



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

2008

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

2008

B197m Barbosa, Fábio Rocha
Monitoramento on-line e diagnóstico inteligente da
qualidade dielétrica do isolamento líquido de transformadores
de potência / Fábio Rocha Barbosa, 2008.
139 f. ; il.; enc.

Orientador: Prof. Dr. Otacílio da Mota Almeida
Área de concentração: Eletrônica de Potência e
Acionamentos

Dissertação (Mestrado) - Universidade Federal do Ceará,
Centro de Tecnologia, Fortaleza, 2008.

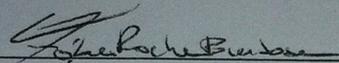
1. Engenharia Elétrica. 2. Eletrônica de potência. 3.
Transformadores elétricos. I. Almeida, Otacílio da Mota.
(Orient.). II. Universidade Federal do Ceará, Centro de
Tecnologia. III. Título.

CDD 621.3

FÁBIO ROCHA BARBOSA

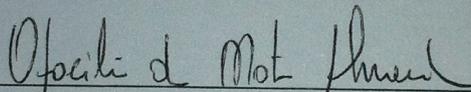
MONITORAMENTO ON-LINE E DIAGNÓSTICO INTELIGENTE DA
QUALIDADE DIELÉTRICA DO ISOLAMENTO LÍQUIDO DE
TRANSFORMADORES DE POTÊNCIA

Esta Dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Elétrica, Área de Concentração em Eletrônica de Potência e Acionamentos, e aprovada em sua forma final pelo Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal do Ceará.



FÁBIO ROCHA BARBOSA

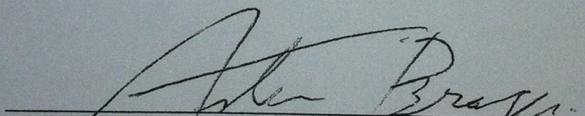
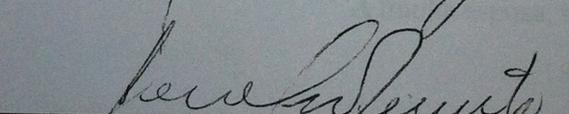
Banca Examinadora:



Prof. Otacílio da Mota Almeida, Dr.



Prof. Leandro dos Santos Coelho, Dr.


Prof. Arthur Plínio de Souza Braga, Dr.
Prof. José Almeida do Nascimento, Dr.

Fortaleza, 13 de 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 de Oliveira Braga.

Agradeço à ENDESA, nas pessoas dos engenheiros Paulo Roberto 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 e diagnóstico inteligente da qualidade dielétrica do isolamento líquido de transformadores de potência**. 2008. 139 f. Dissertação (Mestrado em Engenharia Elétrica)—Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2008.

O monitoramento e o 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, Hydran® da GE, para 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, 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. O sistema implementado apresenta resultados satisfatórios na implantação em uma planta de usina termelétrica.

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

ABSTRACT

BARBOSA, F. R. **On-line monitoring and intelligent diagnosis of dielectric quality of liquid isolation of power transformers.** 2008. 139 f. Dissertation (Master in Electrical Engineering)–Technological Center, Federal University of Ceará, Fortaleza, Brazil, 2008.

The monitoring and diagnosis of incipient fault in power transformers immerses in oil are directly related to the assessment of the isolation system conditions. In this research, it is established the concept of monitoring and diagnosis, after that, on-line monitoring techniques are discussed. A pre-diagnosis system is elaborated based on use of a monitoring on-line device, Hydran® GE, to classify the situation gravity of the detected fault. Once detected a fault situation, intelligent modules of incipient fault diagnosis, by neural networks, can be used to identification of internal fault of the equipment. To complete the checking of the dielectric quality of the isolate liquid, it is also described an intelligent algorithm, based on neural networks, to diagnosis of the oil estate through physical-chemical attribute. The relation between physical-chemical attributes and chromatographic ones regarding to mineral oil were also verified. It was developed, then, the dissolved gases esteem through physical-chemical characteristics. The on-line monitoring modules, diagnosis of oil estate and incipient fault, besides dissolved gases esteem, constitute a computation aid system to operation and maintenance. The implemented system presents satisfied results in a thermoelectric power plant.

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

SUMÁRIO

SUMÁRIO	I
LISTA DE FIGURAS	III
LISTA DE TABELAS	IV
LISTA DE ABREVIATURAS	V
CAPÍTULO 1 - INTRODUÇÃO	6
1.1 A IMPORTÂNCIA DO MONITORAMENTO E DIAGNÓSTICO DE TRANSFORMADORES DE POTÊNCIA	6
1.2 METODOLOGIA	8
1.3 CONTRIBUIÇÕES DA DISSERTAÇÃO.....	8
1.4 DISPOSIÇÃO GERAL DO DOCUMENTO	9
1.5 PRODUÇÃO TÉCNICA	10
CAPÍTULO 2 - ANÁLISE DO ÓLEO MINERAL ISOLANTE	11
2.1 ÓLEO MINERAL ISOLANTE, CELULOSE E A FORMAÇÃO DE GASES EM TRANSFORMADORES	11
2.1.1 <i>DECOMPOSIÇÃO DO ÓLEO MINERAL</i>	13
2.1.2 <i>DECOMPOSIÇÃO DA CELULOSE</i>	15
2.2 ANÁLISE FÍSICO-QUÍMICA DO ÓLEO ISOLANTE	18
2.3 MÉTODOS DE INTERPRETAÇÃO DA ANÁLISE DOS GASES DISSOLVIDOS	20
2.4 CONCLUSÕES	21
CAPÍTULO 3 - MONITORAMENTO <i>ON-LINE</i> DAS CONDIÇÕES DO ÓLEO MINERAL ISOLANTE	22
3.1 DISTRIBUIÇÃO DE FALHAS EM TRANSFORMADORES	22
3.2 MÉTODO TRADICIONAL DE MONITORAMENTO	25
3.2.1 <i>CROMATÓGRAFO</i>	27
3.2.2 <i>ANÁLISES QUALITATIVA E QUANTITATIVA</i>	30
3.3 EQUIPAMENTOS DE MONITORAMENTO	31
3.3.1 <i>MONITORES DE TEMPERATURA</i>	31
3.3.2 <i>MONITORES DE DESCARGAS PARCIAIS</i>	32
3.3.3 <i>MONITORES DE GASES DISSOLVIDOS NO ÓLEO ISOLANTE</i>	34
3.4 MONITORAMENTO <i>ON-LINE</i> DOS GASES DISSOLVIDOS EM TRANSFORMADORES	35
3.5 CONCLUSÕES	37
CAPÍTULO 4 - DIAGNÓSTICO DE FALHAS INCIPIENTES EM TRANSFORMADORES UTILIZANDO INTELIGÊNCIA COMPUTACIONAL	39
4.1 DIAGNÓSTICO DE FALHAS INCIPIENTES UTILIZANDO REDES NEURAS ARTIFICIAIS	40
4.1.1 <i>FALHAS INCIPIENTES EM TRANSFORMADORES DE POTÊNCIA</i>	40
4.1.2 <i>PROJETO DE PERCEPTRONS DE MÚLTIPLAS CAMADAS – MLP</i>	41
4.1.3 <i>ALGORITMOS DE TREINAMENTO BACK-PROPAGATION E ADAPTIVE BACK-PROPAGATION</i>	43
4.1.4 <i>ALGORITMO DE TREINAMENTO LEVENBERG-MARQUARDT</i>	43
4.2 ANÁLISE DOS RESULTADOS	44
4.3 CONCLUSÕES	47
CAPÍTULO 5 - DIAGNÓSTICO DO ESTADO DO ÓLEO ISOLANTE EM TRANSFORMADORES DE POTÊNCIA	49
5.1 DIAGNÓSTICO DO ESTADO DO ÓLEO ISOLANTE	50
5.1.1 <i>IMPORTÂNCIA DO ESTADO DO ÓLEO ISOLANTE</i>	50
5.1.2 <i>CARACTERÍSTICAS FÍSICO-QUÍMICAS DO ÓLEO ISOLANTE</i>	50
5.2 APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NO DIAGNÓSTICO DO ESTADO DO ÓLEO ISOLANTE	55
5.2.1 <i>PROJETO DO PERCEPTRON DE MÚLTIPLAS CAMADAS – MLP</i>	56
5.2.2 <i>ALGORITMO DE TREINAMENTO ADAPTIVE BACK-PROPAGATION</i>	57
5.2.3 <i>ALGORITMO DE TREINAMENTO LEVENBERG-MARQUARDT</i>	57

5.2.4 PROJETO DE REDES DE FUNÇÃO DE BASE RADIAL - RBF	58
5.3 ANÁLISE DOS RESULTADOS	58
5.4 CONCLUSÕES	60
CAPÍTULO 6 - ESTIMAÇÃO DOS GASES DISSOLVIDOS NO ÓLEO ISOLANTE.....	62
6.1 RELAÇÃO ENTRE AS GRANDEZAS DOS ENSAIOS FÍSICO-QUÍMICO E CROMATOGRÁFICO ..	62
6.2 ESTIMAÇÃO DOS GASES DISSOLVIDOS UTILIZANDO REDE NEURAL ARTIFICIAL	64
6.2.1 PROJETO DE REDES NEURAS MLP – TREINAMENTO LEVENBERG-MARQUARDT	65
6.2.2 PROJETO DE REDES NEURAS RBF – ESTRATÉGIA RBF INCREMENTAL	65
6.3 DEFINIÇÃO DOS ATRIBUTOS FÍSICO-QUÍMICOS MAIS INFLUENTES NA ESTIMAÇÃO DO GÁS DISSOLVIDO	65
6.3.1 ATRIBUTOS MAIS INFLUENTES.....	67
6.4 ANÁLISE DOS RESULTADOS	71
6.5 CONCLUSÕES	76
CAPÍTULO 7 - SISTEMA COMPUTACIONAL PARA MONITORAMENTO E DIAGNÓSTICO DO ÓLEO ISOLANTE DE TRANSFORMADORES	78
7.1 CONCEITO DE SISTEMA COMPUTACIONAL PARA MONITORAMENTO E DIAGNÓSTICO	78
7.2 MÓDULO DE MONITORAMENTO	79
7.3 MÓDULO DE DIAGNÓSTICO	81
7.3.1 DIAGNÓSTICO DE FALHAS INCIPIENTES	82
7.3.2 DIAGNÓSTICO DO ESTADO DO ÓLEO	84
7.3.3 ESTIMAÇÃO DA CONCENTRAÇÃO DOS GASES DISSOLVIDOS	86
7.4 DESENVOLVIMENTO DO SISTEMA COMPUTACIONAL	87
7.5 EXEMPLO DE APLICAÇÃO	90
7.6 CONCLUSÕES	92
CAPÍTULO 8 - CONCLUSÃO	94
8.1 DESENVOLVIMENTOS FUTUROS	95
REFERÊNCIAS BIBLIOGRÁFICAS.....	97
APÊNDICE A - REDES NEURAS ARTIFICIAIS.....	107
A.1 NEURÔNIOS ARTIFICIAIS	107
A.2 ARQUITETURA DE RNA.....	109
A.3 PADRÕES DE DADOS.....	109
A.4 PROCESSO DE APRENDIZAGEM DE RNA	111
A.5 PERCEPTRONS DE MÚLTIPLAS CAMADAS (MLP)	112
A.6 ALGORITMOS DE TREINAMENTO.....	114
A.6.1 BACK-PROPAGATION E ADAPTIVE BACK-PROPAGATION	114
A.6.2 LEVENBERG-MARQUARDT	116
A.7 REDES DE FUNÇÃO DE BASE RADIAL (RBF).....	118
A.7.1 ESTRATÉGIA RBF INCREMENTAL.....	121
APÊNDICE B - BANCO DE DADOS DOS ENSAIOS CROMATOGRÁFICOS E FÍSICO-QUÍMICOS	124
B.1 ENSAIOS CROMATOGRÁFICOS	124
B.2 ENSAIOS FÍSICO-QUÍMICOS	133

LISTA DE FIGURAS

FIGURA 2.1 - FORMAÇÃO DOS GASES EM FUNÇÃO DA TEMPERATURA DE DECOMPOSIÇÃO.....	15
FIGURA 3.1 - DISTRIBUIÇÃO DAS POSSÍVEIS FONTES DE FALHAS EM TRANSFORMADORES DE POTÊNCIA.	23
FIGURA 3.2 - GRAU DE IMPORTÂNCIA DOS PARÂMETROS MONITORADOS EM UM TRANSFORMADOR DE POTÊNCIA NOVO.....	24
FIGURA 3.3 - GRAU DE IMPORTÂNCIA DOS PARÂMETROS MONITORADOS EM UM TRANSFORMADOR DE POTÊNCIA EM CONDIÇÃO DE SOBRECARGA.	24
FIGURA 3.4 - GRAU DE IMPORTÂNCIA DOS PARÂMETROS MONITORADOS EM UM TRANSFORMADOR DE POTÊNCIA ANTIGO.....	25
FIGURA 3.5 - CROMATOGRAMA: GRÁFICO DE ANÁLISE CROMATOGRÁFICA.	27
FIGURA 3.6 - REPRESENTAÇÃO ESQUEMÁTICA DE UM SISTEMA DE ANÁLISE CROMATOGRÁFICA.....	28
FIGURA 3.7 - COMPARAÇÃO ENTRE CROMATOGRAMAS DA AMOSTRA E DE UMA SOLUÇÃO PADRÃO.	30
FIGURA 3.8 - SENSOR ÓPTICO DE ULTRA-SOM PARA MEDIDA DE DESCARGAS PARCIAIS.....	33
FIGURA 3.9 - HYDRAN® (GE ENERGY SERVICES, 2005).	35
FIGURA 5.1 - DIAGRAMA VETORIAL DA PERMISSIVIDADE RELATIVA COMPLEXA.....	52
FIGURA 6.1 - ESPECTROSCOPIA DIELÉTRICA DE ÓLEO ISOLANTE ENVELHECIDO.	63
FIGURA 6.2 - VARIAÇÃO DA CONDUTIVIDADE DO ÓLEO EM FUNÇÃO DA TEMPERATURA.	63
FIGURA 7.1 - EVOLUÇÃO DE HIDROGÊNIO E MONÓXIDO DE CARBONO NA PRESENÇA DE CONDIÇÕES DE FALHAS TÍPICAS.....	80
FIGURA 7.2 - EVOLUÇÃO DE HIDROGÊNIO E MONÓXIDO DE CARBONO DURANTE TESTE DE SOBRECARGA.	81
FIGURA 7.3 - TELA PRINCIPAL MÓDULO DE MONITORAMENTO.	88
FIGURA 7.4 - TELA DO MÓDULO DE DIAGNÓSTICO DE FALHAS INCIPIENTES.	89
FIGURA 7.5 - TELA DE GRÁFICO DA EVOLUÇÃO DOS GASES.....	90
FIGURA A.1 - REPRESENTAÇÃO DO MODELO MATEMÁTICO DE UM NEURÔNIO.	107
FIGURA A.2 - TIPOS DE FUNÇÕES NÃO-LINEARES UTILIZADAS COMO FUNÇÃO DE ATIVAÇÃO.....	108
FIGURA A.3 - RNA FEED-FORWARD TOTALMENTE CONECTADA.	112
FIGURA A.4 - FUNÇÃO DE BASE RADIAL.....	119

LISTA DE TABELAS

TABELA 2.1 - PRINCIPAIS TÉCNICAS UTILIZADAS NA ESTIMATIVA DO ENVELHECIMENTO E DEGRADAÇÃO DO SISTEMA ISOLANTE DE TRANSFORMADORES.	17
TABELA 2.2 - ESPECIFICAÇÃO PARA O ÓLEO MINERAL ISOLANTE TIPO “A”.	19
TABELA 2.3 - RAZÕES ENTRE AS CONCENTRAÇÕES DOS GASES.	20
TABELA 2.4 - VALORES LIMITES DAS CONCENTRAÇÕES DOS GASES PARA CONDIÇÃO DE NORMALIDADE.	20
TABELA 4.1 - PERCENTUAL DE ACERTO DAS REDES NEURAIIS.	45
TABELA 4.2 - COMPARAÇÃO ENTRE OS MÉTODOS DE DIAGNÓSTICOS.	46
TABELA 4.3 - EXEMPLOS DAS AMOSTRAS TESTADAS.	47
TABELA 5.1 - NORMAS APLICADAS AOS ENSAIOS FÍSICO-QUÍMICOS NO ÓLEO ISOLANTE.	51
TABELA 5.2 - MÉDIAS E DESVIOS PADRÕES DOS RESULTADOS DOS ENSAIOS FÍSICO-QUÍMICOS COMPARADOS COM OS VALORES NORMALIZADOS.	54
TABELA 5.3 - PERCENTUAL DE ACERTO DAS REDES NEURAIIS.	59
TABELA 6.1 - RESULTADO DA BUSCA EXAUSTIVA - HIDROGÊNIO.	67
TABELA 6.2 - ATRIBUTOS MAIS INFLUENTES - HIDROGÊNIO.	68
TABELA 6.3 - RESULTADO DA BUSCA EXAUSTIVA - MONÓXIDO DE CARBONO.	68
TABELA 6.4 - ATRIBUTOS MAIS INFLUENTES - MONÓXIDO DE CARBONO.	68
TABELA 6.5 - RESULTADO DA BUSCA EXAUSTIVA - DIÓXIDO DE CARBONO.	69
TABELA 6.6 - ATRIBUTOS MAIS INFLUENTES - DIÓXIDO DE CARBONO.	69
TABELA 6.7 - RESULTADO DA BUSCA EXAUSTIVA - METANO.	69
TABELA 6.8 - ATRIBUTOS MAIS INFLUENTES - METANO.	69
TABELA 6.9 - RESULTADO DA BUSCA EXAUSTIVA - ETILENO.	70
TABELA 6.10 - ATRIBUTOS MAIS INFLUENTES - ETILENO.	70
TABELA 6.11 - RESULTADO DA BUSCA EXAUSTIVA - ETANO.	70
TABELA 6.12 - ATRIBUTOS MAIS INFLUENTES - ETANO.	70
TABELA 6.13 - RESULTADO DA BUSCA EXAUSTIVA - ACETILENO.	71
TABELA 6.14 - ATRIBUTOS MAIS INFLUENTES - ACETILENO.	71
TABELA 6.15 - PERCENTUAL DE ACERTO DAS REDES NEURAIIS PARA ESTIMAÇÃO DO HIDROGÊNIO.	72
TABELA 6.16 - PERCENTUAL DE ACERTO DAS REDES NEURAIIS NA ESTIMAÇÃO DO MONÓXIDO DE CARBONO.	73
TABELA 6.17 - PERCENTUAL DE ACERTO DAS REDES NEURAIIS PARA ESTIMAÇÃO DO DIÓXIDO DE CARBONO.	73
TABELA 6.18 - PERCENTUAL DE ACERTO DAS REDES NEURAIIS PARA ESTIMAÇÃO DO METANO.	74
TABELA 6.19 - PERCENTUAL DE ACERTO DAS REDES NEURAIIS PARA ESTIMAÇÃO DO ETILENO.	74
TABELA 6.20 - PERCENTUAL DE ACERTO DAS REDES NEURAIIS PARA ESTIMAÇÃO DO ETANO.	75
TABELA 6.21 - PERCENTUAL DE ACERTO DAS REDES NEURAIIS PARA ESTIMAÇÃO DO ACETILENO.	75
TABELA 7.1 - GUIA DE VERIFICAÇÃO DAS CONDIÇÕES DO ÓLEO ISOLANTE.	85
TABELA 7.2 - NÍVEIS DE ALARMES DISPONÍVEIS NO HYDRAN® M2.	87
TABELA 7.3 - MONITORAMENTO ON-LINE TRANSFORMADOR 140MVA.	91
TABELA 7.4 - RESULTADOS DOS MÉTODOS DE DIAGNÓSTICO DE FALHAS INCIPIENTES.	91
TABELA 7.5 - RESULTADOS DOS MÉTODOS DE DIAGNÓSTICO DO ESTADO DO ÓLEO.	92
TABELA B.1 – RESULTADO DOS ENSAIOS CROMATOGRÁFICOS PARA 354 AMOSTRAS.	124
TABELA B.2 – RESULTADO DOS ENSAIOS FÍSICO-QUÍMICOS PARA 251 AMOSTRAS.	133

LISTA DE ABREVIATURAS

ABNT	ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS
ANFIS	SISTEMA ADAPTATIVO DE INFERÊNCIA NEURO-NEBULOSO
ASTM	<i>AMERICAN SOCIETY FOR TESTING AND MATERIALS</i>
BP	<i>BACK-PROPAGATION</i>
CH ₄	METANO
C ₂ H ₂	ACETILENO
C ₂ H ₄	ETILENO
C ₂ H ₆	ETANO
DADE	DESCARGAS DE ALTA DENSIDADE DE ENERGIA
DAEA	DESCARGAS DE ALTA DENSIDADE DE ENERGIA OU ARCOS
DGA	ANÁLISE DE GASES DISSOLVIDOS EM ÓLEO
DMDE	DESCARGAS DE MÉDIA DENSIDADE DE ENERGIA
DP	DESCARGAS PARCIAIS
EQM	ERRO QUADRÁTICO MÉDIO
FP	FUNÇÃO DE PERTINÊNCIA
FT	FALHA TÉRMICA
FTAT	FALHA TÉRMICA DE ALTA TEMPERATURA
FTBT	FALHA TÉRMICA DE BAIXA TEMPERATURA
FTMT	FALHA TÉRMICA DE MÉDIA TEMPERATURA
GRNN	REDES DE REGRESSÃO GENERALIZADA
H ₂	HIDROGÊNIO
IEC	<i>INTERNATIONAL ELECTROTECHNICAL COMMISSION</i>
IEEE	<i>INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS</i>
L1	NORMA PARA DETERMINAÇÃO DO NÍVEL CRÍTICO DE NORMALIDADE
LM	LEVENBERG-MARQUARDT
MLP	PERCEPTRON DE MÚLTIPLAS CAMADAS
N ₂	NITROGÊNIO
NGG	NÍVEL DO GÁS GERADO
NGF	NÍVEL DO GÁS FINAL
O ₂	OXIGÊNIO
OLTC	<i>ON-LOAD TRANSFORMER TAP CHANGER</i>
PNN	REDES NEURAS PROBABILÍSTICAS
PPM	PARTES POR MILHÃO
R1	RAZÃO CH ₄ /H ₂
R2	RAZÃO C ₂ H ₂ /C ₂ H ₄
R3	RAZÃO C ₂ H ₂ /CH ₄
R4	RAZÃO C ₂ H ₆ /C ₂ H ₂
R5	RAZÃO C ₂ H ₄ /C ₂ H ₆
R6	RAZÃO CO ₂ /CO
RBF	FUNÇÕES DE BASE RADIAL
RDG	REGRA DELTA GENERALIZADA
RNA	REDES NEURAS ARTIFICIAIS
SOM	MAPAS AUTO-ORGANIZÁVEIS
SVM	MÁQUINA DE VETOR DE SUPORTE
TAN δ	TANGENTE DE PERDA OU FATOR DE DISSIPACÃO
TG	TAXA DE GERAÇÃO
TGF	TAXA DE GERAÇÃO FINAL

CAPÍTULO 1 - INTRODUÇÃO

Nestes comentários introdutórios, a problemática envolvendo o tema do estudo é desenvolvida. Uma explanação acerca do monitoramento e diagnóstico de transformadores de potência, bem como do cenário atual das pesquisas na área, é disposta a seguir. Na seção 1.1 é apresentada uma reunião bibliográfica com o objetivo de situar a importância do monitoramento e análise das condições dielétricas e das situações de falhas incipientes em transformadores de potência. Na seção 1.2 é apresentada a metodologia utilizada na abordagem dos assuntos correlatos, bem como as motivações que levaram ao estudo em questão. A seção 1.3 mostra as principais contribuições da pesquisa. O formato de apresentação da dissertação é mencionado na seção 1.4. A seção 1.5 mostra a produção técnica gerada a partir da pesquisa do tema.

