado instante do treinamento.

No treinamento da camada escondida, do tipo não-supervisionado, os neurônios de base radial são adequadamente dispostos no espaço de entrada. Para o ajuste dos pesos da camada de saída, o treinamento é supervisionado e a regra delta é utilizada na determinação dos pesos.

O projeto de RBF é delicado quanto ao número de neurônios que são necessários para uma eficiente aplicação do método e quanto a localização e configuração destes neurônios. Uma estratégia conhecida como RBF Incremental parametriza a rede neural de forma gradual e automática (FRITZKE, 1994).

5.2.6 Estratégia RBF Incremental

Este modelo de RBF iterativamente incrementa, uma unidade por vez, o número de neurônios de base radial perfazendo um modo automático de construir e treinar a rede.

Inicialmente, duas unidades associadas a uma função gaussiana são posicionadas aleatoriamente no espaço de entrada e conectadas entre si por uma conexão de vizinhança. Diante desse quadro, o campo receptivo depende das conexões de vizinhança, uma vez que o valor do desvio padrão da função gaussiana é calculado através da média aritmética dos comprimentos dessas conexões referentes a cada unidade.

Os centros das funções de base radial são atualizados através do deslocamento do neurônio de maior grau de proximidade da entrada e de suas unidades vizinhas, em direção ao próprio vetor de entrada. Como os centros das funções de base radial representam os pesos dos neurônios da camada oculta, esta atualização é semelhante a uma rede auto-organizada de Kohonen (KOHONEN, 1982).

A intensidade do deslocamento do neurônio mais próximo e de seus vizinhos é proporcional à proximidade da entrada de forma que a taxa de aprendizagem para as unidades mais próximas é superior que a das unidades mais distantes. Por exemplo, o neurônio mais próximo tem sua taxa de aprendizagem com valor total, enquanto um valor no intervalo $[0,1]$ multiplica a taxa de aprendizagem para os neurônios vizinhos e 0 é o fator para os não vizinhos. Estes fatores de proximidades são conferidos através da função de atualização de pesos mediante a aplicação da função de vizinhança $h(\theta)$, conforme demonstrado na equação seguinte:

$$w_i(t+1) = w_i(t) + \eta(t) \cdot h(i_{prox}, i, t) \cdot \|x(t) - w_i(t)\| \quad (5.6)$$

onde t é o número da iteração, η é a taxa de aprendizagem, h é a função de vizinhança, i_{prox} é o índice do neurônio mais próximo e p é o número de unidades escondidas da rede.

Os pesos dos neurônios de saída são atualizados através da regra delta tal como os neurônios de saída de uma rede MLP.

Com os pesos atualizados, é calculada a soma do erro quadrático como função de *performance*, em cada iteração, indexada ao neurônio mais próximo. Para este neurônio, o erro acumulado, dado pela equação 5.7, é o parâmetro utilizado para julgar a necessidade de inclusão de novas unidades na camada oculta:

$$ERR_{acu} \leftarrow ERR_{acu} + \sum_{j=1}^m (d_j - y_j)^2 \quad (5.7)$$

onde m é o número de unidades da camada de saída, d_j é a saída desejada e y_j a saída atual do j -ésimo neurônio da camada de saída.

Quando a atual configuração da rede não é mais capaz de melhorar o seu desempenho, ocorre a inserção de novas unidades entre o neurônio que apresenta o maior erro acumulado e o vizinho deste mais distante. A posição do novo neurônio dentro do espaço de entradas é dada pela média dos pesos das unidades entre as quais ela é inserida. Após a inserção da nova unidade, o erro acumulado dos seus vizinhos é reduzido e ao neurônio acrescentado é atribuído, como erro acumulado, a média aritmética dos erros acumulados de seus vizinhos evitando acréscimos sucessivos na mesma região do espaço de entrada.

Assim, a cada iteração, os neurônios ocultos realizam pequenos movimentos dentro do espaço vetorial de entrada fazendo com que seja necessário atualizar a informação de proximidade e conseqüentemente a vizinhança. Assim, uma vez apresentado um novo vetor de entrada são localizados os dois neurônios mais próximos (menores distâncias euclidianas) deste e é formada, ou fortalecida, uma ligação de vizinhança entre eles (FRITZKE, 1994).

A estratégia é repetida até que um erro mínimo objetivo seja atingido ou o máximo número de neurônios ocultos seja alcançado.

5.3 ANÁLISE DOS RESULTADOS

Para realização das etapas de treinamento, validação e testes das redes neurais desenvolvidas foram utilizadas, no total, 102 amostras do banco de dados de análises físico-químicas dispostas no Apêndice C.

No projeto da rede neural, os conjuntos de treinamento, validação e teste apresentam, respectivamente, 60, 20 e 22 amostras sendo a saída desejada para o processo de treinamento o diagnóstico fornecido no laudo técnico do especialista responsável pela análise físico-química do óleo isolante.

Na fase de treinamento, o uso da MLP com algoritmo de treinamento *adaptive back-propagation* não forneceu resultados apropriados, resultando em um percentual de acerto menor que 10% dos dados de teste. Devido a isso, os estudos se voltaram apenas para o algoritmo de treinamento Levenberg-Marquardt na MLP, além da rede RBF. A tabela 5.3 apresenta os valores do percentual de acerto para a MLP treinada pelo algoritmo Levenberg-Marquardt (identificado por LM) e a rede RBF Incremental (identificada por RBF) em função do número de neurônios utilizados na camada escondida nos conjuntos de dados de treinamento, validação e teste.

Tabela 5.3 – Percentual de acerto das redes neurais.

Algoritmo de Treinamem.	Nº de Neurônios na Camada Escondida	Épocas de Treinam.	Diagnóstico Correto (%)		
			Treinamento	Validação	Teste
LM	5	182	100,00	100,00	100,00
RBF	5	5	15,00	5,00	13,64
LM	15	164	100,00	100,00	86,36
RBF	15	15	100,00	95,00	95,45
LM	25	129	100,00	100,00	77,27
RBF	25	24	100,00	100,00	100,00

A tabela de resultados demonstra que o algoritmo de treinamento MLP Levenberg-Marquardt alcança máximo percentual de acerto nos três grupos de dados, a saber, treinamento, validação e teste, quando a rede é projetada com 5 neurônios na

camada escondida. Valores acima deste para o referido parâmetro conduzem a rede para o aprendizado de detalhes, o que, por sua vez, resulta em uma fraca resposta de generalização.

O inverso ocorre no caso dos testes com a estrutura RBF. O índice máximo de acerto somente é alcançado com um número de neurônios escondidos igual a 25. Pois, para a complexidade deste problema específico de diagnóstico, a rede somente é capaz de sobrepor o espaço de entrada com a utilização de um maior número de unidades, em relação à MLP. Daí, uma RBF, mesmo quando eficientemente projetada, tende a ter um número bem superior de neurônios que as redes MLP. Uma razão para isso é que um neurônio sigmóide pode sobrepor uma ampla região do espaço de entrada enquanto um neurônio de base radial responde a regiões relativamente pequenas. Portanto, uma MLP apresenta menos complexidade em sua camada escondida que uma RBF. Em compensação, a RBF exige um tempo de projeto e treinamento bem menores que uma MLP. Por exemplo, para a RBF o tempo de treinamento aumenta proporcionalmente ao número de neurônios na camada escondida, não ultrapassando três dezenas. Mas na MLP a proporcionalidade é inversa e o tempo de treinamento é da ordem das centenas.

Entretanto, mesmo quando a rede tem um desempenho de acerto da ordem de 100%, vale salientar que pode haver algum erro na aplicação de dados isolados, pois não se pode garantir que o conjunto de dados é representativo de todos os casos reais de diagnóstico. Também, como na análise dos resultados do diagnóstico de falhas incipientes, não há como certificar que o resultado do laudo técnico do especialista, utilizado como alvo de treinamento das redes, ainda que baseado em normas padronizadas, esteja completamente correto para todos as situações.

5.4 CONCLUSÃO

Neste capítulo, foram propostas e projetadas duas estruturas de redes neurais objetivando a implementação do módulo do sistema de diagnóstico da qualidade do óleo isolante de transformadores de potência utilizando a análises físico-químicas.

Foi promovida a comparação entre as duas estruturas projetadas diante da mesma problemática. Enquanto redes MLP apresentam características de aproximação global para o mapeamento não-linear entre entrada e saída, as redes RBF,

solucionam o mapeamento através de não-linearidades localizadas com decréscimo exponencial, por exemplo, funções gaussianas. Uma expectativa natural é esperar que, para o mesmo grau de precisão, a MLP requeira um número menor de parâmetros que a rede RBF. Em termo de complexidade de estrutura, conclui-se que redes MLP com apenas uma camada escondida e 5 neurônios nesta se torna a rede menos complexa para o diagnóstico do estado do óleo, sendo o algoritmo indicado para a composição do módulo inteligente de diagnóstico do estado do óleo isolante. Porém, por meio do algoritmo de formação e treinamento da rede RBF Incremental é possível obter redes RBF relativamente pequenas e com boa capacidade de generalização e ainda com um tempo de treinamento menor que os algoritmos convencionais.

Em suma, os sistemas inteligentes possibilitam o diagnóstico automático da qualidade do óleo em transformadores de potência. A importância disto é evidente diante da necessidade de um monitoramento mais acurado e rápido das características físico-químicas, que, como visto, exercem grande influência na potencialidade dielétrica do líquido isolante do equipamento de grande porte.

Também, a implementação de êxito dessa ferramenta de diagnóstico da qualidade do óleo habilita responsáveis técnicos, mesmo inexperientes, a executar diagnósticos com margem de acerto muito elevado. Outra vantagem é a de não ser necessária certa habilidade nas manipulações das várias normas inerentes às várias características físico-químicas. Tudo isso constrói um ambiente de confiança e rapidez em torno do diagnóstico projetado.

Capítulo 6

ESTIMAÇÃO DOS GASES DISSOLVIDOS NO ÓLEO

Visto que se pode verificar a qualidade dielétrica do óleo isolante por intermédio de ensaios físico-químico bem como a existência de falhas, ainda em fase incipiente, por ensaio cromatográfico, grande importância é dada a estes testes em termos de operação e manutenção de um equipamento tão essencial.

Diante disso, surge uma questão acerca do grau de relacionamento que possa haver entre as grandezas que podem diagnosticar o estado do isolamento líquido de um transformador. Neste capítulo, vai ser discutida a possibilidade de uma relação entre os resultados destes dois tipos de ensaios no óleo isolante, levando a um método de estimar os gases dissolvidos em função das grandezas físico-químicas. A seção 6.1 trata do estabelecimento do grau de relacionamento entre os resultados dos dois tipos de testes do óleo isolante. Na seção 6.2 é discutida a estimação dos gases dissolvidos no óleo lançando mão das grandezas físico-químicas através do uso de redes neurais. Na seção 6.3, um método conhecido por busca exaustiva é utilizado para definir quais atributos físico-químicos são mais relevantes na estimação de cada gás dissolvido. Os resultados obtidos são publicados na seção 6.4. Finalmente, as conclusões da seção são apresentadas na seção 6.5.

6.1 RELAÇÃO ENTRE AS GRANDEZAS DOS ENSAIOS FÍSICO-QUÍMICO E CROMATOGRÁFICO

O óleo isolante é propiciador de refrigeração das partes ativas do equipamento elétrico de potência, como o transformador, servindo como meio trocador de calor. Mas uma característica exigida para seu uso neste quesito é que apresente alta capacidade dielétrica, uma vez que estará em circulação por todas as partes ativas e será submetido a altas diferenças de potencial.

No capítulo 2, foi executado um estudo sobre a análise do óleo isolante do transformador que promoveu uma visão da necessidade de se obter tal óleo sob testes que revelem a manutenção das suas características dielétricas. No caso de detecção da deterioração do óleo, é interessante saber se a causa é um

envelhecimento natural ou a ocorrência de falhas internas e ainda, se estes sintomas afetam efetivamente o sistema de isolamento. Isto se dá, principalmente, pela utilização dos resultados dos ensaios físico-químico e cromatográfico. O primeiro qualificando o estado do óleo e o segundo avaliando a existência de falhas internas em fase incipiente.

Observando que é possível garantir certa segurança na operação e manutenção do equipamento através da avaliação dos resultados destes dois ensaios, pode ser levantada a questão sobre uma eventual relação entre as grandezas físico-químicas e os gases dissolvidos no óleo.

Entretanto, apesar da importância das informações advindas destes dois tipos de testes e das possibilidades extraídas da existência de uma associação entre eles, estes relacionamentos não são muito bem definidos na literatura e carecem de investigações mais profundas.

Porém, algumas pesquisas mencionam a influência das características dielétricas anormais do óleo no aparecimento de falhas internas. Tais anormalidades podem estar refletidas na presença de radicais livres e de oxigênio dissolvido sob o efeito catalítico do cobre, reconhecidos como estopim do processo de degradação do óleo na medida do seu envelhecimento (FERGUSSON *et al.*, 2002).

Ocorre que algumas pesquisas demonstram que, à medida que o tempo de operação do óleo isolante aumenta, o surgimento de falhas padrões sai de uma taxa constante para um patamar crescente (WANG M. *et al.*, 2002).

Também, amostras de óleos ensaiadas com métodos de espectroscopia dielétrica têm ressaltado a correlação entre o envelhecimento do óleo e o fator de perdas ($\tan \delta$), concluindo que amostras com pobres características físico-químicas apresentam fator de perdas fortemente dependente da temperatura. Na figura 6.1, é notório o aumento do valor do fator de perdas para o incremento da temperatura do óleo (PARASKEVAS *et al.*, 2006).

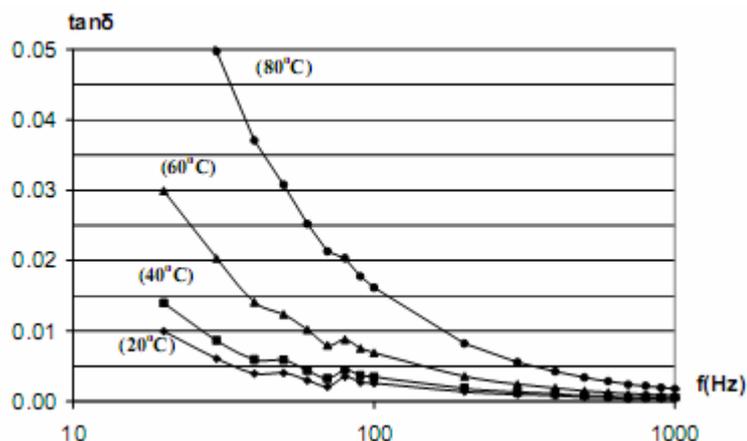


Figura 6.1 – Espectroscopia dielétrica de óleo isolante envelhecido.

Nos estudos de Peyraque *et al.* (1998), vemos a condutividade do óleo, parâmetro complementar à rigidez dielétrica, mantendo uma relação com a temperatura para quatro amostras de óleo: A – óleo novo (virgem); B – óleo em transformador novo; C – Óleo com envelhecimento moderado e D – Óleo fortemente envelhecido em laboratório, conforme demonstrado na figura 6.2.

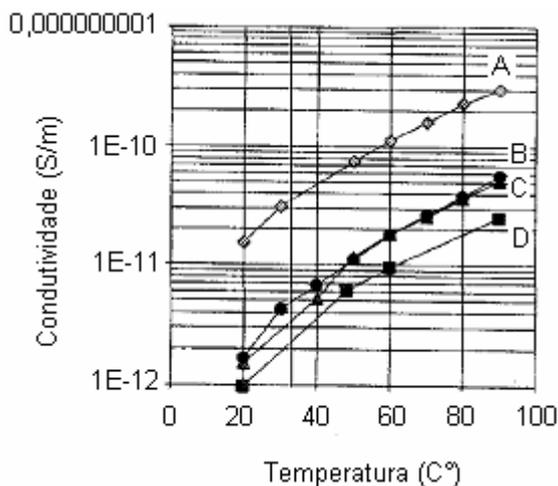


Figura 6.2 – Variação da condutividade do óleo em função da temperatura.

E ainda, o mecanismo de formação de gases no interior dos transformadores segue um modelo termodinâmico que associa a taxa de formação dos gases à temperatura na vizinhança do local onde ocorre a falha (IEEE, 1991; IEC 599, 1978).

Do exposto, há uma grande probabilidade de se obter satisfatoriamente uma relação entre as características físico-químicas e cromatográficas. Porém, por não dispor de uma forma clássica de se estabelecer tal relação, a aplicação de um método

inteligente, especificamente redes neurais artificiais, podem resultar na obtenção de características que tragam à luz uma melhor compreensão acerca da dinâmica que envolve o comportamento do isolamento líquido do transformador.

6.2 ESTIMAÇÃO DOS GASES DISSOLVIDOS UTILIZANDO REDE NEURAL ARTIFICIAL

Uma característica da problemática discutida até agora é que os ensaios físico-químicos e cromatográficos são executados há décadas e, devido a isso, há uma ampla disposição de dados confiáveis sobre as características do óleo isolante. Como uma das mais marcantes habilidades de uma rede neural artificial é aprender a partir de exemplos, há o vislumbre de que esta solução inteligente é a mais aconselhável no intuito de se lograr êxito na busca de uma relação entre as duas formas de análise do óleo.

Em um primeiro momento, a tarefa das redes neurais projetadas será buscar a relação entre os dois testes citados sob a forma da estimação dos gases dissolvidos no óleo em função das grandezas físico-químicas (IMAMURA *et al.*, 2000).

Para tanto, duas estruturas já utilizadas neste trabalho protagonizam os testes por apresentarem resultados excelentes nas aplicações anteriores, sendo estas: MLP com treinamento Levenberg-Marquardt e RBF com estratégia RBF Incremental.

Devido ao uso prévio destas estruturas, segue apenas os detalhes do projeto dessas redes no que concerne à aplicação de estimação dos gases dissolvidos no óleo isolante.

Novamente, baseado nos resultados obtidos por Paraskevas *et al.* (2006), foram definidas as características físico-químicas consideradas de influência na qualidade do óleo isolante. Daí os atributos candidatos a formarem o vetor de entrada aplicado às redes neurais são os seguintes: acidez, rigidez dielétrica, teor de água, tensão interfacial, densidade e fator de potência do óleo (informação complementar ao fator de perda). Por conseqüência, a camada de entrada da rede utiliza o número de neurônios equivalente ao número de atributos realmente influentes que formam o vetor de entrada da rede. Aqui também continua sendo importante o processo de normalização dos dados redimensionando o domínio das entradas da rede para os

limites que garantam a convergência. Este processo de normalização dos dados se dá de forma a terem média igual a 0 e desvio padrão igual a 1.

A estimação dos gases dissolvidos é obtida na saída da rede neural. Os gases estimados serão os necessários para a execução do diagnóstico de falhas incipientes em transformadores, como segue: hidrogênio (H_2), monóxido de carbono (CO), dióxido de carbono (CO_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4) e acetileno (C_2H_2). Diante disso, há o discernimento para a elaboração de uma rede neural, com apenas um neurônio de saída, para cada gás que seja estimado. Portanto, as sete redes neurais proporcionam a ligação associativa entre as grandezas físico-químicas de entrada e os gases dissolvidos no óleo.

Os pares entrada-saída foram obtidos da comparação entre os laudos dos especialistas nas análises físico-químicas e cromatográficas devidamente demonstradas no apêndice C. Os laudos de mesma data de amostragem geraram os pares entrada-saída para o treinamento, validação e teste das redes.

6.2.1 Projeto de Redes Neurais MLP – Treinamento Levenberg-Marquardt

Particularidades do projeto de redes MLP com treinamento Levenberg-Marquardt estão demonstradas no capítulo 4. Para as sete redes projetadas, todos os neurônios da camada escondida utilizam a função de ativação tangente hiperbólica. O neurônio de saída apresenta a função linear e a polarização (*bias*) para todos os neurônios tem seu valor inicial 1.

A estratégia de parada baseada no monitoramento do índice de acerto no conjunto de dados de validação permanece com o treinamento interrompido caso o erro de validação subir por 5 validações consecutivas. E o número máximo de épocas possíveis, outro critério de parada do treinamento, é alcance de 30.000 épocas.

A configuração do passo adaptativo desse algoritmo tem seu valor inicial em 0,01, com taxa de incremento igual a 10 e decremento definida em 0,1, de acordo com o ajuste do algoritmo para o diagnóstico de falhas incipientes.

6.2.2 Projeto de Redes Neurais RBF – Estratégia RBF Incremental

Conforme já visto, no capítulo 5, esta estrutura se refere ao uso de neurônios com função de ativação do tipo gaussiana implementados na camada escondida, conhecida como camada de base radial.

O algoritmo incremental pretende que a função de *performance* seja reduzida a cada época de treinamento através da inserção de novos neurônios no espaço de entrada, paulatinamente, à medida que a configuração da rede não proporciona melhora no índice de desempenho.

