



*Ministério da Educação*  
**UNIVERSIDADE FEDERAL DE ITAJUBÁ**  
*Criada pela Lei nº10.435, de 24 de abril de 2002*  
*Pró-Diretoria de Pesquisa e Pós-Graduação*

**DIAGNÓSTICO DE FALHAS EM**  
**TRANSFORMADORES DE**  
**POTÊNCIA PELA ANÁLISE DE**  
**GASES DISSOLVIDOS EM ÓLEO**  
**ISOLANTE ATRAVÉS DE REDES**  
**NEURAIS**

JOSÉ GERALDO ARANTES

**Diagnóstico de Falhas em Transformadores de  
Potência pela Análise de Gases Dissolvidos em Óleo  
Isolante Através de Redes Neurais**

JOSÉ GERALDO ARANTES

Orientador: Prof. EDSON DA COSTA BORTONI

Dissertação apresentada à  
Universidade Federal de Itajubá para  
obtenção do grau de Mestre em  
Ciências

ITAJUBÁ

Estado de Minas Gerais – Brasil  
2005

Arantes, José Geraldo.

Diagnóstico de Falhas em Transformadores de Potência pela Análise de Gases Dissolvidos no Óleo Isolante Através de Redes Neurais. / José Geraldo Arantes: UNIFEI, 2005.

76p.

Monografia apresentada a UNIFEI para obtenção do grau de mestre em ciências em engenharia.

1. Transformadores de potência 2. Diagnóstico de Falhas

3. DGA 4. Redes Neurais

I. Título.

A minha esposa e filhos

Agradeço de forma especial ao meu orientador Prof. Edson da Costa Bortoni pelo apoio constante e incentivo dado ao longo desta caminhada.

A minha esposa e filhos por estarem ao meu lado em todos os momentos.

A Furnas Centrais Elétricas na figura do Chefe de Departamento do Centro Técnico de Ensaios e Medições, Luiz Antonio Gouvêa de Albuquerque, que muito me incentivou e permitiu o acesso às instalações do CTEE bem como às informações que necessitei durante o trabalho de pesquisa e desenvolvimento.

*Não sei o que possa parecer aos olhos do mundo, mas aos meus pareço apenas ter sido como um menino brincando à beira-mar, divertindo-me com o fato de encontrar de vez em quando um seixo mais liso ou uma concha mais bonita que o normal, enquanto o grande oceano da verdade permanece completamente por descobrir à minha frente.*

**Isaac Newton**

## **RESUMO**

Equipamentos de Subestação que utilizam o óleo isolante para a isolação de suas partes internas necessitam de um programa de manutenção periódico que visa detectar possíveis falhas tais como a deterioração da celulose do isolamento dos enrolamentos, curto circuito entre espiras destes, gases dissolvidos no óleo devido a sua degeneração, etc. Normalmente, programas de manutenção preventiva têm sido utilizados por empresas de geração, transmissão e distribuição de energia elétrica buscando evitar que estas falhas venham a provocar a retirada do equipamento do sistema elétrico o que significa grandes perdas financeiras, seja pela diminuição do faturamento, seja pelo pagamento de multas à agência reguladora, além da diminuição da confiabilidade do sistema. Para evitar estes inconvenientes, sensores on-line e técnicas de inteligência artificial (IA) têm encontrado aplicação na engenharia de sistemas elétricos.

Esta dissertação é um estudo de uma dessas técnicas – cromatografia de gases associada a redes neurais – visando apoiar o diagnóstico de falhas presentes e futuras baseando-se nos resultados obtidos através de cromatografia pela análise de gases dissolvidos em óleo isolante ao longo da vida útil dos transformadores de potência, prevenindo desta forma os inconvenientes acima relatados, facilitando assim a decisão de técnicos e engenheiros de manutenção para a manutenção preditiva daqueles equipamentos servindo também de base para o diagnóstico da

atuação de sensores on-line se instalados naqueles, permitindo ainda uma estimativa do grau de envelhecimento e, portanto da vida útil do transformador.

Técnicas como estas do estudo podem ser associadas a outras ferramentas de IA como a lógica fuzzy, algoritmos genéticos, sistemas especialistas e outras, constituindo assim os sistemas chamados híbridos, na tentativa de se obter a melhor solução para o problema.



## **ABSTRACT**

Substation Equipments that use insulation oil for isolate their internal parts needs a periodic maintenance program to detect possible fails like cellulose deterioration of coils insulation, short circuit between their springs, dissolved gas in oil caused by its deterioration, etc. Actually, preventive maintenance programs have been used by generation, transmission and distribution companies, as a fundamental tool to identify incipient faults, trying to avoid that these faults come to take away the equipment from electrical system, carrying out great financial losses caused by decreasing invoicing, payment of fines to regulatory agency or by decreasing of system reliability. Trying to avoid these inconvenient, on-line sensors and intelligent artificial (IA) techniques has been found application on electrical system engineering.

This dissertation is a study of one of these techniques – gas chromatography associated with neural networks – looking to support presents and futures fault diagnosis based on results from chromatography by the analysis of dissolved insulation oil gases during the useful power transformer life, avoiding this way the inconvenient related above, making easy the decision of engineers and technicians about the predictive maintenance of these equipment and also serving as a base for the on-line sensors actuation diagnosis if installed on these allowing yet an estimated old age degree and so the useful age of transformer. Techniques like that from this study may be associated with other IA tools like fuzzy logic, genetic algorithms, expert system and others, consisting the system called hybrid, attempted to get the best solution for the problem.

# SUMÁRIO

RESUMO.....	VII
ABSTRACT .....	IX
ÍNDICE DE FIGURAS .....	XIII
ÍNDICE DE TABELAS .....	XIV
<b>1. INTRODUÇÃO.....</b>	<b>1</b>
<u>1.1. Considerações Gerais</u> .....	3
<u>1.2. Revisão da Literatura</u> .....	4
<u>1.3. Objetivo do Trabalho</u> .....	13
<u>1.4. Escopo do Trabalho</u> .....	14
<b>2. DIAGNÓSTICO DE FALTAS EM LÍQUIDOS ISOLANTES.....</b>	<b>15</b>
<u>2.1. Materiais e Líquidos Isolantes</u> .....	15
<u>2.2. Cromatografia Gasosa</u> .....	19
2.3. Análise de Faltas .....	21
2.4. Métodos de Detecção de Faltas .....	29
2.5. Métodos de Interpretação .....	31
2.5.2. Método adotado pela C.A.G.B.....	32
2.5.3. Aplicação do Método da Razões de Rogers.....	34

2.6. Estudo e Aplicação do Método do Gás Chave.....	38
2.7. Triângulo de Duval .....	40
2.8. Técnicas Modernas de Detecção de faltas Incipientes baseadas em IA...43	
2.8.1. Sistemas Especialistas.....	43
2.8.2. Lógica Fuzzy .....	46
2.8.3. Redes Neurais .....	48
2.8.4. Sistemas Híbridos.....	49
<b>3. REDES NEURAS ARTIFICIAIS.....</b>	<b>50</b>
3.1. Introdução .....	50
3.2. Histórico .....	50
3.3. Características Básicas de uma Rede Neural .....	53
3.4. Função de Ativação de uma RNA .....	58
3.5. Treinamento e classificação de uma RNA.....	59
3.4. Perceptron.....	63
3.6. Definição de Modelo, Topologia, Parâmetros .....	66

<b>4. APLICAÇÕES DE REDES NEURAIIS NO DIAGNÓSTICO</b> .....	<b>67</b>
<b>4.1. Considerações Gerais</b> .....	<b>67</b>
<b>4.2. Topologia adotada</b> .....	<b>67</b>
<b>4.3. Treinamento da RNA</b> .....	<b>72</b>
<b>4.4. Resultados</b> .....	<b>72</b>
<b>5. CONCLUSÃO</b> .....	<b>75</b>
<b>5.1. Conclusões</b> .....	<b>75</b>
<b>5.2. Sugestão de Trabalhos Futuros</b> .....	<b>76</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	<b>78</b>

## ÍNDICE DE FIGURAS

<u>Figura 1 - Desenho esquemático do sistema de cromatografia a gás</u> .....	21
<u>Figura 2 - Gases típicos gerados durante faltas</u> .....	25
<u>Figura 3 - Percentual dos gases gerados durante um arco elétrico no óleo</u> .....	26
<u>Figura 4 - Percentual dos gases gerados durante descarga parcial no óleo</u> .....	27
<u>Figura 5 - Percentual dos gases gerados na ocorrência de sobre-aquecimento no óleo</u> ..	27
<u>Figura 6 - Percentual dos gases gerados pela degradação da celulose</u> .....	28
<u>Figura 7 - Percentual dos gases gerados durante uma eletrólise</u> .....	28
<u>Figura 8 - Distribuição de faltas típicas e percentuais relativos dos gases</u> .....	29
<u>Figura 9 - Distribuição de faltas típicas e percentuais relativos dos gases</u> .....	30
<u>Figura 10 - Solubilidade relativa como função da temperatura</u> .....	31
<u>Figura 11 - Gráfico de Dornenburg</u> .....	34
<u>Figura 12 - Triângulo de Duval</u> .....	43
<u>Figura 13 - Fluxograma para diagnóstico através do método de Rogers</u> .....	47
<u>Figura 14 - Fluxograma para diagnóstico através do método de Dornenburg</u> .....	48
<u>Figura 15 - Diagramas fuzzy para cada razão de gás</u> .....	50
<u>Figura 16 - Sistema para inferência de diagnóstico de faltas em trafos para Rogers</u> .....	50
<u>Figura 17 - Neurônio Biológico</u> .....	58
<u>Figura 18 - Exemplo de uma rede neural articial</u> .....	61
<u>Figura 19 - Representação de um neurônio artificial</u> .....	62
<u>Figura 20 - Tipos de função mais comuns aplicadas às Redes Neurais Artificiais</u> .....	63
<u>Figura 21 - Perceptron Multicamada</u> .....	69
<u>Figura 22 - Exemplo de uma Rede Neural Artificial</u> .....	72

<u>Figura 23 - Associação entre gases e tipos de faltas</u> .....	76
<u>Figura 24 - Topologia da rede utilizada na dissertação</u> .....	77
<u>Figura 25 - Função do tipo sigmoidal</u> .....	79
<u>Figura 26 - Desempenho da rede</u> .....	82

## ÍNDICE DE TABELAS

<u>Tabela 1 - Principais gases gerados durante faltas.....</u>	25
<u>Tabela 2 - Ocorrência dos gases relativos ao tipo de falta e material envolvido.....</u>	26
<u>Tabela 3 - Solubilidade de gases em transformadores .....</u>	30
<u>Tabela 4 - C.E.G.B. Razões de gases de faltas .....</u>	35
<u>Tabela 5 - Códigos e Diagnósticos C.E.G.B. ....</u>	35
<u>Tabela 6 - Níveis normais e diretrizes da Univ. Sacramento e Pacific Gas &amp; Testing</u>	36
<u>Tabela 7 - Pontos de alerta da Northern Technology &amp; Testing.....</u>	36
<u>Tabela 8 - Valores extremos em ppm e recomendações.....</u>	37
<u>Tabela 9 - Valores extremos em ppm e recomendações (cont.).....</u>	37
<u>Tabela 10 - Valores extremos em ppm e recomendações (cont.).....</u>	37
<u>Tabela 11 - Definição de taxas do Método das Razões.....</u>	38
<u>Tabela 12 - Método das Razões de Dornenburg.....</u>	38
<u>Tabela 13 - Limite L1 de Dornenburg .....</u>	38
<u>Tabela 14 - Diagnóstico original do Método das Razões de Rogers.....</u>	39
<u>Tabela 15 - Definição do código do Método das Razões.....</u>	40
<u>Tabela 16 - Diagnóstico do Método das Razões de Rogers.....</u>	40
<u>Tabela 17 - Critério de diagnóstico do Método do Gás Chave.....</u>	42
<u>Tabela 18 - Limites e Taxas de geração de gases .....</u>	44
<u>Tabela 19 - Sistemas Especialistas para diagnóstico de Transformadores .....</u>	47
<u>Tabela 20 - Código para gases dissolvidos em óleo mineral IEC 10A 53 .....</u>	51
<u>Tabela 21 - Exemplos de concentração de gases usados no treinamento da rede.....</u>	78
<u>Tabela 22 - Dados usados para diagnóstico da rede.....</u>	81