1.1 A IMPORTÂNCIA DO MONITORAMENTO E DIAGNÓSTICO DE TRANSFORMADORES DE POTÊNCIA

Os sistemas para diagnóstico e monitoramento de equipamentos do sistema elétrico de distribuição e transmissão sem a necessidade de desligamentos (*on-site*) têm sido propostos em níveis de pesquisas com implementações práticas finais por agentes do setor elétrico, como fabricantes, transmissoras e distribuidoras (BENGTSON, 1996; KOVACEVIC; DOMINELLI, 2003; CARGOL, 2005; MAK *et al.*, 2007; LEVY *et al.*, 2007; LUMASENSE, 2007). 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; PATEL; KHUBCHANDANI, 2004; CARDOSO, 2005; MIRANDA; CASTRO, 2005; LOBO *et al.*, 2005; LIMA *et al.*, 2006; PRADHAN, 2006; DURAISAMY *et al.*, 2007; LEITE *et al.*, 2007; COLAÇO *et al.*, 2007, ALMEIDA *et al.*, 2007b). No Brasil, mais especificamente, o interesse por esta área tem sido acelerado, nos últimos anos, devido a mudanças estruturais no setor de energia elétrica visando promover a competição entre as empresas de geração, transmissão e distribuição. Tais mudanças 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 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.*, 1999; ZIRBES *et al.*, 2005; DERVOS *et al.*, 2005; PARASKEVAS *et al.*, 2006, WANG *et al.*, 2006).

Os transformadores de potência de grande porte são equipamentos, técnica e economicamente, essenciais em uma planta elétrica de transmissão e distribuição. Assim, esforços vêm sendo empregados para garantir seu bom funcionamento e evitar possíveis falhas que venham a ocorrer devido ao seu ciclo natural de vida ou regimes elétricos a que são submetidos. Atualmente, há o desenvolvimento de considerável número de ferramentas para o monitoramento e diagnóstico das condições dos transformadores de potência imersos em óleo (BENGTSON, 1996; BETTA *et al.*, 2000; KOVACEVIC; DOMINELLI, 2003; TENBOHLEN; FIGEL, 2000; ZYLKA *et al.*, 2002; VARL, 2002; SAHA, 2003; VALIN, 2004; CARDOSO, 2005; LIMA, 2005; LIMA *et al.*, 2006; ALMEIDA *et al.*, 2007a; ALMEIDA *et al.*, 2007b; DURAISAMY *et al.*, 2007; BARBOSA; ALMEIDA, 2008).

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 visa 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 (VARL, 2002; KOVACEVIC; DOMINELLI, 2003; MORAIS, 2004; LIMA; 2005; ALMEIDA *et al.*, 2007b). Atualmente, observa-se a tendência da substituição do diagnóstico feito por um especialista por sistemas automáticos de diagnóstico que incorporam técnicas inteligentes para representar entre outros conhecimentos, aquele acumulado com a experiência de um especialista (FREITAS, 2000; THANG *et al.*, 2003; MORAIS; ROLIM, 2006; DURAISAMY *et al.*, 2007; BARBOSA; ALMEIDA, 2008).

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, 2005; MIRANDA; CASTRO, 2005; DURAISAMY *et al.*, 2007). Também, como verificação da qualidade dielétrica do líquido isolante, algoritmos inteligentes, baseados 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; PARASKEVAS *et al.*, 2006).

Neste estudo, os módulos de monitoramento *on-line*, em conjunto com os algoritmos de diagnóstico e com a estimação dos gases foram projetados de modo a comporem uma ferramenta integrada de diagnóstico da qualidade dielétrica do isolante líquido do transformador. Os resultados da aplicação desses métodos em um programa de computador desenvolvido satisfazem o objetivo de promover a proteção de um transformador monitorado (SHENK *et al.*, 2002; LIMA, 2005; MORAIS; ROLIM, 2006; DUKARM; LANE, 2004).

1.2 METODOLOGIA

O desenvolvimento desta dissertação é iniciado com uma revisão de importantes trabalhos científicos e normas técnicas para interpretação e compreensão das informações provenientes das análises cromatográficas e dos ensaios físico-químicos de óleos minerais. As considerações sobre as técnicas e os instrumentos para monitoramento *on-line* de transformadores e as melhores opções em termos do compromisso técnico-econômico são realizadas. Em seguida, os métodos inteligentes são estudados procurando otimizar os algoritmos convencionais para se obter o diagnóstico confiável do transformador. Os resultados são devidamente avaliados para a determinação dos métodos de melhor desempenho. Finalmente, os métodos são validados em uma plataforma computacional que gerencia o uso dos algoritmos de monitoramento, detecção e identificação das condições de falha, com a capacidade de sintetizar recomendações sobre o estado operacional do transformador.

1.3 CONTRIBUIÇÕES DA DISSERTAÇÃO

Esta dissertação aborda o desenvolvimento de um sistema computacional para realização do monitoramento *on-line* e diagnóstico inteligente do sistema isolante de transformadores de potência. A pesquisa é motivada pelo fato do transformador ser um equipamento essencial na geração, transmissão e distribuição de energia elétrica e os métodos de análise do sistema isolante apresentarem casos de inconsistências normativas e problema de não decisão ou dúvidas de diagnóstico, inerentes aos métodos tradicionalmente aplicados.

Alguns sistemas de monitoramento propostos na literatura, conforme vistos na seção 1.1, aparecem isolados de métodos de diagnóstico de falhas isolantes. E vários sistemas para

diagnóstico desenvolvidos ainda não apresentam credibilidade satisfatória apresentando casos de erro.

Esta pesquisa desenvolve uma solução de monitoramento *on-line* do transformador que apresenta uma otimizada relação técnico-econômica e é integrada a um método de pré-diagnóstico capaz de classificar prioridades de alarmes em condições de falhas da unidade. Esta característica suplanta limitações de sistemas de monitoramentos anteriormente desenvolvidos.

Outra contribuição é o desenvolvimento de um sistema de diagnóstico de falhas incipientes baseado em redes neurais artificiais com índice de acertos da ordem de 100%.

Também, é importante citar a integração de um sistema inteligente de análise da qualidade dielétrica do óleo através da análise físico-química, ampliando o campo de análise das probabilidades de falhas no transformador. Atualmente, a análise do óleo do transformador para verificação do seu apropriado condicionamento de uso é normatizada e envolve as análises cromatográfica e físico-química. A integração de módulos inteligentes para análise físico-química e de falhas incipientes não é mencionada na literatura.

A estimação dos gases dissolvidos no óleo através dos atributos físico-químicos também é verificada nesta pesquisa. Isto possibilita obter os teores dos gases dissolvidos no óleo sem a necessidade de realização do ensaio cromatográfico, apenas dispondo dos atributos físico-químicos do óleo.

Economicamente, o sistema implantado traz um impacto na contratação do seguro do transformador, por exemplo, uma vez que viabiliza credibilidade como sistema de segurança evitando eventualidades que venham a danificar o equipamento.

1.4 DISPOSIÇÃO GERAL DO DOCUMENTO

Esta dissertação está organizada em oito capítulos. Este primeiro capítulo é composto da exposição dos conceitos introdutórios para uma melhor compreensão do problema estudado. No capítulo 2, discute-se a caracterização e análise do óleo isolante de transformadores. Este capítulo também menciona métodos de diagnóstico de falhas incipientes e análises físico-químicas. No capítulo 3, apresenta-se 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 utilizando um sistema de aquisição de dados de um monitor de gases dissolvidos é descrita. O diagnóstico de falhas incipientes baseado em redes neurais artificiais é desenvolvido no capítulo 4. Porém, para uma melhor exposição do texto, os detalhes básicos e conceituais

sobre redes neurais são mencionados no Apêndice A. 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 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. No capítulo 8 são levantados os comentários conclusivos e lançados os desenvolvimentos futuros.

1.5 PRODUÇÃO TÉCNICA

A pesquisa em torno do tema desta dissertação gerou a seguinte produção técnica publicada, conforme segue:

LIMA, S. E. U.; BARBOSA, F. R.; ALMEIDA, O. M. Diagnóstico de Falhas Incipientes em Transformadores de Potência. Anais do Simpósio Brasileiro de Sistemas Elétricos, 2006, Campina Grande, PB.

ALMEIDA, O. M.; BARBOSA, F. R.; AMORA, M. A. B.; BRAGA, P. R. O. Diagnóstico de Transformadores Utilizando Monitoramento *On-line*. Anais do XII ERIAC - Encontro Regional Ibero-Americano do CIGRÈ, 2007, Foz do Iguaçu, PR.

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. Anais do IV CITENEL - Congresso de Inovação Tecnológica em Energia Elétrica, 2007, Araxá, MG.

CAPÍTULO 2 - ANÁLISE DO ÓLEO MINERAL ISOLANTE

As condições de funcionamento e integridade de um transformador de potência imerso em óleo podem ser estabelecidas a partir da análise do seu óleo isolante. Sabe-se que um conjunto de análises definidas por normas técnicas permite o diagnóstico das condições de falhas do transformador.

Os métodos mais estudados de diagnóstico utilizados para identificar falhas incipientes em transformadores de potência são: i) avaliação físico-química, que determina o estado do óleo; ii) análise cromatográfica que verifica possíveis falhas no equipamento. A partir destes dois tipos de análises foram definidas normas e procedimentos de operação e manutenção de equipamentos isolados a óleo.

A caracterização do sistema isolante do transformador e as formas de degradação estão descritas na seção 2.1 deste capítulo. A avaliação físico-química é discutida na seção 2.2. 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 as concentrações dos gases estão descritos na seção 2.3. Finalmente, as conclusões do capítulo são apresentadas na seção 2.4.

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

O óleo mineral isolante é 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; THE ELECTRICITY FORUM, 2005):

- **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 denominada 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 como descrito em 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 co-seno 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, ou 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; RUNGIS, 1995).

Uma 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).

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 pode influenciar 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 *et al.*, 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, apresentado na 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 às 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).

A decomposição do óleo mineral isolante submetido a situações de falhas incipientes em transformadores pode produzir os seguintes 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).

A presença de gases não-combustíveis como oxigênio (O_2) e nitrogênio (N_2) ou hidrocarbonetos com C_3 e C_4 também pode ocorrer. No entanto, como não são 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 a relação entre os gases gerados e a temperatura nas proximidades de uma falha.

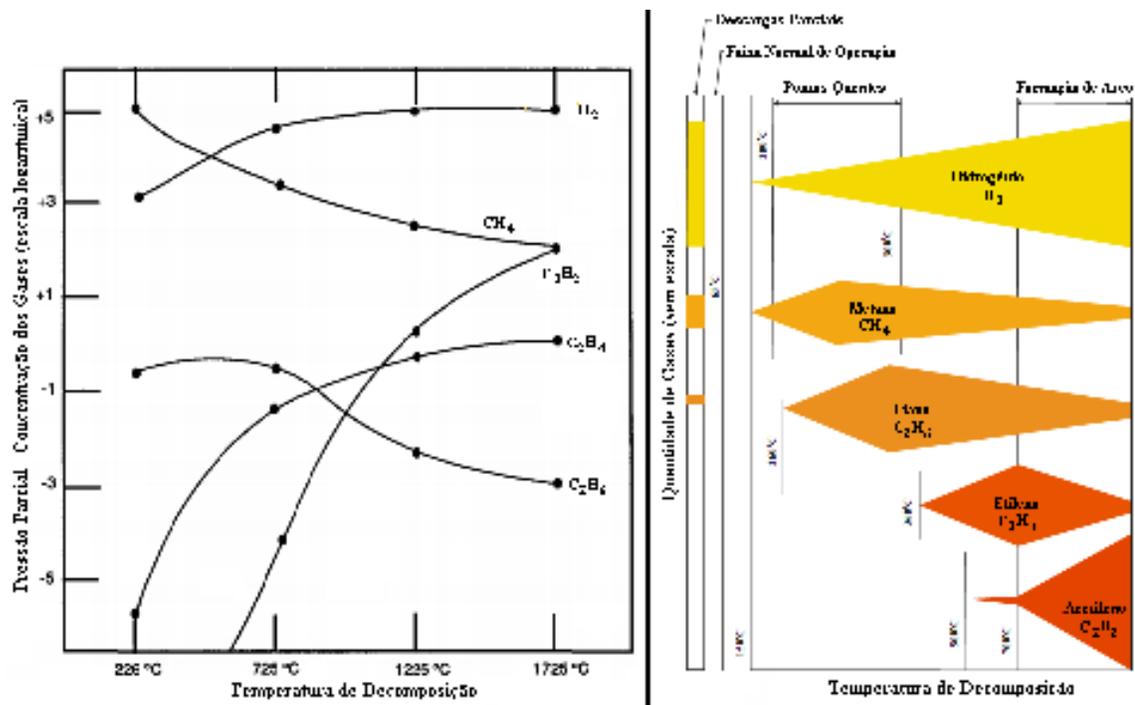


Figura 2.1 - Formação dos gases em função da temperatura de decomposição.

a) pressão x temperatura. b) concentração dos gases x temperatura.

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 o 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).

Propriedades elétricas 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; THE ELECTRICITY FORUM, 2005).

Em termos da decomposição térmica da isolação celulósica, há produção de óxidos de carbono (CO e CO₂) e algumas moléculas de hidrogênio (H₂) e metano (CH₄) 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 determinado volume aquecido a uma temperatura moderada tenha o mesmo efeito de um volume menor a temperatura mais elevada. 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 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 *et al.*, 2005).

Diante do exposto, há interesse acentuado de pesquisadores no 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 *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 (Análise de Gases Dissolvidos em Óleo)	Envelhecimento do óleo e papel, identificação de pontos quentes, arcos elétricos ou descargas parciais.	Amplamente em uso, há estudos em desenvolvimento para refinar a causa da formação do gás.	Diversas concessionárias e laboratórios.	Sim
Grau de Polimerização (GP)	Envelhecimento do papel isolante.	Relaciona a cadeia de polímeros e a resistência mecânica.	Principalmente pesquisadores e poucas concessionárias.	Não
Análise Furfural	Envelhecimento do papel isolante.	O comportamento da formação de compostos furfânicos ainda sob pesquisa.	Concessionárias e laboratórios.	Sim
Medição da Tensão de Reestabelecimento (RVM)	Quantidade de água e envelhecimento do papel isolante.	Sob pesquisa.	Algumas concessionárias e laboratórios.	Não
Tangente Delta	Perdas dielétricas no sistema isolante.	Instrumentos portáteis têm sido desenvolvidos para este fim.	Algumas concessionárias e fabricantes.	Sim, aplicada à bucha de transformadores.
Resistência do isolamento e índice de polarização.	Acúmulo de materiais polarizáveis no sistema isolante.	Conhecido.	Principalmente, concessionárias. Pode ser usada off-line, em testes periódicos.	Não
Tangente Delta (δ)	Resposta em frequência do dielétrico, envelhecimento do papel, acúmulo de materiais polarizáveis no sistema isolante.	Instrumentos são comercialmente avaliados. Muitas pesquisas avançam na interpretação dos resultados.	Algumas concessionárias e laboratórios.	Não
Descargas Parciais	Deterioração do sistema isolante, detecção de alguns defeitos localizados.	Bem conhecidos. Pesquisas estão sendo feitas para supressão de ruídos, interpretação dos dados e uso <i>on-line</i> .	Diversas concessionárias. Compõe os testes para entrega de transformadores de potência.	Sim

2.2 ANÁLISE FÍSICO-QUÍMICA DO ÓLEO ISOLANTE

O óleo mineral isolante é classificado em naftênico ou parafínico, sendo designado do tipo A o primeiro e do tipo B, o último (ABNT, 1993).

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. 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 *et al.*, 2005).

A análise das características físico-químicas, bem como seus valores limites, são indicativos importantes da boa adequação do óleo isolante de acordo com procedimentos padronizados por entidades, tais como os propostos por ABNT (Associação Brasileira de Normas Técnicas), IEC (*International Electrotechnical Commission*) e ASTM (*American Society For Testing And Materials*). Através destas análises, pode-se acompanhar a evolução de algumas características e determinar se o óleo isolante se mostra adequado. Estes atributos sofrem mudanças ao longo do tempo de operação do transformador, modificando assim a capacidade de transferir calor e a própria estabilidade do óleo.

As características mais utilizadas como determinante da boa adequação do óleo isolante, em termos da sua capacidade de isolamento 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 a NBR 5356 (ABNT, 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
COR	-	-	1,0	ABNT-MB-351
DENSIDADE A 20° C	-	0,861	0,900	NBR-7148
ENXOFRE CORROVISO	-	NÃO CORROSIVO		ABNT-899
FATOR DE PERDAS DIELETRICAS A 25° C A 90° C A 100° C	%	- - -	0,05 0,40 0,50	NBR-12133
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 - ELETRODO DE DISCO - ELETRODO VDE	KV	30 42	- -	NBR-6869 NBR-10859
RIGIDEZ DIELETRICA A IMPULSO (ELETRODOS DE AGULHA/ESFERA)	KV	145	-	ASTM-D-3300
TENDÊNCIA A EVOLUÇÃO DE GASES	µl/min	NEGATIVO		ASTM-D-2300 MÉTODO B
TENSÃO SUPERFICIAL A 25° C	mN/m	40	-	NBR-6234
VISCOSIDADE A 20° C 40° C 100° C	mm ² /s (cST)	- - -	25,0 11,0 3,0	ABNT-MB-293
TEOR DE ÁGUA	mg/kg (p.p.m.)	-	35	NBR-10710

Assim, é importante o uso do conhecimento apresentado em 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.

2.3 MÉTODOS DE INTERPRETAÇÃO DA ANÁLISE DOS GASES DISSOLVIDOS

Os métodos de análise dos gases dissolvidos são amplamente aplicados nos sistemas de manutenção nos parques elétricos de todo o mundo. Isto significa o domínio de uma técnica e a comprovação do seu uso a ponto da metodologia ser padronizada por normas nacionais e internacionais, tais como as normas NBR 7070 (ABNT, 1981), IEC 599 (IEC, 1999) e IEEE C57.104 (IEEE, 1991).

Um estudo aprofundado sobre o uso dos métodos de interpretação e uma breve descrição dos principais métodos tidos como convencionais podem ser encontrados em Lima (2005). Para a compreensão do texto desta dissertação é necessário mencionar que a maioria das teorias de DGA faz uso das razões apresentadas na tabela 2.3 e consideram como valores limites para aplicação das técnicas os da norma L1, conforme mostrado na tabela 2.4.

Tabela 2.3 - Razões entre as concentrações dos gases.

Razão	CH ₄	C ₂ H ₂	C ₂ H ₂	C ₂ H ₆	C ₂ H ₄
	H ₂	C ₂ H ₄	CH ₄	C ₂ H ₂	C ₂ H ₆
Notação	R1	R2	R3	R4	R5

Tabela 2.4 - Valores limites das concentrações dos gases para condição de normalidade.

Gás	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO
Norma L1 (p.p.m.)	100	120	35	50	65	350

Muitas pesquisas aplicam técnicas de Inteligência Computacional no diagnóstico de falhas incipientes (DUKARM, 1993; ZANGH, 1996; HUANG *et al.*, 1997; WANG, 2000; MORAIS, 2004; LIMA 2005; ALMEIDA *et al.*, 2007a; BARBOSA; ALMEIDA, 2008). Pode-se citar alguns fatores que estimulam pesquisas nesta área: a facilidade na aplicação das técnicas, a disponibilidade de dados e o desenvolvimento de tecnologias que ajudam na implementação das pesquisas desenvolvidas. Como resultado, tem-se um ambiente de confiabilidade do diagnóstico e, conseqüentemente, uma garantia do investimento realizado.

As pesquisas envolvem técnicas como Sistemas Nebulosos e Redes Neurais Artificiais e podem ser utilizadas isoladamente ou integradas em sistemas híbridos (MIRANDA; CASTRO, 2005; LIMA *et al.*, 2006; ALMEIDA *et al.*, 2007b; DURASAMY *et al.*, 2007).

2.4 CONCLUSÕES

O monitoramento e diagnóstico das condições de envelhecimento e degradação do isolamento de transformadores de potência é, atualmente, um importante quesito na manutenção e operação. O empenho nesse sentido pode ser o diferencial em salvaguardar o equipamento em situações críticas.

A análise dos gases dissolvidos no óleo, apesar de sua eficácia limitada tem tido sucesso no diagnóstico de falhas incipientes em transformadores. No entanto, há uma carência 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.

Diante do que foi discutido, o conhecimento de métodos convencionais para identificação de falhas incipientes possibilita o desenvolvimento de um módulo do sistema de diagnóstico de falhas aliado a um esquema de monitoramento *on-line* que colete os dados do equipamento para alimentar o sistema de informações em tempo real. Paralelo a isso, o estudo das técnicas de DGA permitem a implementação de um sistema de estimação dos gases dissolvidos em função das grandezas físico-químicas. Esta 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 lidar com inconsistências normativas através de aplicações de técnicas que rendam maior confiabilidade aos diagnósticos de falha.

O próximo capítulo menciona os detalhes do esquema de monitoramento *on-line* que tem por objetivo acompanhar a evolução das condições internas com respeito a produção dos gases dissolvidos no interior do transformador.

CAPÍTULO 3 - MONITORAMENTO *ON-LINE* DAS CONDIÇÕES DO ÓLEO MINERAL ISOLANTE

O monitoramento de transformadores de potência tem por fim a aquisição de um conjunto de dados relativos ao funcionamento do transformador, cuja coleta envolve modernas tecnologias em sensores, técnicas de aquisição de dados e dispositivos digitais ou analógicos utilizados. Nesse contexto, se insere o monitoramento e diagnóstico de falhas incipientes em transformadores de potência, tendo, por ponto de partida, a análise dos gases dissolvidos no óleo do transformador.

O acompanhamento em tempo real da condição do óleo de transformadores acarreta benefícios 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 também, aumentar a vida útil do transformador.

A distribuição das falhas no transformador é estudada na seção 3.1. A seção 3.2 apresenta os métodos tradicionais de monitoramento e diagnóstico de falhas incipientes em transformadores de potência. Com os avanços dos estudos nessa área, mais especificamente no desenvolvimento de sensores, surgem alguns equipamentos de monitoramento de falhas incipientes, conforme seção 3.3. Na seção 3.4 apresenta-se uma aplicação prática de um equipamento comercial para monitoramento *on-line*. A conclusão do capítulo é apresentada na seção 3.5.