Dessa forma, a cada iteração os neurônios da camada de base radial promovem um pequeno movimento no espaço vetorial de entrada em direção ao vetor de entrada no objetivo de aperfeiçoar o índice de *performance*.

6.3 DEFINIÇÃO DOS ATRIBUTOS FÍSICO-QUÍMICOS MAIS INFLUENTES NA ESTIMAÇÃO DE CADA GÁS DISSOLVIDO

No ato da estimação dos gases dissolvidos, surge, paralelamente, a questão de se identificar quais as características físico-químicas realmente são relevantes e qual o nível de associação com os gases dissolvidos.

Para realizar esta tarefa, é empreendido o projeto do algoritmo conhecido por busca exaustiva que seleciona os atributos de melhor potencial de predição relacionados a um sistema adaptativo de inferência *neuro-fuzzy* (ANFIS).

Este tipo de sistema de inferência usa uma série de dados de entrada e saída para construir um sistema de inferência *fuzzy* onde as funções de pertinência são ajustadas sob o uso de algoritmos *back-propagation* ou este combinado com método dos mínimos quadrados, permitindo que o sistema aprenda dos próprios dados de modelagem.

A modelagem usada pelo ANFIS é muito similar às muitas técnicas de identificação de sistemas. Uma estrutura de modelo parametrizado é considerada como hipótese, relacionando as funções de pertinência de entrada e as regras para a função de pertinência de saída. Daí, os dados de entrada e saída são utilizados para modificar

os parâmetros das funções de pertinência de acordo com o critério de erro, durante um processo de treinamento (JANG, 1993).

Para a seleção do atributo de entrada mais influente dentre as seis entradas para estimação dos gases dissolvidos, através de busca exaustiva, é necessária a construção de seis ANFIS. Os dados de entrada e saída são organizados em dois grupos. O primeiro grupo, formado pela primeira metade dos dados, é designado para o treinamento enquanto a segunda metade é dirigida à validação, no objetivo de evitar *overfitting*. Para uma mesma dimensão dos valores de erro de treinamento e validação, há um entendimento de que o *overfitting* foi evitado.

O erro é definido pela diferença entre a saída do sistema *fuzzy* e a saída determinada nos dados de treinamento em cada época. O treinamento pára quando o número de épocas projetado, neste caso igual a 1, é alcançado ou quando o erro alvo é atingido (erro = 0). O interesse é qualitativo, ou seja, saber qual entrada apresenta menor erro e não alcançar o erro zero.

A entrada mais influente resultante da busca exaustiva é aquela que apresentar menor valor de erro de treinamento e valor de erro de validação concordante. As características físico-químicas candidatas e que serão testadas por esta estratégia seguem: acidez, rigidez dielétrica, teor de água, tensão interfacial, densidade e fator de potência do óleo.

Entretanto, pode haver mais de um atributo físico-químico influente na relação com gás dissolvido no óleo. A busca exaustiva, então, constrói 15 modelos ANFIS relacionando os atributos dois a dois para definir quais modelos apresentam menores valores de erro de treinamento com erro de validação condizente.

Caso o erro mínimo de treinamento e validação seja reduzido significativamente, o sistema apresenta duas entradas influentes. Na tentativa de se buscar mais uma entrada influente, a estratégia constrói 20 modelos ANFIS, com os atributos organizados aos trios, e os erros de treinamento e validação são analisados. Se não apresentam melhoras, então apenas duas entradas são mais influentes e necessárias para uma boa estimação.

6.3.1 Hidrogênio (H_2)

Primordialmente, a aplicação da busca exaustiva para definição da entrada mais influente no hidrogênio dissolvido obteve-se a seguinte composição de modelos ANFIS:

Tabela 6.1 – Resultado da busca exaustiva - Hidrogênio.

Modelo ANFIS - Entrada	Erro Treinamento	Erro Validação
Acidez	140,52	173,73
Rigidez Dielétrica	140,76	172,95
Teor de Água	140,84	173,00
Tensão Interfacial	138,35	170,97
Densidade	139,23	171,05
Fator de Potência	141,92	173,57

A tabela 6.1 aponta a tensão interfacial como atributo mais influente na presença de hidrogênio dissolvido. Os erros de treinamento e de validação implicam na inexistência de *overfitting* indicando que é possível testar mais entradas. Assim, os resultados para os modelos ANFIS considerando as duas e três entradas mais influentes são demonstrados na tabela a seguir:

Tabela 6.2 – Atributos mais influentes - Hidrogênio.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Rigidez Dielétrica – Tensão Interfacial	131,74	169,97
Rig. Dielétrica – T. Interf. – Teor Água	126,24	186,42

Da tabela 6.2, um comentário pertinente é que ocorre queda nos valores de erro quando outro atributo é acrescentado. No caso de três atributos como entrada, o treinamento melhora, mas o erro de validação aumenta, significando possível indício de *overfitting*. Também, a princípio, o atributo teor de água pode aperfeiçoar a estimação, mas a troca de perda de generalização. A partir dessa tendência de aumento do erro de validação, não é mais vantajoso acrescentar entradas.

6.3.2 Monóxido de Carbono (CO)

A busca exaustiva por intermédio dos modelos ANFIS utilizados para a determinação dos atributos mais relevantes para o monóxido de carbono trazem os resultados que seguem na tabela 6.3.

Tabela 6.3 – Resultado da busca exaustiva – Monóxido de Carbono.

Modelo ANFIS - Entrada	Erro Treinamento	Erro Validação
Acidez	249,74	256,29
Rigidez Dielétrica	256,77	244,35
Teor de Água	258,71	246,73
Tensão Interfacial	254,94	242,81
Densidade	255,89	245,24
Fator de Potência	255,26	247,06

Os resultados apontam a acidez como o atributo mais influente na presença de monóxido de carbono dissolvido.

Não há indícios de *overfitting*, pois os valores do erro de treinamento e validação são muito próximos, logo, há possibilidade de inclusão de novas entradas na estratégia de busca exaustiva. Assim, os resultados para os modelos ANFIS considerando as duas e três entradas mais influentes são demonstrados na tabela a seguir:

Tabela 6.4 – Atributos mais influentes – Monóxido de Carbono.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Fator de Potência – Densidade	218,31	254,03
F. Potência – T. Inter. – Densidade	172,85	531,86

Porém, mesmo com a extrema melhora do erro de treinamento com o acréscimo de uma e depois de duas entradas no modelo ANFIS, a estratégia de busca exaustiva eleva fortemente o valor do erro de validação significando possibilidade de *overfitting*.

6.3.3 Dióxido de Carbono (CO₂)

A aplicação da busca exaustiva para definição da entrada mais influente no dióxido de carbono dissolvido obteve-se a seguinte composição de modelos ANFIS, conforme tabela 6.5.

Tabela 6.5 – Resultado da busca exaustiva – Dióxido de Carbono.

Modelo ANFIS - Entrada	Erro Treinamento	Erro Validação
Acidez	2086,64	2288,84
Rigidez Dielétrica	2123,37	2240,07
Teor de Água	2129,73	2243,06
Tensão Interfacial	2068,92	2215,72
Densidade	2052,51	2224,17
Fator de Potência	2118,29	2216,20

A tabela acima aponta a densidade como atributo mais influente na presença de dióxido de carbono. Como os erros de treinamento e de validação são equiparáveis, *overfitting* é considerado inexistente e há possibilidade de teste de mais entradas. Assim, os resultados para os modelos ANFIS considerando as duas e três entradas mais influentes são demonstrados na tabela a seguir:

Tabela 6.6 – Atributos mais influentes – Dióxido de Carbono.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Tensão Interfacial – Densidade	1833,80	2413,57
R. Dielétrica – T. Inter. – Densidade	1588,79	2706,55

Da tabela 6.6, um comentário pertinente é que o erro de validação aumenta no modelo ANFIS com duas e três entradas, embora o erro de treinamento sofra redução substancial. Isto significa há presença de *overfitting* mesmo que o atributo rigidez dielétrica aperfeiçoe a estimação. Devido à detecção da contínua elevação do erro de validação não é mais vantajoso o acréscimo de características como entrada nos modelos ANFIS.

6.3.4 Metano (CH_4)

Para definir a característica mais influente para o metano através da aplicação da busca exaustiva é necessária a construção e treinamento de seis modelos ANFIS, dos quais serão analisados os erros de treinamento e de validação:

Tabela 6.7 – Resultado da busca exaustiva - Metano.

Modelo ANFIS - Entrada	Erro Treinamento	Erro Validação
Acidez	33,16	40,25
Rigidez Dielétrica	34,70	39,99
Teor de Água	34,96	39,63
Tensão Interfacial	33,73	39,28
Densidade	34,50	39,32
Fator de Potência	30,84	39,33

Os resultados apontam o fator de potência do óleo como o atributo mais influente na presença de metano dissolvido.

É confirmada a inexistência de *overfitting*, visto que os valores do erro de treinamento e validação são equiparáveis. Assim, os resultados para os modelos ANFIS considerando as duas e três entradas mais influentes são demonstrados na tabela a seguir:

Tabela 6.8 – Atributos mais influentes - Metano.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Fator de Potência – Densidade	27,61	38,62
F. Potência – Densidade – Rig. Dielétr.	23,20	77,73

Ao acrescentar nova entrada o desempenho melhorar bastante em relação a um atributo somente. É notório que o erro de validação aumenta quando da inclusão do atributo rigidez dielétrica indicando que há pistas de *overfitting* e que novas inclusões de entrada nos modelos podem causar perda de generalização.

6.3.5 Etileno (C_2H_4)

Os resultados da busca exaustiva por intermédio dos modelos ANFIS utilizados para a determinação das características mais influentes para o etileno trazem os resultados que seguem na tabela 6.9.

Tabela 6.9 – Resultado da busca exaustiva - Etileno.

Modelo ANFIS - Entrada	Erro Treinamento	Erro Validação
Acidez	43,15	58,64
Rigidez Dielétrica	42,74	60,55
Teor de Água	43,35	58,97
Tensão Interfacial	41,20	57,06
Densidade	42,26	59,49
Fator de Potência	43,13	58,91

Os resultados apontam a tensão interfacial como o atributo mais influente na presença de etileno dissolvido.

Os valores do erro de treinamento e validação são equiparáveis, logo, o *overfitting* não é caracterizado e há possibilidade de inclusão de novas entradas na estratégia de busca exaustiva. Assim, os resultados para os modelos ANFIS considerando as duas e três entradas mais influentes são demonstrados na tabela a seguir:

Tabela 6.10 – Atributos mais influentes - Etileno.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Fator de Potência – Tensão Interfacial	37,27	57,55
F. Potência – T. Inter. – Rig. Dielétr.	32,87	101,71

Ocorre crescente melhora no treinamento do sistema à proporção que se acrescentam atributos de entrada. Porém, a situação de inclusão da terceira entrada na estratégia de busca exaustiva provoca a acentuada elevação do valor do erro de validação provocando cautela em termos de inserção de novas entradas.

6.3.6 Etano (C_2H_6)

Os modelos ANFIS utilizados para a determinação das características mais influentes para o etano trazem os resultados que seguem na tabela 6.11.

Tabela 6.11 – Resultado da busca exaustiva - Etano.

Modelo ANFIS - Entrada	Erro Treinamento	Erro Validação
Acidez	52,83	40,70
Rigidez Dielétrica	60,94	44,93
Teor de Água	62,37	41,12
Tensão Interfacial	60,64	40,01
Densidade	61,43	42,06
Fator de Potência	52,28	39,52

Os resultados apontam o fator de potência do óleo como o atributo mais influente na presença de etano dissolvido.

O *overfitting* não é caracterizado, visto que os valores do erro de treinamento e validação são equiparáveis e possibilitam o avanço dos estudos acrescentando entradas à estratégia de busca exaustiva. Assim, os resultados para os modelos ANFIS considerando as duas e três entradas mais influentes são demonstrados na tabela a seguir:

Tabela 6.12 – Atributos mais influentes - Etano.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Fator de Potência – Densidade	36,99	32,88
F. Potência – Densidade – Rig. Dielétr.	25,82	69,54

Grande melhora com relação à agregação de uma e duas entradas ao modelo ANFIS. É nítida a elevação do valor do erro de validação após a inclusão da rigidez dielétrica implicando que novas inserções devem ser evitadas.

6.3.7 Acetileno (C_2H_2)

A determinação da característica mais influente para o acetileno fornece os resultados da busca exaustiva na tabela 6.13.

Tabela 6.13 – Resultado da busca exaustiva - Acetileno.

Modelo ANFIS - Entrada	Erro Treinamento	Erro Validação
Acidez	170,93	271,90
Rigidez Dielétrica	170,28	271,77
Teor de Água	170,59	273,07
Tensão Interfacial	168,29	268,02
Densidade	165,83	262,64
Fator de Potência	172,23	273,58

Estes resultados revelam muita tendência ao *overfitting*, provavelmente devido à carência de dados. A estratégia apresenta dificuldades para desenvolver modelos bem sucedidos para o fim proposto de se estabelecer os atributos mais influenciadores para o acetileno dissolvido. Mesmo assim, a inserção de entradas rende a seguinte tabela:

Tabela 6.14 – Atributos mais influentes - Acetileno.

Modelo ANFIS – Entrada	Erro Treinamento	Erro Validação
Rigidez Dielétrica – Densidade	159,03	255,92
T. Interfac. – Densidade – Rig. Dielétr.	150,02	256,77

Embora os resultados expliquem uma situação de melhora do erro de treinamento e validação na inserção de atributos de entradas, não é possível formar comentários conclusivos devido à carência de dados. Logo, não há garantia acerca da realidade destes resultados.

6.4 ANÁLISE DOS RESULTADOS

Oriundas do banco de dados de análises cromatográficas e físico-químicas foram utilizadas 251 amostras, dispostas no apêndice C, para realização das etapas de treinamento, validação e testes das redes neurais desenvolvidas.

No projeto da rede neural, os conjuntos de treinamento, validação e teste apresentam, respectivamente, 140, 60 e 51 amostras sendo a saída desejada para o processo de treinamento o diagnóstico fornecido no laudo técnico do especialista responsável pela análise físico-química do óleo isolante.

A fase de treinamento das redes neurais projetadas foi desenvolvida com o uso da informação mais coerente acerca das entradas significativas para a estimação de cada gás dissolvido, conforme o estabelecido na seção 6.3 deste capítulo. As redes foram testadas com 2 e 3 atributos de entrada. As tabelas 6.15 a 6.21 apresentam os valores do percentual de acerto para a MLP treinada pelo algoritmo Levenberg-Marquardt (identificado por LM) e a rede RBF Incremental (identificada por RBF) em função do número de neurônios utilizados na camada escondida nos conjuntos de dados de treinamento, validação e teste.

Tabela 6.15 – Percentual de acerto das redes neurais para estimação do Hidrogênio.

Algoritmo de Treinamem.	Nº de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	98,57 / 98,57	100,00 / 100,00	100,00 / 100,00
RBF	5	98,57 / 94,29	98,33 / 90,00	100,00 / 94,12
LM	15	98,57 / 98,57	98,33 / 95,00	100,00 / 98,04
RBF	15	98,57 / 98,57	100,00 / 100,00	100,00 / 100,00
LM	25	98,57 / 98,57	98,33 / 93,33	98,04 / 98,04
RBF	25	98,57 / 98,57	100,00 / 100,00	100,00 / 100,00
CONFIGURAÇÃO ADEQUADA		MLP-LM – 5 neurônios – 2 atributos		

Diante dos resultados, o algoritmo de treinamento MLP Levenberg-Marquardt apresenta propriedade de obter alto grau de acerto nas séries de treinamento, validação e teste. Melhores desempenhos são alcançados com o uso de 2 atributos

físico-químicos como entradas, tendo vantagem, inclusive, como rede menos complexa.

Com relação à estrutura RBF, o índice de acerto é também satisfatório, porém, com uma diferença em relação à MLP: a necessidade de uma maior quantidade de neurônios para apresentar melhores resultados.

Visando a adoção de uma rede mais simples na eventual implementação em uma ferramenta computacional, a escolha da rede MLP-LM com apenas cinco neurônios na camada escondida e com 2 atributos de entrada seria a mais adequada sem comprometer a eficiência da resposta.

Seguindo o mesmo critério acima exposto, as tabelas seguintes apresentam os resultados para as demais estimativas dos gases e elegem uma configuração de rede neural menos complexa e de eficiência considerável.

Tabela 6.16 – Percentual de acerto das redes neurais para estimativa do Monóxido de Carbono.

Algoritmo de Treinamem.	Nº de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	100,00 / 100,00	98,33 / 100,00	94,12 / 100,00
RBF	5	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
LM	15	100,00 / 100,00	98,33 / 98,33	96,08 / 98,04
RBF	15	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
LM	25	100,00 / 100,00	98,33 / 98,33	96,08 / 96,08
RBF	25	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
CONFIGURAÇÃO ADEQUADA		RBF – 5 neurônios – 2 atributos		

Tabela 6.17 – Percentual de acerto das redes neurais para estimativa do Dióxido de Carbono.

Algoritmo de Treinamem.	Nº de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00

RBF	5	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
LM	15	100,00 / 100,00	100,00 / 98,33	98,04 / 100,00
RBF	15	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
LM	25	100,00 / 100,00	100,00 / 98,33	98,04 / 96,08
RBF	25	100,00 / 100,00	100,00 / 100,00	100,00 / 100,00
CONFIGURAÇÃO ADEQUADA		MLP-LM – 5 neurônios – 2 atributos		

Tabela 6.18 – Percentual de acerto das redes neurais para estimação do Metano.

Algoritmo de Treinamem.	Nº de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	97,86 / 94,29	96,67 / 96,67	100,00 / 94,12
RBF	5	97,86 / 97,86	96,67 / 96,67	100,00 / 98,04
LM	15	97,86 / 92,14	96,67 / 96,67	100,00 / 90,20
RBF	15	97,86 / 97,86	96,67 / 96,67	100,00 / 100,00
LM	25	97,86 / 97,86	96,67 / 96,67	96,08 / 96,08
RBF	25	97,86 / 97,86	96,67 / 96,67	100,00 / 100,00
CONFIGURAÇÃO ADEQUADA		MLP-LM – 5 neurônios – 2 atributos		

Tabela 6.19 – Percentual de acerto das redes neurais para estimação do Etileno.

Algoritmo de Treinamem.	Nº de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	86,43 / 86,43	96,67 / 96,67	78,43 / 78,43
RBF	5	86,43 / 82,14	96,67 / 93,33	82,35 / 74,51
LM	15	86,43 / 86,43	96,67 / 96,67	76,47 / 80,39
RBF	15	86,43 / 86,43	96,67 / 96,67	82,35 / 82,35
LM	25	86,43 / 85,71	95,00 / 95,00	76,47 / 80,39
RBF	25	86,43 / 86,43	96,67 / 96,67	82,35 / 82,35
CONFIGURAÇÃO ADEQUADA		RBF – 5 neurônios – 2 atributos		

Tabela 6.20 – Percentual de acerto das redes neurais para estimação do Etano.

Algoritmo de Treinamem.	Nº de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	58,57 / 57,86	66,67 / 66,67	60,78 / 56,86
RBF	5	58,57 / 58,57	66,67 / 66,67	60,78 / 56,86
LM	15	58,57 / 55,71	66,67 / 58,33	60,78 / 43,14
RBF	15	58,57 / 58,57	66,67 / 66,67	60,78 / 60,78
LM	25	58,57 / 52,85	66,67 / 50,00	54,90 / 47,06
RBF	25	58,57 / 58,57	66,67 / 66,67	60,78 / 60,78
CONFIGURAÇÃO ADEQUADA		Resultados Insatisfatórios		

Tabela 6.21 – Percentual de acerto das redes neurais para estimação do Acetileno.

Algoritmo de Treinamem.	Nº de Neurônios na Camada Escondida	Diagnóstico Correto (%) 2 atributos / 3 atributos		
		Treinamento	Validação	Teste
LM	5	5,71 / 5,71	5,00 / 5,00	5,88 / 3,92
RBF	5	5,71 / 5,71	5,00 / 3,33	5,88 / 5,88
LM	15	5,71 / 5,71	5,00 / 5,00	3,92 / 5,88
RBF	15	5,71 / 5,71	5,00 / 5,00	5,88 / 5,88
LM	25	4,28 / 5,71	3,33 / 3,33	3,92 / 3,92
RBF	25	5,71 / 5,71	5,00 / 5,00	5,88 / 5,88
CONFIGURAÇÃO ADEQUADA		Resultados Insatisfatórios		

Dos resultados acima, vê-se uma excelente estimação para o hidrogênio, monóxido e dióxido de carbono e metano, todos apresentando resultados da ordem de 100% de acerto com topologia pouco complexa para a rede neural (2 atributos físico-químicos como entradas) e 5 neurônios na camada escondida. A estrutura MLP com treinamento Levenberg-Marquardt é lançada como mais adequada na maioria das estimações, porém a RBF apresenta resultados tão bons quanto a MLP. Somente nos casos do monóxido de carbono e etileno a estrutura RBF é mais adequada por mostrar melhor taxa de acerto nos dados de teste.