<u>Tabela 23 - Resultados finais</u> .....	81
<u>Tabela 24 - Resultados obtidos pela rede neural usada e métodos tradicionais</u> .....	82



## Capítulo I

### 1. INTRODUÇÃO

Inegavelmente o setor de energia elétrica tem papel preponderante na vida de empresas e do cidadão comum. Entre os centros de geração de energia e o centro consumidor, o transformador de potência representa o equipamento de maior importância estratégica e de maior investimento. A ocorrência de uma falha que venha a retirar um transformador de serviço para evitar danos maiores ao equipamento poderá causar problemas de ordem política, econômica e financeira, já que afetará a estabilidade e a confiabilidade do sistema, podendo deixar importantes cargas inoperantes, além do pagamento de pesadas multas por parte da empresa responsável pelo equipamento faltoso. A acentuada dependência energética mundial aliada à escassez de recursos das fontes de energia, à falta de investimento e à falta de uma política adequada de desregulamentação do setor só agravam este quadro.

Neste cenário torna-se fundamental o monitoramento constante do funcionamento e da operação dos transformadores, principalmente os transformadores elevadores das usinas e subestações buscando evitar-se a ocorrência de superaquecimentos, arcos ou descargas parciais, deterioração acentuada da isolação, formação excessiva de gases, etc., problemas estes derivados de esforços térmicos, mecânicos e elétricos e de reações físico-químicas que ocorrem internamente ao transformador. Deve-se ter em conta também que a

maioria dos transformadores em operação no Brasil foi instalada há 30, 40 anos atrás, além do que, devido a escassez de energia ocorrida há alguns anos, os transformadores tiveram que operar em constantes sobrecargas o que só tem agravado o envelhecimento da isolação.

O transformador de potência é um dos mais caros equipamentos do sistema de potência. Assim, numerosos métodos têm sido desenvolvidos para monitorar as condições deste valioso equipamento. Há duas partes principais na função de monitoramento, a detecção das condições da falta e a detecção das faltas incipientes.

O monitoramento tradicional e as etapas da análise das faltas eram desenvolvidos no campo por engenheiros e técnicos elétricos. Os computadores em um passado recente não eram capazes de processar dados não lineares. Contrariamente, recentes avanços na modelagem das técnicas de inteligência, softwares de programação e processadores mais potentes permitiram a implementação de numerosas aplicações em sistemas de potência. Várias pesquisas foram desenvolvidas na aplicação de técnicas de modelagem de inteligência artificial na análise de faltas em transformadores de potência e diagnóstico de sistemas. Assim no próximo capítulo estaremos apresentando uma revisão da base teórica para o presente trabalho. Para isso, revisamos um grande número artigos da literatura técnica sobre o assunto.

Esta dissertação tem quatro capítulos. O capítulo 1 é uma introdução ao problema. O capítulo 2 é uma revisão da tecnologia DGA e identifica o que é o estado da arte e o que se espera de futuros desenvolvimentos. O capítulo 3 se

concentrará na apresentação de conceitos sobre Redes Neurais Artificiais. O capítulo 4 se baseará extensivamente no diagnóstico de faltas utilizando redes neurais, incluindo a seleção da rede, o vetor de entrada, a otimização da topologia, etc.

## **1.1 Considerações Gerais**

Faz-se aqui uma revisão dos mecanismos da decomposição do óleo e da isolamento e dos métodos tradicionais de detecção de gases dissolvidos no óleo.

Transformadores utilizam óleo isolante mineral derivado de petróleo e, portanto constituído por hidrocarbonetos parafínicos ou naftênicos, óleos sintéticos como os óleos silicones e os askaréis ou ainda envolvidos por compostos resinosos a seco visando a isolamento de suas partes internas. Podem ser ainda, isolados com o gás SF<sub>6</sub> - hexafluoreto de enxofre - que tem propriedades isolantes excelentes, além de ser atóxico e não inflamável. Neste estudo estaremos nos referindo aos óleos isolantes minerais parafínicos que são mais freqüentemente encontrados nos transformadores de grande potência.

A função de um óleo isolante em transformadores é a de garantir isolamento elétrico entre suas partes energizadas e a de permitir a refrigeração interna destas partes através da transferência de calor, substituindo ainda o possível ar existente entre aquelas partes proporcionando alta rigidez dielétrica e baixa condutividade entre si.

O óleo isolante e os materiais de isolamento elétrico em transformadores podem se decompor sob condições normais de operação devido ao stress térmico e elétrico. Três fases distintas indicam o estado da decomposição e deterioração do óleo: a fase inicial caracterizada pela formação de peróxidos quimicamente instáveis quando há a liberação de oxigênio e a formação de compostos oxi-celulósicos com o papel isolante; a fase intermediária caracterizada pela formação de gases dissolvidos no óleo; e a fase final quando há a formação de uma substância resinosa, uma borra que se deposita no fundo do tanque do transformador, resultante da polimerização a partir de ácidos e de outros compostos. Este estudo preocupa-se com o estado intermediário, quando ainda é possível tomar providências sem envolver maiores custos e sem risco de retirada do equipamento do sistema.

A concentração de gases dissolvidos é um indicativo da saúde do transformador. A frequência de surgimento dos gases gerados e as mudanças específicas na concentração dos mesmos ao longo do tempo são usadas para determinar a manutenção de suas partes internas e o tratamento ou troca do óleo isolante, ou a substituição do transformador.

## **1.2 Resenha Bibliográfica**

Vários artigos relacionados com o tema desta dissertação foram consultados e os relacionados abaixo em muito contribuíram para esse trabalho além daqueles também citados na Bibliografia.

GUARDADO, J. L., NAREDO, J. L., et al. A Comparative Study of Neural Network Efficiency in Power Transformers Diagnosis Using Dissolved Gas Analysis, IEEE Trans. on Power Delivery. Vol. 16, No. 4, October 2001, pp. 643-647.

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

X. Ding, E. Yao, Y. Liu, "ANN Based Transformer Fault Diagnosis Using Gas-in- Oil Analysis," Proc. Of the American Power Conference, Illinois Inst. Technol., Chicago, 1995, pp. 1096 – 1100.

Um ponto forte deste artigo é que destaca a dificuldade para se estabelecer um modelo físico vinculando faltas, tipos e concentrações de gases, pois as relações entre eles não são lineares nem diretas, pois algumas faltas são dependentes da existência de vários gases, do tipo do transformador, localização da falta, etc. O

artigo enfatiza que “Diferentes padrões de gases são produzidos devido às diferentes intensidades de energia dissipada quando da ocorrência de faltas.” A precisão desse método para resultados corretos é de 95%; a análise dos gases pode ser usada para determinar além do tipo de falha o material dielétrico envolvido na mesma, o que não é sempre fácil, pois outros fatores como condições externas, sobrecargas, etc.; diferentes padrões de gases resultam em diferentes concentrações / intensidades que auxiliam no diagnóstico das faltas; quanta maior a quantidade de dados para o treinamento, melhor o diagnóstico. A melhor performance foi obtida usando uma topologia com 5 input 1 camada escondida e 1 output; maior precisão é obtida quando o modelo usa as taxas de geração de gases; a topologia da RNA difere dependendo da quantidade de dados existentes para treinamento; não considera as concentrações de CO e CO<sub>2</sub> para o diagnóstico de faltas. Pois estão relacionados com a degradação da isolação e não com o tipo de falta; melhores resultados são obtidos com a degradação da celulose quando um modelo de rede com 1 input é usado.

DUKARM James J., Transformer Oil Diagnosis Using Fuzzy Logic and Neural Networks, Canadian Conference on Electrical and Computer Engineering, Vol. 1, pp 329-332, 1993.

Este artigo apresenta uma forma de uso de redes neurais de modo um pouco diferente daquele exposto no artigo anterior. Ele ressalta alguns pontos interessantes: muitos fatores contribuem para o ruído nos dados obtidos para a análise de gases dissolvidos ou simplesmente DGA, tornando difícil e menos preciso o processo; o diagnóstico é baseado nas concentrações dos gases predominantes e

na sua proporção relativa ao total dos gases combustíveis dissolvidos; Para o TDCG são especificados 3 limites L1, L2, L3 para os níveis anormal, alto e muito alto respectivamente; para cada gás, limites inferiores Q1 e Q2 para proporções altas e muito altas de TDCG respectivamente; para TDG e cada gás, limites inferiores R1 e R2 são definidos para a geração de gases alta e muito alta respectivamente; através de gráficos são mostrados intervalos para 3 razões; 3 exemplos com outros métodos são dados e comparados; ele sugere um método das razões de Rogers melhorado simulado por uma rede com três pequenas camadas feedforward (3 inputs, 3 nós e 6 outputs); lógica fuzzy pode ser utilizada para analisar gases dissolvidos no óleo de transformadores de potência e que embora fiel aos métodos tradicionais melhora o resultado do diagnóstico; em alguns casos as redes neurais podem ser usadas combinadas com lógica fuzzy para implementar métodos de diagnósticos mais complexos.

Wang Z., Liu Y., Griffin, Paul J., A combined ANN and Expert System for Transformer Fault Diagnosis, IEEE Transactions on Power Delivery, Vol.13, No.4, October 1998.

Este tipo de técnica combinando redes neurais e sistemas especialistas, conhecida como ANNEPS foi desenvolvida para melhor diagnosticar faltas em transformadores pela análise de gases dissolvidos em óleo isolante Inclui o conhecimento de especialistas em manutenção de transformadores e regras derivadas do IEEE e IEC. A topologia e o conjunto de dados de treinamento desse sistema são cuidadosamente selecionados para extrair diagnósticos conhecidos e desconhecidos e suas correlações. A combinação das saídas de uma rede neural e

de um sistema especialista otimiza o mecanismo para garantir um alto grau de precisão para o tipo geral de faltas. Mostra que a combinação dos dois métodos resulta melhor que cada método individual para os mesmos dados testados.

NOGAMI T., Y. Yokoi, H. Ichiba, Y. Atsumi, “Gas Discrimination Method for Detecting Transformer Faults by Neural Network”, *Neural Networks*, 1994, IEEE World Congress on Computational Intelligence, pp. 3800 – 3805, vol.6.

Um dos métodos chave usado para diagnóstico de falhas em transformadores é o DGA. Ele usa um processo de cromatografia gasosa e o equipamento é lento e caro. Este paper apresenta um método diferente para determinar os tipos de gases e suas concentrações. Uma série de sensores de gases é colocada em um dispositivo de detecção onde a tensão de saída de um circuito simples é medida. Esta saída varia com o nível dos vários gases presentes no dispositivo de detecção e um computador determina quais os gases e suas concentrações conforme aquela tensão de saída e as informações pré-programadas. Este método evita o uso de separadores de gases caros e complexos tornando o uso de DGA mais acessível e obtendo resultados mais rápidos.