3.1 DISTRIBUIÇÃO DE FALHAS EM TRANSFORMADORES

Os últimos avanços no desenvolvimento da tecnologia de sensores permitem a possibilidade de que praticamente todos os parâmetros de um transformador sejam monitorados. Com isto, tornou-se necessário estabelecer critérios para a escolha de quais parâmetros monitorar. Para se avaliar o grau de adequação do projeto de um sistema de monitoramento e diagnóstico é importante equilibrar eficiência e custos, mediante a identificação de quais parâmetros são relevantes e quais técnicas reduzem a quantidade de sensores, além da possibilidade de 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 (DP). Deve ser observado que, independente da fonte de falha a ser considerada, a temperatura constitui um importante parâmetro a ser monitorado.

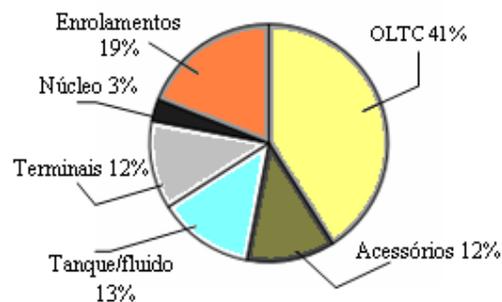


Figura 3.1 - Distribuição das possíveis fontes de falhas em transformadores de potência.

Conforme algumas pesquisas realizadas entre especialistas, como observada em Lumasense (2007), os dois parâmetros mais importantes a serem monitorados em um transformador são os gases dissolvidos no óleo isolante e a temperatura do ponto quente. Para transformadores de instalação recente e que podem ser submetidos a situações de sobrecarga, o parâmetro mais importante a ser monitorado é a temperatura do ponto quente, pois este parâmetro indica, de imediato, as condições operacionais do equipamento e influencia diretamente na vida útil do mesmo. No decorrer da 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).

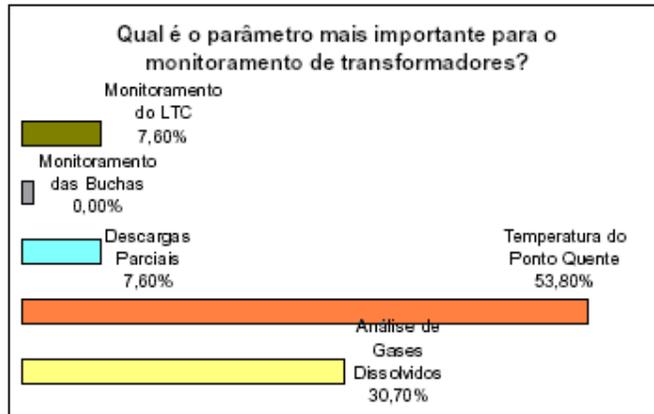


Figura 3.2 - Grau de importância dos parâmetros monitorados em um transformador de potência novo.

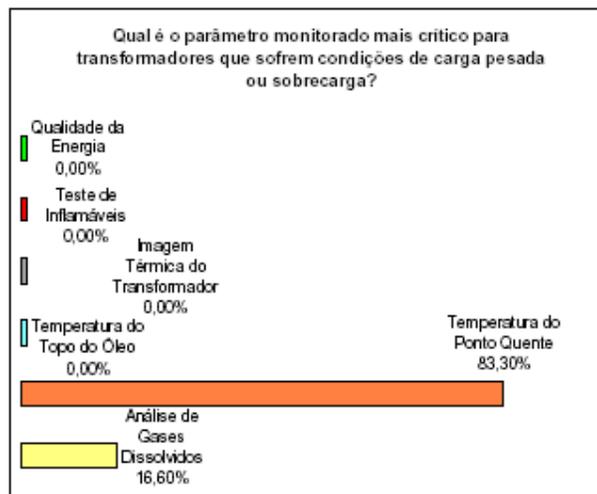


Figura 3.3 - Grau de importância dos parâmetros monitorados em um transformador de potência em condição de sobrecarga.

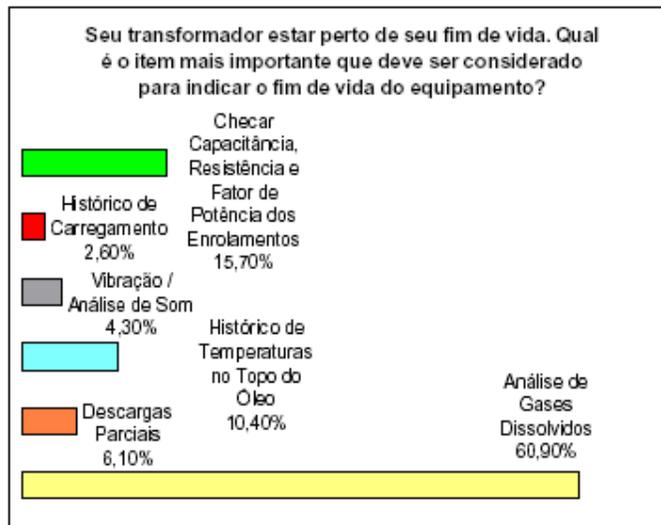


Figura 3.4 - Grau de importância dos parâmetros monitorados em um transformador de potência antigo.

Os resultados destas pesquisas servem para orientar os desenvolvimentos das ferramentas de monitoramento e diagnóstico.

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 verificada a iminência de falha (NEPOMUCENO, 1999). Como não é possível realizar inspeção direta dos componentes dos transformadores imersos em óleo sem a sua retirada de operação, é necessário o acompanhamento periódico e sistemático de várias medidas, por exemplo, dos gases dissolvidos no óleo, 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 é 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 de separação dos componentes de uma mistura, identificando, assim, quais os elementos estão presentes na amostra ensaiada. As falhas

incipientes, classificadas em termos dos esforços térmicos, podem ser identificadas a partir do 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 (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.

A norma ABNT-NBR 7070 (1981) 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 uma 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, incorrendo em contaminação 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.

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, conforme mencionados no capítulo 2.

3.2.1 Cromatógrafo

O cromatógrafo processa o reconhecimento e avaliação dos gases componentes da amostra, gerando um gráfico como resultado da análise. 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 3.5.

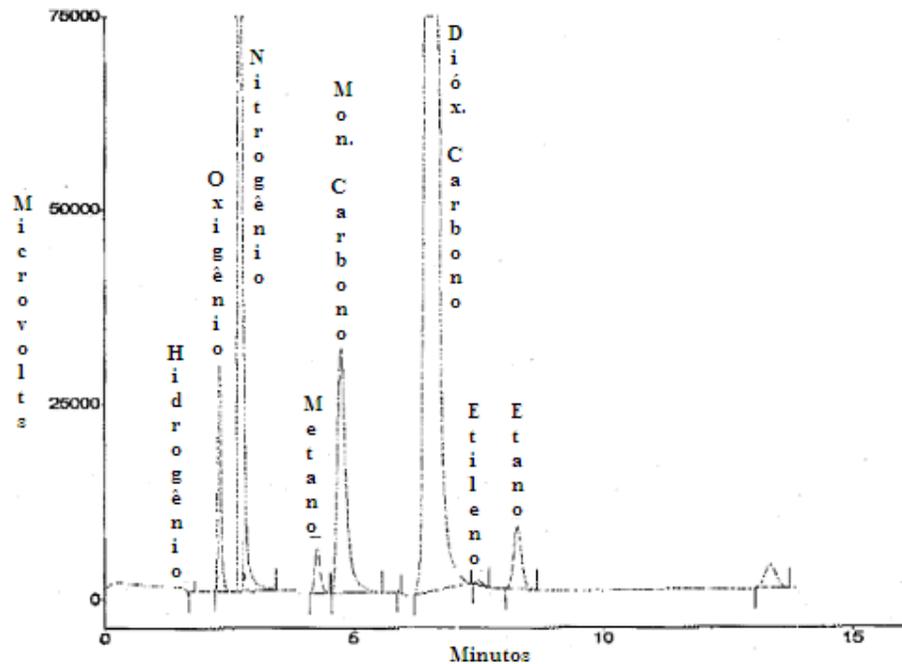


Figura 3.5 - Cromatograma: Gráfico de análise cromatográfica.

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.

As unidades fundamentais de um cromatógrafo, apresentadas na figura 3.6, 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.

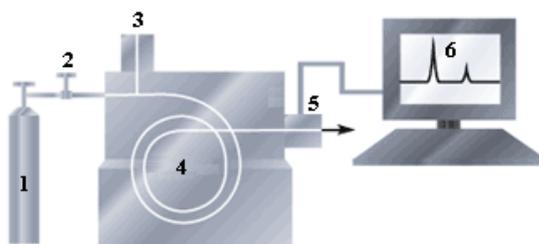


Figura 3.6 - Representação esquemática de um sistema de análise cromatográfica.

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. Os 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 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. As 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 3 m. Porém, as colunas capilares podem ter comprimento de 10 a 100 m e apresentam maior eficiência na eliminação de alargamento de bandas devido a irregularidades no enchimento mediante a baixíssima espessura.

Os 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 3.7 (CARDOSO, 2005).

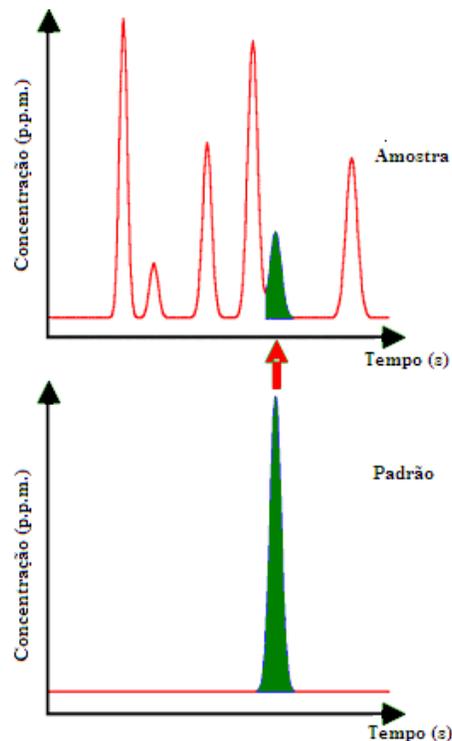


Figura 3.7 - Comparação entre cromatogramas da amostra e de uma solução padrão.

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.

Entretanto, a espectroscopia foto-acústica está se consolidando como técnica moderna de cromatografia, pois se abstêm do uso de gases de arraste ou calibração dos gases.

3.3 EQUIPAMENTOS DE MONITORAMENTO

Os equipamentos para o 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 tem impacto no planejamento da manutenção que é otimizado através da utilização de equipamentos de monitoramento e diagnóstico. Quando se trata de transformadores de potência, tal atitude visa salvaguardar um equipamento importantes das subestações.

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, imagem térmica, 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.*, 1999; PRADHAN, 2006). 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 à 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.

Para superar 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 que 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 aplicadas para medida de cargas térmicas em transformadores (SARAVOLAC, 1994; BETTA *et al.*, 2000).

Dois princípios são comumente usados na concepção dos sensores de fibra óptica de temperatura: variação do tempo de degradação 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; WANG *et al.*, 2006; PRADHAN, 2006).

Porém, a aplicação imediata e em larga escala ainda não ocorre somente devido ao custo da tecnologia, uma vez que há desenvolvimento de métodos de instalação que privilegiam 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; LOBO *et al.*, 2005). O monitoramento de DP 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 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; PRADHAN, 2006).

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, tais 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; LOBO *et al.*, 2005). Um sistema 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 - *Digital Signal Processing*). Para a transmissão do sinal da sonda até o DSP utiliza-se uma fibra óptica, conforme apresentado na figura 3.8.

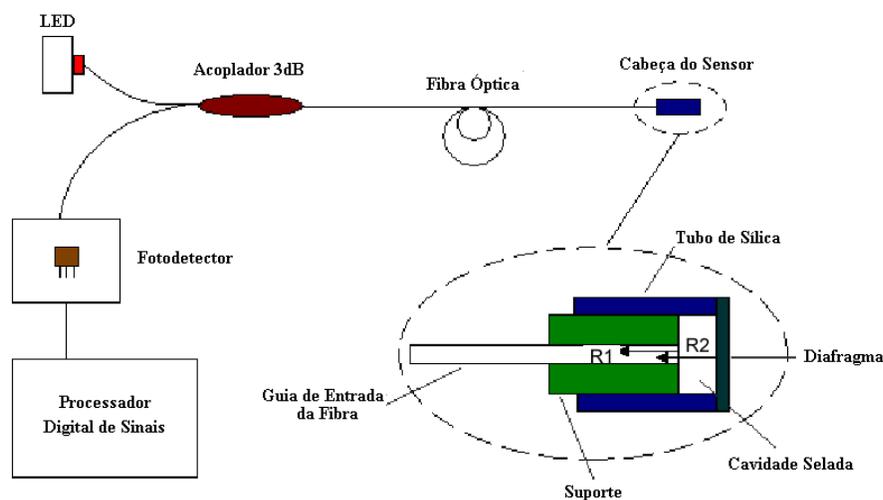


Figura 3.8 - Sensor óptico de ultra-som para medição de descargas parciais.

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; LINDGREN, 2000).

3.3.3 Monitores de Gases Dissolvidos no Óleo Isolante

Os problemas no transformador podem ser detectados através da análise do óleo. Embora o período padrão de acompanhamento da formação dos gases no óleo do transformador seja de um ano, ocorrem situações nas quais um período mais curto de análise se torna necessário para acompanhar a evolução da formação dos gases. Na realidade, mesmo com a análise em períodos menores que o previsto em normas, a informação da evolução do estado interno entre as amostras pode ficar comprometido. Este ponto de vista tem levado a desenvolvimentos tecnológicos no sentido de viabilizar o DGA em tempo real 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 (ALMEIDA *et al.*, 2007b). A possibilidade de realizar DGA em tempo real apóia-se no grande esforço que vem sendo recentemente 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.

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). A figura 3.9 mostra o Hydran® M2, um monitor de gases dissolvidos no óleo em sua aparência externa.

Outros dispositivos para monitoramento *on-line* foram comparados em suas características técnicas e definidas as situações onde melhor poderiam ser aplicados. Baseado nesta comparação e considerando uma relação técnico-econômica, o HYDRAN® M2 da GE justifica sua aplicação no estudo de caso que segue na próxima seção.



Figura 3.9 - Hydran® (GE ENERGY SERVICES, 2005).

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® M2 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 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.

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, 2005).

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.

Paralelamente, o Hydran® M2 possui o sensor Aquaoil® 400 que possibilita a 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 porcentagem, 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, tais 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*.

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. Desse modo é realizado 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 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 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 CONCLUSÕES

Monitorar um equipamento significa obter informações preciosas concernentes a previsibilidade de sinistros, possibilitando a implementação de mecanismos ou manobras de proteção. Os métodos de acompanhamento da quantidade de gás dissolvido em óleo e os sistemas de medição descritos neste capítulo apresentam as ferramentas disponíveis para a elaboração de um sistema de monitoramento *on-line* das condições de isolamento de transformadores de potência.

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 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 o seguro das unidades monitoradas, significando um reconhecimento da eficácia deste tipo de proteção.

A utilização de um sistema de monitoramento deve ser aliada a métodos eficientes de diagnóstico das situações de falhas encontradas. O próximo capítulo aborda a implementação de um sistema de diagnóstico inteligente de falhas incipientes.

CAPÍTULO 4 - DIAGNÓSTICO DE FALHAS INCIPIENTES EM TRANSFORMADORES UTILIZANDO INTELIGÊNCIA COMPUTACIONAL

Entre as técnicas de inteligência computacional, as redes neurais artificiais são referência em aplicações de classificação de padrões. As redes neurais são técnicas eminentemente não-lineares e por isto são utilizadas na modelagem de sistemas que apresentam não-linearidades em sua estrutura. Os estudos para desenvolver o módulo de diagnóstico baseado em Redes Neurais Artificiais (RNA) são descritos neste capítulo.

Inicialmente, são apresentadas as arquiteturas, o método de treinamento e as principais características das redes neurais desenvolvidas para o módulo do sistema de diagnóstico. As redes neurais empregadas são do tipo supervisionadas e alimentadas adiante (*feed-forward*): *perceptron* de múltiplas camadas (MLP – *Multi-Layer Perceptron*). Na realização das etapas de treinamento e validação foram utilizados dois algoritmos de treinamento (*Adaptive Back-Propagation* e *Levenberg-Marquardt*) alimentados pela base de dados do Apêndice B. Em seguida, são apresentados três classificadores de padrões, utilizando sistemas nebulosos com diferentes bases de conhecimento. Os módulos implementados buscam 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 combinado entre os sistemas nebulosos e as redes neurais.

Portanto, o capítulo está dividido conforme segue. Na seção 4.1 apresenta-se a definição das características da RNA aplicada no diagnóstico de falhas através de dois algoritmos de treinamento, devidamente detalhado. 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 B. As conclusões do capítulo são apresentadas na seção 4.4.

4.1 DIAGNÓSTICO DE FALHAS INCIPIENTES UTILIZANDO REDES NEURAIAS ARTIFICIAIS

4.1.1 Falhas Incipientes em Transformadores de Potência

O sistema de isolamento de um transformador, mesmo operando em condições de normalidade, sofre redução de sua capacidade na medida em que envelhece. No caso de operação em condições críticas, esta redução pode ser acelerada e a vida útil do isolamento se torna mais breve. Quando a capacidade do sistema de isolamento é reduzida, vários processos podem ser desencadeados, acelerando o processo de incapacidade do isolamento. Quando o isolamento não tem mais integridade para realizar sua função tem-se a falha do isolamento. Estes processos que colaboram para a aceleração da incapacidade do sistema de isolamento, quando em fase principiante, são conhecidos como falhas incipientes (ZIRBES *et al.*, 2005).

As falhas incipientes são caracterizadas por esforços térmicos, como sobreaquecimentos, e elétricos, relacionados à descargas internas no equipamento. Estas falhas agem sobre o sistema de isolamento conforme descrito na seção 2.1 deste trabalho.

O diagnóstico de falhas em transformadores deve levar em consideração que estes fenômenos são caracterizados por imprecisões, incertezas nas medidas e não-linearidades não modeladas. Dessa forma, métodos baseados em inteligência computacional e em especial, redes neurais artificiais, podem ser empregados, em conjunto com métodos tradicionais, para se obter diagnósticos automáticos de falhas de modo satisfatório (LIMA *et al.*, 2006).

Visando a resolução da problemática do diagnóstico de falhas incipientes, as redes neurais são utilizadas em um sistema de reconhecimento de padrões que apresenta em sua saída o diagnóstico das falhas incipientes em resposta aos padrões de entrada.

Para a implementação deste módulo de diagnóstico é projetada uma estrutura de rede neural Perceptrons de Múltiplas Camadas com dois métodos de treinamento: *Adaptive Back-Propagation* e *Levenberg-Marquardt*. A motivação do uso de dois métodos de treinamento é otimizar os melhores resultados obtidos nos estudos de Lima (2005) com a aplicação de *Adaptive Back-Propagation*. Os conceitos básicos e detalhamentos de projeto sobre redes neurais estão descritos no Apêndice A.

4.1.2 Projeto de Perceptrons de Múltiplas Camadas – MLP

Na busca da definição da arquitetura de MLP mais adequada à aplicação em diagnóstico de falhas incipientes deve-se levar em consideração que este problema se refere a um mapeamento não-linear complexo e não há uma relação linear entre a concentração de gases dissolvidos e a falha incipiente até o presente momento. Esta consideração serve como orientação para a escolha de estrutura de MLP com camadas escondidas. Com relação ao algoritmo de treinamento, o sucesso das aplicações da retro-propagação do erro sugere esta estratégia também nesta aplicação. No projeto do vetor de entradas para a rede neural, inicialmente são 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 B. No entanto, outro teste pode ser 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 . 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, 1999; KAN; MIYAMOTO, 1995; WANG, 2000). Assim, três tipos de vetores de entrada são utilizados para verificação do desempenho da rede neural projetada: 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 4.1, 4.2 e 4.3.

$$X = \begin{pmatrix} H_2 \\ CH_4 \\ CO \\ CO_2 \\ C_2H_4 \\ C_2H_6 \\ C_2H_2 \end{pmatrix} \quad (4.1)$$

$$X = \begin{pmatrix} R1 \\ R2 \\ R5 \end{pmatrix} \quad (4.2)$$

$$X = \begin{pmatrix} R1 \\ R2 \\ R5 \\ R6 \end{pmatrix} \quad (4.3)$$

Também é 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 é associado um valor numérico que represente o diagnóstico de falha, logo, o único neurônio de saída apresenta o diagnóstico através deste tipo de código. O diagnóstico via rede neural faz a classificação dos padrões de falha de acordo com 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).

Com o objetivo de definir a melhor topologia para a MLP sugerida, em termos do número de camadas escondidas e seus respectivos neurônios, é feita a comparação com o percentual de acerto das diversas configurações em uma série de simulações. Os resultados mais promissores são obtidos a partir da estrutura com uma camada escondida fortalecendo o que é defendido em Cybenko (1989) e Hecht-Nielsen (1990) que uma MLP de três camadas, com apenas uma camada escondida, tem a capacidade de aproximar qualquer função contínua e limitada, com determinada precisão, independente de sua complexidade.

A função de ativação tangente hiperbólica é utilizada nos neurônios da camada escondida, devido à sua anti-simetria que proporciona maior velocidade de convergência, e a função linear no neurônio de saída (HAYKIN, 2001).

O processo de treinamento pode ser interrompido pelo critério que leva em consideração o índice de acerto no conjunto de dados de validação para cada época de treinamento. A estratégia evita que a rede aprenda detalhes demais enquanto é treinada (*overtraining*). Então, o processo de treinamento é interrompido quando o erro de validação subir por 5 validações consecutivas ou quando o número máximo de épocas, 30.000, é atingido.

Neste caso, o pré-processamento é efetuado mediante normalização conforme apresentado na equação A.2, uma vez que as dimensões dos valores das entradas são amplamente diferentes. Assim, a normalização processa os dados de forma a ter média igual a 0 e desvio padrão igual

a 1, redimensionando o domínio dos dados para os limites adequados facilitando a convergência.

Para evitar que os pesos da MLP tendam para alguma classe de padrão a série de dados de treinamento é organizada de modo que cada classe apresente quantidades próximas a uma distribuição uniforme de amostras.

4.1.3 Algoritmos de Treinamento *Back-Propagation* e *Adaptive Back-Propagation*

Os princípios que regem os algoritmos de treinamento *Back-Propagation* e *Adaptive Back-Propagation* estão descritos na seção A.6.1 do Apêndice A deste trabalho. Para esta aplicação, 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, os padrões são apresentados à rede, depois 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 suficiente para que a rede aprenda sem aumentar a taxa de erro. Isto resulta na redução do tempo de treinamento, uma vez que, quando comparado ao *Back-Propagation* convencional, este método apresenta convergência mais rápida (PATEL; KHUBCHANDANI, 2004).