Os resultados da estimação do etileno são bons, mas não chegam ao patamar da estimação dos quatro gases já citados. Entretanto, a estimação do etano se

configura muito ruim, em torno de apenas 60% de acerto. A baixa qualidade dos dados disponíveis é a causa para estes resultados. Não há uma variação muito grande nos valores dos ensaios cromatográficos para o Etano.

Vale a pena comentar que os resultados extremamente ruins da estimação do acetileno confirmam as conclusões acerca das tabelas 6.13 e 6.14 e se devem a uma carência de dados que permitam o estabelecimento do relacionamento entre os atributos físico-químicos e cromatográficos para este gás dissolvido. Entretanto, baseado em resultados obtidos em várias aplicações com carência de dados, alguma estratégia envolvendo *Support Vector Machine (SVM)* pode apresentar uma solução para esse problema.

Também, para resultados onde ocorre um desempenho da rede da ordem de 100% de acerto, vale ressaltar o que já foi dito antes em capítulos anteriores, que pode haver algum erro na aplicação de dados isolados devido à possibilidade do conjunto de dados não ser representativo de todos os casos reais.

Também, deve-se levar em consideração alguma incerteza com relação aos resultados dos laudos dos especialistas que perfazem os conjuntos de dados utilizados no desenvolvimento das redes.

6.5 CONCLUSÕES

Neste capítulo, foram propostas e projetadas duas estruturas de redes neurais objetivando a implementação do módulo do sistema para a estimação de gases dissolvidos a partir das grandezas físico-químicas.

O algoritmo de busca exaustiva apresentou resultados fortemente positivos permitindo a identificação dos parâmetros dos ensaios físico-químicos mais influentes na condição de gases dissolvidos no óleo. A maior parte das estimações apresentou ótimos resultados com apenas duas características físico-químicas como entrada da rede neural. Isto otimiza o projeto da rede, simplificando os esforços computacionais, e melhora o desempenho, pois evita o aprendizado de detalhes provenientes de entradas irrelevantes.

Em termos de complexidade de estrutura da rede neural, conclui-se que redes MLP com apenas uma camada escondida formada por 5 neurônios torna a rede menos

complexa para a tarefa de estimação dos gases dissolvidos no óleo e não compromete a eficiência da tarefa.

É evidente a alta eficiência na estimação do hidrogênio, monóxido e dióxido de carbono e metano. Hidrogênio e metano aparecem dissolvidos no óleo quando há ocorrência de falhas térmicas que sobreaquecem o óleo e os óxidos de carbono são decorrentes de falhas que envolvem a celulose. A qualidade da estimação é explicada pelo fato da maior parte dos dados cromatográficos, que apresentam análise físico-química contemporânea, diagnosticarem falhas térmicas no transformador amostrado.

Pelo mesmo fato, é explicada a baixa qualidade da estimação dos gases mais pesados, como etano e acetileno, que são dissolvidos no óleo mediante falhas elétricas.

É necessário enfatizar que os resultados demonstram a existência do relacionamento entre as grandezas físico-químicas e cromatográficas. Esta relação pode ter seus estudos aprofundados de forma a promover um maior conhecimento das dinâmicas que envolvem as falhas internas do transformador e as qualidades dielétricas do óleo isolante. Daí surge a possibilidade de se instituir critérios preventivos acerca da degradação do óleo e das falhas incipientes em transformadores.

No mais, de acordo com esses comentários, é possível acompanhar a evolução dos gases dissolvidos sem a realização de uma cromatografia completa, que em muitos casos é uma facilidade conveniente, devido à fácil disponibilidade dos testes físico-químicos.

Capítulo 7

SISTEMA COMPUTACIONAL PARA MONITORAMENTO E DIAGNÓSTICO DO ÓLEO ISOLANTE DE TRANSFORMADORES

Em transformadores, mesmo novos, quando ocorre algum sinal de problema durante a operação, como alarme de relé de gás Buchholz, proteção diferencial entre outros, certas questões podem ser levantadas sobre a origem do problema, os efeitos na confiabilidade da operação, a necessidade e possibilidade de reparos sem desligamento da unidade ou substituição por outro transformador.

Logo se faz necessário expor aos responsáveis pela operação e manutenção de unidades do parque elétrico uma forma de acesso às informações precisas de monitoramento e diagnóstico.

O conceito de um objeto computacional para interface entre o sistema de monitoramento e diagnóstico do transformador e os operadores está na seção 7.1 deste capítulo. A seção 7.2 demonstra o projeto do módulo de monitoramento on-line do transformador. O módulo de diagnóstico, contemplando diagnóstico de falhas incipientes, estado do óleo e estimação dos gases dissolvidos, está na seção 7.3. Na seção 7.4 está descrito o desenvolvimento da estrutura do aparato computacional. Algumas aplicações e seus respectivos resultados estão descritos na seção 7.5. Os comentários conclusivos estão situados na seção 7.6.

7.1 CONCEITO DE SISTEMA COMPUTACIONAL PARA MONITORAMENTO E DIAGNÓSTICO

A detecção e o monitoramento da evolução de condições de falhas, quando edificadas em uma plataforma computacional, proporcionam um ambiente de confiabilidade e continuidade de operação em torno do equipamento.

Este tipo de concepção pode ser capaz de reconhecer falhas térmicas e elétricas nas partes ativas de um transformador em operação de uma forma antecipada,

superando os resultados dos gases separados no relé Buchholz que usualmente assume o posto de sensor e proteção do equipamento (VARL, 2002).

O desenvolvimento de sistemas que reforcem estas afirmações tem sido alvo de muitas pesquisas e os benefícios da sua aplicação vêm sendo difundidos. Aliado a isso, surge a questão da qualidade do processamento da informação proveniente das múltiplas informações fornecidas pela a grande quantidade de fontes de medição e do amplo número de unidade monitoradas. Daí a tendência à aplicação de métodos inteligentes no projeto de sistemas computacionais para o gerenciamento do monitoramento e diagnóstico de transformadores (SHENCK *et al.*, 2002).

O objetivo é dispor de um método seguro de avaliação das condições de operação de transformadores permitindo melhor desempenho na previsibilidade de falhas. Nisto, é necessário o emprego de análise meticulosa das informações dos dados na geração de uma decisão ou recomendação mais apropriada, algo muitas vezes conseguidas através de especialistas. Daí o grande foco no uso de técnicas inteligentes que abranjam os conhecimentos destes profissionais na avaliação das condições do equipamento com característica grande quantidade de acertos.

O sistema computacional gerencia todas as análises detalhadas dos dados com utilização destas técnicas de inteligência artificial para a aplicação dos conhecimentos e suposições de especialistas. Como resultado, há a constituição de um relatório com recomendações ou decisões acerca da situação investigada.

A utilização de ferramentas computacionais propicia o aumento da confiabilidade das avaliações de especialistas e aperfeiçoa os procedimentos de manutenção permitindo que uma dada situação de falha seja avaliada em tempo reduzido e hábil para tomada de decisões que conservem a operação do sistema e estendam a vida útil do equipamento. Isto significa uma otimização do retorno do investimento e representa uma grande vantagem para o uso deste tipo de recurso.

O sistema computacional desenvolvido é modular e suporta avaliação das informações de monitoramento *on-line*, de diagnóstico de falhas incipientes e do estado do óleo, além da estimação dos gases dissolvidos através das características físico-químicas.

7.2 MÓDULO DE MONITORAMENTO

O módulo de monitoramento apresenta características que objetivam acompanhar a evolução dos dados de interesse no que tange a diminuir a saída de operação não planejada aumentando a credibilidade dos agentes do parque elétrico. Estas características são: a detecção antecipada de falhas incipientes e o monitoramento do avanço das situações de falha.

Na detecção antecipada de falhas os danos ao equipamento são evitados, pois as providências adequadas são tomadas em tempo reduzido limitando as avarias secundárias e limitando a área de reparo e manutenção. Também, os custos de operação são reduzidos quando há uma diminuição dos reparos fora do cronograma planejado para manutenção.

Quando uma falta é detectada e sua evolução monitorada, a sua gravidade pode, então, ser avaliada e uma decisão oportuna pode ser viabilizada. Assim, é criada uma oportunidade de planejamento estratégico do cronograma de saída de operação do equipamento, sua utilização e disponibilidade.

Se a gravidade da falha é considerada moderada, algumas vezes o transformador pode ser mantido em operação sob a ressalva da redução do carregamento. Esta estratégia serve como uma forma de evitar perda de rendimentos e propiciar tempo hábil para organizar uma intervenção para reparo ou substituição do equipamento. Estas providências se revelam como uma vantagem no gerenciamento dos recursos disponíveis, principalmente quando são possíveis os reparos *on-site* gerando benefícios econômicos aos proprietários e aos fabricantes, no caso de trabalho sob o tempo de garantia. Financeiramente, isto pode gerar situação agradável no fluxo de caixa dos responsáveis e liberar capital para outros investimentos.

O monitoramento de uma falta de rápido desenvolvimento e a avaliação do seu progresso remonta à constituição de um cenário que possibilita a reunião de todos os recursos essenciais para reagir a tempo de promover uma preciosa redução dos danos.

Porém, obter ótimos resultados no gerenciamento da disponibilidade e extensão da vida útil do transformador exige que o monitoramento seja de elevada qualidade

garantindo a essência e a validação da reação diante do quadro de falha (GIBEAULT; KIRKUP, 1998).

Convencionalmente, o óleo é amostrado e analisado periodicamente possibilitando um período, entre amostras, onde nenhuma informação pode ser obtida. Por outro lado, a detecção de qualquer desvio nos valores dos gases dissolvidos que são chave no desenvolvimento de determinada falha, de acordo com o comentado no capítulo 3 deste trabalho, gera um alerta sobre o desenvolvimento de uma falha incipiente no equipamento.

Mesmo que os métodos de DGA forneçam as informações necessárias para uma tomada de decisão menos susceptível ao erro sobre a continuidade de operação do equipamento em questão, algumas experiências indicam que somente este tipo de análise não é o bastante para garantir confiabilidade na continuidade de operação de transformadores em situações críticas. Ainda mais quando se trata de uma análise tida por normal, onde o intervalo entre amostras sugerido é de doze meses. Isto parece desconsiderar a probabilidade de ocorrência de eventos imprevistos, durante este período, que desenvolvam situações de falhas, pondo a unidade em risco e desacreditando as recomendações originadas dos métodos convencionais de DGA. Este período crítico, que se estende desde imediatamente após a análise do óleo até a próxima amostragem do óleo sugerida pelo método de DGA, significa um período de certo modo longo, onde não há conhecimento sobre a real situação interna da unidade. Neste ínterim, uma rápida mudança nas condições internas de operação do transformador pode gerar gases que denunciam uma condição de falha, mas estes não serão detectados até a amostragem no tempo padrão, o que em certos casos pode ser muito tarde. Assim, o uso de DGA pode ser referenciado como uma fotografia, que apenas reflete a condição presente de forma momentânea, mas não garante que este estado atual se prolongue até o prazo estabelecido para uma próxima análise.

Quando há o confronto destas considerações com a velocidade de desenvolvimento de alguns tipos de falhas incipientes parece incompatível confiar em uma análise anual como forma de proteção de um equipamento de suma importância para o parque elétrico e de grande valor econômico.

Gerencialmente, pode ser considerado um erro básico fazer suposições e tomar decisões de alta relevância econômica, por se tratar de equipamento elétrico essencialmente de grande porte financeiro, baseado em informações colhidas com diferença de doze meses sem nenhum suporte sobre o período entre análises.

Do exposto, quanto maior o período entre amostra para DGA, sem monitoramento durante este intervalo, maior a probabilidade de não ser detectado, em curto prazo, uma falha de desenvolvimento rápido no equipamento. Mesmo que o tempo de desenvolvimento da falha dure alguns meses, ainda se configura um perigo de catástrofe sem aviso prévio ou detecção.

Então, se mesmo dispondo das informações relevantes dos métodos de DGA não é possível evitar ser surpreendido por falhas repentinas que podem ser catastróficas, é necessário empreender uma forma de se utilizar as informações de DGA mais efetivamente.

Em primeira instância, é fácil raciocinar na redução do tempo de amostragem, mas dependendo do caso, pode se tornar uma solução cara e impraticável se por ocasião de suspeita de falha este tempo diminuir demais. Uma sugestão amadurecida seria o projeto de um método *on-line* de monitoramento provido de alarme para as condições de incremento de gases de falta.

Unindo as inestimáveis informações que podem ser extraídas dos métodos de DGA com a observação incessante das mudanças de comportamento do equipamento que possam revelar situação de falha, um método de monitoramento *on-line* aparece como método mais eficiente e efetivo de detectar, identificar e localizar mais rapidamente as condições de falha em um transformador, porém, com característica desejável de custo acessível e de realização prática com uso de métodos confiáveis para geração de alarmes nos momentos de anormalidades. Este alarme deflagra a ação de manutenção desde amostragem de óleo para uma análise mais acurada até ao desligamento da unidade em casos de acusação de situação muito crítica.

Os gases mais comuns que denunciam falhas no dielétrico do transformador, através da aplicação de DGA, são hidrogênio (H_2), etano (CH_4), acetileno (C_2H_2) e etileno (C_2H_4). Com presença de monóxido de carbono (CO) e dióxido de carbono (CO_2) em falhas que envolvem a celulose. Porém, cabe mencionar que mesmo em

transformadores novos é possível encontrar certos níveis de hidrogênio e monóxido de carbono porque estes gases podem ser formados mesmo em condições de temperatura não muito acima das normais. Isto chama a atenção para uma parametrização correta dos níveis de normalidade desses gases para cada transformador a ser analisado através de métodos de monitoramento no intuito de evitar alarmes em condições de normalidade.

Mas também, pelo mesmo motivo, hidrogênio e monóxido de carbono são os primeiros gases de falha formados e apresentam forte adição no valor da taxa de crescimento na medida em que as temperaturas de falha sofrem acréscimos. Logo, diante disso, um parâmetro que pode mensurar a presença de falha incipiente no equipamento e promover a detecção antecipada de uma situação de falha é o aumento da taxa de geração dos gases. Mais precisamente, a taxa de geração de dois gases principais, hidrogênio e monóxido de carbono, pode ser definida como indicador de falhas internas, tanto no óleo como na celulose.

Nos estudos de Zylka e Mazurek (2002), pode ser observada a relação entre a produção destes dois gases dissolvidos em testes de falhas típicas em óleos isolantes. As falhas ensaiadas foram descargas parciais, descargas de energia constante e sobreaquecimento no óleo e os resultados da evolução na geração dos referidos gases, representada pela tensão de saída do sensor correspondente a cada gás, são mostrados na figura 7.1.

Também, no mesmo trabalho citado, outros testes foram feitos para relacionar a dinâmica de geração dos gases (através da relação k_{CO/H_2} entre os sinais de saída dos sensores), temperatura do óleo e o carregamento do transformador. Sobrecargas foram aplicadas a um transformador de teste nos níveis de 110, 120, 130, 140 e 150% da corrente nominal durante três dias com amostragem do óleo a cada dia. Como resultado, é demonstrada a característica do mecanismo de decomposição térmica do óleo a partir de uma sobrecarga de 30%, conforme visto na figura 7.2. Isto ocorre porque o óleo, a partir deste nível de sobrecarga, passa a apresentar maior energia de ativação, o que inicia uma inversão na evolução da relação entre as produções de hidrogênio e monóxido de carbono. Dessa forma, a interpretação dos dados de monitoramento exige uma observação das condições de carregamento e temperatura do equipamento.

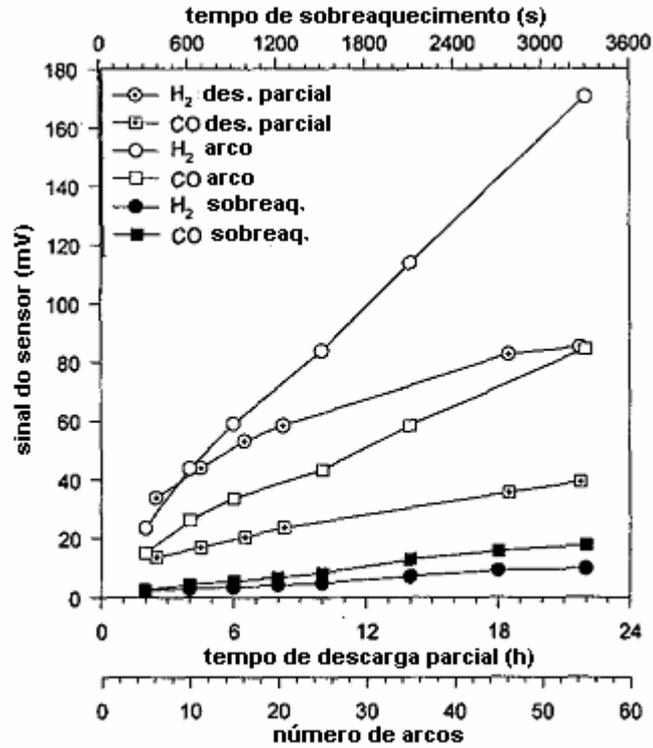


Figura 7.1 – Evolução de hidrogênio e monóxido de carbono na presença de condições de falhas típicas.

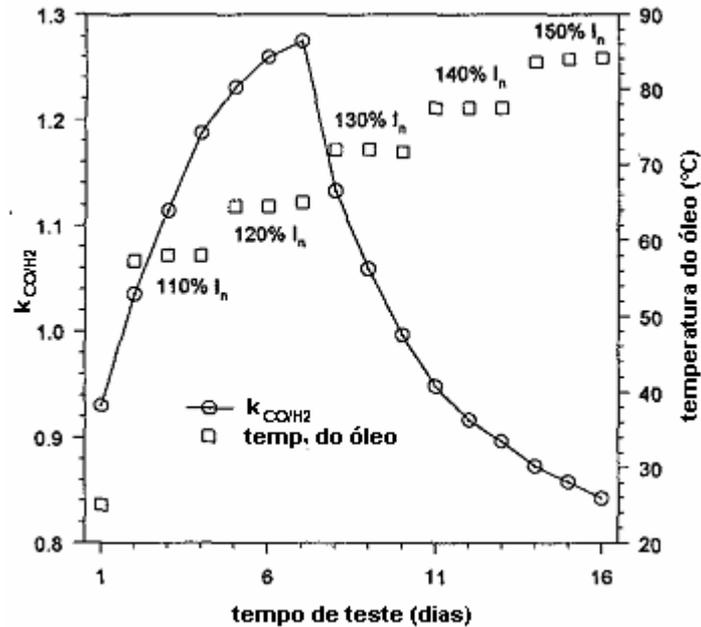


Figura 7.2 – Evolução de hidrogênio e monóxido de carbono durante teste de sobrecarga.

Então, um aumento do valor de hidrogênio acima do valor estabelecido inicialmente como normal indica falha interna com possível presença de outros gases e/ou qualquer anormalidade na geração de monóxido de carbono já é sinal de carência de uma análise mais profunda. Assim, é possível usar os valores de geração desses gases como fator desencadeador de uma amostragem para DGA que fornecerá a confirmação da situação de falha.

O Hydran® M2 usa uma membrana permeável seletiva que é sensível principalmente a hidrogênio e monóxido de carbono, embora mantenha também alguma sensibilidade a etileno e acetileno, conforme descrito no capítulo 3 deste trabalho. Na câmara de reação eletroquímica do Hydran® M2, os gases reagem com o oxigênio do ar ambiente para gerar um sinal elétrico, através de circuitos eletrônicos. O sistema de amostragem é dinâmico e não necessita da ação de agentes externos ao sensor, funcionando através de aquecimento controlado e resfriamento passivo para provocar o movimento do óleo (GE ENERGY SERVICES, 2003).

O Hydran® M2, então, apresenta em sua saída o valor da composição das quantidades dissolvidas no óleo dos gases, como segue: Hidrogênio (H_2): 100% de concentração; Monóxido de Carbono (CO): $(18 \pm 3)\%$ da concentração; Acetileno (C_2H_2): $(8 \pm 2)\%$ da concentração e Etileno (C_2H_4): $(1,5 \pm 0,5)\%$ da concentração. É possível notar que a maior influência no valor de saída é do hidrogênio e do monóxido de carbono. Assim, esta tecnologia pode ser aplicada na detecção de situações de falhas e no monitoramento de suas evoluções, disparando um alarme de aviso que conduza a amostragem e análise que possa determinar a natureza e severidade da falha.

Também, como apoio ao monitoramento da evolução dos gases e aproveitando a capacidade do sensor Aquaoil® 400 do Hydran® M2, é possível obter uma medição de umidade no óleo. A água no óleo aparece em quatro formas diferentes: dissolvida e livre para se mover em busca do equilíbrio; ligada quimicamente a moléculas polares; supersaturada, em uma quantidade superior à capacidade do óleo de dissolvê-la; em ligação com a celulose e partículas metálicas. Através de cálculos específicos, o Hydran® M2 fornece a soma das quatro formas de água no óleo em p.p.m. O sensor do Hydran® M2 fornece a umidade relativa, em percentagem, e o

cálculo da concentração de água dissolvida depende da solubilidade do óleo. O Aquaoil® 400 é calibrado para o óleo Voltesso® 35 da Esso Petroleum. Isto deve ser levado em consideração quando da aplicação de óleos diferentes (*GE ENERGY SERVICES, 2005*).