L. Yongli, G. Fuhai, H. Jiali, “Study on the Fault Identification of Transformers Using the Neural Network”, *POWERCON '98. 1998 International Conference on Power System Technology*, IEEE, NY, 1998, pp. 1058 – 1061.



O processo desenvolvido neste artigo usa 9 inputs (nós) para determinar as faltas e inclui correntes de seqüências positivas e negativas, tensões primárias e faltas internas e externas conhecidas. O sistema usa as entradas para gerar saídas intermediárias que são combinadas ou cruzadas com outras saídas para gerar “Falta (1)” ou “Sem Falta (0)”. O sistema é considerado avançado em relação aos outros métodos e sua maior contribuição é a alta precisão e respostas mais rápidas.

Y. Zhang, X. Ding, Y. Liu, “An Artificial Neural Network Approach to Transformer Fault Diagnosis,” IEEE Transactions on Power Delivery, IEEE Power Engineering Society, NY, 1996, pp. 1836-1841.

Zhang et al. propuseram o uso de redes neurais artificiais para o diagnóstico e detecção de falhas em transformadores de potência. A saída era caracterizada como: sobre aquecimento, corona, arco e condições normais de operação. Foram testadas diferentes topologias de redes, variando os parâmetros de entrada, o número de camadas escondidas e o número de nós na saída. O algoritmo utilizado para treinamento da rede foi o back-propagation. Os vetores de entrada eram constituídos da concentração individual dos gases incluindo em algumas das variações o monóxido de carbono e o dióxido de carbono. Os resultados foram satisfatórios, já que não distinguiam entre falhas de diferentes temperaturas, ou arco de alta ou baixa energia. A topologia ótima para todos os casos foi a que utiliza duas camadas escondidas. A presença do CO e CO<sub>2</sub> está fortemente vinculada à degradação da isolação. O sistema proposto é muito preciso.

HALSTEAD W.D., A Thermodynamic Assessment of the Formation of Gaseous Hydrocarbons in Faulty Transformers, Journal Inst. Petroleum, Vol. 59, Sept. 1973, pp. 239-241.

Halstead propôs um modelo termodinâmico para descrever as relações entre a temperatura e as características dos gases e assume que todos os hidrocarbonetos presentes no óleo são decompostos em os mesmos produtos e que cada produto está em equilíbrio com todos os outros. De acordo com o modelo, a evolução da razão ou taxa de cada gás pode ser calculada a qualquer temperatura. Assim a relação entre a geração de gás e a temperatura pode ser obtida para cada gás.

LIN C., LING J., HUANG C., "An Expert System for Transformer Fault Diagnosis Using Dissolved Gas Analysis," IEEE Transactions on Power Delivery, IEEE, NY, 1993, pp. 231 – 238.

A maioria dos artigos por nós analisados utiliza o método DGA de Rogers. Este artigo foi muito útil pois mostra passo a passo o método utilizado por Rogers para uma amostra de gás. Dá muitos exemplos de que falta pode ocorrer se são conhecidas as razões entre as concentrações dos gases. Um exemplo disso: Se a razão entre  $C_2H_2$  e  $C_2H_4 < 0.1$  e entre  $CH_4$  e  $H_2 > 1.0$  e  $C_2H_4$  com  $C_2H_6$  está entre 1.0 e 3.0, então provavelmente está ocorrendo uma falta térmica envolvendo temperaturas entre 300 e 700 °C. O artigo fornece oito condições de faltas através das razões de faltas incluindo aquela mencionada anteriormente. O artigo também discute que a análise da densidade de energia da falta pode fazer distinção entre

três processos faltosos. Por exemplo, se altos níveis de  $C_2H_2$  e  $H_2$  estão presentes e a concentração de  $C_2H_4$  é maior que a de  $C_2H_6$  então é provável a existência de arco elétrico; se os resultados diferem das normas o grau de severidade implica em manutenção; os intervalos fuzzy e as relações entre os níveis fuzzy podem ser considerados para determinar o tipo de falta.

BALMA P., R. Degeneff, B. Lloyd, "Expert Systems for Power Transformer Maintenance, Diagnostics and Design Review", Proceedings of the American Power Conference, Illinois Inst. Technol., Chicago, USA 1996, pp. 963 – 967.

Este artigo dá uma visão geral dos tipos de sistemas especialistas disponíveis para engenheiros e técnicos e o papel desses sistemas no diagnóstico de faltas. Comenta que alguns sistemas utilizam uma interface gráfica do usuário (GUI) para executar o programa que age sobre parâmetros programados, métodos de análise e banco de dados; o programa faz perguntas aos usuários sobre os dados existentes; todas as informações são registradas e disponibilizadas as pessoas que não conhecem o processo, sendo efetivamente um sistema tutorial; o sistema concentra-se em diagnóstico e manutenção; depois são sugeridos métodos de teste e inspeção; o sistema tenta identificar boas e más condições.

CAO, L., Chan T., Kong C., "A Universal Neural Expert System with Self-Learning Mechanism for DGA of Power Transformer Oil," International Power Engineering Conference 1995, Nanyang Technol. Univ, Singapore, 1995, pp. 355 – 359.

Os autores deste artigo salientam que o diagnóstico de faltas em transformadores é um processo muito complexo e não pode ser facilmente implementado em computadores. É raro que os dados obtidos por DGA se ajustem aos padrões e razões para o exato diagnóstico das faltas. Por essa razão os autores desenvolveram um programa de aprendizagem para enfrentar os casos mais difíceis. O método usa DGA e o método das razões de Rogers para detectar os tipos de faltas. Ele considera os níveis de concentração dos gases, as razões entre essas concentrações, os valores históricos das razões e da vida do transformador e 90% dos valores normalizados na determinação do tipo de falta. Para evitar os casos de “Sem Diagnóstico” ou “Não Identificada”, os especialistas desenvolveram um processo de auto-aprendizagem usando redes neurais para dar a probabilidade da falta em futuros casos limites analisados.

Z. Wang and Y. Liu, “A Combined ANN and Expert System Tool for Transformer Fault Diagnosis,” IEEE Transactions on Power Delivery, IEEE Power Engineering Society, NY, 1998, pp. 1224-1229.

Várias informações úteis estão presentes nesse artigo e agregam conhecimento aos primeiros sistemas utilizados para o diagnóstico de faltas em transformadores como o método das razões de Dornenburg e o de Rogers. Ele apresenta alguns dos problemas desses métodos, tais como a frequência de resultados, “Não Identificado”. Entretanto, a combinação de redes neurais e sistemas especialistas proporcionam: um método de estimativa melhorado – evitando o caso “Não Identificado”; especifica que informação é desejada do transformador para fazer o diagnóstico, tais como fabricante, tipo de transformador, tipo de núcleo etc.;

fornece saídas como – tipo de falta diagnosticada, diagnóstico confiável, intervalo de re-testagem, ações de manutenção recomendadas; executando dados através de dois sistemas ações de manutenção recomendadas; executando dados através de dois sistemas pode-se obter uma interpretação confiável do sistema em geral; tem uma alta precisão de teste e treinamento. O artigo aperfeiçoa um sistema combinado anterior e dá exemplos de diagnóstico de casos. Menciona também que o sistema é muito mais preciso que o método de Rogers para os casos, “Não Identificado”.

Y. Huang, H. Yang, C. Huang, “Developing a New Transformer Fault Diagnosis System through Evolutionary Fuzzy Logic,” IEEE Transactions on Power Delivery, 1997, pp. 761 – 767.

Este artigo apresenta a idéia de que as regras que normalmente são utilizadas no diagnóstico de faltas devem ser estendidas. É descrito como as regras “if-then” devem ser alteradas ou modificadas continuamente de acordo com os dados efetivos para a obtenção de melhores resultados. Também detalha que ainda é necessária a opção da “falta não identificada”; quando múltiplas faltas têm a mesma probabilidade o problema fica mais complexo; o artigo inclui um exemplo de estudo e afirma que um sistema com um grande número de razões de gases (neste caso 3) é necessário para melhores resultados. O ponto principal desse artigo é de que com o uso da lógica fuzzy logic pode-se desenvolver um sistema que dá a melhor estimativa. Se a confiabilidade da melhor estimativa é maior que o caso presente, o programa incorpora essa melhor estimativa, nos dados de treinamento e ainda alerta o usuário de que esta não é ainda confiável.

TOMSOVIC K., M. Tapper, T. Ingvarsson, “A Fuzzy Information Approach to Integrating Different Transformer Diagnostic Methods,” IEEE Transactions on Power Delivery, 1993, pp. 1638 – 1646.

Nesse paper os autores reconhecem que muitos desenvolvedores de técnicas de diagnóstico de faltas em transformadores ignoram a incerteza dos vários métodos existentes. Os autores desenvolveram um método que utilize lógica fuzzy para tentar combinar os métodos para obter um método sistemático melhorado de diagnóstico de faltas. Pontos chaves do artigo: há a necessidade de ter uma tendência a partir das amostras regulares de gases; todos os métodos de diagnóstico têm vantagens e desvantagens. Daí, quando um método indica um problema outros métodos devem ser utilizados. Um exemplo é dado e determina que se a análise DGA indica descarga ativa, é prudente aplicar um teste acústico antes de se tentar uma inspeção que retire o transformador de serviço. Também neste trabalho vários métodos são integrados para tentar formar uma análise simples e coerente. Estabelece também que “Uma característica fundamental nos sistemas baseados no conhecimento” é a simplicidade para adicionar, remover e modificar conhecimentos existentes no sistema. Além disso, medidas erradas ou perdidas não deveriam inviabilizar a análise. Desse modo, cada relação na base do conhecimento deve ser independente.

### **1.3 Objetivo**

Demonstrar que a aplicação de uma rede neural artificial para o diagnóstico de faltas em transformadores proporciona a detecção eficiente de faltas incipientes mais adequadamente e precisa que os métodos tradicionais baseados em DGA.

Através da aplicação do método, proporcionar rapidez e confiabilidade na detecção de defeitos, oferecendo uma melhor programação da manutenção, minimização de custos e prolongamento da vida útil de transformadores.

### **1.3 Escopo do trabalho**

O capítulo 1 apresenta a conceituação do problema, as soluções existentes para a sua solução e proposta da dissertação.

O capítulo 2 descreve os métodos tradicionais existentes e de larga aplicação nas empresas de energia elétrica e em indústrias conceituando o leitor quanto aos termos normalmente utilizados e a composição do óleo isolante e os subprodutos de sua decomposição assim como os tipos de isolação mais comuns utilizados nos transformadores. Esclarece ainda os tipos de faltas mais freqüentes em transformadores de potência e suas prováveis causas a partir da análise do gás de decomposição dissolvido no óleo isolante e como é feito o diagnóstico baseado na DGA.

O capítulo 3 introduz a teoria das redes neurais artificiais RNA ou ANN, relatando seu histórico de desenvolvimento e suas aplicações.

Já no capítulo 4 faço uma discussão e análise da aplicação do método das redes neurais no diagnóstico de falhas incipientes em transformadores de potência, comprovando a sua eficácia.

No capítulo 6 apresento as conclusões sobre o método apresentado e sugestões para trabalhos futuros.



## *Capítulo 2*

### **2. Diagnóstico de Falhas em Transformadores de Potência Baseado em Análise de Gases Dissolvidos em Óleo Isolante**

#### **2.1. Materiais e Líquidos Isolantes**

Sob condições normais de operação, os transformadores de potência isolados a óleo geram gases muito lentamente, como resultado da idade e relativo às condições de carregamento do mesmo.

Durante uma operação anormal, aumenta a produção de gases na relação direta da severidade do stress elétrico ou térmico. Esta formação de gases é causada pela deterioração do óleo e da celulose isolante (papel, por exemplo).