4.1.4 Algoritmo de Treinamento *Levenberg-Marquardt*

Este algoritmo de treinamento é detalhado na seção A.6.2 do Apêndice A deste trabalho. Na aplicação do treinamento da RNA com Levenberg-Marquardt (LM) para o diagnóstico de falhas incipientes, o valor inicial de μ é 0,01, baseado em estudos de Hagan e Menhaj (1994) que apresenta resultados interessantes no treinamento, em termos de percentual de acerto, com o uso deste valor. O parâmetro μ será atualizado dependendo da distância de uma solução ótima com taxa de decremento igual a 0,1 e incremento definida em 10.

Devido a essa característica de acelerar a convergência minimizando rapidamente a função objetivo o algoritmo LM vem sendo comparado e obtém vantagem sobre outras estratégias ou

até utilizada em conjunto para a obtenção de resultados ótimos (RAO; TRIPATHY, 1980; JAZAYERI *et al.*, 2007).

4.2 ANÁLISE DOS RESULTADOS

Para realização das etapas de treinamento, validação e testes das redes neurais desenvolvidas foram utilizadas amostras do banco de dados de análises cromatográficas dispostas no Apêndice B.

O conjunto total de dados foi composto 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 da empresa responsável pela análise dos gases dissolvidos no óleo.

As redes foram treinadas com três formatos para os vetores de entrada com as duas estratégias de treinamento, *Adaptive Back-Propagation* (ABP) e Levenberg-Marquardt (LM). 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 e o terceiro formato de vetores de entrada, que levam em consideração as razões dos gases, 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* e a MLP treinada via algoritmo Levenberg-Marquardt em função do número de neurônios utilizados na camada escondida nos conjuntos de dados de treinamento, validação e teste do Apêndice B.

Tabela 4.1 - Percentual de acerto das redes neurais.

Vetores de Entradas	Algoritmo de Treinamento	Número de Neurônios na Camada Escondida	Épocas de Treinamento	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, pode haver diferenças entre o diagnóstico dado através das redes neurais e o diagnóstico real no transformador, pois não se pode garantir que o conjunto de dados represente 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 *Adaptive 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 neural com menor complexidade e manter o nível de eficiência no diagnóstico abrindo oportunidades para implementações em sistemas embarcados e estudos de aplicações em tempo real, como microcontroladores, FPGAs, Controladores Lógico-Programáveis entre outros.

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

A tabela 4.2 estabelece uma comparação em termos de eficiência de diagnóstico obtido pela Rede Neural projetada, o critério padrão IEC 599 e a falha real no equipamento amostrado. A tabela 4.3 contém 6 exemplos de amostras utilizadas na comparação de eficiência entre os métodos. O diagnóstico via rede neural é representado pela MLP, vetor de entrada com quatro razões (R1, R2, R5 e R6) e treinamento usando Levenberg-Marquardt, com 5 neurônios na camada escondida.

Tabela 4.2 - Comparação entre os métodos de diagnósticos.

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

Tabela 4.3 - 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

4.3 CONCLUSÕES

Neste capítulo, foram propostas e projetadas duas 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.

A dificuldade de convergência durante as simulações foi superada mediante a aplicação de um método de pré-processamento dos dados baseado em normalização. Logo, o domínio dos dados foi redimensionado facilitando o processo de treinamento e garantindo a convergência.

O diagnóstico de falhas incipientes via redes neurais apresentou um percentual elevado de acerto. As falhas a serem identificadas, 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, *Adaptive Back-Propagation* e *Levenberg-Marquardt*, foi realizada na tentativa de se atingir níveis de eficiência 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 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 *Adaptive Back-Propagation* sendo o indicado para a constituição do módulo neural de diagnóstico de falhas incipientes.

A adição de parâmetros para detecção de situações de falhas envolvendo a celulose, razão R6, proporciona uma maior abrangência à solução implementada, uma vez que o problema da não-decisão é superado por não haver mais padrões sem diagnósticos.

Finalmente, pode-se observar que as redes neurais são uma alternativa de diagnóstico automático de falhas incipientes em transformadores de potência. Estes métodos podem complementar os métodos tradicionais para conferir maior segurança ao diagnóstico.

Para complementar as informações obtidas do diagnóstico de falhas incipientes pode ser necessária a verificação da qualidade do óleo. Este é o assunto do próximo capítulo deste trabalho.

CAPÍTULO 5 - DIAGNÓSTICO DO ESTADO DO ÓLEO ISOLANTE EM TRANSFORMADORES DE POTÊNCIA

A verificação da condição do isolamento do óleo é tão importante quanto a análise dos gases dissolvidos no óleo isolante. Alguns testes físico-químicos em amostras do óleo podem revelar a integridade dielétrica e refrigerante do mesmo e são atualmente aplicados na gestão de manutenção de transformadores de potência. Essas análises, bem como a emissão das suas conclusões, são dependentes de métodos padronizados que necessitam da experiência humana gerenciando seu uso. Diante disso, há uma necessidade de se aplicar estudos envolvendo redes neurais 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.

O diagnóstico do estado do óleo isolante pode ser implementado através de redes neurais artificiais. Neste capítulo, duas estruturas de redes neurais serão projetadas com este objetivo. Para o treinamento das redes neurais será utilizado o banco de dados apresentado no Apêndice B. O método de Levenberg-Marquardt será utilizado como algoritmo de treinamento. Inspirado nos estudos de Lima (2005), uma rede neural do tipo função de base radial será também utilizada e o desempenho das estruturas propostas serão investigadas.

Este capítulo está organizado da seguinte forma. Na seção 5.1 apresenta-se o estudo do conceito da análise e diagnóstico do estado do óleo isolante através das características físico-químicas. Na seção 5.2 o processo de definição das características da rede neural RBF, bem como da MLP será abordado. 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

O efeito do envelhecimento do óleo pode ser investigado a partir das suas propriedades físicas, químicas e elétricas. Com isso, testes de avaliação da qualidade do sistema de isolamento têm sido elaborados.

5.1.1 Importância do Estado do Óleo Isolante

Com a necessidade do aumento de demanda por energia e a otimização do uso dos equipamentos do sistema elétrico, a sistemática do procedimento de manutenção e operação vem sendo aprimorado para introduzir novas tecnologias e métodos de diagnóstico (LEITE *et al.*, 2007).

Uma estratégia para melhorar as condições da manutenção e operação tem sido a combinação dos programas baseados no tempo para as rotinas baseadas em condições. Enquanto as primeiras são efetuadas 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 computacionais confiáveis de monitoramento e diagnóstico para avaliação das condições internas dos transformadores. Isto também significa proteção em períodos onde não há manutenção programada (WANG *et al.*, 2002).

Nesse contexto, também ocorre a necessidade de se determinar a perda de vida útil dos transformadores devido a solicitações acima das nominais, uma vez que estas podem afetar o estado do óleo, visando estimar o adicional financeiro a ser ressarcido pelo solicitante (LIMA *et al.*, 2007).

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; LUX, 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 denominada 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).

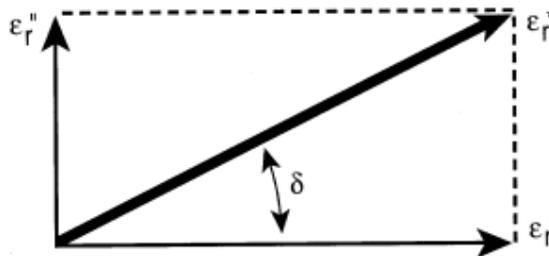


Figura 5.1 - Diagrama vetorial da permissividade relativa complexa.

Nos estudos de Paraskevas *et al.* (2006), sobre a resposta do dielétrico em função da frequência e da temperatura (espectroscopia dielétrica dependente da temperatura) alguns comentários podem ser colocados 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 condicionamento através de desidratação ou filtração 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 condicionamento, 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 normatizados.

Ensaio Físico-químico	Limites (ASTM)	Condição do Óleo		
		1	2	3
Rigidez Dielétrica (kV)	No mínimo 26 (D877)	31,48±5,9	28,70±6,9	27,49±7,24
Tensão Interfacial (dinas /cm)	No mínimo 24 (D971)	34,60±6,18	24,33±3,8	20,13±3,65
Acidez (mg KOH /oil g)	No máximo 0,2 (D974)	0,10±0,016	0,124±0,048	0,19±0,091
Teor de Água (p.p.m.)	No máximo 35 (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 não ter sido ultrapassado por nenhum dos conjuntos de dados, há uma 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 $\tan \delta$. É 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. 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).

Sabe-se também que o óleo isolante tende a ter má qualidade com o decrescimento da rigidez dielétrica e da tensão interfacial e com o aumento do teor de água e da acidez (PALMER *et al.*, 2000).

Em suma, os estudos revelam uma correlação entre a degradação do óleo e os valores das análises físico-químicas. Assim, 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 complexa e que requer experiência do operador.

Buscando auxiliar na solução do problema, o projeto de redes neurais aplicadas ao diagnóstico da qualidade do óleo isolante de transformadores através dos resultados de análises físico-químicas deve 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.

Além de utilizar redes do tipo MLP com algoritmos de treinamento *Adaptive Back-Propagation* e Levenberg-Marquardt, é interessante a implementação de uma outra estrutura de rede neurais baseadas em funções de base radial. Os desenvolvimentos teóricos referentes ao projeto de redes neurais estão devidamente descritos no Apêndice A.

5.2.1 Projeto do Perceptron de Múltiplas Camadas – MLP

As redes MLP aplicadas a este tipo de diagnóstico têm alcançado resultados promissores utilizando uma arquitetura do tipo três camadas, com apenas uma camada escondida. Bons resultados têm sido obtidos através do uso do algoritmo *Adaptive Back-Propagation* e Levenberg-Marquardt (MOKHNACHE; BOUBAKEUR, 2002).

Na definição do vetor de entrada da rede neural são 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.

$$X = \begin{pmatrix} \textit{acidez} \\ \textit{rig. dielétrica} \\ \textit{teor de água} \\ \textit{tensão interfacial} \\ \textit{densidade} \\ \textit{f. potência} \end{pmatrix} \quad (5.1)$$

Os dados são 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, conforme apresentado na equação A.2.

O objetivo da rede neural projetada é classificar a qualidade do óleo isolante segundo o padrão de diagnóstico. Os laudos dos especialistas nas análises físico-químicas são tomados como alvo de saída durante o processo de treinamento das redes. De acordo com estes laudos, as recomendações para o condicionamento por termo-vácuo, regeneração por filtragem, reamostragem imediata, reamostragem em um ano constituem o procedimento padrão de manutenção. Estas também são as opções 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 é tangente hiperbólica. A função linear é escolhida para o neurônio de saída. Também é definida a polarização (*bias*) para todos os neurônios, sendo esta de valor inicial igual a 1.

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

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

5.2.2 Algoritmo de treinamento Adaptive Back-Propagation

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 insatisfatoriamente 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, conforme mostrado na equação A.11 no Apêndice A, acima desse percentual em relação ao da época anterior decrementa o coeficiente de aprendizagem. Caso seja inferior, ocorre o incremento.

5.2.3 Algoritmo de Treinamento Levenberg-Marquardt

O método de Levenberg-Marquardt 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. A meta é que a função objetivo seja sempre reduzida a cada época de treinamento ou utilizando o método de Newton, ou utilizando o gradiente descida de encosta 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 utilizado no algoritmo para o diagnóstico de falhas incipientes.

5.2.4 Projeto de Redes de Função de Base Radial - RBF

Conforme mostrado na seção A.7 do apêndice A, esta estrutura se refere ao uso de neurônios com função de ativação do tipo Gaussiana implementados na camada conhecida como camada de base radial.

O algoritmo incremental apresenta uma característica construtiva na qual a função de *performance* seja reduzida a cada época de treinamento através da inserção de novos neurônios no espaço de entrada, à medida que a configuração da rede proporciona melhores índices de desempenhos.

Dessa forma, a cada iteração os neurônios da camada de base radial promovem deslocamentos no espaço vetorial de entrada em direção ao vetor de entrada com o objetivo de melhorar os índices de desempenho.

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 B.

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 Treinamento	Número de Neurônios na Camada Escondida	Épocas de Treinamento	Diagnóstico Correto (%)		
			Treinamento	Validação	Teste
LM	5	182	100,00	100,00	100,00
RBF Incremental	5	5	15,00	5,00	13,64
LM	15	164	100,00	100,00	86,36
RBF Incremental	15	15	100,00	95,00	95,45
LM	25	129	100,00	100,00	77,27
RBF Incremental	25	24	100,00	100,00	100,00

A tabela 5.3 mostra que o algoritmo de treinamento da rede MLP, o 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 com função 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 treinamento menor 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 CONCLUSÕES

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

Foi realizada a comparação entre as duas estruturas projetadas diante da mesma problemática. Enquanto as 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 decremento exponencial, por exemplo, funções gaussianas. Em termo de complexidade de estrutura, conclui-se que redes MLP com apenas uma camada escondida composta por 5 neurônios é 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 acentuada 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.

O uso de atributos físico-químico na verificação da integridade do óleo isolante em conjunto com a análise dos gases dissolvidos levanta a questão da influência dos atributos físico-químicos na geração de gases dissolvidos, e *vice-versa*. Esta relação é investigada no próximo capítulo e um método de estimação dos gases através dos resultados das análises físico-químicas é demonstrado.

CAPÍTULO 6 - ESTIMAÇÃO DOS GASES DISSOLVIDOS NO ÓLEO ISOLANTE

A qualidade dielétrica do óleo isolante e as falhas incipientes de natureza térmica e elétrica podem ser determinadas a partir de ensaios físico-químico e cromatográfico. Estes ensaios são, portanto, importantes para manter a integridade dos transformadores de potência. Acredita-se que exista uma correlação entre estes dois tipos de ensaios e este capítulo abordará este tema.

As relações entre estes dois tipos de ensaios podem ser estudadas no sentido de determinar a concentração dos gases (hidrogênio, monóxido de carbono, dióxido de carbono, metano, etano, etileno e acetileno) dissolvidos em função das grandezas físico-químicas (acidez, rigidez dielétrica, teor de água, tensão interfacial, densidade e fator de potência do óleo). A seção 6.1 trata da correlação entre os resultados dos dois tipos de análises do óleo isolante. Na seção 6.2 são investigados métodos para estimar os gases dissolvidos a partir de grandezas físico-químicas com o uso de estruturas de redes neurais. Na seção 6.3 apresenta-se o método da busca exaustiva, utilizado para definir quais atributos físico-químicos são mais relevantes na estimação de cada gás dissolvido. Os resultados obtidos são apresentados 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

Algumas pesquisas procuram associar as características dielétricas anormais do óleo ao aparecimento de falhas internas. Tais anormalidades podem estar relacionadas com a 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 (FERGUSON *et al.*, 2002; WANG *et al.*, 2002).

Outras referências têm demonstrado que amostras de óleos ensaiadas com métodos de espectroscopia dielétrica apresentam correlação entre o envelhecimento do óleo e o fator de perdas ($\tan \delta$). Estas pesquisas concluem que amostras com características físico-químicas alteradas apresentam fator de perdas dependente da temperatura. Na figura 6.1 nota-se o aumento do valor do fator de perdas para o incremento da temperatura do óleo (PARASKEVAS *et al.*, 2006).

Os estudos de Peyraque *et al.* (1998), demonstram que a condutividade do óleo, parâmetro complementar à rigidez dielétrica, mantém 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.

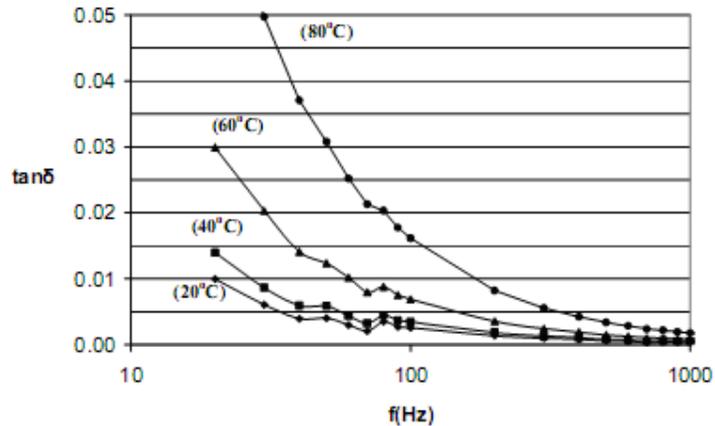


Figura 6.1 - Espectroscopia dielétrica de óleo isolante envelhecido.

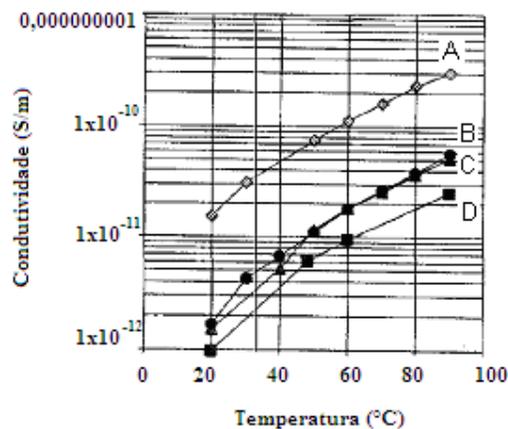


Figura 6.2 - Variação da condutividade do óleo em função da temperatura.

E sabe-se também que 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, 1999).

A literatura indica que há possibilidade de se obter relações entre as características físico-químicas e cromatográficas. Porém, por não se dispor de uma forma clássica para estabelecer

tais relações, a aplicação de métodos baseados em inteligência computacional, mais especificamente as redes neurais artificiais, podem resultar na obtenção de características que tragam um melhor entendimento acerca da dinâmica que envolve o comportamento do isolamento líquido do transformador (IMAMURA *et al.*, 2000).

6.2 ESTIMAÇÃO DOS GASES DISSOLVIDOS UTILIZANDO REDE NEURAL ARTIFICIAL

Para a estimação dos gases dissolvidos no óleo do transformador a partir de análise físico-química e utilizando redes neurais, duas estruturas, já discutidas em capítulos anteriores, podem ser projetadas: MLP com treinamento Levenberg-Marquardt e RBF com estratégia RBF Incremental.

Considerando os resultados obtidos por Paraskevas *et al.* (2006), foram definidas as características físico-químicas que influenciam na qualidade do óleo isolante. O vetor de entrada a ser aplicado às redes neurais é constituído dos seguintes elementos: acidez, rigidez dielétrica, teor de água, tensão interfacial, densidade e fator de potência do óleo. Por consequência, a camada de entrada da rede foi projetada com o número de neurônios igual ao número de atributos formando o vetor de entrada da rede. Vale ressaltar a importância do 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 obter 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 (H₂), monóxido de carbono (CO), dióxido de carbono (CO₂), metano (CH₄), etano (C₂H₆), etileno (C₂H₄) e acetileno (C₂H₂). 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, estas 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 a partir das análises físico-químicas e cromatográficas demonstradas no Apêndice B.

6.2.1 Projeto de Redes Neurais MLP – Treinamento Levenberg-Marquardt

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 é baseada no índice de acerto no conjunto de dados de validação. O treinamento é interrompido no caso do erro de validação ser incrementado por 5 validações consecutivas. O número máximo de épocas possíveis, outro critério de parada do treinamento, é fixado em 30.000 iterações.

Baseado nas redes projetadas nos capítulos anteriores, 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.

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.

A estratégia do algoritmo RBF incremental é caracterizada pela redução da função de *performance* durante o processo de treinamento. Isto se deve ao acréscimo de novos neurônios no espaço de entrada dependendo dos índices de desempenho.

Dessa forma, a cada iteração os neurônios da camada de base radial promovem deslocamentos no espaço vetorial de entrada em direção ao vetor de entrada com o objetivo de melhorar os percentuais de acerto.

6.3 DEFINIÇÃO DOS ATRIBUTOS FÍSICO-QUÍMICOS MAIS INFLUENTES NA ESTIMAÇÃO DO 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, utiliza-se um algoritmo conhecido por busca exaustiva que seleciona os atributos de melhor potencial de predição relacionados a um sistema adaptativo de inferência *neuro-fuzzy* (ANFIS - Adaptive Neuro-Fuzzy Inference

Systems). Este algoritmo é apresentado pela MathWorks no algoritmo de demonstração *Car mileage prediction with ANFIS* que faz parte do *toolbox* de *Fuzzy Systems* do Matlab 6.5 Release 13 (2002).

Este tipo de sistema de inferência usa uma série de dados de entrada e saída para construir um sistema nebuloso, onde as funções de pertinência são ajustadas sob o uso de algoritmo *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 técnicas de identificação de sistemas com parametrização. 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; JANG; SUN, 1995).

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 nebuloso e a saída determinada nos dados de treinamento em cada época, de acordo com a equação 6.1, tal que.

$$e_j(t) = d_j(t) - y_j(t) \quad (6.1)$$

onde e_j representa o sinal de erro do j -ésimo ANFIS, ou seja, a diferença entre a saída desejada d_j e a saída atual y_j e t é o número da iteração de treinamento.

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 representativa 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 estimativa.

6.3.1 Atributos Mais Influentes

A aplicação do algoritmo de busca exaustiva para definição da entrada mais influente no hidrogênio dissolvido obteve a seguinte composição de modelos ANFIS:

Tabela 6.1 - Resultado da busca exaustiva - Hidrogênio.

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

Da tabela 6.2, 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 sobre-ajuste. Também, a princípio, o atributo teor de água pode aperfeiçoar a estimativa, mas com perda de generalização. A partir dessa tendência de aumento do erro de validação, não é mais vantajoso acrescentar entradas.

Seguindo o mesmo algoritmo apresentado para o hidrogênio, a busca exaustiva foi aplicada para monóxido e dióxido de carbono, metano, etileno, etano e acetileno. Os resultados seguem nas tabelas 6.3 a 6.14.

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

Modelo ANFIS – Entrada	Erro de Treinamento	Erro de 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

Tabela 6.4 - Atributos mais influentes - Monóxido de Carbono.

Modelo ANFIS – Entrada	Erro de Treinamento	Erro de Validação
Fator de Potência – Densidade	218,31	254,03
Fator de Potência – Tensão Interfacial – Densidade	172,85	531,86

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

Modelo ANFIS – Entrada	Erro de Treinamento	Erro de 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

Tabela 6.6 - Atributos mais influentes - Dióxido de Carbono.

Modelo ANFIS – Entrada	Erro de Treinamento	Erro de Validação
Tensão Interfacial – Densidade	1833,80	2413,57
Rigidez Dielétrica – Tensão Interfacial – Densidade	1588,79	2706,55

Tabela 6.7 - Resultado da busca exaustiva - Metano.

Modelo ANFIS – Entrada	Erro de Treinamento	Erro de 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

Tabela 6.8 - Atributos mais influentes - Metano.

Modelo ANFIS – Entrada	Erro de Treinamento	Erro de Validação
Fator de Potência – Densidade	27,61	38,62
Fator de Potência – Densidade – Rigidez Dielétrica	23,20	77,73

Tabela 6.9 - Resultado da busca exaustiva - Etileno.

Modelo ANFIS - Entrada	Erro de Treinamento	Erro de 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

Tabela 6.10 - Atributos mais influentes - Etileno.