A medida de umidade relativa fornece informações úteis como:

- Saturação relativa do óleo na temperatura de operação;
- Temperatura na qual a água vai condensar no óleo;
- Estimação do percentual de água no papel isolante.

No caso do cálculo do teor de água na celulose, a umidade relativa é mais significativa que a umidade absoluta, valorizando a medição direta do Aquaoil® 400.

Além disso, mediante a disponibilidade de entrada analógica no dispositivo Hydran® M2, as medições da temperatura do óleo e da temperatura do enrolamento do transformador são disponibilizadas no banco de dados das medições do monitor *on-line*.

O uso de monitoramento *on-line* finda no aumento da confiabilidade da operação e na preservação do equipamento, além de redução dos custos de manutenção. Os programas de manutenção podem ser aperfeiçoados com a inclusão de uma lógica de decisão que leve em consideração as vantagens do uso de um método de monitoramento *on-line*. Por exemplo, um monitor instalado é sensível a mudanças na concentração de gases de falha dissolvidos e detecta condições de falha antes que estas possam se desenvolver. A evolução das concentrações dos gases é acompanhada para fornecer informações em tempo-real vitais na elaboração de alertas em ocasiões de falha. A detecção e avisos de alarme antecipados de falhas favorecem a eficiência do programa e conseqüentemente reduzem custos de manutenção.

Em termos financeiros, possui melhor retorno a realização de testes que evidenciem os totais dos gases dissolvidos que execução de uma análise cromatográfica completa, ainda mais em amostras que apresentem níveis normais de gases dissolvidos.

7.3 MÓDULO DE DIAGNÓSTICO

A aplicação de métodos de DGA, como já citado, realmente aparece com um meio de se verificar a existência de condições de falta e identificar o grau de severidade envolvida. Mesmo diante de um período amplo entre uma amostragem e outra, em um trabalho conjunto com sistemas de monitoramento pode-se prever um sistemas de prevenção contra falhas internas em transformadores com alto índice de confiabilidade.

Entrementes, como já verificado neste trabalho em capítulos anteriores (capítulos 3 e 4), os métodos tidos como convencionais apresentam, inerentes às suas formas de análises, certas dependências de limites dos gases e alguns detalhes que variam entre os equipamentos. Também, estes métodos carregam algumas falhas nos diagnósticos ligados ao fenômeno da não-decisão. Assim, a precisão do diagnóstico baseado nestes métodos ainda é insatisfatória.

Por isso, a confecção de um aparato computacional que contemple, além dos métodos convencionais de análise, métodos inteligentes que possam atingir índices de acertos desejáveis se caracteriza como uma boa ferramenta de suporte à gerência de manutenção no que tange a proteger a unidade e prolongar o tempo de vida útil.

Também vale a pena propor, neste mesmo produto computacional, um algoritmo de diagnóstico de qualidade dielétrica do óleo em complemento ao diagnóstico de falhas incipientes, uma vez que estes dois tipos de análises, cromatográfica e físico-química, são análises padrões para transformadores.

Em adição, também é estabelecido um método inteligente que demonstra a relação entre os atributos físico-químicos e cromatográficos, revelando a influência das produções dos gases na qualidade do óleo.

Dessa forma, o módulo de diagnóstico apresenta estratégias inteligentes para a solução de identificação e classificação das falhas internas, quando detectadas, e da qualidade do óleo isolante, mesmo que se disponha apenas de resultados laboratoriais de testes físico-químicos, de fácil obtenção em comparação às cromatográficas.

7.3.1 Diagnóstico de Falhas Incipientes

Para a confecção do módulo de diagnóstico de falhas incipientes, três algoritmos foram concebidos e funcionam em paralelo. Estes algoritmos abrangem os métodos convencionais, sistemas nebulosos e redes neurais, conforme abordados neste estudo, no intuito de caracterizar as falhas incipientes em transformadores de potência.

O diagnóstico fornecido por cada algoritmo é então combinado de acordo com uma estratégia de decisão que privilegia a maior probabilidade de acerto para compor o diagnóstico final do módulo apresentado no diagrama de blocos da figura 7.3.

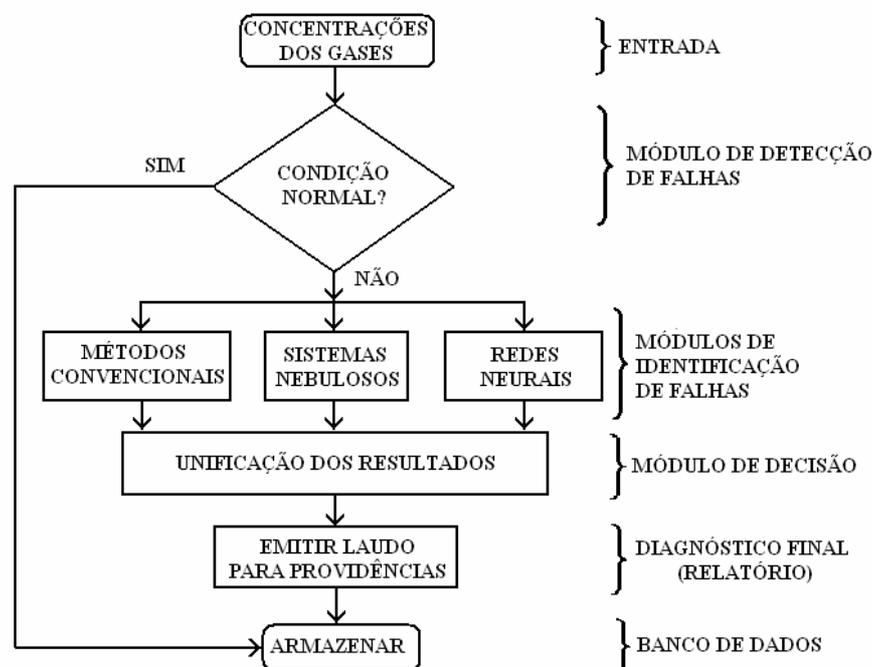


Figura 7.3 – Diagrama de blocos do algoritmo proposto.

A verificação da condição da amostra se refere à detecção de falhas incipientes que finda por definir uma condição de normalidade ou não através de comparação com valores tidos como normais para as concentrações dos gases de falhas estratificados na amostra. Esses limites, inicialmente, podem ser os da Norma L1, demonstrada na tabela 2.3. Ao se detectar um nível de qualquer concentração de gás que ultrapasse esses limiares pré-estabelecidos, é levantada uma suspeita de anormalidade e o algoritmo avança no sentido de identificar o tipo da falha.

Devido à forma de elaboração dos métodos de identificação, a interpretação das análises cromatográficas dos gases pelos algoritmos somente são realizados na dependência da suspeita de falhas. Quando não ocorre essa suspeita de falha, a amostra é considerada em condição de degradação normal e a unidade é considerada sem falha.

Com relação ao algoritmo com métodos convencionais de identificação de falhas, a saída é proveniente da implementação do método de Rogers revisado constante das normas (IEEE, 1992; IEC, 1999; ABNT, 1982) que traz uma representatividade do conhecimento na área de diagnóstico de falhas incipientes. Este citado conhecimento não deve ser de todo desprezado, mesmo apesar de apresentar casos onde não há diagnóstico válido. Isto porque esses métodos tidos por tradicionais carregam um peso de nascerem após vários testes laboratoriais e inúmeras inspeções em transformadores no objetivo de serem confirmados.

Como em todos os métodos utilizados na composição do módulo de diagnóstico, as variáveis de entrada são as concentrações dos gases dissolvidos (H_2 , N_2 , O_2 , CH_4 , C_2H_2 , C_2H_4 , C_2H_6 , CO e CO_2), em p.p.m., colhidos da cromatografia da amostra do óleo. O algoritmo se encarrega de gerar as razões entre os gases definidas como entrada para o método convencional.

O resultado da aplicação do método é apresentado em uma variável de saída que indica o diagnóstico através das seguintes possíveis: normal (condição de degradação e envelhecimento normal do sistema de isolamento), descargas parciais de baixa densidade de energia, falha térmica em quatro níveis de sobreaquecimento FT T1 ($T < 150^\circ C$), FT T2 ($150^\circ C < T < 300^\circ C$), FT T3 ($300^\circ C < T < 700^\circ C$) e T4 ($T > 700^\circ C$) e descargas de alta densidade de energia ou arcos em dois níveis de densidade de energia.

Na aplicação de sistemas nebulosos na identificação de falhas, a vantagem reside na capacidade destes sistemas na manipulação de informações imprecisas e incompletas. Sua forte característica permite a utilização, na rotina de decisão, de conhecimento de especialistas, fato que não ocorre na aplicação direta e confere a este método a capacidade de solucionar os problemas de não-decisão inerentes aos métodos tradicionais.

A rotina foi projetada sobre o sistema integrado apresentado na seção de análise de resultados do capítulo 4 deste estudo e apresenta saída de diagnóstico como segue: normal, descargas parciais, falha térmica em quatro níveis de sobreaquecimento FT T1 ($T < 150^{\circ}\text{C}$), FT T2 ($150^{\circ}\text{C} < T < 300^{\circ}\text{C}$), FT T3 ($300^{\circ}\text{C} < T < 700^{\circ}\text{C}$) e T4 ($T > 700^{\circ}\text{C}$) e descargas de alta densidade de energia ou arcos em dois níveis de densidade de energia.

O desenvolvimento da identificação de falhas incipientes através de redes neurais se aproveita da característica das redes neurais de minerar conhecimento estabelecido no universo de dados de treinamento e formar, a partir disso, uma relação entre entrada e saída. Esta qualidade da rede favorece o seu alto índice de acertos com relação a este tipo de aplicação, uma vez que o conjunto de dados é confiável e possui tamanho suficiente para o trabalho de modelagem do problema.

Este algoritmo foi implementado tendo por base a rede neural artificial desenvolvida no capítulo 4 desta dissertação. O diagnóstico de saída é como segue: falha térmica de baixa temperatura, falha térmica de alta temperatura, descargas de baixa energia, descargas de alta energia, degradação da celulose e normal.

É formulado, também, um valor de diagnóstico final unificando os resultados dos três métodos implementados. Quando as saídas são condizentes, o diagnóstico final já está estabelecido. Em caso de diagnóstico discordante, a unificação das saídas é baseada em uma rotina de competição e compromisso (WANG, 2000).

É proposto um valor de confiança, entre 0 e 1, para as saídas dos métodos implementados e diagnóstico final. Devido a erros envolvendo problemas de não decisão e o desejo de tender a um afastamento do conservadorismo das normas, o método convencional sempre adquire valor de confiança igual a 0,6 em seus diagnósticos, excetuando o caso de diagnóstico de falhas térmicas de baixa temperatura onde o desempenho é melhor e o grau de confiança atribuído é 0,8.

Os sistemas nebulosos recebem grau de confiança 0,8 nos diagnósticos, com exceção dos diagnósticos de descargas parciais e falha térmica de baixa temperatura por ocasião deste método classificar erroneamente estes tipos de falhas. Para estes, o valor de confiança é 0,5.

Como o desempenho da rotina implementada com rede neural apresentou índice de acerto de 100% para o diagnóstico de falhas dentro do universo testado, o grau de confiança atribuído é 1 para os casos de falha.

Nos casos em que os métodos não identificam a falha, inclusive casos de não decisão dos métodos convencionais, o valor de confiança atribuído para a saída do algoritmo é 0,3. Se a falta identificada pelo método é de ordem menor, como descargas parciais e falhas de baixa temperatura, há uma probabilidade de a condição estar no limiar entre normalidade e falha. Então é utilizado um critério de apoio baseado no cálculo dos valores de Total de Gases Combustíveis Dissolvidos (TGCD) e a Taxa de Crescimento dos Gases Combustíveis (TCGC) (WANG, 2000). Um TGCD maior que 720 ppm e uma TCGC maior que 10 % por mês revelam uma condição de anormalidade confirmando a falha e atribuindo 0,8 ao grau de confiança. Caso este critério não confirme a falha, a saída do diagnóstico é mantida, mas o grau de confiança assume valor 0,5.

Nota-se que a saída do algoritmo baseado na rede neural foi escolhido para dominar a saída final, por razão óbvia do alto índice de acerto. A saída final de diagnóstico é obtida pela comparação entre os valores de confiança das saídas das rotinas de diagnóstico. O maior grau de confiança aponta o diagnóstico final.

7.3.2 Diagnóstico do Estado do Óleo

A observação das propriedades físico-químicas do óleo do transformador pode conduzir a um diagnóstico da qualidade dielétrica do meio isolante, o grau de deterioração e uma indicação da real condição de operação do transformador (WARD, 2000).

O programa desenvolvido para o diagnóstico físico-químico tem por finalidade definir uma indicação mais acurada sobre os problemas de qualidade dielétrica do líquido isolante do transformador que as análises convencionais não são capazes de demonstrar. O uso de sistemas computacionais para implementar este tipo de diagnóstico é uma forma de aumentar a credibilidade da análise (WANG Z., 2000).

Com os resultados desta análise, é disponibilizada uma série de recomendações preventivas visando manter o bom desempenho dielétrico do sistema isolante e uma conseqüente extensão da vida útil do transformador (WANG M. *et al.*, 2002).

A vantagem da constituição das rotinas em ferramentas computacionais é a capacidade de análise dos dados e a correlação com os padrões de normalidade. Dessa forma, qualquer anormalidade quando detectada gera situação de alerta e pode descrever uma lista de recomendações para aperfeiçoar a manutenção. Os resultados alcançados provêm de avanços das técnicas de inteligência artificial, em especial, métodos de redes neurais artificiais que geram um ambiente de crédito com eficiência na interpretação e análise dos dados.

Os atributos físico-químicos, que são as entradas do algoritmo, são analisados de acordo com a tabela 5.2, por exemplo, para lançar uma perspectiva sobre as condições de normalidade do estado dielétrico do óleo. Daí, qualquer anormalidade detectada conduz para um prosseguimento na rotina para firmamento de diagnóstico e recomendação condizente com a análise efetuada.

As entradas do algoritmo são os valores dos atributos coletados das análises físico-químicas, como seguem: acidez, rigidez dielétrica, teor de água, tensão interfacial, densidade e fator de potência do óleo. Estas entradas, conforme estudado no capítulo 5, comportam informações importantes para um diagnóstico confiável de forma que, na saída, são listadas posturas de manutenção como recondicionamento por termo-vácuo, regeneração por filtração, reamostragem imediata e reamostragem em um ano no caso de normalidade. Entende-se a recomendação de regeneração por filtração com tratamento químico com meio básico, por exemplo, metassilicatos, ou tratamento com meio absorvente sólido, por exemplo, argilas ou carvão ativado.

A figura 7.4 apresenta um guia, fornecido por fabricante de transformadores, para a verificação das condições do óleo isolante mediante as análises físico-químicas, propiciando um método convencional de se obter recomendações para manutenção.

Tg a 90°C (%) ou FP a 100°C (%) (fator de perdas dielétricas a 90 ou 100°C)	Rigidez	Teor de água	Acidez	TIF > 20 mN/m a 25°C	Recomendações		
Atende	Atende	Atende	Atende	Atende	Nenhuma		
				Não atende	Regeneração ou troca de óleo		
			Não atende	—	Regeneração ou troca do óleo e limpeza da parte ativa		
	Não atende	Atende	Atende	Atende	Atende	Filtragem do óleo	
					Não atende	Regeneração ou troca de óleo	
				Não atende	—	Regeneração ou troca de óleo	
		Não atende	Não atende	Atende	Atende	Atende	Secagem da parte ativa e de óleo
						Não atende	Secagem da parte ativa e regeneração ou troca de óleo
					Não atende	—	Secagem da parte ativa e regeneração ou troca de óleo
		Não atende	—	—	—	—	Regeneração ou troca de óleo

Figura 7.4 – Guia de verificação das condições do óleo isolante.

Através do uso de um monitor, como o Centurion® apresentado no capítulo 3 desta dissertação, é possível projetar um sistema de monitoramento *on-line* para a qualidade do óleo isolante de forma que este seja integrado com o algoritmo explanado aqui. O monitoramento *on-line* da rigidez dielétrica serve como parâmetro de detecção de anormalidade nas características dielétricas do óleo deflagrando uma análise físico-química de uma amostra do óleo podendo ser necessária até uma análise de gases dissolvidos também.

Outra sugestão poderia ser o desenvolvimento de um sistema de espectrofotometria ultravioleta para monitoramento da absorvância que designa a qualidade isolante do óleo amostrado (PALMER *et. al.*, 2000).

7.3.3 Estimação da Concentração dos Gases Dissolvidos

Em complemento aos algoritmos anteriores, foi desenvolvida a rotina de estimação da concentração dos gases dissolvidos para prover a possibilidade de diagnóstico de falhas incipientes sem a necessidade de posse das proporções dos gases dissolvidos provenientes do ensaio de cromatografia laboratorial. Com o uso desta rotina, bastam as informações dos atributos físico-químicos para um indicativo sobre a presença de falhas internas.

Por muitas vezes, os dados dos ensaios físico-químicos são bem mais acessíveis que os dados cromatográficos. Esse fato aparece como uma vantagem do uso deste algoritmo na agilidade da definição das condições internas do líquido isolante de transformadores.

As entradas da rotina de estimação, baseada nos desenvolvimentos do capítulo 6 deste trabalho, são as grandezas resultantes das análises físico-químicas como seguem: densidade relativa (adimensional), tensão interfacial (dyn/cm), teor de água (p.p.m.), índice de neutralização (mgKOH/g), rigidez dielétrica (kV) e fator de potência (adimensional). Como saída, o sistema fornece a estimação para os gases hidrogênio, monóxido e dióxido de carbono, metano e etileno.

Entretanto, pelo motivo dos resultados pobres na estimação do etano e acetileno, a rotina não propicia resultados para estes gases. Isto significa que, a partir desta estratégia, é possível diagnosticar falhas incipientes com exceção apenas de falhas envolvendo alta densidade de energia, exatamente pela falta da estimação destes gases.

Vale a pena mencionar que desenvolvimentos futuros consideram a determinação do acetileno e etano o que promoverá o aperfeiçoamento desta estratégia.

7.4 DESENVOLVIMENTO DO SISTEMA COMPUTACIONAL

No intento de disponibilizar, mediante uma interface gráfica, um meio de acesso e uso dos módulos de monitoramento e diagnóstico baseados nos métodos que utilizam inteligência artificial, foi desenvolvido um sistema computacional.

O sistema apresenta telas gráficas de IHM (interface homem-máquina) contendo os comandos, as entradas de dados e o resultado das análises. Estes resultados podem ser expressos através de gráficos, barras animadas ou textos mediante relatórios contendo os diagnósticos e as recomendações pertinentes.

Cada módulo que compõe o sistema computacional funciona de modo independente como se fosse um programa individual. Para o monitoramento, o módulo é integrado ao banco de dados que armazena as leituras do instrumento de monitoramento Hydran® M2, enquanto o módulo de diagnóstico está integrado a um banco de dados que contempla os resultados das cromatografias e ensaios físico-químicos dos óleos isolantes.

No monitoramento, o Hydran® M2 pode ser usado em uma configuração local ou remota através de uma rede usando padrão RS-485. Na rede, o programa de acesso pode se comunicar com cada estação monitora individualmente. Todas as comunicações são coordenadas pelo Hydran® M2, priorizando os envios de alerta, e a transmissão de dados é *half-duplex*.

A ferramenta computacional suporta emissão de alertas sobre condições perigosas dos gases monitorados, umidade e as temperaturas enviadas pelas entradas analógicas. Estes alarmes servem como sinal de condições de falhas internas no transformador.

No momento de um disparo de alarme, algumas ações são efetuadas:

- Uma mensagem de alarme é disposta na tela do programa;
- Os relés de alarme do Hydran® M2 mudam seus estados. Sinalizadores podem ser conectados em painéis para indicar o alerta;

- No arquivo de histórico no banco de dados de diagnóstico são gravadas as informações do evento de alarme, como data e horário, valor das medições de gás, umidade e tendências.

Os alarmes possuem quatro níveis de gravidade conforme exemplo da tabela abaixo:

Tabela 7.1 – Níveis de alarmes disponíveis no Hydran® M2.