A maior parte da isolação sólida dos transformadores é constituída de papel e, portanto, de natureza celulósica. Estes materiais têm elevada resistência de isolamento quando secos (0,5% a 1% de umidade) e são altamente higroscópicos, isto é têm absorvem umidade e óleo. Os principais tipos de materiais celulósicos empregados na isolação que envolve os enrolamentos dos transformadores são:

Papel Kraft – feito de fibras de madeiras

Papel manilha – feito de fibras de madeira e cânhamo

Papelão Kraft – feito de fibra de madeira

Pressboard – feito de papelão com fibras de algodão

O papel kraft é muito poroso, estimando-se que contenha de 80% a 90% de ar. Ele absorve cerca de 10% do volume do óleo contido no tanque do transformador.

O papel isolante utilizado em transformadores é, depois de seco, impregnado de verniz ou resina isolante e posteriormente de óleo isolante. Sua impregnação com verniz ou resina não impede, mas retarda a penetração de água. A impregnação do papel com verniz que contém um solvente volátil pode dar origem à formação de cavidades na massa isolante favorecendo a formação de descargas parciais, que podem ser avaliadas pela medição do fator de potência da isolação, descargas estas que darão origem a gases que se dissolverão no óleo como será relatado mais á frente.

O óleo mineral isolante utilizado em aparelhos elétricos, como transformadores, reatores, disjuntores, religadores, etc., é extraído do petróleo. O óleo mineral pode ser de origem naftênica, mais usual, mas em vias de escassez (3% do óleo disponível), ou parafínica, tipo de óleo mais comum existente nas jazidas do Brasil e que tem baixo ponto de fluidez o que dificulta seu uso em regiões de inverno rigoroso, mas que tem recebido altos investimentos em pesquisas para obter este tipo de óleo com características mais adequadas para utilização em aparelhos e equipamentos elétricos. Este dois tipos de óleo apresentam características distintas [MYERS, 2004].

Estes óleos têm cor amarelo-pálida e são transparentes. Eles são constituídos por uma mistura de hidrocarbonetos (saturados e aromáticos) em maior proporção e de não-hidrocarbonetos (compostos de nitrogênio de enxofre e de oxigênio).

Sua deterioração, principalmente pela ocorrência de arcos e descargas elétricas, pode provocar a precipitação de partículas de carvão, a formação de ácidos e a liberação de gases. Com a deterioração a cor do óleo muda e escurece.

O envelhecimento dos óleos parafínicos tende a produzir uma maior quantidade de dióxido de carbono do que os naftênicos o que pode acelerar a deterioração dos papéis celulósicos.

Se misturados os dois tipos de óleo, a mistura apresentará características médias dos valores de seus componentes, tendo sempre melhores características que o pior dos componentes. Portanto, não se deve misturar óleos deteriorados com óleos novos.

A água e o calor são dois dos piores inimigos da isolação dos transformadores. A deterioração da isolação sólida e líquida dá origem á água e outros produtos que podem também servir como catalisadores, juntamente com o ferro do tanque, do núcleo, dos parafusos e suportes, com o cobre do enrolamento e com a umidade, e aceleradores do processo, o que irá diminuir o poder dielétrico do óleo. As condições podem ficar propícias também á ocorrência de descargas parciais que levam á ionização e á condução. Com a continuidade do processo, poderá haver a formação de corona com conseqüente falha de isolação. Todo o processo pode ser agravado com o aumento de temperatura.

Diz-se que o óleo está contaminado quando contém água e outras substâncias estranhas que não são produtos de sua decomposição. Diz-se que ele está

deteriorado quando contém produtos resultantes de sua oxidação. A deterioração se inicia tão logo ocorre o enchimento do transformador quando o oxigênio existente no tanque entra em combinação com os hidrocarbonetos instáveis do óleo. Por isso ultimamente tem-se adotado a prática de encher o tanque dos transformadores com nitrogênio desde a fábrica até o local da instalação dos mesmos e só então proceder ao enchimento dos mesmos para minimizar o problema, mas como existe oxigênio dissolvido no próprio óleo o processo de oxidação é inevitável.

Desde 1930 se tem estudado o processo de gases dissolvidos no óleo devido ao stress do papel e do líquido isolante e o ponto de partida deu-se com os estudos e publicações de Halstead [Halstead, 70]. Estudos similares ocorreram a partir daí especialmente na degradação do papel isolante. Há trinta anos, a técnica de análise de gases dissolvidos no óleo tem sido implementada e desenvolvida como ferramenta de diagnóstico para monitoramento de transformadores isolados a óleo mineral. Este método é agora aceito universalmente para localizar falhas incipientes térmicas e elétricas. O desenvolvimento desta técnica inclui novos métodos de laboratório, análise de gases dissolvidos on-line aplicação de outros fluídos dielétricos que não o óleo isolante e novos protocolos de diagnóstico. Dispositivos que periodicamente ou continuamente monitoram um ou mais gases dissolvidos no óleo estão disponíveis para análise on-line. A DGA foi originalmente desenvolvida para transformadores, mas está sendo agora aplicada a buchas de alta tensão isoladas a óleo e em comutadores de derivação em carga também isolados a óleo. Os métodos de interpretação dos dados têm sido extensivamente desenvolvidos para transformadores preenchidos com óleo isolante mineral e a IEEE ultimamente está desenvolvendo um guia para transformadores preenchidos com silicone.

Assim, a vida útil de um transformador dependerá das condições de sua operação e manutenção. Esta vida, estimada em 25 a 30 anos, poderá ser prolongada há até 50 anos com um programa de acompanhamento de operação e de manutenção adequados. Testes e ensaios periódicos podem detectar falhas incipientes, avaliar as condições de deterioração e orientar as medidas para evitar o envelhecimento prematuro e a progressão de falhas incipientes, evitando assim um enorme prejuízo á empresa de energia proprietária do equipamento.

Durante o tempo de operação do transformador, os gases gerados permanecem dissolvidos no óleo e a cromatografia gasosa é usada para analisar a concentração dos vários gases presentes.

## 2.2 Cromatografia gasosa

A Cromatografia Gasosa (CG) é uma técnica para separação e análise de misturas de substâncias voláteis. A amostra (2) é vaporizada e introduzida em um fluxo de um gás adequado denominado de fase móvel (FM) ou gás de arraste (1) como ilustrado na figura 1 a seguir:




Figura 1 - Desenho esquemático do Sistema de Cromatografia a gás

Este fluxo de gás com a amostra vaporizada, passa por um tubo (3) contendo a fase estacionária FE (coluna cromatográfica), onde ocorre a separação da mistura. A FE pode ser um sólido adsorvente (Cromatografia Gás-Sólido) ou, mais comumente, um filme de um líquido pouco volátil (4), suportado sobre um sólido inerte (Cromatografia Gás-Líquido com Coluna Empacotada ou Recheada) ou sobre a própria parede do tubo (Cromatografia Gasosa de Alta Resolução). Na cromatografia gás-líquido (CGL), os dois fatores que governam a separação dos constituintes de uma amostra são:

- a solubilidade na FE: quanto maior a solubilidade de um constituinte na FE, mais lentamente ele caminha pela coluna.

- a volatilidade: quanto mais volátil a substância (ou, em outros termos, quanto maior a pressão de vapor), maior a sua tendência de permanecer vaporizada e mais rapidamente caminha pelo sistema.

As substâncias separadas saem da coluna, dissolvidas no gás de arraste e passam por um dispositivo detector (5) que gera um sinal elétrico proporcional à quantidade de material fluido. O registro deste sinal em função do tempo é o cromatograma (6), sendo que as substâncias aparecem nele como picos com área proporcional à sua massa, o que possibilita a análise quantitativa.

Durante a vida útil do transformador, amostras de óleo são colhidas com o equipamento em operação e enviadas a um laboratório que irá testar as condições deste óleo cujo resultado facilitará a tomada de decisão quanto ao que fazer com o óleo e/ou com o equipamento. O resultado da análise do óleo isolante é assim um diagnóstico do grau de envelhecimento e desgaste dos transformadores e determina

a sua vida útil, o que torna importante conhecer os mecanismos da sua deterioração e os meios para a sua detecção. Métodos padrão ASTM (American Society for Testing and Materials) extraem e medem os gases dissolvidos no óleo isolante elétrico usando a cromatografia gasosa. Um destes métodos, o ASTM D3612-01, especifica que a análise de hidrogênio, oxigênio, nitrogênio, monóxido de carbono, dióxido de carbono, metano, etano, etileno, acetileno, propano e propileno que são gases característicos da decomposição do óleo isolante mineral devem ser obtidos para identificação e quantificação.

Assim, a vida útil de um transformador dependerá das condições de sua operação e manutenção. Esta vida, estimada em 25 a 30 anos, poderá ser prolongada há até 50 anos com um programa de acompanhamento de operação e de manutenção adequados.

### **2.3. Análise de faltas**

Testes e ensaios periódicos podem detectar falhas incipientes, avaliar as condições de deterioração e orientar as medidas para evitar o envelhecimento prematuro e a progressão de falhas incipientes, evitando assim um enorme prejuízo à empresa de energia proprietária do equipamento.

A análise de gases dissolvidos no óleo pela cromatografia gasosa, DGA, tem provado ser viável e preditiva. Alguns problemas que poderiam caminhar para falhas catastróficas em transformadores que podem ser detectadas são: arco elétrico (freqüentemente devido à perda ou mau contato de conexões dentro dos transformadores causados por vibrações); corona (descargas elétricas no

enrolamento); sobre aquecimento do óleo (sobrecarga do transformador, aquecimento exagerado do óleo isolante e de outras partes do equipamento, ou óleo em más condições necessitando de reciclagem ou regeneração, resultando em transferência de calor ineficiente); e degradação da celulose (o papel de material isolante enrolado em torno das bobinas torna-se frágil e começa a se deteriorar).

Assim, a análise dos gases dissolvidos em óleo isolante é capaz de identificar o tipo de falta bem como a sua severidade além de possibilitar a elaboração de ações de manutenção pelo acompanhamento e tendência de evolução das faltas.

A intensidade mais severa de dissipação de energia acontece na ocorrência de arco elétrico, é menor no aquecimento, e menor ainda no corona.