Modelo ANFIS – Entrada	Erro de Treinamento	Erro de Validação
Fator de Potência – Tensão Interfacial	37,27	57,55
Fator de Potência – Tensão Interfacial – Rigidez Dielétrica	32,87	101,71

Tabela 6.11 - Resultado da busca exaustiva - Etano.

Modelo ANFIS - Entrada	Erro de Treinamento	Erro de 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

Tabela 6.12 - Atributos mais influentes - Etano.

Modelo ANFIS – Entrada	Erro de Treinamento	Erro de Validação
Fator de Potência – Densidade	36,99	32,88
Fator de Potência – Densidade – Rigidez Dielétrica	25,82	69,54

Tabela 6.13 - Resultado da busca exaustiva - Acetileno.

Modelo ANFIS - Entrada	Erro de Treinamento	Erro de 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

Os resultados referentes ao acetileno revelam muita tendência ao *overfitting*, provavelmente devido à carência de dados. A estratégia com modelo ANFIS 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 é demonstrada na tabela 6.14.

Tabela 6.14 - Atributos mais influentes - Acetileno.

Modelo ANFIS – Entrada	Erro de Treinamento	Erro de Validação
Rigidez Dielétrica – Densidade	159,03	255,92
Tensão Interfacial – Densidade – Rigidez Dielétrica	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 para o acetileno.

6.4 ANÁLISE DOS RESULTADOS

A partir do banco de dados de análises cromatográficas e físico-químicas foram utilizadas 251 amostras, dispostas no Apêndice B, 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 Treinamento	Número 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 Incremental	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 Incremental	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 Incremental	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 Levenberg-Marquardt da MLP apresenta alto grau de acerto nas séries de treinamento, validação e teste. Os melhores desempenhos são alcançados com o uso de 2 atributos físico-químicos como entradas, tendo vantagem, inclusive, como algoritmo menos complexo.

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

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 6.16 a 6.21 apresentam os resultados para as estimativas dos demais gases. É indicada a rede neural menos complexa e de eficiência considerável.

Tabela 6.16 - Percentual de acerto das redes neurais na estimativa do Monóxido de Carbono.

Algoritmo de Treinamento	Número 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 Incremental	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 Incremental	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 Incremental	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 Treinamento	Número 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 Incremental	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 Incremental	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 Incremental	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 Treinamento	Número 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 Incremental	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 Incremental	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 Incremental	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 Treinamento	Número 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 Incremental	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 Incremental	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 Incremental	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 Treinamento	Número 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 Incremental	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 Incremental	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 Incremental	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 Treinamento	Número 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 Incremental	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 Incremental	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 Incremental	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 menos complexa para a rede neural (2 atributos físico-químicos como entradas) e 5 neurônios na camada escondida. A estrutura MLP com treinamento Levenberg-Marquardt aparece 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 não foi satisfatória, em torno de apenas 60% de acerto. Pode-se supor que a representatividade dos dados disponíveis é a causa para estes resultados. Não há uma variação 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 amenizar a situação.

Para os 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.

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 neurais.

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 satisfatórios permitindo a identificação dos parâmetros dos ensaios físico-químicos mais influentes na condição de gases dissolvidos no óleo. A maior parte das estimações apresentou resultados satisfatórios 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 de menor influência.

Em termos de complexidade de estrutura da rede neural, conclui-se que redes MLP com apenas uma camada escondida formada por 5 neurônios é a menos complexa para a tarefa de estimação dos gases dissolvidos no óleo sem comprometimento da eficiência da tarefa.

É evidente a alta eficiência na estimação do hidrogênio, monóxido e dióxido de carbono e metano. O hidrogênio e o 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 as falhas térmicas no transformador amostrado.

Pelo mesmo fato, é explicada a baixa qualidade da estimação dos gases mais pesados, tais 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. Surge a possibilidade da instituição de critérios preventivos acerca da degradação do óleo e das falhas incipientes em transformadores.

A partir das implementações apresentadas pode-se concluir que 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.

Um sistema computacional comportando os algoritmos de monitoramento, diagnóstico e estimação dos gases dissolvidos é o tema do próximo capítulo.

CAPÍTULO 7 - SISTEMA COMPUTACIONAL PARA MONITORAMENTO E DIAGNÓSTICO DO ÓLEO ISOLANTE DE TRANSFORMADORES

Na ocorrência de alguns sinais de problemas, tais como alarme de relé de gás Buchholz e proteção diferencial, se faz necessário disponibilizar para a operação e manutenção informações precisas sobre o transformador de potência para que a falha ou falhas que ocasionaram os alarmes sejam identificadas com maior precisão pela operação e manutenção e decisões eficientes sejam tomadas.

Neste capítulo apresenta-se um sistema para o monitoramento e diagnóstico de transformadores de potência. A seção 7.1 apresenta a interface com o operador. A seção 7.2 trata do 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 descreve-se o desenvolvimento da estrutura do aparato computacional. Algumas aplicações e seus respectivos resultados estão descritos na seção 7.5. Os comentários conclusivos deste capítulo estão 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 implementadas em uma plataforma computacional, proporcionam um ambiente de confiabilidade e continuidade de operação em torno do equipamento.

O sistema constituído de *software* e *hardware* desenvolvido nesta dissertação é capaz de identificar falhas térmicas e elétricas nas partes ativas de um transformador em operação de forma antecipada, superando os resultados dos gases separados no relé Buchholz que, usualmente, assume somente uma função de sensor e proteção do equipamento (VARL, 2002).

O desenvolvimento de sistemas com este enfoque tem sido acentuado 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 grande quantidade de fontes de medição e do amplo número de unidade monitoradas. Esta característica reforça a aplicação de métodos inteligentes no projeto de sistemas computacionais para o gerenciamento do monitoramento e diagnóstico de transformadores (SHENCK *et al.*, 2002).

O sistema computacional implementado gerencia todas as análises dos dados com utilização de 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. 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 tem o objetivo de acompanhar a evolução dos dados de interesse do equipamento visando diminuir a saída de operação não planejada aumentando os índices de confiabilidade do sistema. Isto se dá através da detecção antecipada de falhas incipientes e o monitoramento do avanço das situações de falha.

Para se obter resultados satisfatórios no gerenciamento da disponibilidade e extensão da vida útil do transformador é necessário que os sistemas de monitoramento sejam equipados com tecnologias atuais de sensores e atuadores (GIBEAULT; KIRKUP, 1995).

Com o avanço tecnológico das últimas décadas, tornou-se comum, atualmente, a utilização de equipamentos para monitoramento e diagnóstico *on-line*. Algumas combinações com métodos *off-line* são também encontradas e têm sua importância para um sistema de diagnóstico.

Os gases mais comuns que denunciam falhas no dielétrico do transformador, através da aplicação de DGA, são hidrogênio (H₂), etano (CH₄), acetileno (C₂H₂) e etileno (C₂H₄). Com presença de monóxido de carbono (CO) e dióxido de carbono (CO₂) 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 pouco acima das normais.

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. A evolução na geração dos referidos gases e a característica do mecanismo de decomposição térmica do óleo a partir de uma sobrecarga são mostrados nas figuras 7.1 e 7.2, respectivamente.

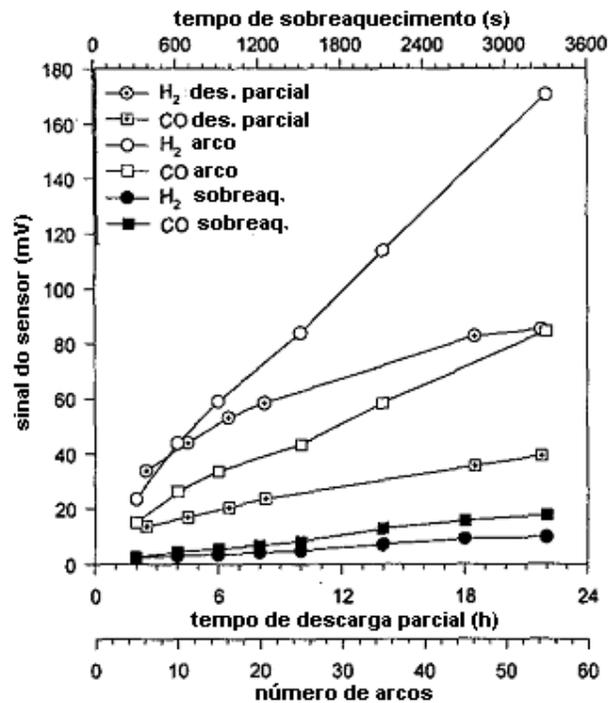


Figura 7.1 - Evolução de hidrogênio e monóxido de carbono na presença de condições de falhas típicas.

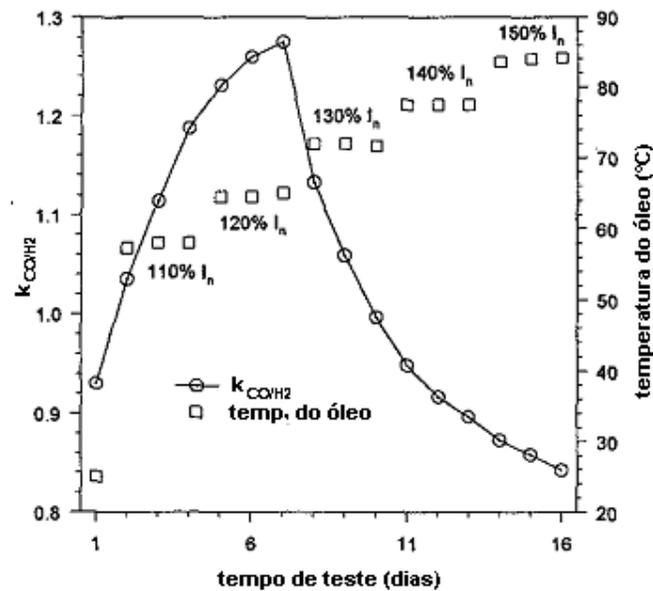


Figura 7.2 - Evolução de hidrogênio e monóxido de carbono durante teste de sobrecarga.

O uso de monitoramento *on-line* tem impacto direto na 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

No módulo de diagnóstico desenvolvido, utilizaram-se técnicas de inteligência computacional para a identificação e classificação das falhas incipientes, 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. Os dois primeiros são abordados em Almeida *et. al* (2007b) enquanto a aplicação das redes neurais é descrita no capítulo 4.

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.

A verificação da condição de detecção de falhas incipientes que define uma condição de normalidade ou não é realizada a partir 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 o algoritmo proposto é executado.

Devido à forma de elaboração dos métodos de identificação, a interpretação das análises cromatográficas dos gases pelos algoritmos somente são realizados quando existe a possibilidade de falhas. Caso contrário, julga-se que a condição de degradação é 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, 1991; IEC, 1999; ABNT, 1982) que traz uma representatividade do conhecimento na área de diagnóstico de falhas incipientes. Este conhecimento não pode ser desprezado por ser de comprovada validade frente a inúmeras inspeções em transformadores.

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 condições 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 ($T < 150^{\circ}\text{C}$), 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.

A aplicação de sistemas nebulosos na identificação de falhas, conforme apresentado em Almeida *et al.* (2007a) e Almeida *et al.* (2007b), aproveita vantagens residentes na capacidade de manipulação de informações imprecisas e incompletas. Esta característica permite a utilização, na rotina de decisão, do 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 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 leva em conta a 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 possui tamanho suficiente para o trabalho de modelagem do problema. 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.

Desde que vários métodos são executados em paralelo, o valor de diagnóstico final unifica os resultados dos 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).

Na rotina de desempate um valor de confiança, entre 0 e 1, é proposto para as saídas dos métodos implementados e diagnóstico final. Devido a erros envolvendo problemas de não decisão e a tendência do 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 p.p.m. 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 partir das análises físico-químicas, implementou-se algoritmo capaz de indicar de forma mais acurada problemas relacionados com a qualidade dielétrica do líquido isolante do transformador. O uso de sistemas computacionais para implementar este tipo de diagnóstico é uma forma de aumentar a confiabilidade na análise (WANG, 2000; WARD; LINDGREN, 2000). Com os resultados do diagnóstico, o programa computacional disponibiliza uma série de recomendações preventivas visando manter as características do sistema isolante e conseqüentemente a vida útil do transformador (WANG *et al.*, 2002).

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 as informações importantes para um diagnóstico confiável de forma que, na saída, são listados procedimentos de manutenção como recondicionamento por termo-vácuo, regeneração por filtragem, reamostragem imediata e reamostragem em um ano no caso de normalidade. A recomendação de regeneração por filtragem ocorre com tratamento químico com meio básico, por exemplo, metassilicatos, ou tratamento com meio absorvente sólido, por exemplo, argilas ou carvão ativado.

A tabela 7.1 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 obter recomendações para a manutenção (WEG, 2004).

Tabela 7.1 - Guia de verificação das condições do óleo isolante.

Tg a 90° C (%) ou FP a 100° C (%) (fator de perdas dielétricas a 90° C 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 do 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 do óleo
				Não atende	-	Regeneração ou troca do óleo
		Não atende	Não 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

O algoritmo desenvolvido neste trabalho pode ser integrado a monitores tais como o Centurion®, que é um sistema de monitoramento de qualidade do óleo, de forma que é possível projetar um sistema integrado de monitoramento *on-line* para a qualidade do óleo isolante. O Centurion® atua na verificação da rigidez dielétrica diagnosticando o grau de pureza do óleo. O monitoramento *on-line* da rigidez dielétrica pode servir 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 em casos mais críticos.

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, desenvolveu-se um método de estimação da concentração dos gases dissolvidos para possibilitar o diagnóstico de falhas incipientes sem a necessidade da obtenção das concentrações 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 incipientes.

As entradas da rotina de implementação do método proposto 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, dado que não se dispunha de dados de análises físico-químicas e cromatográficas contemporâneas em número suficiente, o treinamento do sistema para a estimação do etano e acetileno foi comprometido. Torna-se necessária uma melhor base de dados para complementar a estimação.

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.

7.4 DESENVOLVIMENTO DO SISTEMA COMPUTACIONAL

O sistema computacional desenvolvido apresenta telas gráficas para interação homem-máquina contendo os comandos, as entradas de dados, o resultado das análises e a implementação dos algoritmos propostos. Estes resultados podem ser expressos através de gráficos, barras animadas ou textos mediante relatórios contendo os diagnósticos e as recomendações pertinentes.

Para o monitoramento, o módulo foi integrado a um 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 do óleo isolante.

A ferramenta computacional emite 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 e possuem quatro níveis de gravidade.

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. Os 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.

Tabela 7.2 - Níveis de alarmes disponíveis no Hydran® M2.

Fonte de Alarme	Níveis de Alarme			
Gás	-	-	Alto	Alto-Alto
Umidade	-	-	Alto	Alto-Alto
Entr. Analógica	Baixo-Baixo	Baixo	Alto	Alto-Alto
Temp. sensor Hydran	-	Baixo	Alto	-
Bateria	Baixo-Baixo	Baixo	-	-

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 7.3 apresenta a tela principal do módulo de monitoramento.

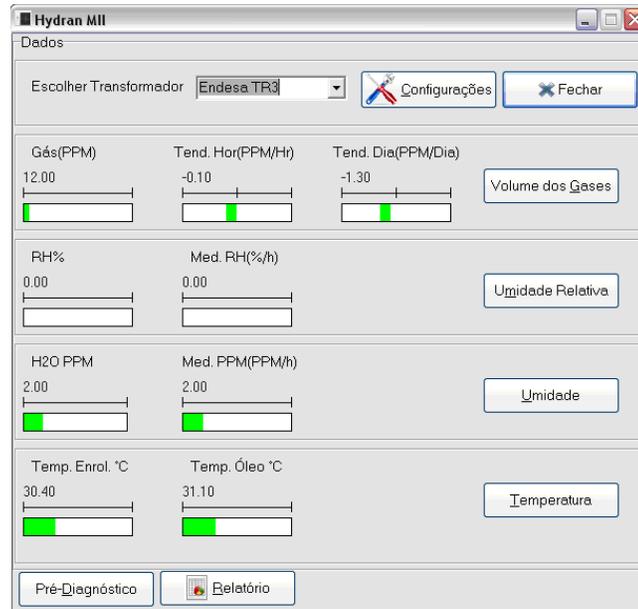


Figura 7.3 - Tela principal módulo de monitoramento.

A unidade de configuração é utilizada para estabelecer os níveis de alarme de sistemas de monitoramento. Caso seja configurado um limite de alarme para valores das grandezas 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 sistema executa as rotinas de diagnóstico e os resultados podem ser acompanhados por visualização em tempo real, conforme demonstrado na figura 7.4.

Concentração dos Gases em ppm					
H2	6	CO	191	C2H2	0
O2	4462	CO2	1092	C2H4	2
N2	18651	CH4	4	C2H6	1
Total de Gases	24409	Total Gases Combustíveis	204		

Figura 7.4 - Tela do módulo de diagnóstico de falhas incipientes.

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, conforme ilustrado na figura 7.5.



Figura 7.5 - Tela de gráfico da evolução dos gases.

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

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

7.5 EXEMPLO DE APLICAÇÃO

Algumas aplicações do sistema Hydran® M2 são colocadas para demonstrar a importância do equipamento quanto à proteção do transformador. Na literatura são relatados casos de sucesso de aplicação do Hydran® M2 (GIBEAULT; KIRKUP, 1995; VARL, 2002; ZYLKA; MAZUREK, 2002).

Neste estudo, o Hydran® M2 foi aplicado no monitoramento *on-line* de um transformador de 140 MVA, 230 kV da CGTF Endesa Fortaleza, Ceará.

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

Tabela 7.3 - Monitoramento on-line transformador 140MVA.

Gases		Máximo de Valores		6/11/02	3/7/03	7/7/03	15/4/04	17/8/04	25/2/05	25/5/05	8/12/05	24/3/06	19/10/06
		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
Monóxido de Carbono	CO	15	350	11	12	27	139	144	162	162	41	166	193
Dióxido 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		96,7	3.220,0	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 Combustíveis		26,7	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

Pode-se notar que, a leitura do monitor acompanha o crescimento da produção dos gases de forma que o monitoramento é 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, acionaria a execução dos algoritmos de diagnóstico de falhas incipientes. Os diagnósticos apresentariam, então, os seguintes resultados:

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

Método	Diagnóstico	G. de Confiança
Convencional	Não-decisão	0,3
Sistema Nebuloso	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 desenvolvido foi, então, comparado com os resultados obtidos da aplicação da guia fornecida pelos fabricantes, conforme mostrado na tabela 7.5 para as análises feitas no transformador objeto do estudo.

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

A operação e manutenção são atividades consideradas de importância vital para manter um sistema elétrico. Para auxiliar nessas atividades com eficiência, muitos programas de manutenção têm sido desenvolvidos com o objetivo de atender uma série de exigências e restrições inerentes aos avanços na área. Atualmente, os conceitos de manutenção desempenham um papel mais participativo e passam a prezar pelo auxílio de ferramentas computacionais em conjunto com novos princípios de aplicação.

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 contribuir 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 para uma região.

Os benefícios do monitoramento e da detecção antecipada de falhas internas são satisfatórios e a cada dia mais 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 importantes 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.

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. Em casos de transformadores com cenário de gases dissolvidos implicando alto grau de probabilidade de falhas este tipo de monitoramento é prioritariamente indicado.

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 uso das informações e na aplicação das normas pertinentes, pois os resultados alcançados superam os advindos das normas.

Os resultados alcançados provêm de aplicações das técnicas de inteligência artificial, em especial, métodos de redes neurais artificiais que realizam com eficiência o reconhecimento de padrões e o mapeamento dos dados.

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 íntegras para a operação. E ainda, acompanhando a evolução das condições de modo contínuo.

CAPÍTULO 8 - CONCLUSÃO

A idéia de monitorar, detectar e identificar as condições de envelhecimento e degradação do isolamento de transformadores foi sistematicamente estudado nesta dissertação. Este assunto tem sido tratado com maior intensidade e começa a fazer parte da estratégia de operação e manutenção de transformador.

Isto representa um incremento nos índices de confiabilidade e valorização dos ativos dos 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, o sistema é capaz de emitir alertas antecipando o diagnóstico de falha. Isto possibilita que as equipes de operação e manutenção antecipem a tomada das providências adequadas. Aliando um equipamento de monitoramento *on-line* ao algoritmo de pré-diagnóstico desenvolvido, foram obtidos resultados satisfatórios na predição de situações de falhas. Além disso, foi proporcionada redução nos insumos de contratação de seguro das unidades monitoradas.

Na implementação do módulo de diagnóstico de falhas incipientes, comparou-se os resultados de duas redes neurais projetadas para se chegar à melhor composição. Satisfatoriamente, o diagnóstico de falhas incipientes via redes neurais com estrutura do tipo MLP e treinamento com algoritmo Levenberg-Marquadt apresentou melhor índice de acerto que através do treinamento *Adaptive Back-Propagation*.

O treinamento com a otimização de Levenberg-Marquardt, que possui característica de convergência rápida devido ao uso das informações da curvatura da superfície de erro e não somente do gradiente, apresentou os melhores resultados e por isto foi utilizado no módulo de diagnóstico de falhas incipientes.

A aplicação de redes neurais proporcionou a solução do problema da não-decisão. O problema de não-decisão é crítico quando métodos convencionais são aplicados no diagnóstico de falhas.

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 velocidade, eficiência e simplicidade das redes neurais MLP e RBF. Diante dos resultados, a rede MLP foi preferida por apresentar estrutura simples para o algoritmo de diagnóstico do estado do óleo.

O sistema, portanto, permite o acompanhamento das características físico-químicas que exercem influência na característica dielétrica do óleo do transformador.

Nesta dissertação, verificou-se a existência do relacionamento entre as grandezas dos 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, tais como acidez, rigidez dielétrica, teor de água, tensão interfacial, densidade e fator de potência do óleo.

Isto é relevante desde que torna possível acompanhar a evolução dos gases dissolvidos sem a realização de uma cromatografia completa, que em muitos casos é uma facilidade conveniente, devido à simplicidade de execução dos testes físico-químicos quando comparados aos cromatográficos.

Os resultados foram implementados em uma plataforma computacional de característica modular. A plataforma foi composta dos seguintes módulos: módulo de monitoramento da evolução dos gases de falha, módulo detector e identificador de falhas incipientes, módulo de diagnóstico da qualidade do óleo, módulo de estimação dos gases dissolvidos a partir dos atributos físico-químicos. Além dos módulos de suporte para configuração e manipulação de banco de dados e comunicação com os equipamentos de monitoramento.

8.1 DESENVOLVIMENTOS FUTUROS

Seguem algumas sugestões para trabalhos de pesquisa e desenvolvimentos futuros com objetivo 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 e/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 absorbância através de espectrofotometria ultravioleta para aumentar a eficiência do diagnóstico da integridade do óleo isolante.
- Obtenção de dados mais completos sobre etano e acetileno ou utilização de técnicas que permitam uma boa estimação do etano e do acetileno, mesmo sem uma coleção de dados representativos, tal como o *Support Vector Machine*.
- 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.