Fonte de Alarme	Níveis de alarme			
Gás	-	-	High	High-High
Umidade	-	-	High	High-High
Entr. Analógica	Low-Low	Low	High	High-High
Temp. sensor Hydran	-	Low	High	-
Bateria	Low-Low	Low	-	-

As fontes de alarme podem ser desencadeadas pelas seguintes formas:

- Nível de gás: valor diretamente medido pelo dispositivo monitor;
- Tendência horária de gás: variação do nível de gás durante um período de tempo de 1 a 100 horas, atualizada a cada 5 segundos;
- Tendência diária de gás: variação do nível de gás durante um período de tempo de 1 a 100 dias, atualizada a cada 5 minutos;
- Umidade Relativa: valor diretamente medido pelo dispositivo monitor;
- Umidade relativa média: baseado nos cálculos de umidade relativa em um período de tempo de 1 a 170 horas, atualizada a cada 5 segundos;
- Nível de umidade: Valor calculado com base na umidade relativa e na temperatura;
- Umidade média: cálculo baseado nas leituras do nível de umidade em um período de tempo de 1 a 170 horas, atualizada a cada 5 segundos.

A figura 7.5 mostra a tela principal do módulo de monitoramento.

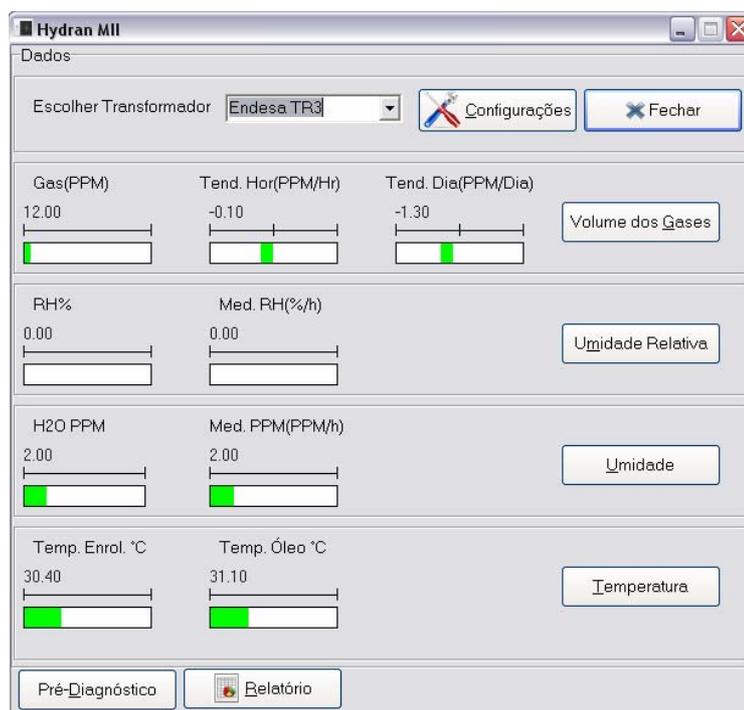


Figura 7.5 – Tela principal módulo de monitoramento.

É necessário lançar um olhar cuidadoso sobre a questão da configuração dos níveis de alarme de sistemas de monitoramento *on-line*. Caso seja configurado um limite de alarme muito alto, o sistema pode ser insensível a algum tipo de falha. Se o limite é muito baixo, podem ocorrer falsos alertas (VARL, 2002).

O módulo apresenta facilidade de execução das rotinas de diagnóstico e conseqüente obtenção do resultado acompanhado por visualização dos procedimentos pertinentes, conforme demonstrado na figura 7.6.

Também há possibilidade de acompanhamento gráfico da evolução das produções dos gases. Este tipo de visualização permite avaliar com clareza o crescimento ou dissipação de uma falha à medida que novas amostras são inseridas no banco de dados.

O mesmo desenvolvimento é utilizado para o diagnóstico fisco-químico.

Um relatório das análises é preparado pelo dispositivo computacional de forma que os resultados sejam documentados.

Figura 7.6 – Tela do módulo de diagnóstico de falhas incipientes.

7.5 ANÁLISE DOS RESULTADOS

Algumas aplicações de detecção e monitoramento produziram resultados vantajosos, como citam os estudos de Gibeault e Kirkup (1998).

Um sensor Hydran® M2, instalado em um transformador 500/13.8kV mantinha uma leitura da ordem de 20 p.p.m. até que um incremento rápido eleva o valor da leitura para 120 p.p.m., o que dispara um alarme. Uma análise dos gases dissolvidos confirma a falta e o transformador é retirado de serviço. Após passar por uma inspeção, foi encontrada uma perca de conexão em uma proteção corona relacionada à instalação de acessórios internos. O transformador foi consertado sob garantia. Isto provocou modificações nos transformadores da mesma família, uma vez que uma unidade já havia apresentado falha catastrófica sem causa determinada.

Em outro caso, a instalação de um monitor Hydran® M2 em um transformador 500/13,8 kV apresenta o total de gases medido em torno de 44 p.p.m. e acompanha a evolução rápida para um patamar de 72 p.p.m em um período de apenas quatorze

minutos. Um alarme é disparado e após a confirmação do quadro, o equipamento é retirado de serviço. A inspeção interna revela condição de falha no OLTC.

E ainda, em um transformador de 21,4 kV e 300 MVA, o alarme foi disparado em 200 p.p.m. e a situação de falha confirmada por DGA. Após quatro dias, a leitura avança para 230 p.p.m. e a unidade é retirada de serviço. A inspeção interna mostra que a cobertura epóxi do suporte das espiras havia sido queimada, o que proporcionou circulação de corrente de falha. Os procedimentos de manutenção puderam, então, ser executados.

A tabela 7.2 apresenta três exemplos de aplicação do método de monitoramento oferecido pelo Hydran® M2. Três transformadores foram selecionados das amostras cromatográficas contidas no apêndice C. Dos dados disponíveis nos ensaios cromatográficos, foram simuladas, mediante a aplicação da seletividade da membrana do sensor, as medidas do total da produção de gases dissolvidos.

Tabela 7.2 – Exemplos da leitura Hydran® M2.

Caso	Data	H ₂ (p.p.m.)	CO (p.p.m.)	C ₂ H ₄ (p.p.m.)	C ₂ H ₂ (p.p.m.)	Hydran® (p.p.m.)
1	5/5/2003	479	84	133	1121	521,6
	11/7/2003	1418	296	257	1435	1513,4
2	15/9/2003	38	590	69	0	149,7
	23/8/2004	57	425	84	0	140,2
3	14/6/2002	2	439	97	0	88,8
	27/1/2003	28	153	8	0	56,2

Como é possível observar nos dados do transformador 1, á medida em que ocorre incremento na produção de gases o sensor apresenta crescimento em sua medição. Isto representa a atuação desejada do monitor. Estes dados correspondem a um diagnóstico de descargas de alta energia.

Entretanto, há de se verificar condições de falha onde a variação de CO é superior à variação de H₂, uma vez que aquele possui valores normais 3,5 vezes maiores que este, e pode mascarar o resultado reportado pelo Hydran® M2 (VARL, 2002).

Este tipo de situação ocorre nos três casos restantes da tabela 7.2. No caso 2, um leve aumento da concentração de hidrogênio, no período de 1 ano, é camuflado pelo decréscimo do monóxido de carbono. A medição teórica do Hydran® M2 não perceberia o acréscimo.

Porém, no caso 3, a produção de hidrogênio aumenta em uma média de 200% por mês. Mas o sensor não percebe, pois é mascarada pelo decréscimo da concentração de monóxido de carbono. É interessante que neste caso a medição teórica do sensor sofre redução. Logo, isto se revela como uma limitação na aplicação deste sensor em monitoramento *on-line* podendo fornecer informações equivocadas acerca da real condição operacional do transformador.

No intuito de evitar as conseqüências desta limitação no monitoramento, pode-se considerar a implementação do monitor com um par de membranas sensíveis, uma dedicada à medição de hidrogênio e outra dedicada ao monóxido de carbono (ZYLKA; MAZUREK, 2002).

Neste estudo, o Hydran® M2 foi aplicado no monitoramento *on-line* de um transformador de 140 MVA, 230 kV, que apresenta a particularidade de ter sido tombado no momento de seu transporte, o que levanta uma suspeita acerca da sua real condição de funcionamento.

Diante do cálculo teórico da medição do sensor para o histórico deste transformador vê-se o perfeito acompanhamento da evolução das produções dos gases, de acordo com a tabela a 7.3:

Tabela 7.3 – Monitoramento on-line transformador 140MVA.

Gases		Máx. Valores		6/11/2002	3/7/2003	7/7/2003	15/4/2004	17/8/2004	25/2/2005	25/5/2005	8/12/2005	24/3/2006	19/10/2006
		Fábrica	Norma L1	Fábrica	Antes do Teste de Excitação	Após o Teste de Excitação	Análise 1	Análise 2	Análise 3	Análise 4	Análise 5	Análise 6	Análise 7
Hidrogênio	H ₂	10	100	1	10	14	33	15	7	5	0	2	3
Oxigênio	O ₂	0	0	1.832	1.588	3.166	10.211	1.684	706	2.351	1.586	3.522	896
Nitrogênio	N ₂	0	0	3.356	4.373	9.916	48.158	17.289	23.005	25.463	13.642	36.734	28.977
Metano	CH ₄	1	120	0	0,1	0,2	9	15	19	18	5	20	27
Mon. de Carbono	CO	15	350	11	12	27	139	144	162	162	41	166	193
Dióx. de Carbono	CO ₂	70	2.500	39	12	65	2.518	1.358	1.330	1.290	442	1.544	1.573
Etileno	C ₂ H ₄	0,2	50	0	0	0	0,3	0	0	0	0	0	1
Etano	C ₂ H ₆	0,5	65	0	0	0,3	13	15	18	16	5	19	24
Acetileno	C ₂ H ₂	0	35	0	0	0	0	0	0	0	0	0	0
Total de Gases		0,0	0,0	5.239,0	5.995,1	13.188,5	61.081,3	20.520,0	25.240,0	29.300,0	15.721,0	42.005,0	31.691,0
Total de Gases Combust.		0	720	12	22,1	41,5	194,3	189	206	201	51	207	248
Leitura Monitor		-	-	2,98	12,16	18,86	58,044	40,92	36,16	34,16	7,38	31,88	37,82

Como é possível notar, a leitura do monitor acompanha o crescimento da produção dos gases de forma que o monitoramento tem sido confiável e a condição de operação considerada normal. Somente na análise 1 obtém-se ultrapassagem de valores normais (dióxido de carbono) o que, segundo o planejamento do sistema computacional, aciona a execução dos algoritmos de diagnóstico de falhas incipientes. Os diagnósticos apresentam os seguintes resultados:

Tabela 7.4 – Resultados dos métodos de diagnóstico de falhas incipientes.

Método	Diagnóstico	Grau de Confiança
Convencional	Não-decisão	0,3
Sistema <i>Fuzzy</i>	Falha Baixa Temperatura	0,5
Rede Neural	Normal	1
Diagnóstico Final	Normal	1

Os dados dos ensaios físico-químicos do mesmo transformador foram submetidos a um teste de diagnóstico da qualidade do óleo isolante. O algoritmo inteligente desenvolvido foi, então, comparado com os resultados obtidos da aplicação da guia fornecida pelos fabricantes, conforme tabela 7.5.

Tabela 7.5 – Resultados dos métodos de diagnóstico do estado do óleo.

Atributo Físico-químico	Valores padrões	10/8/2004	22/2/2005	16/5/2005	12/8/2005	9/12/2005
Rigidez Dielétrica	>26	59,2	55,2	58,6	57,8	57,2
Fator de Potência	0,1-0,3	0,18	0,24	0,23	0,23	0,225
Densidade	0,84-0,90	0,883	0,8851	0,8872	0,8872	0,885
Tensão Interfacial	>24	40,54	46,2	40	41,07	43,68
Índice de Neutralização	<0,2	0,008	0,009	0,006	0,006	0,008
Teor de Água	<35	3,46	4,22	6,32	6,42	7,02
Diagnóstico Convencional		Normal	Normal	Normal	Normal	Normal
Diagnóstico Inteligente		Normal	Normal	Normal	Normal	Normal

Percebe-se que as amostras do período revelam condições de normalidade, onde a recomendação é uma nova amostragem em 12 meses.

7.6 CONCLUSÕES

Operação e manutenção são atividades consideradas críticas no cotidiano do setor elétrico. Para enfrentar o desafio de executar essas atividades com eficiência muitos programas têm sido adaptados com o objetivo de atender uma série de exigências e restrições inerentes aos avanços na área. Daí a evolução dos conceitos de manutenção que ganham formato mais agressivo e passam a prezar pelo auxílio de ferramentas computacionais em conjunto com novos princípios de aplicação. Evidentemente, antes do uso de novos conceitos em larga escala, cada proposta deve ser submetida a um período para testar e aprovar o seu uso.

O desenvolvimento de um sistema de monitoramento, detecção e identificação de falhas incipientes em transformadores de potência deve levar em consideração a inovação dos conceitos de manutenção e deve servir de agente que traga forte contribuição para a continuidade e ampliação de tais conceitos. Outrora, é de interesse do setor observar a redução de custos de operação e o aperfeiçoamento da disponibilidade dos equipamentos que compõem o parque elétrico no sentido de favorecer a qualidade do fornecimento de energia elétrica.

Os benefícios do monitoramento e da detecção antecipada de falhas internas são palpáveis e a cada dia são mais largamente difundidos e aceitos pelos novos conceitos de manutenção.

As avaliações sobre a integridade dielétrica do líquido isolante através das grandezas físico-químicas via implementação computacional oferece informações vitais que, unificado ao diagnóstico de falhas incipientes, permite obter uma visão geral das condições de operação do equipamento.

Uma solução para aumentar a eficiência do diagnóstico da integridade do óleo isolante é produzir um método de monitoramento *on-line* através do uso de dispositivos de medida de rigidez dielétrica ou absorbância através de espectrofotometria ultravioleta.

Porém, no caso de monitoramento de falhas incipientes, é necessário algum cuidado com a aplicação de um monitoramento *on-line* com Hydran® M2, uma vez que pode conduzir a situações indesejáveis, como: indicação de retirada de operação da unidade, sinalizada por uma falsa detecção de falha, ou por avaliação imprecisa da capacidade de operação do transformador; detecção precária de falhas onde o hidrogênio é um gás importante, mas seu crescimento pode não ser percebido por uma influência da variação normal de monóxido de carbono.

Daí, o uso eficiente do monitoramento com o Hydran® M2 é estritamente ligado a um conhecimento histórico dos resultados cromatográficos referentes à unidade monitorada no que concerne à análise das situações de alarmes. Porém, em casos de transformadores com cenário de gases dissolvidos implicando alto grau de probabilidade de falhas este tipo de monitoramento será mais adequadamente indicado.

Vale a pena ressaltar um modo de evitar esta limitação que é projetar um sistema de monitoramento de hidrogênio e monóxido de carbono de modo individual, sem uso de membrana multi-seletiva, evitando que a medição conjunta das concentrações dos gases influencie no acompanhamento do total de gás gerado.

O uso de um sistema computacional valida o projeto de monitoramento e diagnóstico rendendo alto grau de confiança ao resultado das análises, uma vez que o sistema

contempla testes realmente relevantes na conformidade do isolante líquido. Também, confere isenção a erros operacionais no manuseio das informações e na aplicação das normas pertinentes, pois os resultados alcançados superam os advindos das normas.

Como benefício, as informações fornecidas pela ferramenta computacional permitem um avanço no que diz respeito aos procedimentos de manutenção evitando paradas desnecessárias e retiradas de serviço de unidades em bom estado de operação. E ainda, acompanhando a evolução das condições de modo contínuo.

Capítulo 8

COMENTÁRIOS CONCLUSIVOS

A idéia de monitorar, detectar e identificar as condições de envelhecimento e degradação do isolamento de transformadores foi sistematicamente estudado nesta dissertação. A seriedade com que este assunto é tratado pode ser a diferença entre uma vida útil extensa e a perda catastrófica de uma unidade tão economicamente e estrategicamente importante para o parque elétrico. A idéia se traduz no projeto de um sistema de monitoramento *on-line*, trabalhando em conjunto com algoritmos de diagnóstico da qualidade do óleo isolante e de falhas incipientes. Isso, debaixo de um objetivo de viabilizar a tomada de decisão diante de uma condição de falha, priorizando a proteção e continuidade de operação.

Este tipo de projeto representa adição de confiabilidade e valorização dos ativos de agentes do setor de energia.

Na experiência de monitoramento *on-line* descrita, a escolha do melhor método de monitoramento deve ser baseada em um compromisso técnico-financeiro. Na aplicação citada, o instrumento selecionado é capaz de emitir um alerta antecipado de falha em fase ainda incipiente, rendendo às equipes de operação e manutenção tempo hábil para a tomada das providências cabíveis. Aliado ao algoritmo de pré-diagnóstico desenvolvido, o sensor apresentou resultados satisfatórios na predição de situações de falhas e, além disso, propiciou redução nos insumos de contratação de seguro das unidades monitoradas. Entretanto, alguns cuidados devem ser tomados com respeito à aplicação de monitores *on-line* que não estratificam os gases dissolvidos, pois esta característica pode mascarar as leituras e conduzir a situações indesejáveis.

Para a elaboração do módulo de diagnóstico de falhas incipientes, houve uma comparação entre os resultados de três redes neurais projetadas para se chegar à melhor composição. Satisfatoriamente, o diagnóstico de falhas incipientes via redes neurais apresentou um percentual elevado de acerto se mostrando como ótima solução para a problemática.

O treinamento com a otimização de Levenberg-Marquardt, que apresenta característica de convergência muito rápida devido ao uso das informações da curvatura da superfície de erro e não somente do gradiente, apresentou resultados de ótimo desempenho o credenciando a compor o algoritmo neural do módulo de diagnóstico de falhas incipientes.

Também foi efetuada uma comparação entre três sistemas nebulosos propostos para realização do diagnóstico de falhas incipientes. Porém os resultados não foram tão excelentes quanto os da rede neural. Um algoritmo que integra dois dos sistemas *fuzzy*, Rogers revisado e Tsuchie, foi proposto e os resultados foram melhores que os sistemas isolados, sendo esta integração que compõe o algoritmo *fuzzy* do módulo de diagnóstico de falhas incipientes.

A aplicação de redes neurais e a adição de regras especiais à base de conhecimento dos sistemas *fuzzy*, proporcionaram a solução do problema da não-decisão, encontrado nos métodos convencionais.

Por apresentarem elevado índice de acerto os métodos inteligentes representam uma alternativa valiosa para o diagnóstico de falhas incipientes em transformadores de potência.

No que tange à confecção do sistema de diagnóstico da qualidade do óleo isolante de transformadores, o estudo focalizou a avaliação dos atributos físico-químicos e a aplicação de técnicas de redes neurais para o diagnóstico automático.

Nestes termos, houve um confronto entre a rapidez, eficiência e simplicidade das redes neurais MLP e RBF. Diante de resultados ótimos e semelhantes, a preferência pela rede MLP se deu no âmbito desta apresentar estrutura menos complexa sendo, então, o algoritmo implementado na realização do diagnóstico do estado do óleo.

A importância deste empreendimento vem diretamente da necessidade de um acompanhamento das características físico-químicas que exercem forte influência na característica dielétrica do óleo do transformador.

Também, nesta dissertação, verificou-se a existência do relacionamento entre as grandezas dos ensaios relevantes na determinação de falhas ligadas ao óleo isolante, ou seja, ensaios físico-químicos e cromatográficos do óleo. Para isso, um

algoritmo de busca exaustiva identificou os atributos físico-químicos mais influentes na condição dos gases dissolvidos no óleo.

Depois de verificada a relação entre as grandezas, uma rede neural foi aplicada no objetivo de promover um meio para a estimação de gases dissolvidos a partir das grandezas físico-químicas relevantes.

A estimação, devido às características dos dados disponíveis para teste, possui melhores resultados na estimação de gases gerados por falhas térmicas e as que envolvem baixa densidade de energia. Em todo caso, é possível acompanhar a evolução dos gases dissolvidos sem a realização de uma cromatografia completa, que em muitos casos é uma facilidade conveniente, devido à fácil disponibilidade dos testes físico-químicos.

De posse dos desenvolvimentos para a composição dos módulos para monitoramento, detecção e diagnóstico, visando corresponder às necessidades dos avanços dos programas de operação e manutenção, um sistema computacional foi desenvolvido para gerar confiabilidade à aplicação dos métodos discutidos.

Integrando os módulos em um programa computacional, os benefícios do monitoramento e da detecção antecipada de falhas internas, bem como avaliação da integridade dielétrica do líquido isolante exprimem uma visão geral das condições de operação do equipamento e permitem o desenvolvimento de ações que prezem pela integridade do equipamento e pela continuidade da operação. Isto favorece a evolução dos conceitos de manutenção evitando paradas desnecessárias e a retirada de serviço de unidades em boas condições de operação.

A plataforma computacional, através do gerenciamento da utilização dos recursos inteligentes projetados, ampara os operadores do sistema, mesmo que inexperientes, na execução de diagnósticos eficientes evitando manipulações equivocadas das normas o que conduziria a erros.