Algumas vantagens óbvias da análise de faltas são:

1. Aviso antecipado da ocorrência de faltas
2. Evita o uso impróprio das unidades
3. Aceitação de unidades novas ou reparadas
4. Agendamento conveniente de manutenções
5. Monitoramento de unidades em sobrecarga

Os gases gerados durante as faltas que são geralmente encontrados em transformadores estão ilustrados abaixo na figura 2 relacionados á temperatura em que ocorrem e á proporção do seu desenvolvimento:



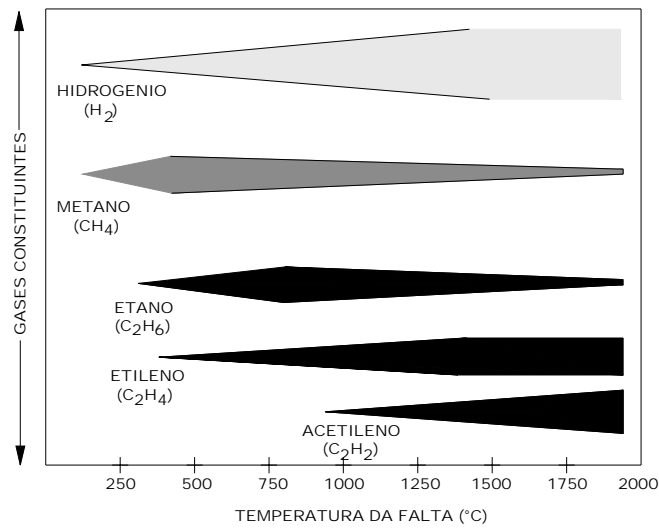


Figura 2 – Gases típicos gerados durante falhas

Estes gases podem ser relacionados nos três grupos seguintes:

- Hidrocarbonetos e hidrogênio

<b>Metano</b>	<b>CH<sub>4</sub></b>
<b>Etano</b>	<b>C<sub>2</sub>H<sub>6</sub></b>
<b>Etileno</b>	<b>C<sub>2</sub>H<sub>4</sub></b>
<b>Acetileno</b>	<b>C<sub>2</sub>H<sub>2</sub></b>
<b>Hidrogênio</b>	<b>H<sub>2</sub></b>

- Óxidos de carbono

<b>Monóxido de carbono</b>	<b>CO</b>
<b>Dióxido de carbono</b>	<b>CO<sub>2</sub></b>

- Gases não oriundos de falhas

<b>Nitrogênio</b>	<b>N<sub>2</sub></b>
<b>Oxigênio</b>	<b>O<sub>2</sub></b>

Tabela 1 – Principais gases gerados durante falhas

A maioria dos gases gerados nas falhas pode ser classificada de acordo com o tipo de material envolvido e o tipo de falta presente como segue:

<b>1. Corona</b>	
a. Óleo	H <sub>2</sub>
b. Celulose	H <sub>2</sub> , CO e CO <sub>2</sub>
<b>2. Pirólise</b>	
a. Óleo	
Baixa temperatura	CH <sub>4</sub> , C <sub>2</sub> H <sub>6</sub>
Alta temperatura	C <sub>2</sub> H <sub>4</sub> , H <sub>2</sub> (CH <sub>4</sub> , C <sub>2</sub> H <sub>6</sub> )
b. Celulose	
Baixa temperatura	CO <sub>2</sub> (CO)
Alta temperatura	CO (CO <sub>2</sub> )
<b>3. Arco elétrico</b>	
H <sub>2</sub> , C <sub>2</sub> H <sub>2</sub> , (CH <sub>4</sub> , C <sub>2</sub> H <sub>6</sub> , C <sub>2</sub> H <sub>4</sub> )	

Tabela 2 – Ocorrência dos gases relativos ao tipo de falta e material envolvido

- a. **Arco elétrico.** – Produção de grande volume de hidrogênio e acetileno e em menores volumes o metano e o etileno. Se o arco envolve a celulose, também podem ser formados monóxido e dióxido de carbono. *Gás chave: acetileno.*

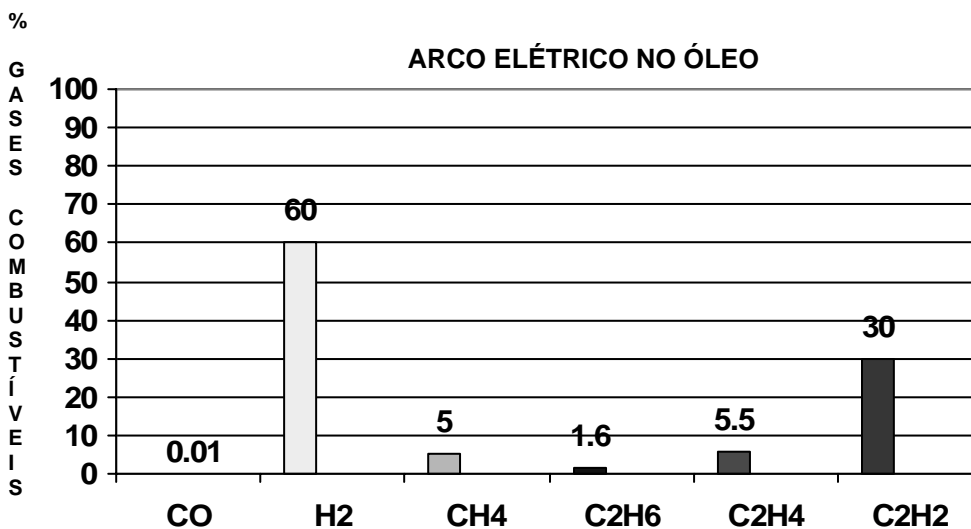


Figura 3 – Percentual dos gases gerados durante um arco elétrico no óleo

- b. **Corona.** – Descargas elétricas de baixa energia produzem hidrogênio e metano com pequenas quantidades de etano e etileno. Quantidades significativas de monóxido e dióxido de carbono podem ser devido a descargas na celulose. *Gás chave: hidrogênio.*




Figura 4 – Percentual dos gases gerados durante uma descarga parcial no óleo

- c. **Sobre aquecimento do óleo.** – Decomposição de produtos incluindo etileno e metano, juntos com pequenas quantidades de hidrogênio e etano. Traços de acetileno podem ser formados se o sobre aquecimento é severo ou envolve contatos elétricos. *Gás chave: etileno.*

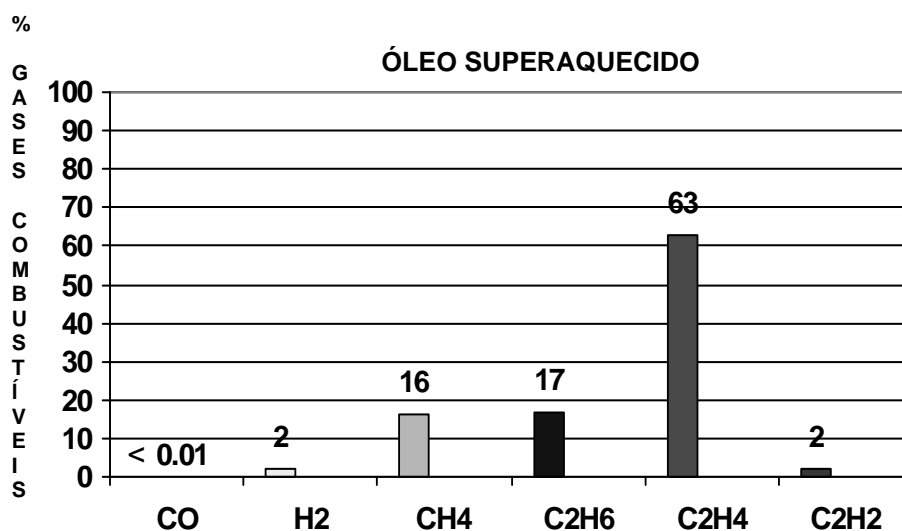


Figura 5 – Percentual dos gases gerados na ocorrência de sobre aquecimento no óleo

d. **Degradação da celulose.** – Grandes quantidades de monóxido e dióxido de carbono estão envolvidas no sobre aquecimento da celulose. Gases hidrocarbonetos, tais como o metano e etileno serão formados se o problema envolver a isolação do enrolamento, normalmente papel isolante impregnado de óleo. *Gás chave: monóxido de carbono.*




Figura 6 – Percentual dos gases gerados pela degradação da celulose

e. **Eletrólise.** – Formação de grandes quantidades de hidrogênio, com pequenas quantidades de outros gases combustíveis devido à decomposição da água associada com a ferrugem. *Gás-chave: hidrogênio.*




Figura 7 – Percentual dos gases gerados durante uma eletrólise

A interpretação dos resultados a partir da cromatografia de gases depende da quantidade total de gases combustíveis, TDCG, da quantidade de cada gás individual, e da taxa de crescimento destes gases. Entretanto a interpretação dos gases dissolvidos no óleo não é exatamente uma ciência.

Desde que uma operação normal também causa a formação de certos gases, simplesmente determinar a presença de gases no óleo não deveria causar alarme. O que é importante é a taxa e a quantidade dos gases gerados. Como em outros testes, a análise gases deveria ser conduzida em uma base regular para indicar traços ou alterações nos resultados.

As figuras a seguir ilustram os processos desenvolvidos na ocorrência do corona, pirólise e arco no óleo e pirólise da celulose respectivamente. Distribuições de faltas típicas nos gases também são mostradas.

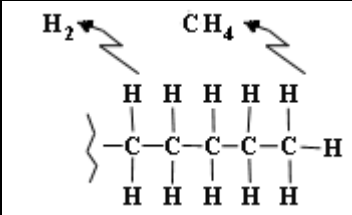
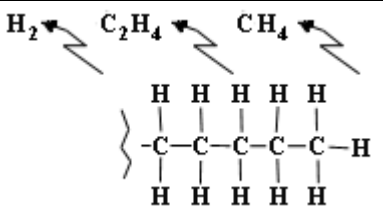
Corona no Óleo		Pirólise no Óleo	
			
H <sub>2</sub>	88%	H <sub>2</sub>	16%
CO <sub>2</sub>	1	CO <sub>2</sub>	traços
CO	1	CO	traços
CH <sub>4</sub>	6	CH <sub>4</sub>	16
C <sub>2</sub> H <sub>6</sub>	1	C <sub>2</sub> H <sub>6</sub>	6
C <sub>2</sub> H <sub>4</sub>	0.1	C <sub>2</sub> H <sub>4</sub>	41
C <sub>2</sub> H <sub>2</sub>	0.2	C <sub>2</sub> H <sub>2</sub>	traços

Figura 8 – Distribuição de faltas típicas e percentuais relativos dos gases

Arco no Óleo		Pirólise da Celulose	
H <sub>2</sub>	39%	H <sub>2</sub>	9%
CO <sub>2</sub>	2	CO <sub>2</sub>	25
CO	4	CO	50
CH <sub>4</sub>	10	CH <sub>4</sub>	8
C <sub>2</sub> H <sub>4</sub>	6	C <sub>2</sub> H <sub>4</sub>	4
C <sub>2</sub> H <sub>2</sub>	35	C <sub>2</sub> H <sub>2</sub>	0.3

Figura 9 – Distribuição de falhas típicas e percentuais relativos dos gases

A solubilidade dos gases de falta no óleo mineral assim como a sua dependência da temperatura são também fatores importantes a serem considerados na análise de gases de falta. A tabela abaixo lista as solubilidades de saturação para os gases de falta.

Deve-se notar que há quase duas ordens de diferença de magnitude entre o gás menos solúvel (hidrogênio) e o gás mais solúvel (acetileno). A maioria dos gases que são indicativos de falhas são também aqueles que, em geral, são mais solúveis no óleo.

Hidrogênio	7 % em volume
Nitrogênio	8.6 %
Monóxido de	9 %
Oxigênio	16 %
Metano	30 %
Dióxido de carbono	120 %
Etano	280 %
Etileno	280 %
Acetileno	400 %
Equilíbrio Estático á 760 mm Hg e 25°C	

Tabela 3 – Solubilidade de gases em transformadores

Quando as taxas de geração de gases estão sendo acompanhadas é importante levar em conta as solubilidades destes gases como uma função da temperatura do óleo.




Figura 10 – Solubilidade relativa como função da temperatura

Acima da faixa de temperatura de 0 a 80°C alguns gases aumentam em solubilidade em mais de 79% enquanto outros decrescem em solubilidade em até 66%.

## 2.4. Métodos de Detecção de Falhas

Três métodos serão discutidos e suas vantagens e desvantagens serão comparadas. O primeiro método é provavelmente a técnica mais usada atualmente é aquela que determina o total de gases combustíveis (TCG) que estão presentes no gás acima do nível do óleo. A maior desvantagem do método TCG comparado com outros é que ele é mais rápido e aplicável no campo. De fato este indicador pode ser usado para monitorar continuamente uma unidade. Entretanto, há várias

desvantagens do método TCG. Embora ele detecte os gases combustíveis de falta (hidrogênio, dióxido de carbono, metano, etano, etileno, e acetileno), ele não detecta outros gases não combustíveis (dióxido de carbono, nitrogênio e oxigênio).