REFERÊNCIAS BIBLIOGRÁFICAS

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. NBR 5356: Transformador de Potência. Rio de Janeiro, RJ, 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, RJ, 1981.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. NBR 7274: Interpretação da Análise dos Gases de Transformadores em Serviço. Rio de Janeiro, RJ, 1982.

ALMEIDA, O. M.; BARBOSA, F. R.; AMORA, M. A. B.; BRAGA, P. R. O. Diagnóstico de Transformadores Utilizando Monitoramento On-line. Anais do XII ERIAC - Encontro Regional Ibero-Americano do CIGRÈ, Foz do Iguaçu, PR, 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. Anais do IV CITENEL - Congresso de Inovação Tecnológica em Energia Elétrica, 2007, Araxá, MG, 2007b.

BAUGH, P. J. Gas Chromatography: a Practical Approach. Oxford University, New York, NY, USA, 1993.

BENGTSSON, C. Status and Trends in Transformer Monitoring. IEEE Transactions on Power Delivery, vol. 11, no. 3, pp. 1379-1384, 1996.

BETTA, G.; PIETROSANTO, A.; SCAGLIONE, A. An Enhanced Fiber-Optic Temperature Sensor System for Power Transformer Monitoring. Instrumentation and Measurement, IEEE Transactions on vol. 50, no. 5, pp. 1138-1143, 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 – Programa de Pós-Graduação em Metrologia Científica e Industrial, Florianópolis, SC, 2005.

CARGOL, T. A Overview of On-Line Oil Monitoring Technologies. Fourth Annual Weidmann-ACTI Technical Conference, San Antonio, USA, 2005.

CAVALEIRO, P. M.; ARAÚJO, F. M.; FERREIRA, L. A.; SANTOS, J. L.; FARAHI, F. Simultaneous Measurement of Strain and Temperature Using Bragg Gratings Written in Germanosilicate and Boron-Codoped-Germanosilicate Fibres, IEEE Photonics Technology Letters, vol. 11, no. 12, pp. 1635-1637, 1999.

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, USA, 1999.

COLAÇO, D. F.; de ALEXANDRIA, A. R.; CORTEZ, P. C.; FROTA, J. B. B.; de LIMA, J. N.; CALAZANS, A. E. A. L.; FAÇANHA, F. A. Sistema de Monitoramento de Chaves Seccionadoras por Visão Computacional e Redes Neurais Artificiais para Suporte ao Sistema de Controle Supervisório da CHESF. Anais do IV CITENEL - Congresso de Inovação Tecnológica em Energia Elétrica, 2007, Araxá, MG, 2007.

CYBENKO, G. Approximation by Superpositions of a Sigmoid Function. Mathematics of Control, Signals and Systems, vol. 2, no. 4, p. 303-314, 1989.

DERVOS, C.T.; PARASKEVAS, C. D.; SKAFIDAS, P.; VASSILIOU, P. Dielectric Characterization of Power Transformer Oils as a Diagnostic Life Prediction Method, IEEE Electr. Insul. Mag., vol. 21, no. 1, pp.11-19, 2005.

DÖRNENBURG, E.; GERBER, O. E. Analysis of Dissolved and Free Gases for Monitoring Performance of Oil-Filled Transformers. The Brown Boveri Review, vol. 54 no. 213, pp. 104-111, 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.

DUKARM, J. J.; LANE, J. Transformer Maintenance, Electrical Transformer Handbook, Electricity Forum, Vol. 1, pp. 55-57, Canada, 2004

DURASAMY, V.; DEVARAJANB, D.; SOMASUNDARESWARIA, D.; VASANTHB, A. M. ; SIVANANDAMC, S.N. Neuro-nebuloso Schemes for Fault Detection in Power Transformer. Applied Soft Computing vol. 7, no. 2, pp. 534-539, 2007.

FERGUSON, R.; LOBEIRAS, A.; SABOU, J. Suspended Particles in the Liquid Insulation of Aging Power Transformers. IEEE Electrical Insulation Magazine. vol. 18, v. 4, pp. 17-23, 2002.

FREITAS, A. A. C. Redes Neurais Artificiais Aplicadas em Transformadores de Distribuição Imersos em Óleo. Dissertação de Mestrado, UNESP/FE/DEE-Departamento de Engenharia Elétrica, Bauru-SP, 2000.

FRITZKE, B. Fast Learning with Incremental RBF Networks. Neural Processing Letters, vol. 1, no. 1, pp. 2-5, 1994.

GE ENERGY SERVICES. Hydran M2 Fault Gas and Moisture Monitor. Instruction Manual - Quebec, Canada, 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 – Quebec, Canada, pp. 285-293, 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, São Leopoldo, RS, 2005.

HAGAN, M.T.; MENHAJ, M.B. Training Feed-Forward Networks with the Marquardt Algorithm; IEEE Transactions on Neural Networks, vol. 5, no. 6, pp. 989-993, 1994.

HALSTEAD, W.D. A Thermodynamic Assessment of the Formation of Gaseous Hydrocarbons in Faulty Transformers. Journal Institute of Petroleum, vol. 59, no. 9, pp.239-241, 1973.

HAYKIN, S. Redes Neurais: Princípios e Práticas. Trad. Paulo Martins Engel, 2ª ed., Porto Alegre, RS, Bookman, 2001.

HECHT-NIELSEN, R. Neurocomputing, Addison Wesley Publ. Co., New York, NY, USA, 1990.

HUANG, Y.C.; YANG, H.T.; HUANG, C.L. Developing a New Transformer Fault Diagnosis System through Evolutionary Fuzzy Logic. IEEE Transactions on Power Delivery, vol. 12, no.2, pp.761-767,1997.

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. Anais do XIII CONGRESSO BRASILEIRO DE AUTOMÁTICA - CBA 2000, Florianópolis, pp. 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, 1993.

JANG, J. S. R.; Sun, C. T. Neuro-fuzzy Modeling and Control, Proceedings of the IEEE, 1995.

JAZAYERI, P.; ROSEHART, W.; WESTWICK, D. T.; A Multistage Algorithm for Identification of Nonlinear Aggregate Power System Loads; IEEE Transactions on Power Systems, vol. 22, no. 3, pp. 1072-1079, 2007.

KAN, H.; MIYAMOTO, T. Proposals for an Improvement in Transformer Diagnosis Using Dissolved Gas Analysis (DGA). IEEE Electrical Insulation Magazine, vol. 11, no. 6, pp. 15-21, 1995.

KHALIFA, M. High-Voltage Engineering: Theory and Practice, Marcel Dekker Inc., USA 1990.

KOHONEN, T. Self-Organized Formation of Topologically Correct Feature Maps. *Biological Cybernetics*, v. 43, no. 1, p. 59-69, 1982.

KOVACEVIC, S.; 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*. 3ª 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, Blacksburg, Virginia, USA, 2003.

LEITE, C.T.C.; SANTOS, E.P.; PERONDI, E. S.; FONSECA, G.J.F.; AZEVEDO, J.N.; STATERI, L.C.; NARDIN, S.G. Sistema de Informações Gerenciais e Operativas - SIGO. *Anais do IV CITENEL - Congresso de Inovação Tecnológica em Energia Elétrica*, 2007, Araxá, MG, 2007.

LEVENBERG, K. A Method for the Solution of Certain Non-linear Problems in Least Squares. *Quarterly of Applied Mathematics*, vol. 2, no. 2, pp. 164-168, 1944.

LEVY, A. F. S.; CARVALHO, A. T.; AMORIM Jr., H. P.; OLIVEIRA Filho, O.; CARDOSO, J. A. A. S.; NASCIMENTO, L. F. A. Implementação de um Sistema de Medição de Descargas Parciais e Fator de Perdas On-line em Transformadores de Potência na ELETRONORTE. *Anais do IV CITENEL - Congresso de Inovação Tecnológica em Energia Elétrica*, 2007, Araxá, MG, 2007.

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. *Anais do 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. *Anais do Simpósio Brasileiro de Sistemas Elétricos*, 2006, Campina Grande, PB, 2006.

LIMA, S. L.; PEREIRA-NETO, A.; SAAVEDRA, O. R.; ROSA FILHO, R. N.; FERNANDES, O. A.; de SOUZA, A. N. VITRAN: Sistema Computacional para a Avaliação das Condições de Carga Admissíveis e Perda de Vida Útil de Transformadores de Dois e Três Enrolamentos. Anais do IV CITENEL - Congresso de Inovação Tecnológica em Energia Elétrica, 2007, Araxá, MG, 2007.

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 - Departamento de Energia Elétrica, Fortaleza, CE, 2005.

LIN, C. E.; LING, J. M.; HUANG, C. L. An Expert System for Transformer Fault Diagnosis Using Dissolved Gas Analysis. IEEE Transactions on Power Delivery, vol. 8, no. 1, pp.231-238, 1993.

LOBO, A. B. R.; SANTOS, J. L.; BAPTISTA, J. M.; FERREIRA, L. A.; ARAÚJO, F. M., LEITE, A. P. Optical Fiber Sense Technology in Portugal, Fiber and Integrated Optics, vol. 24, no. 3 & 4, pp. 171-199, 2005.

LUMASENSE Technologies e T&D World Magazine. Web Seminar. Disponível em: www.electricityforum.com. Acessado em: Junho de 2007, 2007.

MAK, J.; MACIEL, R. L.; FRANCHINI, L. R.; VASCONCELLOS, V. Transformador de Distribuição de Maior Vida Útil e Menor Agressividade Ambiental. Anais do IV CITENEL - Congresso de Inovação Tecnológica em Energia Elétrica, 2007, Araxá, MG, 2007.

MARQUARDT, D. W.; An Algorithm for Least-squares Estimation of Nonlinear Parameters, SIAM Journal on Applied Mathematics, vol.11, no. 12, pp. 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, Anais do 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, SP, 1984.

MIRANDA, V.; CASTRO, A. R. G. Improving the IEC Table for Transformer Failure Diagnosis with Knowledge Extraction from Neural Networks. *IEEE Transactions on Power Delivery*, vol. 20, no. 4, pp. 2509-2516, 2005.

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*, Waterloo, Canada, 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. *Anais do XVII CBA - Congresso Brasileiro de Automática*, 2004, Gramado, RS, pp. 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, SC, 2004.

MORAIS, D. R.; ROLIM, J. G. A hybrid tool for detection of incipient faults in transformers based on the dissolved gas analysis of insulating oil, *IEEE Transactions on Power Delivery*, vol. 21, no. 2, pp. 673-680, 2006.

NEPOMUCENO, L X. *Técnicas de Manutenção Preditiva*, vol. 2. Edgard Blücher, São Paulo, SP, 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, SC, 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*, pp. 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, *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 13, no. 3, pp. 539-546, 2006.

PATEL, N. K.; KHUBCHANDANI, R. K. ANN Based Power Transformer Fault Diagnosis. IE Journal, [S.l.], vol. 85, no. 1, p. 60-63, June, 2004.

PEYRAQUE, L.; BEROUAL, A.; BURET, F. Static Electrification of Pressboard/Oil Interface and Transient Phenomena. IEEE Transactions on Dielectrics and Electrical Insulation, vol. 5, no. 3, pp. 443-449, 1998.

PRADHAN, M. K. Assessment of the Status of Insulation during Thermal Stress Accelerated Experiments on Transformer Prototypes. IEEE Transactions on Dielectrics and Electrical Insulation, vol.13, no.1, pp. 227-237, 2006.

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, vol. PAS-99, no. 2, pp. 695-702, 1980.

ROUSE T. O. Mineral Insulating Oil in Transformers, IEE Electrical Insulation Magazine, vol. 14, no. 3, pp. 6-16, 1998.

RUMMELHART, D., HINTON, W. Learning Internal Representations by Error Propagation. In: Parallel Distributed Processing - MIT Press, Cambridge, MA, 1986.

SAHA, T. K. Review of Modern Diagnostic Techniques for Assessing Insulation Condition in Aged Transformers. IEEE Transactions on Dielectrics and Electrical Insulation, vol. 10, no. 5, pp. 903-917, 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, London, UK, pp 1-7, 1994.

SCHENK, A.; NATALE, S.; GERMOND, A. Transformer State Assessment: Self-Organizing Maps as an Intelligent Online Data Processor Presented at: CIGRÈ, Paris, France, 2002.

SIEROTA, A.; RUNGIS, J. Charaterization and Pre-treatment of New Transformer Oils. IEEE Electrical Insulation Magazine, vol. 11, no. 1, pp. 8-20, 1995.

TENBOHLEN, S.; FIGEL, F. On-line Condition Monitoring of Power Transformers. IEEE Power Engineering Society Winter Meeting, vol. 3, no. 23-27, 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, vol. 1, pp. 541- 544, 2002.

THANG K. F.; AGGARWAL, R. K.; McGRIL, A. J; ESP D. G. Analysis of Power Transformer Dissolved Gas Data Using the Self-Organizing Map. IEEE Transactions on Power Delivery, vol. 18, no. 4, pp. 1241-1248, 2003.

THE ELECTRICITY FORUM By Department of the Interior; Bureau of Reclamation; Hydroelectric Research; Technical Services Group. Transformer Maintenance, Electrical Transformer Handbook, Electricity Forum, Vol. 2, pages 25-64, Canada, 2005.

VALIN, S. Transformer moisture measurement gain status as transformers age, Electrical Transformer Handbook, Electricity Forum, Vol. 1, pages 58-59, Canada, 2004.

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 Nebuloso para Diagnóstico de Transformadores de Potência. Anais do VII SEPOPE - Symposium of Specialists in Electric Operational and Expansion Planning, Curitiba, PR, 2000.

VARL, A. On-line Diagnostics of Oil-filled Transformers. Milan Vidmar Electrical Power Research Institute, In: Dielectric Liquids, 2002. Proceedings of IEEE 14th International Conference on Publication, Ljubljana, Slovenia, pp. 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. IEEE Electrical Insulation Magazine, vol. 18, no. 6, pp. 12-25, 2002.

WANG, X.; LI, B.; ROMAN, H. T.; RUSSO, O. L.; CHIN, K.; FARMER, K. R. Acoustic-optical PD Detection for Transformers, IEEE Transactions Power Delivery, vol. 21 no. 3, pp. 1073, 2006.

WANG, Z. Artificial Intelligence Applications in the Diagnosis of Power Transformer Incipient Faults. PhD Thesis, Virginia Polytechnic Institute and State University, Blacksburg, USA, 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 IEEE International Symposium on 2000; pp. 141-147 Anaheim, CA, USA, 2000.

WEG. Manual de Instalação e de Manutenção de Transformadores. Catálogo. 16 p. Blumenau, 2004.

ZAENGL, W. S. Dielectric Spectroscopy in Time and Frequency Domain for HV Power Equipment, Part I: Theoretical Considerations, IEEE Electrical Insulation Magazine vol. 19, no. 5, pp 5-19, 2003.

ZHANG, Y. An Artificial Neural Network Approach to Transformer Fault Diagnosis, Thesis, Virginia Tech, Blacksburg, USA, 1996.

ZHU, D.; TAN, K.; WANG, C.; JIN, X. Computer-aided On-line Detection of Partial Discharge in Power Transformer, In: Properties and Applications of Dielectric Materials, Proceedings of the 3rd International Conference on Date: 8-12 Jul 1991; pp. 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, pp. 318-331, 2005.

ZYLKA, P.; MAZUREK, B. Rapid Dissolved Gas Analysis by Means of Electrochemical Gas Sensors. In: Dielectric Liquids, Proceedings of IEEE 14th International Conference on Wroclaw University of Technology, Poland, pp. 325-328, 2002.

APÊNDICE A - REDES NEURAIS ARTIFICIAIS

A Rede Neural Artificial (RNA) é uma estrutura baseada em unidades de processamento capazes de realizar um mapeamento do universo de dados a que esta estrutura é previamente apresentada. O universo de dados, denominado de padrões de treinamento, representam o mapeamento que a rede deve ser capaz de modelar.

A.1 NEURÔNIOS ARTIFICIAIS

Os neurônios artificiais foram inspirados nos neurônios biológicos. McCulloch e Pitts em 1943 propuseram o primeiro modelo matemático de um neurônio, mostrado na equação A.1.

$$y = \Phi \left(\sum_{i=1}^n w_i \cdot x_i - b \right) \quad (\text{A.1})$$

A função (Φ) é denominada de função de ativação e, neste modelo, é uma função limiar simples. As entradas (x_i) chegam ao neurônio através dos pesos das conexões (w_i). A função de ativação também leva em consideração a polarização (b), valor abaixo do qual a saída é nula.

O neurônio de McCulloch-Pitts é limitado se comparado com a complexidade de um neurônio natural, pois apresenta uma resposta binária (0 ou 1) a uma estimulação da entrada. A figura A.1 ilustra o modelo de McCulloch-Pitts (HAYKIN, 2001).

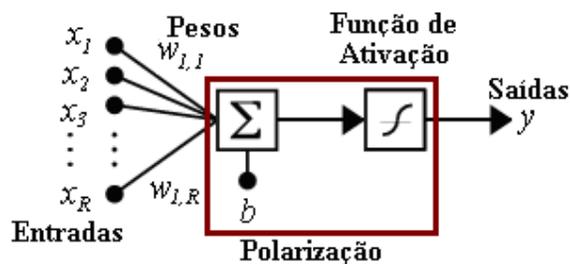


Figura A.1 - Representação do modelo matemático de um neurônio.

De uma forma geral, o neurônio recebe a informação de entrada por uma soma ponderada através dos pesos de cada entrada e faz uso da função de ativação para gerar uma resposta ao estímulo dado pelo padrão de entrada. 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. Dessa forma, o ajuste correto dos pesos é fundamental para que a saída da rede satisfaça o estímulo da entrada.

A função de ativação determina a forma e a intensidade da alteração dos valores transmitidos ao neurônio e algumas funções são, geralmente, selecionadas como função de ativação: a função degrau, a função em rampa limitada, a função logística e a tangente hiperbólica. A figura A.2 ilustra algumas opções de funções utilizadas como função de ativação.

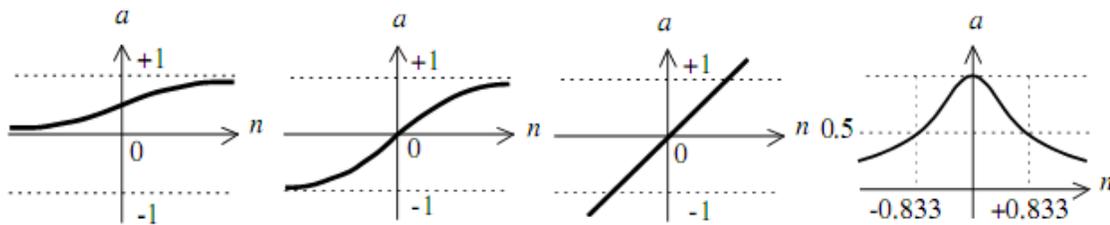


Figura A.2 - Tipos de funções não-lineares utilizadas como função de ativação.

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 a função de ativação $\Phi(v)$. Assim, a função logística da equação (A.2) e a função tangente hiperbólica da equação (A.3) são as formas mais utilizadas por serem simétricas e preservarem características de saturação e monotonicidade na faixa dinâmica.

$$\Phi(v) = \frac{1}{1 + \exp(-av)} \quad (\text{A.2})$$

$$\Phi(v) = \tanh(av) = \frac{1 - \exp(-av)}{1 + \exp(-av)} \quad (\text{A.3})$$

onde $\exp()$ é a função exponencial, v ($-\infty < v < \infty$) é o argumento da função de ativação (somatório ponderado das entradas menos a polarização) e 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 retropropagação 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 A.4 e A.5, por estas possuírem suas derivadas contínuas, tais que

$$\Phi'(v) = a \cdot \Phi(v) \cdot [1 - \Phi(v)] \quad (\text{A.4})$$

$$\Phi'(v) = a \cdot [1 + \Phi(v)] \cdot [1 - \Phi(v)] \quad (\text{A.5})$$

A.2 ARQUITETURA DE RNA

Uma rede neural artificial (RNA) é um sistema composto por neurônios ordenados em camadas interligados através de pesos sinápticos. Estes pesos sinápticos ponderam a ligação entre dois neurônios, ou entre uma entrada e um neurônio assumindo valor mais elevado de acordo com a influência daquela ligação na saída da rede.

A RNA possui neurônios de entrada que recebem os estímulos do meio externo e neurônios de saída que fornecem a resposta da rede. Normalmente é utilizada uma camada entre os neurônios de entrada e saída conhecida como camada oculta ou intermediária (“*hidden*”). O uso da estrutura com camada escondida habilita a RNA a resolver problemas não-linearmente separáveis.

Um tipo de estrutura aplicada é a rede *feed-forward* onde as informações fluem da entrada para a saída da rede, através das conexões, 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.

Para se obter o melhor projeto de RNA, em geral, são realizadas diversas simulações comparando o desempenho da rede para cada variação dos valores dos parâmetros de projeto. A configuração com melhor desempenho nos testes é selecionada para realizar o mapeamento desejado. No entanto, o algoritmo de aprendizagem utilizado e os padrões de dados para o treinamento são fatores de influência sobre o desempenho de uma RNA.

A.3 PADRÕES DE DADOS

Os padrões de dados representam a natureza do problema através da relação mantida entre os vetores de entrada (X) e de saída (Y). Estes padrões são utilizados como ponto de partida para a RNA, mediante procedimento de aprendizagem, ajustar seus pesos de modo a apresentar em sua saída um valor concordante com o padrão de entrada fornecido.

Assim, o aprendizado de uma RNA que os dados utilizados no processo de treinamento sejam representativos do problema em questão. De uma forma geral, o aprendizado da rede é mais eficiente para uma maior quantidade e qualidade dos dados.

Também é levado em consideração o tamanho da amostra a ser utilizada no treinamento, evitando informações repetidas ou que podem ser derivadas de outras. Fundamentalmente, à medida que a complexidade do problema aumenta, a quantidade dos dados também deve aumentar para uma modelagem eficiente por parte da rede neural.

Muitas vezes os elementos do vetor de dados possuem grandezas diferentes representadas em escalas desiguais. Isso pode causar uma polarização indesejada nos valores dos pesos da rede e até mesmo dificultar a convergência do processo de treinamento. Surge a necessidade de se pré-processar os padrões. A normalização é um dos métodos de pré-processamento mais utilizado. A normalização produz uma distribuição estatística uniforme dos valores de entrada colocando os componentes do vetor de entrada numa mesma escala de valores. As técnicas de normalização mais utilizadas são:

- Normalização suave cujas distribuições das componentes x_j são normalizadas para terem média zero e variância unitária, tal como na equação A.6.
- Normalização severa cujas componentes x_j são re-escaladas para o intervalo $[0,1]$, tal como na equação A.7.

As equações são as seguintes:

$$x_j^{norm} = \frac{x_j - \overline{x_j}}{\sigma_j} \quad (A.6)$$

$$x_j^{norm} = \frac{x_j - x_j^{min}}{(x_j^{min} - x_j^{max})} \quad (A.7)$$

onde x_j^{norm} é o valor normalizado correspondente ao valor original x_j , $\overline{x_j}$ 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.4 PROCESSO DE APRENDIZAGEM DE RNA

O termo aprender para uma RNA, é o ato de estabelecer a saída da rede mediante apresentação de um conjunto de exemplos durante a etapa de treinamento. Nesta etapa, ocorrem os ajustes dos pesos sinápticos no intuito de se obter as relações entre entrada e saída, através de um algoritmo de treinamento da rede.