8.1 DESENVOLVIMENTOS FUTUROS

Seguem algumas sugestões para trabalhos futuros no intuito de aperfeiçoar a aplicação prática do que foi estudado:

- Projeto de sistema de monitoramento de hidrogênio e monóxido de carbono separadamente, sem uso de membrana multi-seletiva, evitando que a medição conjunta das concentrações dos gases influencie no acompanhamento do total de gás gerado.
- Uso de sensores com estratificação dos gases dissolvidos, ou cromatografia completa, no monitoramento *on-line* de falhas incipientes.
- Avaliar a implementação, em complemento à detecção e identificação de falhas, de métodos de localização das regiões de falha através de métodos acústicos ou de sensoriamento utilizando a tecnologia de fibras ópticas.
- Verificar a influência dos gases dissolvidos nas características físico-químicas e estabelecer uma função de correspondência entre as grandezas envolvidas.
- Produzir um método de monitoramento *on-line* através do uso de dispositivos de medida de rigidez dielétrica ou absorvância através de espectrofotometria ultravioleta para aumentar a eficiência do diagnóstico da integridade do óleo isolante.
- Utilização de técnicas que permitam uma boa estimativa do etano e do acetileno, mesmo sem uma coleção de dados representativos, como SVM.
- Promover um maior conhecimento das dinâmicas que envolvem as falhas internas do transformador e as qualidades dielétricas do óleo isolante, possibilitando o estabelecimento de critérios preventivos acerca da degradação do óleo e das falhas incipientes em transformadores.
- Propor aplicação de métodos inteligentes na predição temporal dos gases dissolvidos no óleo, antecipando-se à geração dos mesmos.
- Extração do conhecimento das redes neurais utilizadas neste estudo para aprofundar os conceitos e relações entre as grandezas envolvidas.

Apêndice A

REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA's), são constituídas, basicamente, por dois elementos físicos: conexões e nós de processamento (neurônios artificiais). Existem ainda outros componentes (não-físicos) das redes neurais, tais como, os padrões e os algoritmos de treinamento. Os padrões são os dados que servirão para o treinamento, validação e teste da rede. Portanto, os padrões representam o mapeamento que a rede deve ser capaz de modelar.

Os algoritmos de treinamento são constituídos, basicamente, por modelos matemáticos iterativos capazes de alterar os pesos sinápticos de modo que a rede realize o mapeamento requerido, tais como: aproximação de funções ou reconhecimento de padrões.

A.1.1. Modelos de Neurônios Artificiais

A construção dos primeiros modelos de redes neurais artificiais tiveram inspirações nas redes de neurônios biológicos. No entanto, o primeiro modelo matemático de um neurônio, equação A.1, proposto por McCulloch e Pitts em 1943, é um modelo muito simples, portanto não apresenta a capacidade de imitar a complexa atividade biológica de um neurônio natural.

$$y = \Phi \left(\sum_{i=1}^n w_i \cdot x_i - b \right) \quad (\text{A.1})$$

O neurônio de McCulloch-Pitts apresenta uma resposta binária (saída igual a 0 ou 1) em resposta a uma estimulação de entrada. Uma soma ponderada das entradas (x_i), através dos pesos das conexões (w_i), serve como argumento de uma função (Φ), denominada função de ativação, que neste modelo é uma função limiar simples. O argumento da função de ativação em geral, incorpora ainda uma polarização (b),

valor abaixo do qual a saída é nula. A Fig A.1 ilustra o modelo de McCulloch-Pitts (HAYKIN, 1994).

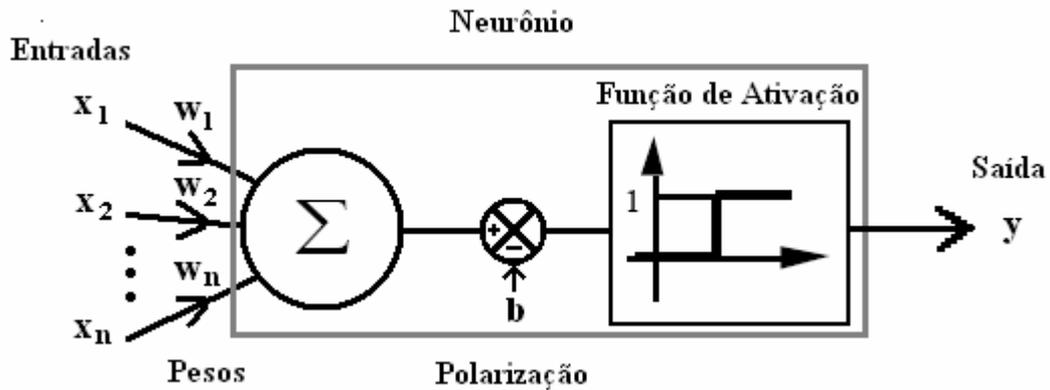


Figura A.1 – Representação do modelo matemático de um neurônio.

Um modelo, mais geral, de neurônio pode utilizar uma função de agregação diferente do somatório, tal como o produto e uma função de ativação qualquer. A função de ativação é responsável por determinar a forma e a intensidade da alteração dos valores transmitidos ao neurônio. Em geral, são utilizadas funções de ativação não lineares, tais como, a função degrau, a função em rampa limitada, a função logística e a tangente hiperbólica. A figura A.2 ilustra algumas opções de funções não lineares que podem ser utilizadas como função de ativação.

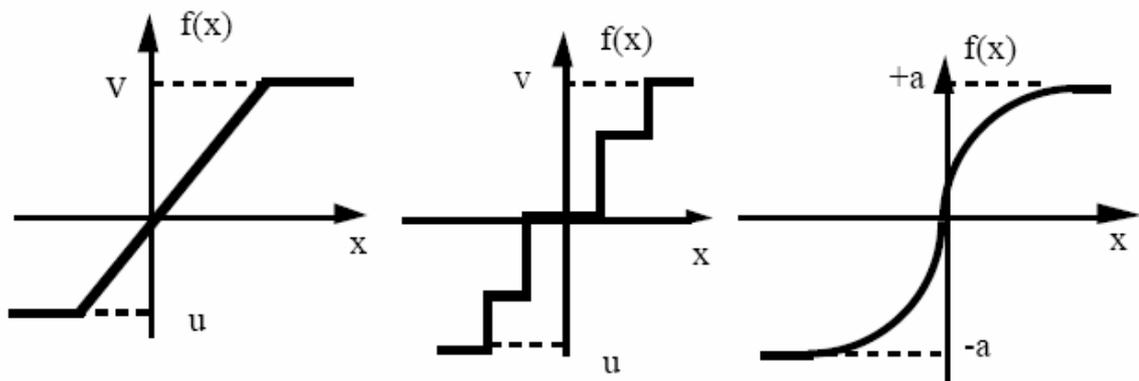


Figura A.2 – Tipos de funções não-lineares utilizadas como função de ativação.

Existem duas importantes características que um neurônio deve possuir: os neurônios devem necessitar apenas de informações locais, portanto, a saída dos neurônios deve ser função apenas dos seus pesos sinápticos, da polarização de sua função de ativação e de suas entradas; os neurônios devem produzir apenas um

valor de saída. Este valor único é propagado através das conexões do elemento emissor para o receptor, ou para fora da rede, quando for um elemento da camada de saída. Estas duas características permitem que RNA's operem em paralelo.

A.1.2. Conexões e Pesos Sinápticos

Uma rede neural artificial (RNA) é um sistema composto por um conjunto de neurônios. Estes neurônios estão interligados através conexões. A cada conexão está associado um peso sináptico, que pondera a ligação entre dois neurônios, ou entre uma entrada e um neurônio. Portanto, pode-se dizer que quanto maior for o peso de uma conexão, maior será a capacidade daquela ligação para ativar a saída do neurônio.

Definição A.1: Um neurônio McCulloch-Pitts se encontra em estado ativado quando sua saída apresenta valor numérico igual 1.

Os neurônios que recebem excitações do meio ambiente são chamados de neurônios de entrada. Aqueles que têm suas respostas usadas para alterar, de alguma forma, o mundo exterior são chamados neurônios de saída. Os neurônios que não são nem entrada nem saída são conhecidos como neurônios internos ou escondidos (*"hidden"*). A utilização de neurônios escondidos é de fundamental importância, pois, estes habilitam as RNA's a resolver problemas não-linearmente separáveis. Neurônios que desempenham funções semelhantes dentro de uma rede formam uma camada.

Em uma rede *feedforward* as informações fluem, através das conexões, unicamente da camada de entrada para a saída. Portanto, não existem conexões de realimentação, ou seja, as conexões são realizadas de forma que as saídas da camada de entrada são conectadas às entradas da primeira camada interna e assim por diante até chegar à camada de saída.

Os pesos sinápticos são as variáveis de memorização de uma rede neural. Durante o processo de aprendizado, eles são ajustados de modo a reter a informação do comportamento desejado da rede. Utilizando uma inspiração biológica podemos definir conexões excitatórias e inibitórias:

Definição A.2: Conexões excitatórias são aquelas que possuem peso de valor numérico positivo e, portanto, contribuem para ativação da saída.

Definição A.3: Conexões inibitórias são aquelas cujo peso é negativo e, portanto, tentam inibir a ativação da saída.

No caso do valor de um peso sináptico ser exatamente igual a zero, é como se a conexão não existisse, pois um neurônio não pode influenciar a ativação ou desativação do outro.

A.1.3. Processo de Aprendizagem de uma RNA

Para uma RNA, aprender é o ato de determinar um comportamento da rede a partir de um conjunto de exemplos ou estímulos que lhes são apresentados em uma etapa do projeto, chamada treinamento. Nesta etapa, os pesos sinápticos da rede são ajustados iterativamente para “memorizar” as relações de entrada-saída através de um algoritmo de aprendizagem ou treinamento. Portanto, nesta etapa é realizada a aquisição de conhecimento que possibilitará a rede desenvolver a capacidade de generalização (interpolação do que aprenderam). O processo de aprendizagem de uma RNA não busca representar o conhecimento através de regras simbólicas, tal como nos sistemas nebulosos, mas sim, através da intensidade das conexões entre os neurônios (valor dos pesos sinápticos). Quanto à independência da rede, o aprendizado é classificado como: supervisionado e não-supervisionado ou auto-aprendizado.

No aprendizado supervisionado, há uma definição sobre qual a saída que se deseja para a rede (os dados apresentam tanto a excitação quanto a saída desejada). Dado que, a saída desejada é conhecida, para cada conjunto de excitação é verificado se a saída é igual a desejada neste caso nenhuma alteração é necessária, caso contrário os valores dos pesos sinápticos devem ser ajustados no sentido de fazer a saída se aproximar da desejada. No aprendizado não-supervisionado ou auto-aprendizado a metodologia de aprendizado configura-se como uma representação da distribuição de probabilidade dos padrões de entrada através dos pesos dos neurônios da rede. Por não dispor da saída desejada os métodos de aprendizado deste tipo devem ser capazes de reconhecer as características estatísticas mais significativas do espaço vetorial de entrada e ajustar os pesos sinápticos de modo a

construir uma representação compacta desse espaço. As redes que utilizam esse processo de aprendizagem implementam neurônios competitivos, por isso, essas redes são conhecidas também como redes competitivas.

Definição A.4: Um neurônio é dito competitivo, quando a sua ativação, implica na inibição dos demais neurônios da rede ou da camada a qual ele pertence.

O aprendizado supervisionado tem atraído atenção de muitos pesquisadores (FREITAS, 2000; PATEL; KHUBCHANDANI, 2004). Uma motivação, talvez, é o fato que o aprendizado supervisionado comporta-se como um problema de otimização e, portanto, podem ser utilizadas ferramentas que já mostraram sua eficácia, tanto em programação linear quanto não-linear. Considerando para tanto o aprendizado como uma minimização do erro entre a saída rede e a saída desejada.

A determinação dos parâmetros de uma rede neural, seja aqueles relativos à topologia ou mesmo ao algoritmo de aprendizagem, é problema complexo. Para otimizar o projeto de uma RNA, em geral, são realizadas diversas simulações variando-se os valores dos parâmetros de projeto e avaliando o desempenho da rede. Assim, aquela configuração que apresentar melhor desempenho nos testes é selecionada para realizar o mapeamento desejado. Porém, outras questões também podem ser significativas, principalmente, aquelas relativas aos dados de treinamento. Na próxima subseção apresenta-se como o desempenho de uma rede é afetado pela seleção e dimensionalidade dos dados de treinamento.

A.1.4. Padrões Utilizados no Treinamento de RNA Supervisionadas

No aprendizado supervisionado considera-se que as relações entre os vetores de entrada (X) e os vetores de saída (Y) são definidas pela natureza física do problema, e que estas relações podem ser representadas por um número limitado de pares de entrada-saída. Estas suposições são de fundamental importância, principalmente para analisar se uma determinada amostra de dados é realmente representativa para um dado sistema.

O aprendizado de uma RNA depende, fundamentalmente, da qualidade dos dados utilizados no processo de treinamento. Assim quanto mais informações estiverem disponíveis nos dados melhor será o aprendizado da rede. Portanto, antes de iniciar

o treinamento, faz-se necessário realizar um estudo de quais são as variáveis mais significativas e o domínio do problema.

Uma vez definido o vetor característico de entrada ou padrão de entrada é necessário determinar o tamanho da amostra que será utilizada no treinamento. Para tanto, é importante evitar as relações triviais, ou seja, informações repetidas ou que podem ser derivadas de outras. Em geral, quanto mais complexo é o mapeamento que a rede deve aprender maior deve ser o conjunto de amostra de dados do treinamento.

Uma vez que os dados de entrada mais apropriados foram selecionados, estes devem ser pré-processados. Pois, usualmente cada componente do vetor de entrada representa uma grandeza diferente, apresentando sua própria escala de valor. Isso pode causar uma polarização indesejada nos valores dos pesos da rede. A normalização é um dos métodos de pré-processamento mais utilizado. A normalização é uma transformação executada com o objetivo de produzir uma distribuição estatística uniforme dos valores de entrada e garantir que os valores de cada componente serão colocados numa mesma escala de valores. As técnicas de normalização mais utilizadas são: *i*) A Normalização suave cujas distribuições das componentes x_j são normalizadas para terem média zero e variância unitária, tal como na equação A.2 e *ii*) A Normalização severa cujas componentes x_j são reescaladas para o intervalo $[0,1]$, tal como na equação A.3.

$$x_j^{norm} = \frac{x_j - \bar{x}_j}{\sigma_j} \quad (\text{A.2})$$

$$x_j^{norm} = \frac{x_j - x_j^{\min}}{(x_j^{\min} - x_j^{\max})} \quad (\text{A.3})$$

onde x_j^{norm} é o valor normalizado correspondente ao valor original x_j , \bar{x}_j é o valor médio, σ_j é o desvio padrão, x_j^{\min} é o valor mínimo e x_j^{\max} o valor máximo (separadamente por componente).

A apresentação de todas amostras de dados de treinamento à rede é denominada “época”. Os padrões de treinamento devem ser apresentados à rede em uma seqüência aleatória a cada nova época.

Etapas que buscam validar o processo de treinamento (etapas de validação) são periodicamente realizadas, por exemplo, a cada dez épocas de treinamento. Na validação, um conjunto de dados, não utilizados no treinamento, alimenta a rede e saídas são calculadas utilizando os valores dos pesos memorizados até o momento.

Uma vez obtida a saída atual da rede é verificado se esta já atingiu um nível de desempenho satisfatório, caso contrário o treinamento deve prosseguir. Podem ser necessárias muitas épocas para atingir a exatidão requerida. Em problemas de aproximação de funções (com apenas um neurônio de saída) o treinamento termina, em geral, quando o erro quadrático de uma iteração (e_{quad}) ou o erro quadrático médio (EQM) de uma época é menor que valores pré-estabelecidos. Estes erros são definidos como:

$$e_{quad}(t) = \frac{1}{2} [d(t) - y(t)]^2 \quad (A.4)$$

$$EQM = \frac{1}{2N} \sum_{t=1}^N [e_{quad}(t)] \quad (A.5)$$

onde d é a saída desejada, y é a saída atual, N é o número de amostras de treinamento (número de iterações de uma época) e t é o número da iteração atual.

Na realidade é recomendável que o treinamento seja interrompido quando o erro no conjunto de validação atingir um mínimo, pois, a partir desse ponto o erro para dados de treinamento seria cada vez menor, mas o erro para os dados de validação seria cada vez maior, ou seja, a rede estaria aprendendo apenas detalhes irrelevantes do conjunto de treinamento (*overfitting*).

Em aplicação de RNA's como classificador de padrões o erro utilizado para determinar o final do treinamento é o erro de classificação (ERR_{class}), que é calculado de acordo com a equação A.6.

$$ERR_{class}(\%) = 100 \cdot \frac{N_{errado}^{padrões}}{N_{total}^{padrões}} \quad (A.6)$$

onde $N_{total}^{padrões}$ e $N_{errado}^{padrões}$ são o número total de padrões e de erradamente classificados.

Ao encerrar o treinamento, as especificações da rede são mantidas fixas e pode-se realizar ainda uma etapa de testes com um terceiro conjunto dados. Para realizar estas três etapas faz-se necessário dividir o conjunto total de dados em três subconjuntos. Uma partição freqüentemente utilizada constitui-se de 50% dos dados para o treinamento, 25% para validação e 25% para testes.

Apêndice B

SISTEMAS NEBULOSOS (FUZZY LOGIC)

A lógica nebulosa suporta os modos de raciocínio que são aproximados, ao invés de exatos, é baseada na teoria dos conjuntos nebulosos e difere dos sistemas lógicos tradicionais em suas características e detalhes. Nesta lógica, o raciocínio exato corresponde a um caso limite do raciocínio aproximado, sendo interpretado como um processo de composição nebulosa.

Em uma visão restrita a lógica nebulosa pode ser considerada como a lógica do raciocínio aproximado, portanto, poderia ser entendida como uma generalização da lógica de multivalores. Em uma visão muito mais abrangente e significativa está diretamente associada à teoria dos conjuntos nebulosos. O desenvolvimento da teoria dos conjuntos nebulosos, assim como a própria lógica nebulosa, introduziu uma classe de objetos na qual a transição entre a pertinência e a não-pertinência se dá de forma gradual ao invés de abrupta. Essa última visão possibilitou o desenvolvimento de sistemas que realizam funções que vai desde o controle de processos complexos até o reconhecimento de padrões (WANG L., 1994; HESK, 1999; LIMA, 2004b).

O Raciocínio na lógica nebulosa utiliza um conjunto de regras nebulosas realizar uma inferência sobre a operação do sistema. Assim, é formada uma base de regras do tipo:

Se <premissa 1> e <premissa 2> ... e <premissa n> **Então** <conclusão>.

O conhecimento, representado na base de regras, é derivado da heurística, experiência e intuição de especialistas. Se o conhecimento representado na base de regras é derivado do sistema de forma analítica, e representa o conhecimento de especialistas um questionamento pode ser levantado: Por que utilizar sistemas nebulosos? A resposta dessa pergunta reporta a capacidade dos sistemas nebulosos de utilizar adequadamente informações imprecisas e incorporar em sistemas automáticos de decisão o conhecimento de especialistas que outros sistemas nem sempre conseguem acomodar (LEE, 1990a; LEE, 1990b; HARRIS *et*

al., 1993; YAGER; FILEV, 1994; KOSKO, 1996; COELHO *et al.*, 1998, ALMEIDA 2002). Atualmente, a teoria dos conjuntos nebulosos é a mais adequada para tratar informação imprecisa, também conhecida como vaga (KOSKO, 1996).

B.1.1 Conjuntos nebulosos

Na teoria de conjuntos nebulosos, os conjuntos no sentido ordinário são denominados conjuntos “*crisp*”. Se um conjunto “*crisp*” (C) pertence ao conjunto dos números reais (\mathfrak{R}), é verdadeira a preposição de que um elemento $x \in \mathfrak{R}$ implica que $x \in C$ ou $x \notin C$. Com os conjuntos nebulosos esta preposição não necessariamente é verdadeira, ou seja, um elemento $x \in \mathfrak{R}$ pode pertencer parcialmente a um conjunto nebuloso (N). Esta propriedade caracteriza o conceito de informação vaga ou imprecisa. Os conjuntos nebulosos são caracterizados por funções de pertinência que assumem valores contínuos entre o *falso* (0) e *verdadeiro* (1).

Definição B.1. Uma função de pertinência μ_N de um conjunto nebuloso (N) é uma função que associa a cada elemento (x) um valor ente 0 e 1, ou seja:

$$\mu_N : \mathfrak{R} \rightarrow [0, 1] \quad (\text{B.1})$$

determina o grau de pertinência $\mu_N(x)$ de um elemento x em um conjunto nebuloso N .

Um conjunto nebuloso é completamente definido por:

$$F = \{(x, \mu_N(x)) \mid x \in \mathfrak{R}\} \quad (\text{B.2})$$

As funções de pertinência podem ter formas triangulares, trapezoidais, B-splines, ou gaussianas (forma de sino), conforme ilustra a figura B.1.