Este método é somente aplicável a aquelas unidades que têm um manto de gás sobre o óleo e não às unidades completamente cheias de óleo do tipo com conservador ou tanque de expansão de óleo. Como a maioria das falhas ocorre sob a superfície do óleo, os gases devem primeiro saturar o óleo e difundir-se na superfície antes de se acumular acima no manto de gás acima do óleo. Estes processos levam tempo, o que atrasa a detecção prematura da falta. A maior desvantagem do método TCG é aquela que dá somente um valor simples para a percentagem dos gases combustíveis, mas não identifica quais os gases que estão normalmente presentes. É esta última informação a mais útil na determinação do tipo de falta que está ocorrendo.

O segundo método para a detecção dos gases de falta é a análise do manto de gás na qual uma amostra do gás no espaço acima do óleo tem sua composição analisada.

Este método detecta todos os componentes individuais; entretanto, ele também não se aplica às unidades com tanque de expansão e também apresentam a desvantagem de que os gases, primeiro precisam difundir-se no manto de gás. Além disso, este método não é o melhor para aplicação no campo. Um laboratório adequadamente equipado é preferido para a requerida separação, identificação, e para a determinação quantitativa destes gases em partes por milhão. O terceiro e



mais informativo dos métodos de detecção de gases de falta é a análise dos gases dissolvidos no óleo (DGA). Neste método uma amostra do óleo é retirada de uma unidade e os gases dissolvidos são extraídos do óleo. Então, os gases extraídos são separados, identificados, e quantitativamente determinados.

Atualmente esta técnica é mais bem realizada em um laboratório desde que ela requer operações de precisão. Como este método usa uma amostra de óleo ele é aplicável a todos os tipos de unidades e como o método do manto de gás ele detecta todos os componentes individuais. A principal vantagem da técnica DGA é que ele detecta os gases na fase de óleo possibilitando a detecção antecipada de uma falta incipiente. Esta vantagem por si anula qualquer desvantagem desta técnica.

A técnica DGA envolve vários métodos tais como o Método dos Gases Chave [Fallou, 75], o Método das Razões de Dornenburg [Dornenburg, 67], [Dornenburg e Strittmatter, 74], [Fallou et al., 70] e o Método das Razões de Rogers [Rogers, 75], (Rogers, 78). Estes métodos foram desenvolvidos a partir de análises estatísticas de bases de dados europeias e assim apresentam erros significativos quando aplicados a equipamentos instalados em países que apresentam diferenças climáticas relativas à Europa.

Diversos sistemas de diagnóstico vêm sendo desenvolvidos buscando reduzir estes erros, usando principalmente técnicas de Inteligência Artificial (IA), como apresentadas por [Dukarm, 93], [Zang, et Gao, 76], [Huanf et al., 97], [Darveniza et al., 97], [Wang, 98], [Lin et al., 93], [Tonsovic et al., 93], [Werle et al., 2003].

## 2.5. Métodos de Interpretação

O aspecto mais importante da análise de gases de falta é tomar os dados dos gases gerados e diagnosticar corretamente a falta que está gerando os gases que foram detectados. Muitos métodos que estão atualmente em uso serão aqui cobertos.

Um dos métodos mais recentes é o de Dornenburg [Dornenburg e Strittmatter, 74] no qual duas taxas de gases são plotadas em eixos log-log. A área em que os pontos se situarem é indicativa do tipo de falta que foi desenvolvida.

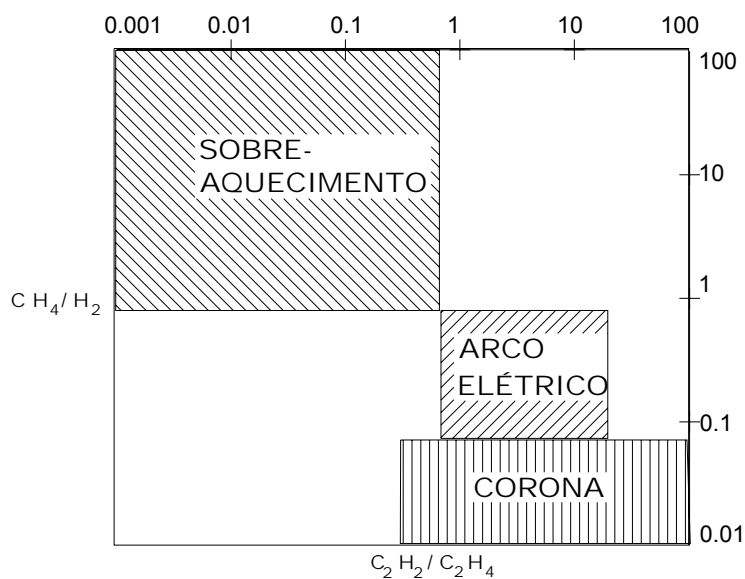


Figura 11 – Gráfico de Dornenburg

### 2.5.1. Método adotado pela empresa CEGB

A Central Electric Generating Board (CEGB) da Inglaterra tem usado o método desenvolvido por Rogers [ROGERS, 75] no qual a grandeza das quatro razões de gases é usada para gerar um código de quatro dígitos como mostrado na tabela abaixo.

Razão	Faixa	Código
CH <sub>4</sub> /H <sub>2</sub>	≤ 0.1	5
	> 0.1 < 1	0
	≥ 1 < 3	1
	≥ 3	2
C <sub>2</sub> H <sub>2</sub> /CH <sub>4</sub>	< 1	0
	≥ 1	1
C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>	< 1	0
	≥ 1 < 3	1
	≥ 3	2
C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>	< 0.5	0
	≥ 0.5 < 3	1
	≥ 3	2

Tabela 4 – C.E.G.B. Razões de Gases de Falta

O número de código gerado pode ser associado a um diagnóstico como mostrado na tabela abaixo:

CÓDIGO				DIAGNÓSTICO
0	0	0	0	Normal
5	0	0	0	Descarga Parcial
1 ou 2	0	0	0	Sobre aquecimento desprezível < 150°C
1 ou 2	1	0	0	Sobre aquecimento desprezível 150 - 200°C
0	1	0	0	Sobre aquecimento desprezível 200 - 300°C
0	0	1	0	Sobre aquecimento geral do condutor
1	0	1	0	Correntes circulantes no enrolamento
1	0	2	0	Correntes circulantes no núcleo e no tanque, Sobre
0	0	0	1	Flashover, sem continuidade elétrica.
0	0	1,2	1,2	Arco elétrico, com continuidade elétrica.
0	0	2	2	Centelha continuada para potencial flutuante
5	0	0	1,2	Descarga parcial com vestígios (nota CO)
CO <sub>2</sub> / CO > 11				Mais alta que a temperatura normal na isolação

Tabela 5 – Códigos e diagnósticos da C.E.G.B.

A tabela a seguir mostra as diretrizes desenvolvidas pela Universidade de Sacramento do estado da Califórnia em cooperação com a Pacific Gas & Electric Company para indicar os níveis normais e anormais dos gases individuais.

<b>Gás</b>	<b>Normal (&lt;)</b>	<b>Anormal (&gt;)</b>	<b>Interpretação</b>
Hidrogênio	150 ppm	1000 ppm	Corona, Arco elétrico
Metano	25	80	Centelha
Etano	10	35	Sobre aquecimento local
Etileno	20	150	Sobre aquecimento severo
Acetileno	15	70	Arco elétrico
Monóxido de carbono	500	1000	Sobre aquecimento severo
Dióxido de Carbono	10,000	15,000	Sobre aquecimento severo
Nitrogênio	1 to 10 %	N.A.	N.A.
Oxigênio	0.2 to 3.5%	N.A.	N.A.
Total de Combustíveis	0.03 %	0.5 %	N.A.

Tabela 6 – Níveis normais e anormais e diretrizes da Universidade de Sacramento e Pacific Gás & Electric

Atualmente a Northern Technology & Testing está usando os seguintes pontos de alerta (flag points) para os vários gases de falta mostrados na tabela abaixo:

<b>Gás</b>	<b>Pontos de alerta (&gt;)</b>
Hidrogênio	1500 ppm
Metano	80
Etano	35
Etileno	150
Acetileno	7
Monóxido de Carbono	1000
Dióxido de Carbono	10,000

Tabela 7 – Pontos de alerta da Northern Technology & Testing

Os seguintes exemplos são extremos, mas servem para ilustrar como a análise de gases dissolvidos no óleo pode ser usada para focar problemas ativos.

Informações do Transformador	Análise DGA	Recomendação
400 MVA	Hidrogênio: 7.040	O etileno é o gás chave na análise sugerindo alta temperatura e sobre aquecimento do óleo.
345 kV	Metano: 17.700	
	Etano: 4.200	
Tanque com manto de gás	Etileno: 21.700	
	Acetileno: 165	
Ano de fabricação 1969	Monóxido de carbono: 67	
	Dióxido de carbono: 1.040	

Tabela 8 – Valores extremos em ppm vol/vol a 25°C e 760 mmHg e recomendações

Informações do Transformador	Análise DGA*	Recomendação
2.5 MVA	Hidrogênio: 10.900	O etileno e o metano são os gases chave sugerindo alta temperatura e sobre aquecimento do óleo. O conteúdo de acetileno é alto o bastante para sugerir que ocorreu arco elétrico no óleo. Os óxidos de carbono estão em níveis muito altos indicando sobre aquecimento envolvendo a celulose.
44 kV	Metano: 18.400	
	Etano: 4.400	
Ano de fabricação 1991	Etileno: 24.500	
	Acetileno: 3.820	
Falhou após quatro anos de serviço	Monóxido de carbono: 23.800	
	Dióxido de carbono: 36.900	

Tabela 9 – Valores extremos em ppm vol/vol a 25°C e 760 mmHg e recomendações

Informações do Transformador	Análise DGA*	Recomendação
11.46 MVA	Hidrogênio: 1.980	Embora a concentração de hidrogênio esteja alta e alguma descarga parcial possa ter ocorrido a grande concentração de CO e CO <sub>2</sub> indica severo sobre aquecimento envolvendo a celulose.
33 kV	Metano: 166	
	Etano: 87	
Tanque com manto de gás	Etileno: 205	
	Acetileno: 0	
Ano de fabricação 1940	Monóxido de carbono: 2.990	
	Dióxido de carbono: 58.300	

Tabela 10 – Valores extremos em ppm vol/vol a 25°C e 760 mmHg e recomendações

### 2.5.2. Aplicação do método das razões de Rogers

O método das razões usa a relação entre as concentrações de gases dissolvidos como base para o diagnóstico de falhas. Historicamente cinco razões têm sido usadas [RANDY, 97].

<b>Razão</b>	CH <sub>4</sub> /H <sub>2</sub>	C <sub>2</sub> H <sub>2</sub> / C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub> / CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub> / C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub> / C <sub>2</sub> H <sub>6</sub>
<b>Abreviação</b>	R1	R2	R3	R4	R5

Tabela 11 – Definição de taxas do método das Razões [Randy, 97]

A primeira tentativa foi feita no final dos anos 1960 na Central Electricity Generating Board (CEGB) [Rogers 78] como mostrado anteriormente. Em 1970 Dornenburg foi capaz de diferenciar falhas térmicas e elétricas usando quatro razões e seis gases [Dornenburg, 67], [Fallou, 70], [Randy, 97]. Os seis gases são H<sub>2</sub>, CH<sub>4</sub>, CO, C<sub>2</sub>H<sub>2</sub>, C<sub>2</sub>H<sub>4</sub> e C<sub>2</sub>H<sub>6</sub>. As quatro razões e seus valores de diagnósticos estão mostrados na tabela a seguir.