O processo de aprendizagem é classificado como: supervisionado ou não-supervisionado. Os processos tratam de uma minimização do erro entre a saída da rede e a saída desejada.

No aprendizado supervisionado, os padrões de dados apresentados contêm informações sobre o estímulo à entrada e sobre a saída que se deseja ter na última camada da rede. O aprendizado não-supervisionado é uma distribuição de probabilidade dos padrões de entrada através dos pesos dos neurônios da rede.

O aprendizado supervisionado é um problema de otimização do erro e tem sido aplicado em muitos casos (FREITAS, 2000; PATEL; KHUBCHANDANI, 2004).

A apresentação de todas as amostras de dados de treinamento à rede é denominada época. Para cada época os padrões de treinamento devem ser apresentados à rede em uma seqüência aleatória.

Para a verificação da eficiência do processo de treinamento, periodicamente, um conjunto de dados, não utilizados no treinamento, alimenta a rede e saídas são calculadas utilizando os valores dos pesos memorizados até o momento. Caso um nível de desempenho satisfatório não tenha sido atingido o treinamento deve continuar. Esta etapa é a validação.

O algoritmo de treinamento também pode ser interrompido quando o erro quadrático de uma iteração (e_{quad}) ou o erro quadrático médio (EQM) de uma época é menor que valores previamente estabelecidos. As equações A.8 e A.9 definem estes erros como segue:

$$e_{quad}(t) = \frac{1}{2} [d(t) - y(t)]^2 \quad (A.8)$$

$$EQM = \frac{1}{2N} \sum_{t=1}^N [e_{quad}(t)] \quad (A.9)$$

onde d é a saída desejada, y é a saída atual, N é o número de amostras de treinamento e t é o número da iteração atual.

Geralmente o treinamento é interrompido através do monitoramento do erro no processo de validação. Quando o erro no processo de validação não se elevar por algumas épocas consecutivas a rede estaria aprendendo apenas detalhes irrelevantes do conjunto de treinamento, o que é conhecido como *overfitting*.

Quando o processo de treinamento é encerrado, os parâmetros ajustados durante o processo são mantidos e uma etapa de testes, com novo conjunto de dados, pode ser realizada.

Frequentemente, para a realização destas três etapas é necessário distribuir a amostra total de dados em três subconjuntos. Um exemplo de distribuição pode ser 50% dos dados para o treinamento, 25% para validação e 25% para testes.

A.5 PERCEPTRONS DE MÚLTIPLAS CAMADAS (MLP)

Muitas vezes os neurônios de uma camada podem ser totalmente conectados aos da seguinte, conforme ilustrado na figura A.3.

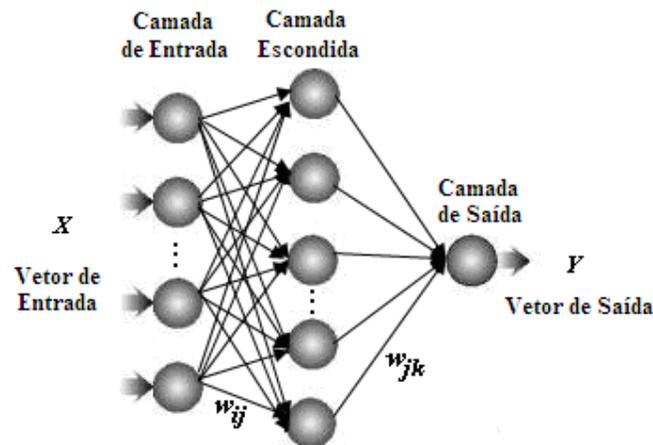


Figura A.3 - RNA feed-forward totalmente conectada.

Conforme mostra a figura A.3, a RNA é composta pela camada de entrada, onde os neurônios constituem a interface de entrada (X), por uma ou mais camadas intermediárias ou escondidas, e por uma camada 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 , por exemplo.

Entre as principais características das redes neurais está a capacidade de realizar um mapeamento não-linear entre as entradas e saídas, conservando o fluxo de sinal sempre adiante, são *feed-forward*.

A implementação de redes neurais 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 mapear 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 (ALMEIDA *et al.*, 2007a).

Em termos de aplicações em reconhecimento de padrões, A MLP é talvez a rede neural mais popular (HAYKIN, 2001). O seu poder computacional de aprender através da experiência mediante treinamento torna esta estrutura 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 apresenta uma distribuição de unidades não-lineares sob um conjunto de neurônios altamente conectados, inclusive em camadas escondidas tornando o processo de aprendizagem menos transparente ou difícil de ser visualizado.

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 muito simples 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*.

Assim, as entradas são descritas por atributos quantitativos, enquanto a saída desejada é um atributo qualitativo.

A.6 ALGORITMOS DE TREINAMENTO

A.6.1 *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 e Hinton (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 o cálculo do gradiente da função de erro convencionalmente denominado 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. Os neurônios são associados a um parâmetro definido de forma a atribuir um valor relacionado ao erro calculado permitindo 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 A.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. Os pesos sinápticos são ajustados para valores aleatórios ou segundo funções de inicialização.

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

Passo 3: Apresenta-se um par entrada-saída e calcula-se a saída das camadas da rede utilizando a equação A.1. Calcula-se o erro na última camada, segundo a equação A.10, e atualiza-se o erro quadrático médio (EQM), dado pela equação A.11:

$$e_j(t) = d_j(t) - y_j(t) \quad (\text{A.10})$$

$$EQM = \frac{1}{2N} \left[\sum_{j=1}^m e_j^2(t) \right] \quad (\text{A.11})$$

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 atual.

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

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

$$\delta_j^{(l)}(t) = \begin{cases} e_j^{(L)} \Phi' \left(v_j^{(L)}(t) \right) & (\text{camada de saída}) \\ \Phi' \left(v_j^{(L)}(t) \sum_k \delta_k^{(l+1)}(t) w_{kj}^{(l+1)}(t) \right) & (\text{camada escondida}) \end{cases} \quad (\text{A.12})$$

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:

$$w_{ji}^{(l)}(t+1) = w_{ji}^{(l)}(t) + \eta \delta_j^{(l)}(t) y_i^{(l-1)}(t) \quad (\text{A.13})$$

onde w_{ij} é o peso da i -ésima entrada para o j -ésimo neurônio, η é o parâmetro da taxa de aprendizagem, 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 (iteração).

Passo 7: Ao final de uma iteração, 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 platôs 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 conseqüência, 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 solucionar 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 *Adaptive Back-Propagation*. A equação A.14 apresenta a atualização dos pesos para este algoritmo, tal que

$$w_{ji}^{(l)}(t+1) = w_{ji}^{(l)}(t) + \alpha w_{ji}^{(l)}(t-1) + \eta \delta_j^{(l)}(t) y_i^{(l-1)}(t) \quad (\text{A.14})$$

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.

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.6.2 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 (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, 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 desempenho 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 A.15, a seguir:

$$H(\bar{w}) = J^T(\bar{w})J(\bar{w}) \quad (\text{A.15})$$

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 polarização.

Daí, o gradiente pode ser obtido mediante a equação A.16:

$$\delta = J^T(\bar{w})e(\bar{w}) \quad (\text{A.16})$$

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

O problema é que a matriz Hessiana, conforme definida na equação A.15, pode não ter inversa. A modificação de Levenberg-Marquardt propõe uma solução adicionando à matriz Hessiana a parcela μI , onde μ é um escalar, conhecido como tamanho de passo adaptativo e I é a matriz identidade resultando na equação A.17 para atualização dos pesos e polarização (HAGAN; MENHAJ, 1994; JAZAYERI *et al.*, 2007).

$$\bar{w}_{k+1} = \bar{w}_k - [J^T(\bar{w})J(\bar{w}) + \mu I]^{-1} J^T(\bar{w})e(\bar{w}) \quad (\text{A.17})$$

onde k é a época atual de treinamento.

Dessa forma, quando o escalar μ é próximo de zero o método LM comporta-se como o 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 desempenho, então seguir o gradiente descendente deve ser a melhor escolha. Assim, μ é decrementado a cada época bem sucedida (com redução do índice de desempenho) e incrementado apenas a cada época que poderia levar o índice de desempenho a aumentar. Isto resulta em uma função de desempenho 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 desempenho 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 A.1. Calcula-se o erro na última camada e atualiza-se o índice de desempenho (EQM), conforme A.10 e A.11:

Passo 4: Cálculo da Matriz Hessiana, gradiente e atualização dos pesos, conforme A.15, A.16 e A.17, respectivamente:

Passo 5: Recalcula-se a função de desempenho. 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.

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

A.7 REDES DE FUNÇÃO DE BASE RADIAL (RBF)

As Redes de Função de Base Radial, RBF, são constituídas de uma camada de neurônios com função de ativação do tipo gaussiana, conforme figura A.4 e equação A.18, 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.

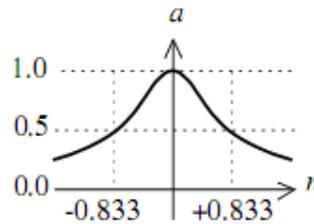


Figura A.4 - Função de base radial.

$$a = e^{-n^2} \quad (\text{A.18})$$

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 (HAYKIN, 2001).

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 $G()$ 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 A.19 e então a saída h do neurônio escondido i é calculada mediante a aplicação da equação A.20, como segue:

$$v_i = \|X - C_i\| b_i \quad (\text{A.19})$$

$$h_i = G(v) = \exp\left(-\frac{v^2}{2\sigma_i^2}\right) \quad (\text{A.20})$$

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, pode ser definido 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:

$$y_j = \sum_{i=1}^p [w_{ij} \cdot G(\|X - C_i\|, b_i)] \quad (\text{A.21})$$

onde p é o número de unidades escondidas da rede.

As RBF exigem maior número de neurônios que as MLP e possuem resultados mais eficientes no diagnóstico 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, da afirmação de que 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 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 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; HAYKIN, 2001).

A.7.1 Estratégia RBF Incremental

Esta estratégia de uso de redes RBF 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 $h(\cdot)$, conforme demonstrado na equação seguinte:

onde t é o número da iteração, η é a taxa de aprendizagem, h é a função de vizinhança, i_{prox} é o

$$w_i(t+1) = w_i(t) + \eta(t) \cdot h(i_{prox}, i, t) \cdot \|x(t) - w_i(t)\| \quad (A.22)$$

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 A.23, é o parâmetro utilizado para julgar a necessidade de inclusão de novas unidades na camada oculta:

$$ERR_{acu} \leftarrow ERR_{acu} + \sum_{j=1}^m (d_j - y_j)^2 \quad (A.23)$$

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, HAYKIN, 2001).

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

APÊNDICE B - BANCO DE DADOS DOS ENSAIOS CROMATOGRÁFICOS E FÍSICO-QUÍMICOS

B.1 ENSAIOS CROMATOGRÁFICOS

Tabela B.1 – Resultado dos ensaios cromatográficos para 354 amostras.

Amostra	H ₂	CH ₄	CO	CO ₂	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂
1	32	4	520	1766	0,1	0,1	0
2	24	4	766	4154	0,1	0,1	0
3	50	9	1025	3723	0,1	3	0
4	60	8	1170	4187	0,1	0,1	0
5	24	120	690	2616	38	64	0
6	29	111	624	2215	26	74	0
7	44	104	736	2862	16	88	0
8	22	1	102	1199	6	0,1	0
9	32	63	226	1512	178	47	0
10	1	0,2	2	36	0,1	0,1	0
11	12	0,4	36	523	4	0,1	0
12	55	123	227	1818	266	68	0,7
13	63	7	657	2341	0,5	1	0
14	30	225	678	3374	168	76	0
15	36	10	862	3898	2	2	0
16	37	218	716	5005	182	87	0
17	24	222	783	4908	168	84	0
18	27	235	843	4880	151	77	0
19	27	8	500	2774	0,3	3	0
20	8	2	258	2873	1	0,1	0
21	26	3	178	2664	1	0,1	0
22	100	4	577	5484	2	3	0
23	1	1	146	678	0,1	0,1	0
24	1569	216	241	1455	184	13	1539
25	1533	231	284	1697	231	17	1599
26	479	109	84	1433	133	11	1121
27	35	4	700	2937	0,1	0,1	0
28	1418	243	296	1671	257	19	1435
29	468	123	107	1524	163	14	1113
30	41	4	868	3553	0,1	0,1	0
31	39	6	884	3711	0,1	0,1	0
32	1238	216	260	1491	207	14	1403
33	1	0,3	27	153	0,1	0,1	0

Amostra	H2	CH4	CO	CO2	C2H4	C2H6	C2H2
34	54	2	368	1750	0,1	0,6	0
35	24	4	647	2163	0,1	0,1	0
36	70	55	1093	3732	17	18	0
37	43	3	377	2845	2	1	0
38	56	75	953	3947	18	27	0
39	32	3	480	2569	0,1	0,1	0
40	4	1	180	840	0,1	0,1	0
41	54	2	368	1750	0,1	0,6	0
42	24	2	263	1161	0,1	0,1	0
43	21	4	450	1704	0,1	0,5	0
44	37	4	427	2558	0,1	0,1	0
45	3	0,5	21	82	0,7	0,1	0
46	45	4	603	3094	49	0,1	0
47	4	13	194	1284	3	16	0
48	55	50	995	3951	10	21	0
49	58	83	1325	6201	16	24	0
50	24	2	218	4372	28	0,5	0
51	27	4	442	3789	70	2	0
52	120	68	716	4471	12	94	0
53	3	2	11	63	0,4	0,6	0
54	26	4	237	3347	12	2	0
55	27	2	162	2212	20	0,1	0
56	4	0,9	36	224	0,1	0,1	0
57	74	2	377	1321	0,1	0,1	0
58	99	3	469	1858	0,1	0,1	0
59	10	5	961	4286	0,1	0,1	0
60	38	2	388	3138	2	0,1	0
61	27	2	447	3616	5	0,1	0
62	27	2	392	3648	10	0,1	0
63	27	2	132	1322	0,5	0,7	0
64	24	4	460	7389	74	0,1	0
65	0,9	0,7	47	1074	3	0,1	0
66	26	2	204	2536	11	0,1	0
67	30	1	127	2286	7	0,1	0
68	24	1	121	2227	8	0,1	0
69	5	0,6	6	90	2	0,1	0
70	23	2	150	1466	5	0,1	0
71	21	17	384	5414	38	39	0
72	0,7	0	19	155	0,5	0,8	0
73	26	1	89	1521	5	0,1	0

Amostra	H2	CH4	CO	CO2	C2H4	C2H6	C2H2
74	25	1	94	1153	7	0,1	0
75	28	2	96	2197	8	0,1	0
76	38	18	79	438	2	31	0
77	162	100	178	1315	10	309	0
78	47	70	157	738	5	112	0
79	93	110	208	1736	15	360	0
80	94	98	250	1207	8	200	0
81	23	8	498	4036	77	0,1	0
82	30	7	831	5221	84	0,1	0
83	2	0,4	39	149	0,1	0,1	0
84	3	0	34	252	5	0,1	0
85	26	1	120	2483	11	0,1	0
86	26	1	120	2483	11	0,1	0
87	25	3	147	3266	2	0,1	0
88	11	3	664	3969	0,1	0,1	0
89	35	6	803	5513	0,1	0,3	0
90	71	2	215	1617	2	0,7	0
91	28	2	321	2092	5	0,1	0
92	2	5	373	3670	99	2	0
93	7	6	80	170	0,3	1	0
94	12	3	68	231	0,4	0,5	0
95	3	1	13	60	0,4	0,1	0,7
96	24	2	147	1461	12	0,1	0
97	33	3	241	2931	21	0,1	0
98	12	0,5	16	297	0,1	0,1	0
99	28	5	723	3346	0,1	0,1	0
100	180	17	279	5142	143	3	159
101	243	19	281	4898	143	3	117
102	88	12	280	5130	145	2	58
103	32	0,9	111	824	0,1	0,1	0
104	24	2	248	1521	0,1	0,1	0
105	22	2	283	1839	0,1	0,1	0
106	42	67	300	1730	76	13	0
107	15	3	202	960	0,2	0,3	0
108	29	2	74	325	0,1	0,1	0
109	44	3	155	558	0,1	0,1	0
110	45	5	208	738	0,1	0,1	0
111	28	7	153	579	8	1	0
112	19	2	395	1456	40	0,1	0
113	38	4	590	4881	69	0,1	0

Amostra	H2	CH4	CO	CO2	C2H4	C2H6	C2H2
114	74	5	312	3178	0,5	2	0
115	135	4	412	4470	1	2	0
116	93	3	437	5820	4	1	0
117	29	9	767	4690	0,1	0,1	0
118	30	9	829	4940	1	2	0
119	30	8	958	5859	0,1	1	0
120	36	12	1118	7347	1	2	0
121	31	9	1008	7347	1	3	0
122	4	3	679	5186	0,1	0,1	0
123	1	0,1	1	30	0,1	0,1	0
124	23	6	962	6329	1	0,1	0
125	22	3	390	2221	0,1	0,1	0
126	37	4	598	3706	0,1	0,1	0
127	3	0,3	13	84	0,1	0,1	0
128	14	2	99	656	0,1	0,1	0,4
129	19	0,3	20	252	0,1	0,1	0
130	45	3	528	2997	0,1	0,1	0
131	1036	79	301	1980	9	224	0
132	166	50	337	2192	8	87	0
133	18	1	28	90	0,1	0,2	0
134	28	0,6	13	99	0,1	1	0
135	22	6	28	100	0,3	7	0
136	11	3	362	1667	0,1	0,1	0
137	2	4	411	5907	38	2	0
138	19	1	24	209	1	0,1	0
139	31	2	374	4207	43	0,1	0
140	3	0,5	12	82	0,9	0,1	0
141	23	2	312	1968	32	0,1	0
142	7	4	900	5189	0,1	0,1	0
143	36	9	1214	5956	0,1	0,1	0
144	38	10	1207	5522	0,1	0,1	0
145	45	12	1330	7053	0,1	0,1	0
146	2	4	465	5178	4	0,1	0
147	0,7	0,7	20	341	0,1	0,1	0
148	27	2	87	3383	5	0,1	0
149	0,8	4	12	40	3	1	0
150	21	1	65	1264	4	0,1	0
151	21	0,9	63	687	12	0,1	0
152	30	2	268	3628	0,5	1	0
153	4	4	480	3264	72	2	0

Amostra	H2	CH4	CO	CO2	C2H4	C2H6	C2H2
154	53	2	275	3292	0,8	1	0
155	65	2	321	3772	0,3	1	0
156	3	2	36	132	2	0,4	0
157	6	0,6	50	262	3	0,1	0
158	30	2	299	1891	22	0,1	0
159	13	2	327	1474	0,1	0,1	0
160	31	4	658	2692	0,1	0,3	0
161	30	6	884	4079	0,1	0,1	0
162	0,6	0,5	28	433	15	0,1	0
163	1	0,7	36	762	12	0,1	0
164	0,6	0	12	255	2	0,1	0
165	0,1	0,2	15	122	0,9	0,1	0
166	25	3	342	6534	46	0,1	0
167	2	0,1	2	36	0,1	0,1	0
168	2	0	0,3	29	0,1	0,1	0
169	35	2	210	2612	14	0,1	0
170	29	2	202	2318	10	0,1	0
171	2	0	2	24	0,2	0,1	0
172	32	4	464	9066	50	0,1	0
173	31	3	309	4280	19	0,1	0
174	21	4	610	3280	0,5	3	0
175	23	6	944	4787	0,4	1	0
176	18	3	450	2977	0,8	1	0
177	9	3	115	570	0,1	2	0
178	4	0,2	8	74	0,4	0,1	0
179	5	0,1	0,4	56	0,2	0,1	0
180	16	11	129	638	7	7	0
181	2	0,1	3	45	0,1	0,1	0
182	24	3	255	1592	12	0,1	0
183	5	0,1	3	47	0,3	0,1	0
184	17	3	225	870	0,1	0,1	0
185	31	3	224	1822	11	0,1	0
186	42	5	306	4128	20	0,1	0
187	5	1	275	2424	0,1	0,1	0
188	25	2	249	2132	2	0,8	0
189	14	1	190	722	0,1	0,1	0
190	64	8	813	2345	4	2	0
191	33	3	546	1888	0,1	0,1	0
192	25	4	730	2500	0,1	0,1	0
193	34	7	927	7259	93	3	0

Amostra	H2	CH4	CO	CO2	C2H4	C2H6	C2H2
194	9	7	114	841	6	2	0
195	38	4	690	3988	57	0,1	0
196	17	3	431	1762	0,1	0,1	0
197	16	1	146	2011	36	0,1	0
198	0,8	2	240	3154	51	8	0
199	28	3	365	5071	75	6	0
200	24	2	268	2365	19	0,1	0
201	22	3	292	4492	71	4	0
202	21	7	346	2892	26	0,1	0
203	0,1	0,3	12	72	0,3	0,1	0
204	25	2	110	1863	9	0,1	0
205	22	1	243	4156	13	0,1	0
206	103	8	25	149	9	0,6	36
207	0,8	0,1	51	520	3	0,1	0
208	25	1	270	2575	16	0,1	0
209	27	3	302	5918	11	0,1	0
210	34	3	333	8635	24	0,1	0
211	28	1	338	3626	35	0,1	0
212	6	2	179	4741	0,1	0,1	0
213	29	38	589	5125	138	14	0
214	217	66	311	7708	122	8	274
215	6	2	47	473	7	0,4	0
216	53	3	430	4413	28	0,1	0
217	5	4	38	177	0,7	4	0
218	39	4	301	6327	9	0,1	0
219	32	4	262	4220	2	0,1	0
220	29	3	261	3153	1	0,1	0
221	25	3	232	3714	5	0,1	0
222	479	67	243	1114	8	131	0
223	25	109	246	1070	9	232	0
224	361	107	278	1285	12	266	0
225	4	91	551	2498	10	103	0
226	7	3	63	105	0,3	2	0
227	40	28	605	1608	2	7	0
228	30	2	230	1571	12	0,1	0
229	28	2	231	4026	46	0,1	0
230	28	2	227	1772	15	0,1	0
231	4	2	136	4412	0,1	0,1	0
232	4	2	46	308	6	0,4	0
233	23	2	141	4345	0,1	0,1	0