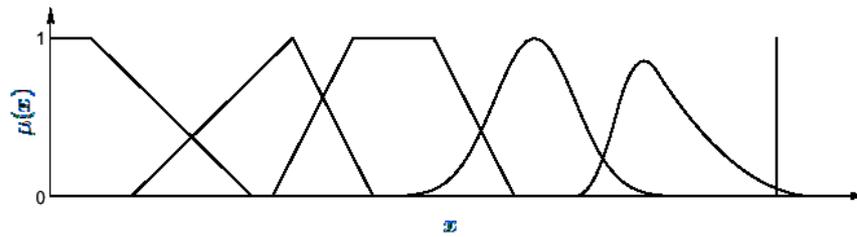


Figura B.1 – Formas típicas de funções de pertinência.

Um conjunto nebuloso denominado “*singleton*” apresenta uma forma especial para a função de pertinência. Um “*singleton*” é um conjunto que possui apenas um elemento x_0 com função de pertinência dada por:

$$\mu_F = \begin{cases} 1, & \text{se } x = x_0 \\ 0, & \text{se } x \neq x_0 \end{cases} \quad (\text{B.3})$$

“*Singletons*” são bastantes utilizados como consequentes de regras nebulosas.

Através das funções de pertinência avalia-se o grau de verdade de uma preposição nebulosa.

Definição B.2. Uma preposição nebulosa é uma expressão do tipo ‘ x é N ’, onde N é um conjunto nebuloso com função de pertinência μ_N . A função de pertinência é a medida do grau verdade da preposição nebulosa.

Sistemas nebulosos são uma coleção de regras “*se-então*” formadas por preposições nebulosas relacionadas através de conectivos nebulosos do tipo “*e*” e “*ou*”.

B.1.2 T-norma e T-conorma

Conjuntos nebulosos são geralmente relacionados através de uma função *interseção* ou *união*, representadas através de normas do tipo *T-norma*, *T-conorma* (ou *S-norma*). A função de pertinência do conjunto nebuloso resultante é composta de funções de pertinência dos conjuntos originais através de *T-norma* ou *T-conorma*. As normas são também utilizadas nos mecanismos de raciocínio nebuloso.

Seja a, b e c valores verdade de uma preposição nebulosa.

Definição B.3. Seja $T:[0,1] \times [0,1] \rightarrow [0,1]$; T é uma T -norma se e somente se para todo $a, b, c \in [0,1]$:

$$T(a,b)=T(b,a) \quad (\text{B.4})$$

$$T(a,b) \leq T(a,c), \text{ se } b < c \quad (\text{B.5})$$

$$T(a, T(b,c)) = T(T(a,b), c) \quad (\text{B.6})$$

$$T(a, 1) = a \quad (\text{B.7})$$

onde a, b e c são valores verdade de funções de pertinência.

T -norma é utilizada para representar a interseção entre dois conjuntos nebulosos ou um conectivo lógico ‘e’ entre duas preposições nebulosas. Zadeh (1965) propôs a função $T(a,b)=\min(a,b)$ para a T -norma, atualmente o produto $T(a,b)=ab$ é mais utilizado.

Definição B.4. Seja $S:[0,1] \times [0,1] \rightarrow [0,1]$. S é uma S -norma se e somente se para todo $a, b, c \in [0,1]$:

$$S(a,b)= S(b,a) \quad (\text{B.8})$$

$$S(a,b) \leq S(a,c), \text{ se } b < c \quad (\text{B.9})$$

$$S(a, S(b,c)) = S(S(a,b), c) \quad (\text{B.10})$$

$$S(a, 0) = a \quad (\text{B.11})$$

T -conorma é utilizada para representar a união de dois conjuntos nebulosos ou o conectivo “ou” entre duas preposições nebulosas. Zadeh propôs a função $S(a,b)=\max(a,b)$ para a T -conorma, outra possibilidade bastante utilizada é $S(a,b)=a+b-ab$. Existem vários tipos de normas, informações adicionais podem ser encontradas em Gupta e Qi (1991).

B.1.3 Raciocínio nebuloso

O mecanismo de raciocínio nebuloso ou procedimento de inferência é o núcleo de um sistema nebuloso. Este deve ser capaz de tomar decisões a partir das informações de entrada e do conhecimento armazenado na base de regras, utilizando os conceitos advindos da lógica nebulosa (LEE, 1990a e 1990b). As regras são formadas por preposições nebulosas nos antecedentes e conseqüentes das mesmas, que estabelecem as implicações nebulosas para o comportamento do sistema. O processo de inferência consiste nas seguintes ações (SANDRI; CORREIA, 1999): verificação do grau de compatibilidade entre os fatos e as cláusulas nas premissas das regras; determinação do grau de compatibilidade global ou grau de disparo (*GD*) da premissa de cada regra; determinação do valor da conclusão, em função do grau de compatibilidade da regra com os dados e as ações de controle constantes na conclusão; agregação dos valores obtidos como conclusão nas várias regras, obtendo-se uma única saída global.

Os sistemas nebulosos mais encontrados na literatura são os modelos clássicos, compreendendo os modelos de Mamdani e Larsen e os modelos de interpolação de Takagi-Sugeno e Tsukamoto, (LEE, 1990a, 1990b; YEGER; FILEV, 1994; SANDRI; CORREIA, 1999). Os sistemas nebulosos diferem quanto à forma do nebulizador (*Singleton* ou não *Singleton*), quanto à máquina de inferência (representação dos termos nas premissas das regras, tipo de implicação e operadores utilizados) e a técnica de desnebulização (pelo valor máximo, centro de gravidade ou centro médio modificado). O método de raciocínio nebuloso, por sua vez, é classificado com base na forma dos conseqüentes das regras.

B.1.3.1 Regras nebulosas do tipo Mamdani

Se em ambos antecedentes e conseqüentes as regras são combinadas utilizando-se conectivos nebulosos, estas são do tipo Mamdani e expressas da seguinte forma:

se x_1 é X_1^i e x_2 é X_2^i e ...e x_{nx} é X_{nx}^i então z é Z^i

onde X_j^i é o conjunto nebuloso da *j*-ésima entrada (*nx* é o número de entradas) e Z^i é o conjunto nebuloso da saída, ambos relacionados à *i*-ésima regra.

Na execução do raciocínio nebuloso aplicando às regras do tipo Mamdani, inicialmente o valor verdade dos antecedentes são avaliados conforme o conectivo utilizado. Para as regras do tipo Mamdani em que o conectivo “e” é utilizado, o valor verdade é determinado por:

$$\psi_i = T(\mu_{X_1^i}(x_1), \dots, \mu_{X_{nx}^i}(x_{nx})) \quad (\text{B.12})$$

O conjunto nebuloso de saída é obtido através da avaliação com T -norma dos conseqüentes das regras nebulosas. O raciocínio nebuloso produz um conjunto nebuloso de saída do tipo:

$$\mu_{Z^i}(z) = T(\psi_i, \mu_{Z^i}(z)) \quad \forall z \in \mathfrak{R} \quad (\text{B.13})$$

Os conseqüentes de todas as regras são combinados (agregados) através da T -conorma como segue:

$$\mu_{Z^m}(z) = S(\mu_{Z^1}(z), \dots, \mu_{Z^m}(z)) \quad \forall z \in \mathfrak{R} \quad (\text{B.14})$$

onde m é o número de regras.

O raciocínio nebuloso do tipo Mamdani é ilustrado na figura B.2 para o caso de duas entradas e duas regras do tipo

se x_1 é X_1^1 e x_2 é X_2^1 então z é Z^1

se x_1 é X_1^2 e x_2 é X_2^2 então z é Z^2

Utilizando-se a função *min* para o conectivo T -norma e a função *max* para o conectivo T -conorma.

B.1.3.2 Regras nebulosas do tipo Sugeno

Nas regras do tipo Sugeno, conseqüentes são funções das entradas. A forma típica destas regras é:

se x_1 **é** X_1^i **e** x_2 **é** X_2^i **e** ...**e** x_{nx} **é** X_{nx}^i **então**

$$z = f_i(x_1, x_2, \dots, x_{nx}),$$

onde X_j^i é o conjunto nebuloso da j -ésima entrada (nx é o número de entradas) e f_i é a função de saída para a i -ésima regra.

A saída de uma regra do tipo Sugeno é o valor “*crisp*” da função. A saída final do raciocínio é obtida através de uma média ponderada dada por:

$$z = \frac{\sum_{i=1}^m \psi_i f_i(x_1, x_2, \dots, x_{nx})}{\sum_{i=1}^m \psi_i} \quad (\text{B.15})$$

onde m é o número de regras e ψ_i é o valor verdade do antecedente obtido através de (B.12)

Sob algumas suposições o mecanismo de raciocínio Mamdani é igual ao mecanismo Sugeno. No mecanismo Mamdani os conseqüentes das regras são proposições nebulosas e o sistema tem uma interpretação lingüística. No mecanismo Sugeno os conseqüentes são funções dos parâmetros de entrada do sistema. Se o mecanismo Mamdani utiliza “*singletons*” para os conjuntos nebulosos de saída e o mecanismo Sugeno utiliza funções do tipo constante na saída, os mecanismos são iguais. A figura B.2 ilustra o raciocínio nebuloso do tipo Mamdani.

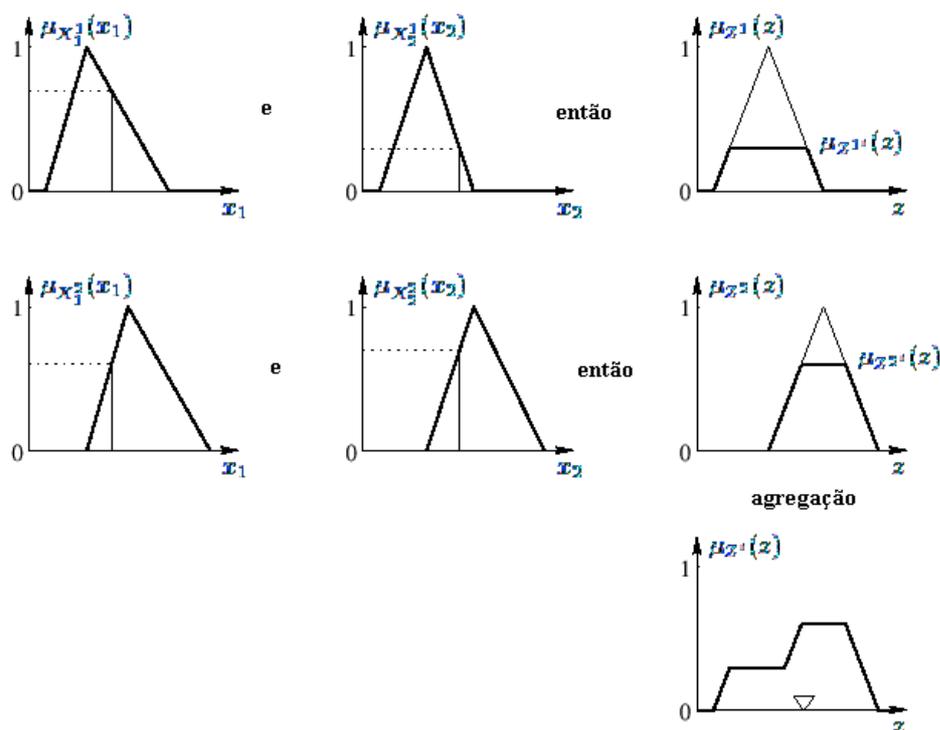


Figura B.2 – Raciocínio nebuloso com regras do tipo Mamdani.

B.1.4 Interface de nebulização

A interface de nebulização é responsável pela realização do mapeamento dos valores numéricos das variáveis de entrada em conjuntos nebulosos, através da transformação da entrada “crisp” em instâncias das variáveis linguísticas, dentro do conjuntos nebulosos associados. As funções de pertinência (*FP*'s) formam a base da nebulização.

A forma, a sobreposição e os valores de pico influenciam diretamente em como deve ser o projeto e como se comporta o sistema. É importante, portanto, estabelecer propriedades das *FP*'s, do conjunto de *FP*'s, assim como dos conjuntos nebulosos às quais representam. Propriedades dos conjuntos nebulosos tais como as associadas ao suporte, normalidade, núcleo, convexidade, localidade e globalidade são de importante significado prático. As propriedades dos conjuntos nebulosos são ilustradas na figura B.3.

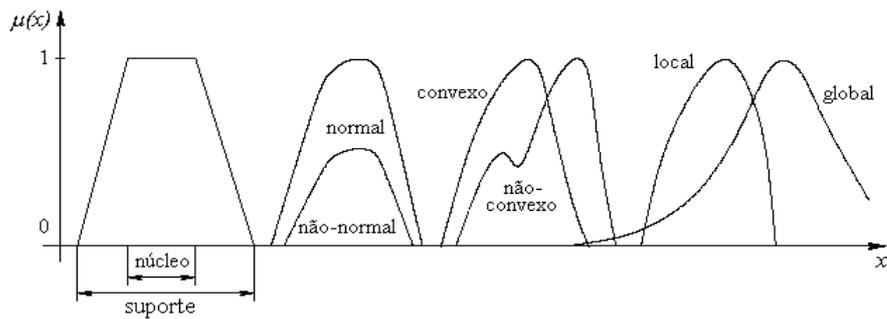


Figura B.3 – Propriedades dos conjuntos nebulosos.

A figura B.4 ilustra a nebulização da variável R5, ou seja, a transformação do valor determinístico 1,5 para uma representação difusa através de *singletons*. Os valores de pertinência são 0,25 e 0,75 para os conjuntos nebulosos pequeno e médio, respectivamente.

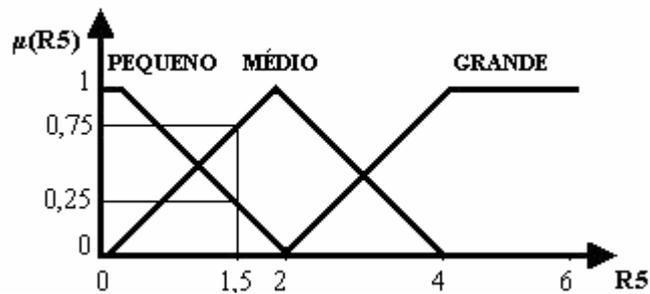


Figura B.4 – Nebulização da variável R5.

O conjunto de *FP's* apresenta, também, importantes propriedades práticas tais como as associadas à normalidade, integralidade, área de eficiência. As propriedades do conjunto *FP's* são apresentadas na figura B.5.

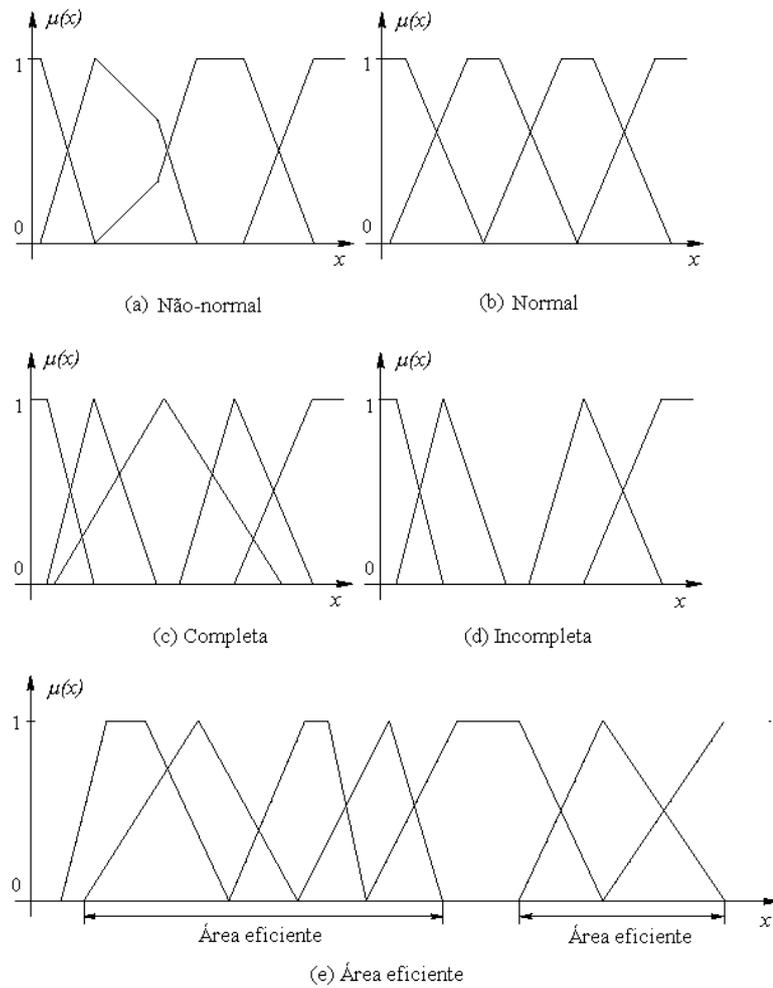


Figura B.5 – Propriedades do conjunto da função de pertinência.

A propriedade de transparência é também importante para os sistemas nebulosos. Um sistema nebuloso é dito ser transparente se o resultado confere com o que está expresso na base de regras.

B.1.5 Desnebulização

Regras do tipo Mamdani produzem uma saída nebulosa. Na prática um valor “*crisp*” pode ser necessário como saída. Neste caso, um procedimento de desnebulização se faz necessário.

Assumindo que o conseqüente do raciocínio nebuloso é uma função de pertinência $\mu(z)$, um único valor numérico de saída do conseqüente nebuloso pode ser obtido através de diferentes métodos (YAGER; FILEV, 1994). O método mais comum emprega a técnica do centro de gravidade ou centróide:

$$z = \frac{\sum_{i=1}^n \mu(z_i) z_i}{\sum_{i=1}^m \mu(z_i)} \quad (\text{B.16})$$

onde z_i são pontos da função de pertinência de saída $\mu(z)$ e n o número de pontos.

A figura B.6 ilustra o processo de desnebulização pelo método do centro de gravidade.

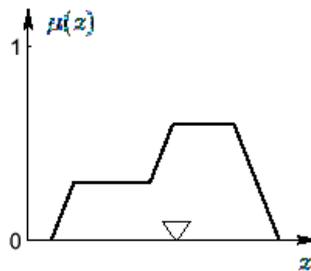


Figura B.6 – Desnebulização pelo método do centro de gravidade.

B.1.6 Definições para sistemas nebulosos

Definição B.5 Uma base de regras é completa se todas as combinações possíveis das variáveis nebulosas de entrada são expressas na base.

Definição B.6 Um sistema nebuloso é normal se a soma de valores verdade dos antecedentes é igual à unidade, ou seja:

$$\sum_{i=1}^{n_\psi} \psi_i = 1, \quad \forall x \in \mathfrak{R}^{n_x} \quad (\text{B.17})$$

onde ψ_i é o valor verdade da i -ésima regra e n_ψ é o número de regras.

REFERÊNCIAS BIBLIOGRÁFICAS

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. NBR 5356: Transformador de Potência. Rio de Janeiro, 1993.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. NBR 7070: Guia para Amostragem de Gases e Óleo em Transformadores e Análise dos Gases Livres e Dissolvidos. Rio de Janeiro, 1981.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. NBR 7274: Interpretação da Análise dos Gases de Transformadores em Serviço. Rio de Janeiro, 1982.

ALMEIDA, O. M.; BARBOSA, F. R.; AMORA, M. A. B.; BRAGA, P. R. O. Diagnóstico de Transformadores Utilizando Monitoramento On-line. In: XII ERIAC - Encontro Regional Ibero-Americano do CIGRÈ, 2007, Foz do Iguaçu. Anais do XII ERIAC - Encontro Regional Ibero-Americano do CIGRÈ, 2007a.

ALMEIDA, O. M.; AMORA, M. A. B.; BARBOSA, F. R.; ARAGAO, F. A. P.; NOTTINGHAM, O. C. E. S.; BARRETO, L. H. S. C.; VITOR, R. Monitoramento e Diagnóstico de um Transformador de Potência: Análise de Gases Dissolvidos no Óleo e Análise Térmica. In: IV CITENEL - Congresso de Inovação Tecnológica em Energia Elétrica, 2007, Araxá. ANAIS DO IV CITENEL, 2007b.

BAUGH, P. J. Gas Chromatography: a Practical Approach. Oxford University, New York, 1993.

BENGTSSON, C. Status and Trends in Transformer Monitoring. IEEE Transactions on Power delivery, vol. 11, No. 3, 1996.

BETTA, G.; PIETROSANTO, A.; SCAGLIONE, A. An Enhanced Fiber-Optic Temperature Sensor System for Power Transformer Monitoring. Instrumentation and Measurement, IEEE Transactions on Volume 50, Issue 5, Page(s):1138 – 1143, Oct. 2001.

CARDOSO, P. M. Adaptação de um Sistema de Medição de Gases Dissolvidos em Óleo Mineral Isolante para Monitoração de Múltiplos Transformadores de Potência. Dissertação de Mestrado, UFSC/CT/PPGMCI, Florianópolis-SC, 2005.