O método consiste em muitos testes de validação antes de atingir a decisão final e sempre falha. O teste de validação mais importante é o teste L1, que determina um valor crítico para cada gás. De modo a aplicar o método, ao menos um gás para cada uma das razões deve exceder a norma L1 correspondente. As normas L1 revisadas estão listadas abaixo.

Falta	R1	R2	R3	R4
<b>Decomposição térmica</b>	>1	<0.75	<0.3	>0.4
<b>Corona (baixa intensidade)</b>	>0.1	Não significativo	<0.3	>0.4
<b>Arco elétrico (alta intensidade)</b>	>0.1 e < 1	>0.75	>0.3	<0.4

Tabela 12 – Método das razões de Dornenburg [Randy, 97]

Gás	H <sub>2</sub>	CH <sub>4</sub>	CO	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
<b>Limite de L1 (ppm)</b>	100	120	350	35	50	65

Tabela 13 – Limite L1 de Dornenburg [Randy, 97]

Segundo o modelo termodinâmico de Halstead [Halstead, 73], o método das razões de Rogers foi primeiro proposto em 1973 [Barracough, 73], refinado em 1975 [Rogers 1975], e mais uma vez refinado em 1977 [Rogers, 77]. Levando em

consideração experiências industriais [Manger, 78], testes de laboratório, e considerações teóricas posteriores, o método foi modificado para o padrão IEC [IEC599]. O método original das razões de Rogers foi usado na tabela acima para o diagnóstico, onde o 1 indica que o valor normal é acima de 1.0, e um 0 indica que o valor normal é abaixo de 1.0.

O método refinado de Rogers usava duas tabelas: uma definia o código, e a outra definia as regras de diagnóstico, como mostrado nas tabelas 14 a 16. Estes métodos preliminares usavam quatro razões. A razão etano/metano ( $C_2H_6/CH_4$ ) somente indicava uma faixa limitada de temperatura de decomposição, mas não fornecia suporte na identificação da falta. Posteriormente, no padrão IEC 599, o desenvolvimento adicional do método das razões de Rogers foi suprimido.

$CH_4/H_2$	$C_2H_6/CH_4$	$C_2H_4/C_2H_6$	$C_2H_2/C_2H_4$	Diagnóstico
0	0	0	0	Se $CH_4/H_2$ é 0.1 ou mais $\Rightarrow$ descarga parcial, senão deterioração normal
1	0	0	0	Leve sobre aquecimento $\Rightarrow$ abaixo de 150° C
1	1	0	0	Leve sobre aquecimento $\Rightarrow$ entre 150 e 200°C
0	1	0	0	Leve sobre aquecimento $\Rightarrow$ entre 200 e 300°C
1	0	1	0	Sobre aquecimento geral do condutor
0	0	0	1	Correntes circulantes com sobre aquecimento de juntas
0	1	0	1	Flashover sem continuidade elétrica
0	0	1	1	Corrente de interrupção no seletor do comutador
				Arco com continuidade elétrica ou centelha persistente

Tabela 14 – Diagnóstico Original do Método das Razões de Rogers [Barraclough, 73]

As vantagens de métodos baseados em razões são que eles são quantitativos e independem do volume de óleo no transformador. Entretanto, o método de razões pode produzir interpretações errôneas ou nenhuma. Mas pode ser usado em conjunto com outros métodos de diagnóstico como o do gás chave.

Razão do gás	Faixa	Código
<b>CH<sub>4</sub>/H<sub>2</sub></b> <b>(R1)</b>	Não maior que 0.1	5
	Entre 0.1 e 1.0	0
	Entre 1.0 e 3.0	1
	Não menor que 3.0	2
<b>C<sub>2</sub>H<sub>2</sub>/CH<sub>4</sub></b> <b>(R4)</b>	Menor que 1.0	0
	Não menor que 1.0	1
<b>C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub></b> <b>(R5)</b>	Menor que 1.0	0
	Entre 1.0 e 3.0	1
	Não menor que 3.0	2
<b>C<sub>2</sub>H<sub>2</sub>/C<sub>2</sub>H<sub>4</sub></b> <b>(R2)</b>	Menor que 0.5	0
	Entre 0.5 e 3.0	1
	Não menor que 3.0	2

Tabela 15 – Definição do código do Método das Razões de Rogers [Barraclough, 73]

R1	R4	R5	R2	Diagnóstico
0	0	0	0	Deterioração normal
5	0	0	0	Descarga parcial
1 ou 2	0	0	0	Leve sobre aquecimento – abaixo de 150°C
1 ou 2	1	0	0	Leve sobre aquecimento – entre 150 e 200°C
0	1	0	0	Leve sobre aquecimento – entre 200 e 300°C
0	1	0	0	Sobre aquecimento geral do condutor
1	0	1	0	Correntes de circulação no enrolamento
1	0	2	0	Correntes circulantes no tanque e no núcleo, juntas sobre aquecidas.
0	0	0	1	Flashover sem consequência elétrica
0	0	1 ou 2	1 ou 2	Arco com consequência elétrica
0	0	2	2	Centelhamento contínuo para potencial flutuante
5	0	0	1 ou 2	Descarga parcial com trilha (notar CO)

Tabela 16 –Diagnóstico do Método das Razões de Rogers Refinado[Rogers, 75]



## **2.6 Estudo e aplicação do método do gás chave**

O estudo do método do gás chave começou nos laboratórios da Doble foi estabelecido em 1973 [Pugh, 73] e oficialmente proposto em 1974 [Pugh, 74]. Em 1978, a comparação entre o método do gás chave e o método das razões de Rogers ocorreu na conferência anual da Doble [Rick, 78]. Imaginou-se que o método das razões fosse exclusivo para transformadores do tipo com conservador, mas o método do gás chave foi desenvolvido seja para transformadores selados seja para transformadores com pulmão de gás. Griffin fez uma grande revisão no método do gás chave, métodos das razões, e aplicações relacionadas [Griffin, 88].

O método do gás chave identifica o gás chave para cada tipo de falta e usa o percentual deste gás para identificar a falta. Ele interpreta a análise de gases dissolvidos no óleo baseado em um conjunto simples de fatos. Por exemplo, baixa intensidade de descargas parciais ou produção de corona principalmente  $H_2$  com alguns traços de gases derivados de hidrocarbonetos, assim o gás chave para descargas parciais ou corona é o  $H_2$ , e a descarga parcial e o corona podem ser detectados se o percentual da quantidade de  $H_2$  é significativo em uma amostra de óleo. Baseado no trabalho original do Dr. Pugh e no padrão IEEE C57.104, a Tabela 17 resume o critério de diagnóstico do método do gás chave. O percentual do gás é baseado no total de gases combustíveis dissolvidos (TDCG) e é um número aproximado.

Falta	Gás chave	Critério	Percentual do gás
<b>Arco</b>	Acetileno  C <sub>2</sub> H <sub>2</sub>	Grande quantidade de H <sub>2</sub> e C <sub>2</sub> H <sub>2</sub> e menor quantidade de CH <sub>4</sub> e C <sub>2</sub> H <sub>4</sub> . CO e CO <sub>2</sub> podem também existir se a celulose estiver envolvida.	H <sub>2</sub> : 60%  C <sub>2</sub> H <sub>2</sub> : 30%
<b>Corona</b>	Hidrogênio  (H <sub>2</sub> )	Grande quantidade de H <sub>2</sub> , algum CH <sub>4</sub> , com pequena quantidade de C <sub>2</sub> H <sub>6</sub> e C <sub>2</sub> H <sub>4</sub> . CO e CO <sub>2</sub> podem ser comparados se a celulose estiver envolvida.	H <sub>2</sub> : 85%  CH <sub>4</sub> : 13%
<b>Sobre aquecimento do óleo</b>	Etileno  (C <sub>2</sub> H <sub>4</sub> )	Grande quantidade de C <sub>2</sub> H <sub>4</sub> , menor quantidade de C <sub>2</sub> H <sub>6</sub> algum a quantidade de C <sub>2</sub> H <sub>4</sub> e H <sub>2</sub> . Traços de CO e CO <sub>2</sub> .	C <sub>2</sub> H <sub>4</sub> : 63%  C <sub>2</sub> H <sub>6</sub> : 20%
<b>Sobre aquecimento da celulose</b>	Monóxido de Carbono  (CO)	Grande quantidade de CO e CO <sub>2</sub> . Gases hidrocarbonetos podem existir.	CO: 92%

Tabela 17 – Critério de Diagnóstico do Método do Gás Chave

## 2.7 Triângulo de Duval

Michel Duval, [Duval, 82, 89, 01, 02] desenvolveu na década de 1960 uma técnica de análise que plota a concentração de três gases específicos, metano, etileno e acetileno, dissolvidos no óleo de transformadores que possibilita apontar as possíveis causas de falta incipiente, tais como arco elétrico e pontos quentes dentro do transformador. Duval verificou que um número significativo de resultados da análise de gases dissolvidos no óleo não se enquadrava nos códigos do IEEE-IEC não podendo assim ser diagnosticados. Este método é largamente usado na Europa e Canadá e pouco usado nos Estados Unidos, e nos países da América Latina, Ásia e África.

O triângulo de Duval não se aplica à maioria dos transformadores a não ser quando os três gases explosivos citados aparecem juntos, caracterizando um iminente perigo ao equipamento mesmo em concentrações moderadas.

O triângulo é traçado utilizando os dados históricos obtidos pela análise de gases dissolvidos no óleo. O tipo de falta é diagnosticado diretamente no gráfico triangular gerado.

Como usar:

1. Primeiramente determina-se a existência do problema através da aplicação das técnicas das Razões de Rogers e de Dornenburg ou dos gases chave já descritos, e ou a tabela 3 abaixo. Ao menos um dos gases hidrocarbonetos ou o hidrogênio (H<sub>2</sub>) devem estar na condição 3 do IEEE e o aumento da taxa de geração (G<sub>2</sub>) da tabela abaixo, antes que o problema seja confirmado. Para usar a tabela 17 a seguir sem o método do IEEE, ao menos um dos gases individuais deve estar no nível L1 ou acima e a taxa de geração de gás ao menos em G<sub>2</sub>. Os limites L1 e as taxas de geração de gases da tabela 17 são mais confiáveis que o método do IEEE; entretanto, deve-se usar ambos os métodos para confirmar a existência do problema. Os passos para o diagnóstico através do triângulo de Duval estão listados na próxima página.




Figura 12 – Triângulo de Duval

Onde: PD = Descargas Parciais (corona)  
T1 = Faltas Térmicas abaixo de 300 °C (pontos quentes)  
T2 = Faltas Térmicas entre 300 ° e 700 °C (pontos quentes)  
T3 = Faltas Térmicas Maiores que 700 °C (pontos quentes)  
D1 = Descarga de Baixa Energia (Centelhamento)  
D2 = Descarga de Alta Energia (Arco Elétrico I > 20 In)  
DT = Ocorrência Simultânea de Falta Térmica e Arco

<b>Gás</b>	<b>Limite L1</b>	<b>Limite G1 (ppm/mês)</b>	<b>Limite G2 (ppm/mês)</b>
H <sub>2</sub>	100	10	50
CH <sub>4</sub>	75	8	38
C <sub>2</sub> H <sub>2</sub>	3	3	3
C <sub>2</sub> H <sub>4</sub>	75	8	38
C <sub>2</sub> H <sub>6</sub>	75	8	38
CO	700	70	350
CO <sub>2</sub>	7000	700	3500

Tabela 18 – Limites e taxas de geração de gases

Se houver um súbito incremento em H<sub>2</sub> com somente monóxido de carbono (CO) e dióxido de carbono (CO<sub>2</sub>) e pouco ou nenhum gás hidrocarboneto, usar a razão CO<sub>2</sub>/CO abaixo para determinar se a isolação da celulose está degradada por sobre aquecimento.