Amostra	H2	CH4	CO	CO2	C2H4	C2H6	C2H2
234	110	125	350	2102	13	334	0
235	6	6	52	219	0,8	16	0
236	0,2	0,5	27	255	4	0,2	0
237	158	128	361	1577	12	197	0
238	15	0,6	24	359	0,1	0,1	0
239	40	110	672	3903	12	162	0
240	13	79	596	2515	16	113	0
241	4	1	32	59	0,2	0,2	0
242	4	2	17	70	0,2	0,6	0
243	28	3	228	1558	23	0,1	0
244	7	0,4	25	190	0,1	0,1	0
245	35	40	308	1903	33	18	0
246	33	72	374	2408	72	31	0
247	0,1	0	16	214	0,1	0,1	0
248	33	2	277	1686	0,1	0,1	0
249	31	2	491	2894	0,1	0,1	0
250	28	4	545	3339	0,1	0,9	0
251	30	3	809	5547	0,1	0,1	0
252	45	10	1106	6015	0,1	1	0
253	361	102	108	1624	215	17	1634
254	862	229	283	2131	325	23	2215
255	2332	462	488	2680	516	37	2886
256	31	6	999	4026	0,1	0,1	0
257	23	8	1015	4239	0,9	0,1	0
258	24	3	357	3411	34	0,1	0
259	39	11	1096	3283	2	1	0
260	24	216	966	4994	154	78	0
261	23	3	483	1807	0,1	1	0
262	28	4	638	2011	0,1	0,1	0
263	16	0,9	87	1071	0,1	0,1	0
264	38	5	716	2810	0,1	0,1	0
265	22	2	140	2274	20	0,1	0
266	24	2	335	2123	0,1	0,1	0
267	22	19	138	2360	61	10	0
268	24	1	120	1709	10	0,1	0
269	22	2	100	2130	8	0,1	0
270	22	1	66	1883	7	0,1	0
271	27	5	120	2566	110	2	0
272	27	5	842	4288	0,1	0,1	0
273	26	4	437	6416	67	0,5	0

Amostra	H2	CH4	CO	CO2	C2H4	C2H6	C2H2
274	65	2	311	3400	7	0,1	0
275	144	102	236	1762	12	360	0
276	25	12	957	4948	2	2	0
277	61	10	959	3277	0,1	1	0
278	32	7	420	6766	52	2	0
279	36	5	672	3949	4	14	0
280	19	0,5	10	102	0,4	0,1	0
281	15	0,5	14	103	0,8	0,1	0
282	22	2	158	2226	1	0,1	0
283	11	4	243	1399	0,3	0,5	0
284	33	9	957	5472	0,2	0,9	0
285	25	12	1010	5947	1	2	0
286	21	2	187	1090	0,1	0,1	0
287	33	4	814	3878	0,1	0,1	0
288	37	12	1385	6956	0,5	2	0
289	4	3	30	82	0,8	0,9	0
290	4	0,6	18	101	0,5	0,1	0
291	114	5	649	2301	0,1	0,7	0
292	22	3	180	626	4	0,3	0
293	27	7	828	5239	81	3	0
294	39	13	1287	6712	0,1	0,1	0
295	39	15	1405	3919	4	2	1
296	42	20	736	3430	8	39	0
297	28	6	815	2710	0,1	1	0
298	35	3	738	9364	169	0,1	0
299	22	58	611	3168	68	13	0
300	22	5	600	4211	2	0,1	0
301	26	6	870	2910	0,1	0,7	0
302	15	4	363	1638	0,1	0,1	0
303	25	6	587	5777	13	2	0
304	21	2	149	2384	7	0,1	0
305	20	4	618	2415	0,1	0,6	0
306	28	4	563	4131	69	2	0
307	29	3	647	5616	98	0,1	0
308	28	7	873	7711	93	2	0
309	29	2	355	2713	12	0,8	0
310	26	3	392	9230	38	0,1	0
311	28	3	381	7136	25	0,1	0
312	28	5	862	4342	0,1	0,1	0
313	39	8	844	3788	4	6	0

Amostra	H2	CH4	CO	CO2	C2H4	C2H6	C2H2
314	96	174	461	2099	14	304	0
315	36	13	1190	6361	0,2	1	0
316	25	2	108	1913	10	0,1	0
317	29	76	594	3184	63	28	0
318	27	7	1013	3818	0,1	0,1	0
319	506	125	292	1653	17	351	0
320	23	0	13	95	2	0,1	0
321	29	1	129	1016	0,1	0,1	0
322	5	5	32	63	0,2	4	0
323	24	3	637	1998	0,1	0,7	0
324	4	0,7	12	48	4	0,1	0
325	24	1	195	1840	17	0,1	0
326	29	2	107	2814	24	0,1	0
327	31	3	564	2941	87	0,1	0
328	10	0,5	92	1094	0,4	0,1	0
329	28	4	804	3534	0,1	0,1	0
330	69	116	276	1253	13	376	0
331	33	3	641	3273	0,5	1	0
332	3	0,9	10	64	1	0,1	0
333	1	0,1	5	53	0,1	0,1	0
334	5	0,4	9	61	2	0,1	0
335	14	3	687	2360	0,1	0,5	0
336	27	193	840	4738	148	82	0
337	4	0,5	12	42	4	0,1	0
338	3	0,2	8	52	0,8	0,1	0
339	12	5	23	33	0,1	3	0
340	20	1	87	1195	12	0,1	0
341	22	1	70	1299	7	7	0
342	3	0,8	16	67	3	0,1	0
343	19	0,9	89	722	7	0,1	0
344	5	0,4	9	72	0,3	0,1	0
345	68	100	226	1206	8	223	0
346	23	2	230	3259	1	0,1	0
347	9	0,3	5	98	0,1	0,1	0
348	24	2	221	1841	11	0,1	0
349	22	6	672	4815	90	0,1	0
350	23	2	238	2054	9	0,1	0
351	23	2	266	2337	3	0,1	0
352	39	8	1299	5076	0,1	0,1	0
353	31	2	314	1991	8	0,1	0

Amostra	H2	CH4	CO	CO2	C2H4	C2H6	C2H2
354	21	2	404	1708	0,1	0,1	0

B.2 ENSAIOS FÍSICO-QUÍMICOS

Tabela B.2 – Resultado dos ensaios físico-químicos para 251 amostras.

Amostra	ACIDEZ	RIGIDEZ DIELÉTRICA	TEOR ÁGUA	TENSÃO INTERFACIAL	DENSIDADE	F.P. 100°
1	0,020	85,8	15,8	34,6	0,8731	1,012
2	0,056	83,6	22,0	30,0	0,8695	5,84
3	0,056	79,3	13,2	29,3	0,8696	6,8
4	0,030	88,6	18,4	33,1	0,8742	1,114
5	0,024	77,3	16,0	34,3	0,874	1,276
6	0,023	87,7	6,5	37,8	0,8787	0,554
7	0,175	54,8	34,8	20,0	0,882	5,71
8	0,200	60,4	41,6	19,3	0,8826	5,29
9	0,021	63,7	26,6	36,7	0,8739	0,75
10	0,011	80,4	25,8	35,5	0,8738	1,078
11	0,028	87,4	13,6	33,2	0,8752	1,177
12	0,034	57,6	26,8	34,3	0,8756	1,256
13	0,034	57,6	23,9	34,4	0,875	1,493
14	0,023	87,7	6,5	37,8	0,8787	0,554
15	0,033	73,9	26,9	33,8	0,88	0,564
16	0,014	88,6	15,2	38,0	0,8677	0,324
17	0,028	78,5	16,0	34,5	0,8677	1,177
18	0,024	85,8	15,8	34,0	0,8692	1,038
19	0,026	87,8	13,0	29,3	0,8921	1,896
20	0,044	77,9	12,8	27,9	0,8926	1,883
21	0,044	75,8	14,4	28,8	0,8916	1,798
22	0,026	87,4	17,7	37,8	0,8716	0,842
23	0,039	15,5	79,4	32,6	0,8797	1,556
24	0,044	67,0	19,8	33,5	0,8856	2,148
25	0,055	88,6	14,4	34,6	0,8856	2,721
26	0,046	51,4	24,7	34,2	0,887	3,072
27	0,026	90,5	23,8	33,1	0,8921	2,702
28	0,033	63,8	21,4	32,6	0,8932	1,566
29	0,031	72,9	22,5	33,2	0,8929	1,672
30	0,018	84,1	25,8	38,7	0,8846	1,628
31	0,024	67,2	29,0	36,1	0,8849	1,45
32	0,035	46,9	26,6	32,2	0,877	1,5
33	0,044	40,2	36,9	31,1	0,8784	1,506

Amostra	ACIDEZ	RIGIDEZ DIELÉTRICA	TEOR ÁGUA	TENSÃO INTERFACIAL	DENSIDADE	F.P. 100°
34	0,049	83,2	13,8	28,0	0,871	1,817
35	0,028	84,6	17,8	36,4	0,8767	0,814
36	0,021	36,4	27,6	35,6	0,8779	0,6
37	0,059	85,6	12,6	29,2	0,8791	0,927
38	0,075	59,5	33,8	28,2	0,8797	2,966
39	0,007	87,9	14,8	45,4	0,8932	0,322
40	0,014	88,5	11,7	36,6	0,8764	1,44
41	0,020	40,4	36,4	34,4	0,8741	1,204
42	0,033	54,4	35,0	34,6	0,8742	0,388
43	0,030	85,3	15,4	34,6	0,8734	1,137
44	0,024	32,9	31,2	40,5	0,8761	1,302
45	0,029	36,3	26,1	35,8	0,8861	1,818
46	0,020	84,6	10,2	41,7	0,8911	0,412
47	0,075	19,6	38,9	24,5	0,8728	1,58
48	0,071	24,2	82,9	26,0	0,8747	1,447
49	0,073	34,3	31,4	24,0	0,8739	1,586
50	0,082	42,2	31,4	26,9	0,8751	1,467
51	0,073	88,2	5,5	27,5	0,874	1,58
52	0,079	40,7	30,4	26,2	0,8747	1,917
53	0,062	87,1	11,6	27,2	0,874	1,724
54	0,068	87,0	22,2	26,9	0,875	1,956
55	0,065	24,6	18,7	27,3	0,8734	1,672
56	0,063	36,7	44,1	27,3	0,8736	1,256
57	0,062	49,2	35,8	25,7	0,8736	1,407
58	0,074	21,0	49,1	26,1	0,8752	1,414
59	0,066	81,3	17,1	26,2	0,8744	1,44
60	0,077	40,9	39,4	26,7	0,8751	2,306
61	0,063	46,1	16,8	26,9	0,8743	1,563
62	0,049	86,1	8,1	27,4	0,8754	1,633
63	0,073	68,7	23,7	30,5	0,8899	6,765
64	0,008	79,0	4,8	46,8	0,8898	0,834
65	0,033	59,7	27,4	34,5	0,8863	1,817
66	0,030	56,8	21,2	28,6	0,8889	5,46
67	0,058	54,8	26,6	28,7	0,8884	6,315
68	0,060	34,8	30,5	27,6	0,8898	6,165
69	0,058	58,6	27,4	28,6	0,8895	6,105
70	0,038	32,6	25,7	28,9	0,89	6,975
71	0,057	75,1	7,9	28,6	0,8905	8,095
72	0,067	73,8	35,0	24,8	0,8879	7,185

Amostra	ACIDEZ	RIGIDEZ DIELÉTRICA	TEOR ÁGUA	TENSÃO INTERFACIAL	DENSIDADE	F.P. 100°
73	0,083	87,2	8,8	25,3	0,8877	7,06
74	0,093	51,3	35,0	25,1	0,8897	7,485
75	0,092	78,4	15,9	26,1	0,8895	7,01
76	0,021	72,9	24,0	38,2	0,8882	0,761
77	0,109	79,9	30,0	24,4	0,8676	0,722
78	0,129	66,1	27,5	23,3	0,8883	7,555
79	0,018	39,5	31,9	41,3	0,8936	0,672
80	0,016	24,9	29,2	41,2	0,8927	0,8774
81	0,028	24,5	40,4	36,0	0,8713	1,174
82	0,031	34,3	25,7	34,3	0,8711	1,384
83	0,034	48,6	41,0	34,2	0,8725	1,929
84	0,030	81,3	13,4	33,2	0,8718	1,414
85	0,031	24,6	43,6	33,9	0,8711	1,487
86	0,033	87,6	8,2	32,9	0,8725	1,857
87	0,033	36,4	30,4	33,3	0,8723	1,976
88	0,011	66,8	12,6	37,7	0,8941	1,493
89	0,018	51,5	31,2	38,5	0,8938	1,844
90	0,023	57,4	26,4	39,5	0,8704	0,662
91	0,031	22,8	40,8	37,5	0,8705	0,85
92	0,026	64,6	17,4	35,7	0,87	0,705
93	0,036	25,6	42,6	35,9	0,8717	0,9
94	0,045	54,2	35,8	35,7	0,8704	0,938
95	0,050	26,2	38,5	35,0	0,8718	0,999
96	0,015	81,8	13,3	41,3	0,8916	2,101
97	0,022	86,0	11,4	41,2	0,891	1,989
98	0,020	86,8	6,6	40,3	0,8906	1,922
99	0,027	56,6	17,6	38,5	0,8822	2,319
100	0,027	87,2	24,1	37,4	0,8842	3,032
101	0,121	78,2	30,4	24,0	0,8862	26,56
102	0,033	86,4	23,1	40,6	0,8769	1,454
103	0,025	83,5	22,6	37,8	0,8788	2,412
104	0,063	76,1	32,1	37,2	0,8845	3,74
105	0,022	50,6	20,6	39,9	0,8846	1,936
106	0,025	76,2	19,4	40,0	0,885	1,61
107	0,032	40,5	37,2	35,1	0,8776	2,934
108	0,035	26,2	34,0	32,8	0,8783	1,137
109	0,035	40,9	33,2	33,3	0,8789	2,966
110	0,032	50,6	22,7	33,2	0,8788	2,901
111	0,037	22,4	49,0	34,2	0,8796	2,914

Amostra	ACIDEZ	RIGIDEZ DIELÉTRICA	TEOR ÁGUA	TENSÃO INTERFACIAL	DENSIDADE	F.P. 100°
112	0,050	47,8	32,2	31,5	0,8706	3,23
113	0,055	80,9	18,0	30,7	0,873	3,428
114	0,045	78,5	21,6	30,4	0,8704	3,4638
115	0,064	43,2	29,7	30,3	0,8711	3,338
116	0,026	34,8	17,3	39,3	0,8846	3,338
117	0,036	66,1	7,4	38,0	0,8856	4,26
118	0,037	84,8	18,4	36,1	0,8853	4,29
119	0,035	67,8	23,4	37,4	0,8854	4,325
120	0,013	76,9	19,0	42,4	0,8822	1,064
121	0,022	78,5	14,1	40,0	0,8826	1,158
122	0,022	75,6	22,9	38,5	0,8835	1,316
123	0,020	60,0	13,3	38,8	0,8821	2,332
124	0,030	87,1	16,7	38,0	0,8835	2,544
125	0,026	71,8	12,7	36,7	0,8832	2,557
126	0,024	83,6	17,4	34,2	0,8731	2,134
127	0,020	72,5	22,6	37,6	0,8925	3,558
128	0,006	82,2	12,0	48,2	0,8926	0,751
129	0,006	18,1	48,9	46,3	0,8913	0,54
130	0,013	76,6	12,4	40,9	0,884	0,824
131	0,026	87,0	7,0	39,7	0,8834	0,764
132	0,011	74,7	13,4	45,8	0,8924	1,263
133	0,019	50,9	25,8	42,7	0,8924	1,306
134	0,017	89,0	15,3	41,3	0,8917	1,401
135	0,024	89,4	14,0	37,2	0,8777	1,566
136	0,016	69,6	11,5	42,9	0,891	1,646
137	0,016	82,3	8,3	43,0	0,8917	1,903
138	0,024	65,2	28,4	41,0	0,893	0,91
139	0,012	86,8	13,4	41,7	0,8684	0,504
140	0,014	80,4	13,6	38,6	0,8699	0,732
141	0,024	81,4	16,4	36,3	0,8702	0,822
142	0,038	89,6	21,4	33,2	0,8674	2,874
143	0,077	74,0	20,7	28,0	0,8685	4,52
144	0,108	85,6	22,4	25,4	0,8686	3,84
145	0,019	89,7	9,2	42,3	0,8672	0,466
146	0,019	85,6	7,2	40,8	0,8688	0,57
147	0,046	64,9	16,3	31,6	0,8662	1,678
148	0,053	74,6	18,0	30,6	0,8678	2,082
149	0,008	88,3	13,6	44,6	0,8738	0,327
150	0,016	86,9	11,0	42,7	0,8768	0,351

Amostra	ACIDEZ	RIGIDEZ DIELÉTRICA	TEOR ÁGUA	TENSÃO INTERFACIAL	DENSIDADE	F.P. 100°
151	0,017	89,1	6,3	42,6	0,8692	0,436
152	0,017	82,4	8,0	40,3	0,8685	0,403
153	0,014	83,0	10,8	39,1	0,8652	0,715
154	0,026	88,5	12,4	37,2	0,8676	1,08
155	0,041	65,6	18,1	37,0	0,8686	1,507
156	0,043	73,1	11,4	38,0	0,8659	1,27
157	0,017	22,8	9,8	38,1	0,8671	0,762
158	0,022	87,5	6,2	37,5	0,8686	0,814
159	0,018	74,4	15,4	38,8	0,8687	0,764
160	0,068	77	11,8	35,3	0,8676	2,029
161	0,005	92,3	7,1	44,9	0,8675	0,41
162	0,005	80,5	10,0	45,2	0,8692	0,397
163	0,012	87,9	4,4	45,0	0,8701	0,396
164	0,027	84,6	18,8	37,2	0,8671	1,025
165	0,059	84,8	21,3	35,5	0,8691	2,009
166	0,044	71	14,2	33,4	0,8859	2,774
167	0,066	87,1	15,6	30,7	0,8849	2,531
168	0,028	56,3	17,3	38,5	0,8851	2,022
169	0,037	87,0	14,0	36,8	0,8854	2,266
170	0,023	63,4	13,1	35,3	0,883	2,985
171	0,029	84,9	14,9	35,5	0,8857	3,164
172	0,030	77,1	16,7	35,4	0,8811	2,372
173	0,035	64,9	22,8	34,3	0,8819	2,432
174	0,034	22,5	22,9	33,5	0,8848	4,04
175	0,037	49,5	21,1	34,1	0,8847	3,98
176	0,030	79,9	10,0	34,7	0,885	3,74
177	0,021	38,3	26,8	42,1	0,8826	1,17
178	0,022	61,6	12,2	39,5	0,8839	1,474
179	0,021	83,0	23,6	38,6	0,8836	1,374
180	0,022	64,3	21,5	38,3	0,8847	1,306
181	0,008	89,5	16,6	46,0	0,8718	0,426
182	0,009	88,0	9,2	44,6	0,875	0,883
183	0,006	81,5	14,6	47,6	0,8753	0,386
184	0,014	75	7,5	44,8	0,8759	0,83
185	0,006	75,0	10,4	46,1	0,8901	0,306
186	0,010	86,2	9,1	48,5	0,8905	0,873
187	0,006	87,6	14,7	49,4	0,8916	0,296
188	0,015	87,4	8,0	36,0	0,8661	0,501
189	0,016	86,1	13,7	33,4	0,867	0,699

Amostra	ACIDEZ	RIGIDEZ DIELÉTRICA	TEOR ÁGUA	TENSÃO INTERFACIAL	DENSIDADE	F.P. 100°
190	0,600	53,9	29,5	28,6	0,8905	7,78
191	0,013	79,0	16,6	46,9	0,8928	0,332
192	0,010	75,4	15,4	47,9	0,8924	0,297
193	0,008	84,3	12,5	48,4	0,889	0,577
194	0,007	86,8	9,7	47,2	0,8891	0,336
195	0,011	83	13,2	46,8	0,8897	0,54
196	0,008	84,9	25,4	48,5	0,8915	0,272
197	0,005	83,7	11,5	48,5	0,8918	0,202
198	0,007	85,6	11,4	47,8	0,893	0,294
199	0,016	56,2	25,2	41,5	0,8908	0,898
200	0,008	63,2	16,0	45,2	0,8901	0,52
201	0,010	72,3	13,3	45,0	0,8913	0,214
202	0,006	76,8	15,7	46,3	0,8916	0,304
203	0,008	85,7	12,0	47,1	0,8926	0,202
204	0,012	86,0	13,8	44,3	0,8899	5,74
205	0,010	84,3	9,5	45,8	0,8996	0,448
206	0,024	87	13,6	42,4	0,8908	0,353
207	0,007	50,7	18,4	46,9	0,8902	0,309
208	0,006	62,4	13,9	49,4	0,889	0,24
209	0,015	88,4	13,0	44,9	0,8908	0,244
210	0,010	76,9	11,3	46,9	0,8946	0,396
211	0,005	77,5	8,1	75,3	0,8941	0,862
212	0,01	67,2	6,8	44,8	0,8929	0,366
213	0,008	86,8	23,4	50,6	0,8918	2,636
214	0,006	86,8	11,1	47,5	0,8923	0,216
215	0,010	72,4	20,5	45,0	0,8917	0,144
216	0,008	86,7	11,8	46,4	0,8923	0,16
217	0,007	17	11,6	46,3	0,8833	0,294
218	0,007	83	6,3	48,5	0,8887	0,284
219	0,025	54,1	18,0	40,4	0,8741	1,386
220	0,062	65,2	16,2	27,1	0,8696	15,4
221	0,086	89,2	9,6	25,3	0,8712	15,74
222	0,077	86,6	15,6	25,8	0,8701	11,58
223	0,056	83,6	22,0	30,0	0,8695	5,84
224	0,056	79,3	13,2	29,3	0,8696	6,8
225	0,134	57,7	20,1	23,4	0,8685	5,61
226	0,022	58,2	18,9	36,6	0,8796	0,998
227	0,030	57,8	26,9	35,4	0,8802	1,038
228	0,026	58,4	21,3	35,7	0,8807	1,144

Amostra	ACIDEZ	RIGIDEZ DIELÉTRICA	TEOR ÁGUA	TENSÃO INTERFACIAL	DENSIDADE	F.P. 100°
229	0,008	85,6	10,1	44,4	0,8912	0,226
230	0,012	82,4	8,2	44,1	0,8908	0,63
231	0,008	88,2	9,0	45,4	0,8996	0,593
232	0,007	86,2	6,7	46,0	0,884	0,626
233	0,008	89,2	9,1	46,4	0,89	0,697
234	0,010	85,1	14,6	45,6	0,8995	0,598
235	0,012	87,3	13,7	45,3	0,89	0,738
236	0,076	61,5	20,1	23,4	0,8685	0,91
237	0,055	82,3	18,9	26,4	0,8665	1,678
238	0,050	81,8	15,1	27,6	0,8691	1,62
239	0,056	85,1	9,7	25,9	0,8683	1,692
240	0,164	58,9	24,1	21,7	0,8801	10,46
241	0,210	68,0	31,0	20,2	0,8796	11,71
242	0,022	84,0	9,5	36,3	0,8759	1,094
243	0,030	24,2	71,4	34,4	0,8757	0,946
244	0,181	86,2	16,8	21,1	0,8724	8,935
245	0,022	86,6	9,9	37,3	0,8755	0,866
246	0,026	51,3	28,1	34,7	0,8763	2,649
247	0,041	72,1	20,4	27,8	0,8715	14,66
248	0,082	84,2	8,4	27,2	0,873	14,36
249	0,111	89,4	14,0	25,7	0,8702	5,875
250	0,136	61,0	16,7	23,8	0,8711	6,45
251	0,167	80,3	26,5	23,0	0,8726	7,88