CARGOL, T. A Overview of On-Line Oil Monitoring Technologies. Fourth Annual Weidmann-ACTI Technical Conference, San Antonio, 2005.

CAVALEIRO, P. M.; ARAÚJO, F. M.; FERREIRA, L. A.; SANTOS, J. L.; FARAH, F. Simultaneous Measurement of Strain and Temperature Using Bragg Gratings Written in Germanosilicate and Boron-Codoped-Germanosilicate Fibres, IEEE Photonics Technology Letters, 2003.

CHEN, S.; COWAN, C. F. N.; GRANT, P. M. Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks. IEEE Transactions on Neural Networks, Vol. 2, No. 2, pp. 302–309, March 1991.

CHEN, C. H. Fuzzy Logic and Neural Network Handbook. McGrawHill, 1996.

CHU, D., LUX, A. On-Line Monitoring of Power Transformers and Components: A Review of Key Parameters. IEEE Electrical Insulation Conference & Electrical Manufacturers and Coil Winding Exposition, Cincinnati, Ohio, Oct 1999.

CYBENKO, G. Approximation by Superpositions of a Sigmoid Function. Mathematics of Control, Signals and Systems, vol. 2, p. 303-314, 1989.

DÖRNENBURG, E.; GERBER, O.E. Analysis of Dissolved and Free Gases for Monitoring Performance of Oil-Filled Transformers. The Brown Boveri Review, 54 (2/3):104-11, 1967.

DUKARM, J. J. Transformer Oil Diagnosis Using Fuzzy Logic and Neural Networks. Canadian Conference on Electrical and Computer Engineering, Vol.1, pp.329-332, 1993.

DURASAMY, V.; DEVARAJANB, D.; SOMASUNDARESWARIA, D.; VASANTHB, A. M. ; SIVANANDAMC, S.N. Neuro-fuzzy Schemes for Fault Detection in Power Transformer. Applied Soft Computing Volume 7, Issue 2, Pages 534-539, March 2007.

DUVAL, M. Dissolved Gas Analysis: It Can Save Your Transformer. IEEE Electrical Insulation Magazine, v. 5, n. 6, p. 22-27, 1989.

DUVAL, M.; de PABLO, A. Interpretation of Gas-In-Oil Analysis Using New IEC Publication 60599 and IEC TC 10 databases. IEEE Electrical Insulation Magazine, vol. 17, no. 2, pp. 31-41, 2001.

DUVAL, M. A Review of Faults Detectable by Gas-In-Oil Analysis in Transformers. Electrical Insulation Magazine, IEEE Volume 18, Issue 3, Page(s):8 - 17, May-June 2002.

DUVAL, M.; DUKARM, J. Improving the Reliability of Transformer Gas-In-Oil Diagnosis. Electrical Insulation Magazine, IEEE Volume 21, Issue 4, Page(s):21 - 27, July-Aug. 2005.

FERGUSON, R.; LOBEIRAS, A.; SABOU, J. Suspended Particles in the Liquid Insulation of Aging Power Transformers. Electrical Insulation Magazine, IEEE; Volume 18, Issue 4, Page(s):17 - 23, July-Aug. 2002.

FREITAS, A. A. C. Redes Neurais Artificiais Aplicadas em Transformadores de Distribuição Imersos em Óleo. Dissertação de Mestrado, UNESP/FE/DEE, Bauru-SP, 2000.

FRITZKE, B. Fast Learning with Incremental RBF Networks. Neural Processing Letters, v. 1, n. 1, p. 2-5, 1994.

GE ENERGY SERVICES. Hydran M2 Fault Gas and Moisture Monitor. Instruction Manual - Rev. 2, 2005.

GIBEAULT, J.-P.; KIRKUP, J.K. Early Detection and Continuous Monitoring of Dissolved Key Fault Gases in Transformers and Shunt Reactors. Syprotec Inc., Pointe-Claire, Que.; Electrical Electronics Insulation Conference, 1995, and Electrical Manufacturing & Coil Winding Conference, Proceedings Publication, page(s): 285-293, Sep. 1995.

GONÇALVES ,H. I. V.; COIMBRA, R. C. M.; LADEIRA, M.;PRADO, H. A. Ferramenta de Regressão Não-linear Múltipla com Redes Neurais Artificiais. XXV Congresso da Sociedade Brasileira de Computação - SBC, 2005.

GRIFFIN, P.J. Criteria for the Interpretation of Data for Dissolved Gases in Oil from Transformers. A Review. Electrical Insulating Oils, STP 998, H.G. Erdman edited, American Society for Testing and Materials, Philadelphia, p.89-106, 1988.

GUARDADO, J.L.; NAREDO, J.L.; MORENO, P.; FUERTE, C.R. A comparative Study of Neural Network Efficiency in Power Transformers Diagnosis Using Dissolved Gas Analysis, Power Delivery, IEEE Transactions on Volume 16, Issue 4, Page(s):643 – 647, Oct. 2001.

HAGAN, M.T.; MENHAJ, M.B. Training Feed-Forward Networks with the Marquardt Algorithm; Neural Networks, IEEE Transactions on Volume 5, Issue 6, Page(s):989 - 993, Nov. 1994.

HALSTEAD, W.D. A Thermodynamic Assessment of the Formation of Gaseous Hydrocarbons in Faulty Transformers. Journal Inst. Petroleum, Vol.59, pp.239-241, Sept. 1973.

HAYKIN, S. Redes Neurais: Princípios e Práticas; trad. Paulo Martins Engel, 2.ed., Porto Alegre : Bookman, 2001.

HECHT-NIELSEN, R. Neurocomputing – Addison Wesley Publ. Co., New York, 1990.

HESK, T.; NEPORENT, J. Fuzzy Logic for Real World Design. AB Anna Books Ed., 1999.

HUANG, Y.C.; YANG, H.T.; HUANG, C.L. Developing a New Transformer Fault Diagnosis System through Evolutionary Fuzzy Logic. IEEE Trans., Vol.PD-12, No.2, pp.761-767, Apr 1997.

INTERNATIONAL ELECTROTECHNICAL COMMISSION – IEC 60599. Mineral Oil-Impregnated Electrical Equipment in Service - Guide to the Interpretation of Dissolved and Free Gases Analysis. Geneva, Switzerland, 2. ed.,1999.

IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers – IEEE Std C57.104-1991 – 1991.

IMAMURA, M. M.; SILVA, I. N.; SOUZA, A. N. Uma Abordagem Neural para Análise dos Gases Dissolvidos em Óleo Isolante em Função das Grandezas Físico-Químicas. In: XIII CONGRESSO BRASILEIRO DE AUTOMÁTICA - CBA 2000, Florianópolis. XIII Congresso Brasileiro de Automática, p. 2288-2293, 2000.

JANG, J.-S.R. ANFIS: Adaptive - Network - based Fuzzy Inference Systems, IEEE Transactions on Systems, Man and Cybernetics, Vol. 23, No. 3, pp. 665 - 85, May 1993.

JAZAYERI, P.; ROSEHART, W.; WESTWICK, D. T.; A Multistage Algorithm for Identification of Nonlinear Aggregate Power System Loads; Power Systems, IEEE Transactions on Volume 22, Issue 3, Page(s):1072 – 1079, Aug. 2007.

KAN, H.; MIYAMOTO, T. Proposals for an Improvement in Transformer Diagnosis Using Dissolved Gas Analysis (DGA). Electrical Insulation Magazine, IEEE; Volume 11, Issue 6, Page(s):15 - 21, Nov.-Dec. 1995.

KELMAN. Transfix - On Line DGA and Moisture for Transformers. Transfix Brochure, 2007.

KHALIFA, M. High-Voltage Engineering: Theory and Practice. USA, Marcel Dekker Inc., 1990.

KOHONEN, T. Self-Organized Formation of Topologically Correct Feature Maps. Biological Cybernetics, v. 43, p. 59-69, 1982.

KOVACEVIC, S. and DOMINELLI, N. Transformer Life Extension by Continuous On-Line Oil Conditioning. Proceedings of Electrical Insulation Conference and Electrical Manufacturing & Coil Winding Technology Conference, pp.23-25, 2003.

KOVÁCS, Z. L. Redes Neurais Artificiais: Fundamentos e Aplicações: um texto básico. 3 ed., São Paulo: Editora Livraria da Física, 2002.

LAZAREVICH, A. K. Partial Discharge Detection and Localization in High Voltage Transformers Using an Optical Acoustic Sensor. Thesis submitted to the faculty of the Virginia Polytechnic Institute and State University, 2003.

LEVENBERG, K. A Method for the Solution of Certain Non-linear Problems in Least Squares. Quart. Applied Mathematics, vol. 2, no. 2, pp. 164-168, 1944.

LIMA, S. E. U.; ALMEIDA, O. M.; REIS, L. L. N. Diagnóstico de Falhas Incipientes em Transformadores de Potência Imersos em Óleo Utilizando Sistemas Nebulosos. In: CBA 2004 - XV Congresso Brasileiro de Automática, Gramado – RS, 2004.

LIMA, S. E. U.; BARBOSA, F. R.; ALMEIDA, O. M. Diagnóstico de Falhas Incipientes em Transformadores de Potência. In: Simpósio Brasileiro de Sistemas Elétricos, 2006, Campina Grande, Anais do Simpósio Brasileiro de Sistemas Elétricos, 2006.

LIMA, S.E.U. Diagnóstico Inteligente de Falhas Incipientes em Transformadores de Potência Utilizando a Análise dos Gases Dissolvidos em Óleo. Dissertação de Mestrado, UFC/CT/DEE, Fortaleza-CE, 2005.

LIN, C.E.; LING, J.M.; HUANG, C.L. An Expert System for Transformer Fault Diagnosis Using Dissolved Gas Analysis. IEEE Trans. on Power Delivery, Vol.8, No.1, pp.231~238, Jan. 1993.

LUMASENSE Technologies e T&D World Magazine. Web Seminar. Disponível em: www.electricityforum.com. Acessado em: Junho de 2007, 2007.

MAMDANI, E. H.; ASSILIAN, S. An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller. International Journal of Man-Machine Studies 7(1): 1-13, 1975.

MARQUARDT, D.W. An Algorithm for Least-squares Estimation of Nonlinear. Parameters, J. Soc. Industr. Appl. Math., 11, 431-441, 1963.

MELO, A. M. B.; MOTA, F. A. S.; DIAS, F. P.; ALMEIDA, R. F.; LUNA, F. M. T.; RIBEIRO, M. O. A.; CAVALCANTE Jr., C. L.; AZEVEDO, D. S. C. Estudos de Oxidação em Compostos Parafínicos e Avaliação do Desempenho de Aditivos. - VI Congresso Brasileiro de Engenharia Química em Iniciação Científica - COBEQ 2005, Campinas - SP, 2005.

MILASCH, M. Manutenção de Transformadores em Líquido Isolante. Edgar Blücher, São Paulo, 1984.

MIRANDA, V.; CASTRO, A.R.G. Improving the IEC Table for Transformer Failure Diagnosis with Knowledge Extraction from Neural Networks. Power Delivery, IEEE Transactions on Volume 20, Issue 4, Page(s):2509 – 2516, Oct. 2005.

MITSUBISHI ELECTRIC - Transformer Monitoring Dissolved Gas Analyzer; Mitsubishi Electric Brochure, 2007.

MOKHNACHE, L.; BOUBAKEUR, A. Comparison of Different Back-propagation Algorithms Used in the Diagnosis of Transformer Oil. Annual Report Conference on Electrical Insulation and Dielectric Phenomena IEEE, 2002.

MORAIS, D. R.; ROLIM, J. G. Ferramenta Inteligente para Detecção de Falhas Incipientes em Transformadores Baseada na Análise de Gases Dissolvidos no Óleo Isolante. In: XVII CBA - Congresso Brasileiro de Automática, 2004, Gramado – RS, p. 1-6, 2004.

MORAIS, D. R. Ferramenta Inteligente para Detecção de Falhas Incipientes em Transformadores Baseada na Análise de Gases Dissolvidos no Óleo Isolante. Dissertação de Mestrado - UFSC - Florianópolis, 2004.

MORGAN SCHAFFER SYSTEMS. Calisto - Dissolved Hydrogen and Water Monitor. Morgan Schaffer Systems Transformers, 2001.

NEPOMUCENO, L X. Técnicas de Manutenção Preditiva, V.2. Edgard Blücher, São Paulo, 1999.

NOGUEIRA, C. A. A. Avaliação de Sistemas de Medição da Concentração de Hidrogênio Dissolvido em Óleo Isolante. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina, Florianópolis, 2004.

PALMER, J.A.; WANG, X.; SHOURESHI, R.A.; MANDER, A.; TORGERSON, D. RICH, C. Effect of Aging on the Spectral Response of Transformer Oil. Colorado Sch. of Mines, Golden – CO, Electrical Insulation, Conference Record of the 2000, IEEE International Symposium, page(s): 460-464, Anaheim, CA, USA, 2000.

PARASKEVAS, C.D.; VASSILIOU, P.; DERVOS, C.T. Temperature Dependent Dielectric Spectroscopy in Frequency Domain of High-voltage Transformer Oils Compared to Physicochemical Results. Dielectrics and Electrical Insulation, IEEE Transactions on Volume 13, Issue 3, Page(s): 539-546, June 2006.

PATEL, N. K.; KHUBCHANDANI, R. K. ANN Based Power Transformer Fault Diagnosis. IE Journal - EL, [S.l.], v. 85, p. 60-63, June, 2004.

PEYRAQUE, L.; BEROUAL, A.; BURET, F. Static Electrification of Pressboard/Oil Interface and Transient Phenomena. Dielectrics and Electrical Insulation, IEEE Transactions on Volume 5, Issue 3, Page(s): 443-449, June 1998.

PUGH, P. S.; WAGNER, H. H. Detection of Incipient Faults in Transformer by Gas Analysis. AIEE Transactions, v. 80, p. 189-195, 1961.

RANGANATHAN, A. The Levenberg-Marquardt Algorithm. Disponível em: <http://www.cc.gatech.edu/~ananth/docs/lmtut.pdf>. Acesso em: 5/11/2007.

RAO, N.D.; TRIPATHY, S.C. Power System Static State Estimation By the Levenberg-Marquardt Algorithm. IEEE Transactions on Power Apparatus and Systems Volume PAS-99, Issue 2, Page(s):695 – 702, March 1980.

ROGERS, R.R. IEEE and IEC Codes to Interpret Incipient Faults in Transformers Using Gas in Oil Analysis. IEEE Transactions Electrical Insulation, v. 13, n. 5, p. 349-354, 1978.

ROUSE T.O. Mineral Insulating Oil in Transformers, IEE Electrical Insulation Magazine, Vol. 14, Nº 3, Maio/Junho 1998.

RUMMELHART, D., HINTON, W. Learning Internal Representations by Error Propagation. In: Parallel Distributed Processing - MIT Press, Cambridge, 1986.

SAHA, T.K. Review of Modern Diagnostic Techniques for Assessing Insulation Condition in Aged Transformers. Dielectrics and Electrical Insulation, IEEE Transactions on Volume 10, Issue 5, Page(s):903 – 917, Oct. 2003.

SARAVOLAC, M. P. The Use of Optic Fibres for Temperature Monitoring in Power Transformer. IEE Colloquium on Condition Monitoring and Remanent Life Assessment in Power Transformers, pp 1-7, 1994.

SERVERON CORPORATION. True Gas – On-Line Transformer Dissolved Gas Analyzer. Disponível - Rev. C, 2005.

SCHENK, A.; NATALE, S.; GERMOND, A. Transformer State Assessment: Self-Organizing Maps as an Intelligent Online Data Processor Presented at: CIGRÈ, Paris, Août, 2002.

SIEROTA, A.; RUNGIS, J. Charaterization and Pre-treatment of New Transformer Oils. IEEE Electrical Insulation Magazine, 1995.

SU, Q.; MI, C.; LAI, L.L.; AUSTIN, P. A Fuzzy Dissolved Gas Analysis Method for the Diagnosis of Multiple Incipient Faults in a Transformer. Power Systems, IEEE Transactions on Volume 15, Issue 2, Page(s):593-598, May 2000.

TECHNOCHEM, Big Dipper Dissolved Gas Analyzer For Transformer Fault Gas Detect Application - Products Datasheet - Rev. July 2005, 2005.

TENBOHLEN, S.; FIGEL, F. On-line Condition Monitoring of Power Transformers. IEEE Power Engineering Society Winter Meeting, vol.3, pp. 2211 – 2216, 2000.

TEUNISSEN, J.; MERTE, R.; PEIER, D. Stability of fiber Bragg Grating Sensors for Integration into High-voltage Transformers for Online Monitoring. Inst. of High Voltage Eng., Dortmund Univ., in Optical Fiber Sensors, 15th Conference Technical Digest 2002, page(s): 541- 544, vol.1, 2002.

TREE TECH SISTEMAS DIGITAIS. GMM – Gas and Moisture Monitor. Product Datasheet, 2004.

TSUCHIE, M. Recent Diagnostic Technology on Oil-immersed Power Transformer. Japan; Mitsubishi Eletric Corporation, p. 1496-1499, 2002.

VAN BOLHUIS, J. P.; GULSKI, E.; SMIT, J. J. Monitoring and Diagnostic of Transformer Solid Insulation. IEEE Transactions on Power Delivery, vol. 17, nº 3, p. 528-536, 2002.

VARELLA, V., CHEIM, L. e DUPONT, C. Sistema de Inferência Fuzzy para Diagnóstico de Transformadores de Potência. In: VII SEPOPE - Symposium of Specialists in Eletric Operational and Expansion Planning, Curitiba - PR, 2000.

VARL, A. On-line Diagnostics of Oil-filled Transformers. Milan Vidmar Electr, Power Res. Inst., Ljubljana, Slovenia; In: Dielectric Liquids, 2002. Proceedings of IEEE 14th International Conference on Publication, page(s): 253- 257, 2002.

WANG, Z.; LIU, Y.; GRIFFIN, P.J. Neural Net and Expert System Diagnose Transformer Faults. IEEE Computer Applications in Power, vol. 13, no. 1, pp. 50-55, 2000.

WANG, M.; VANDERMAAR, A. J.; SRIVASTAVA, K. D. Review of Condition Assessment of Power Transformers in Service. *Electrical Insulation Magazine*, IEEE Volume 18, Issue 6, Page(s):12-25, Nov.-Dec. 2002.

WANG, Z.; LIU, Y.; GRIFFIN, P.J. A Combined ANN and Expert System Tool for Transformer Fault Diagnosis. *Power Delivery*, IEEE Transactions on Volume 13, Issue 4, Page(s):1224 – 1229, Oct. 1998.

WANG, Z. Artificial Intelligence Applications in the Diagnosis of Power Transformer Incipient Faults. Thesis (PhD.), Virginia Polytechnic Institute and State University, Blacksburg, 105 p, 2000.

WARD, B. H.; LINDGREN, S. A Survey of Developments in Insulation Monitoring of Power Transformers. EPRI, Palo Alto, CA, In: *Electrical Insulation*, 2000. Conference Record of the 2000 IEEE International Symposium on 2000; page(s): 141-147 Anaheim, CA, USA, 2000.

WEG. Manual de Instalação e de Manutenção de Transformadores. Catálogo. 16 p. Blumenau, 2004.

WEIDMANN-ACTI, Centurion On-Line Dielectric Strength Monitor - Product Datasheet - Rev. B, 2005.

ZADEH, L. A. Outline of a New Approach to the Analysis of Complex Systems and Decision Process. *IEEE Trans. Systems Man Cybernetics*, SMC-3, p. 28-44, 1973.

ZAENGL, W. S. Dielectric Spectroscopy in Time and Frequency Domain for HV Power Equipment, Part I: Theoretical Considerations *IEEE Electr. Insul. Mag.* Vol. 19, No. 5, pp 5-19, 2003.

ZHANG, Y. An Artificial Neural Network Approach to Transformer Fault Diagnosis, Thesis of Virginia Tech, 1996.

ZHU, D.; TAN, K.; WANG, C.; JIN, X. Computer-aided On-line Detection of Partial Discharge in Power Transformer. Dept. of Electr. Eng., Tsinghua Univ., Beijing ; In: *Properties and Applications of Dielectric Materials*, Proceedings of the 3rd International Conference on Date: 8-12 Jul 1991; page(s): 1128-1131 vol.2; Tokyo, Japan, 1991.

ZIRBES, R.; Rolim, J. G.; Zürn, H. H. Metodologias para Avaliação e Diagnóstico do Estado de Isolamentos de Papel Impregnado com Óleo Mineral. *Sba Controle & Automação*, vol.16, no. 3, p.318-331, Set 2005.

ZYLKA, P.; MAZUREK, B. Rapid Dissolved Gas Analysis by Means of Electrochemical Gas Sensors. *Inst. of Electr. Eng. Fundamentals*, Wroclaw Univ. of Technol., Poland, In: *Dielectric Liquids*, Proceedings of IEEE 14th International Conference on Date: 2002; page(s): 325- 328, 2002.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)