2. Confirmando a existência do problema, usar a quantidade total de gases acumulados do triângulo de Duval e plotar as percentagens do total no triângulo para chegar a um diagnóstico. Também, calcular a quantidade dos três gases usados no triângulo de Duval, gerados desde o início do súbito incremento. Subtraindo o total dos gases gerados desde o súbito aumento dos gases obtém-se a quantidade de gases gerados desde o início da falta.

a. Tomar a quantidade em partes por milhão de metano (CH<sub>4</sub>) obtida da análise de gases dissolvidos no óleo e subtrair a quantidade CH<sub>4</sub> desde a primeira análise de gases, antes do aumento súbito de gases. Isto dará a quantidade de metano gerada desde o início do problema.

b. Repetir o processo para os dois gases restantes, etileno (C<sub>2</sub>H<sub>4</sub>) e acetileno (C<sub>2</sub>H<sub>2</sub>).

3. Adicionar os três números (diferenças) obtidos no passo dois do processo acima. Isto representa 100% dos três gases chave gerados desde o início da falta.
4. Dividir cada diferença individual de gás pela diferença total dos gases obtidos no passo 3 acima. Isto fornece o aumento percentual de cada gás em relação ao aumento total.
5. Plotar o percentual de cada gás no triângulo de Duval, começando do lado de um gás em particular. Desenhar linhas paralelas através do triângulo para cada gás a partir da marcas mostradas em cada lado do triângulo.

Na maioria dos casos o acetileno ( $C_2H_2$ ) será zero, e o resultado será um ponto no lado direito do triângulo de Duval.

## **2.8 Técnicas modernas de detecção de falhas incipientes baseadas em IA**

Os métodos do gás chave, de Rogers e de Dornenburg são facilmente computados e dão bons resultados para o diagnóstico para a prevenção ou após a ocorrência de falhas severas em transformadores mas podem ser pouco sensíveis na detecção de falhas. Entretanto são usados como guias para os sistemas inteligentes baseados em inteligência Artificial.

Técnicas de inteligência artificial tais como Sistemas Especialistas [Barret 89, Lin, 93], Joseph, 94], Lógica Fuzzy [Dukarm, 93], [Tom 93], [Huang, 97], [Gao, 98], [Yang, 98] e Redes Neurais Artificiais (ANN) [Dukarm, 93], [Sumit, 93], [Ding, 95],

[Zhang, 97], [Wang, 97, 98], [Yang 98 para assistir a análise de gases dissolvidos em óleo têm sido bastante pesquisadas e utilizadas desde os anos 90.

### **2.8.1 Sistemas especialistas**

Um Sistema Especialista é um método que fornece o diagnóstico da falta e sugestões para a manutenção. Os métodos de análise de gases dissolvidos no óleo formam a maior parte do sistema além de outras regras de diagnóstico que têm sido desenvolvidas pelas indústrias. Informações, tais como, o tipo de transformador, nível de tensão, tendência de formação de gases, e histórico de manutenção são também incorporados.

Há um bom número de sistemas especialistas já desenvolvidos e em uso pelas empresas de energia. A tabela a seguir lista três deles como exemplos, dos quais podemos resumir as três últimas funções que deverão ser incluídas em um sistema de diagnóstico de falhas para transformadores de potência: primeiro, o “mecanismo central de diagnóstico” incorpora vários métodos de análise de gases dissolvidos em óleo; depois, um “gerente especialista” considera regras especiais; e por fim, o “consultor da manutenção” propõe a época da próxima análise e as ações de manutenção que devem ser tomadas.

A eficácia de um sistema especialista depende da precisão e da extensão de dados da base de conhecimento, que normalmente é muito complicada e deve ser construída manualmente. O maior problema com os sistemas especialistas é que estes não podem ajustar automaticamente as regras de diagnósticos, e assim não

podem adquirir conhecimento a partir de novas amostras de dados através de um processo de auto-aprendizagem. Uma vez construídos são normalmente difíceis de ser atualizados.

Referência	Métodos DGA	Características
[BARRET, 89]	Razões de Rogers IEC 599 Gás Chave	<ul style="list-style-type: none"> <li>Controle do estado da gaxeta e do aquecimento</li> <li>Controle do conteúdo de água e do aquecimento</li> <li>“Norma” baseada na identificação do nível de gases suspeitos</li> </ul> Orientações de manutenção baseadas na TDCG
[LIN, 93]	Razões de Dornenburg Razões de Rogers IEC599	<ul style="list-style-type: none"> <li>Tendência das razões, limites da norma, gás chave e outros especialistas considerados.</li> <li>Conjuntos fuzzy condicionados aos limites da norma, análises de razões limites e de gases chave.</li> </ul> Regras Heurísticas de manutenção
[JOSEPH, 94]	Método das razões	<ul style="list-style-type: none"> <li>Limites da “Norma”</li> <li>Análise de tendências históricas</li> <li>Regras Heurísticas de experiências</li> <li>Banco de dados e acesso avançado a dados remotos</li> <li>Recomendações de manutenção</li> </ul>

Tabela 19 – Sistemas Especialistas para Diagnóstico de Transformadores de Potência

Um sistema especialista para o método de Rogers pode ser implementado por programação a partir de um fluxograma:

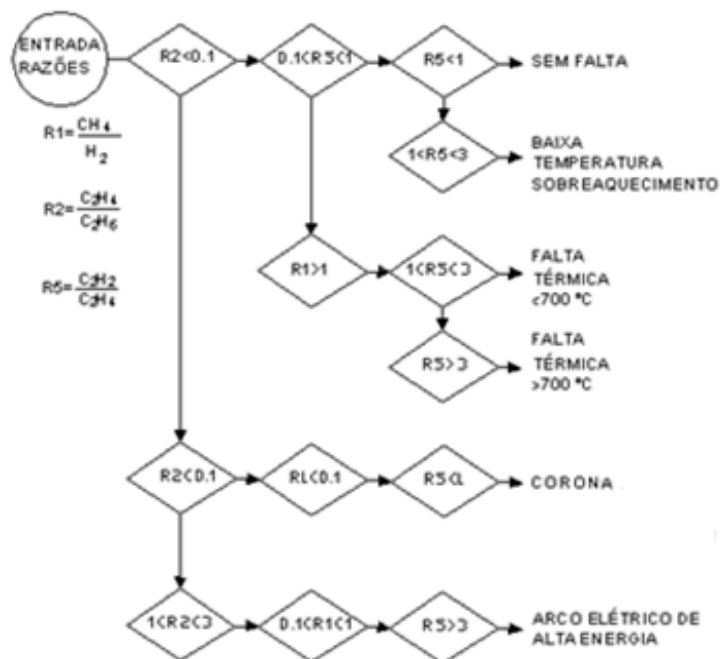


Figura 13 – Fluxograma para diagnóstico através do método de Rogers

Ou para o método de Dornenburg:

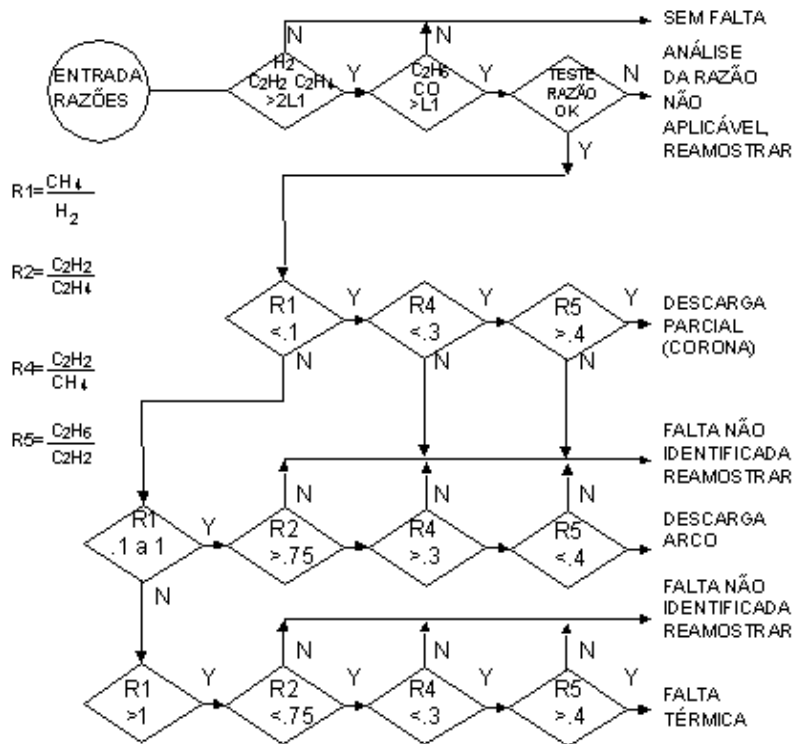


Figura 14 – Fluxograma para diagnóstico através do método de Dornenburg

### 2.8.2 Lógica Fuzzy

A Lógica Fuzzy é baseada na teoria dos Conjuntos Fuzzy. Esta é uma generalização da teoria dos Conjuntos Tradicionais para resolver os paradoxos gerados a partir da classificação “verdadeiro ou falso” da Lógica Clássica. Tradicionalmente, uma proposição lógica tem dois extremos: ou “completamente verdadeiro” ou “completamente falso”. Entretanto, na Lógica Fuzzy, uma premissa varia em grau de verdade de 0 a 1, o que leva a ser parcialmente verdadeira ou parcialmente falsa, permitindo assim incluir a imprecisão ("fuzziness") nos processos decisórios usando termos lingüístico, tais como: alto, morno, ativo, pequeno, perto, etc. o que caracteriza o grau de pertinência variável (valor que indica o grau em que um elemento pertence a um conjunto).



A força da Lógica Fuzzy deriva da sua habilidade em inferir conclusões e gerar respostas baseadas em informações vagas, ambíguas e qualitativamente incompletas e imprecisas. Neste aspecto, os sistemas de base Fuzzy têm habilidade de simular o raciocínio de forma semelhante à dos humanos. Seu comportamento é representado de maneira muito simples e natural, levando à construção de sistemas compreensíveis e de fácil manutenção.

Usando a teoria de inferência fuzzy, pode ser construído um conjunto fuzzy baseado no diagnóstico de falhas [Tom, 93]. O foco principal é sintonizar as funções de pertinência baseadas nos métodos e experiências da análise de gases dissolvidos no óleo. Convencionalmente isto é feito manualmente [Tom, 93, Dukarm 93], e depois automaticamente utilizando métodos matemáticos sofisticados como computação evolucionária (evolutionary computing), algoritmos genéticos, apodização adaptiva (adaptive pruning) [Huang, 97], [Yang, 98].

Dukarm [Dukarm, 93] verificou que uma abordagem utilizando técnicas fuzzy e sistemas de inferência fuzzy se aplicariam aos métodos de análise de gases dissolvidos já apresentados. Como os métodos de diagnóstico de Rogers e Dornenburg baseiam-se em valores limiares, para que se possa aplicar a lógica fuzzy juntamente com estes métodos, as razões de gases são aplicadas a um sistema de inferência onde as funções de pertinência associadas aos conjuntos fuzzy são relacionadas às variáveis consideradas. Para cada gás é associado um conjunto denominado Baixo, Médio ou Alto de acordo com seu nível de concentração no óleo.

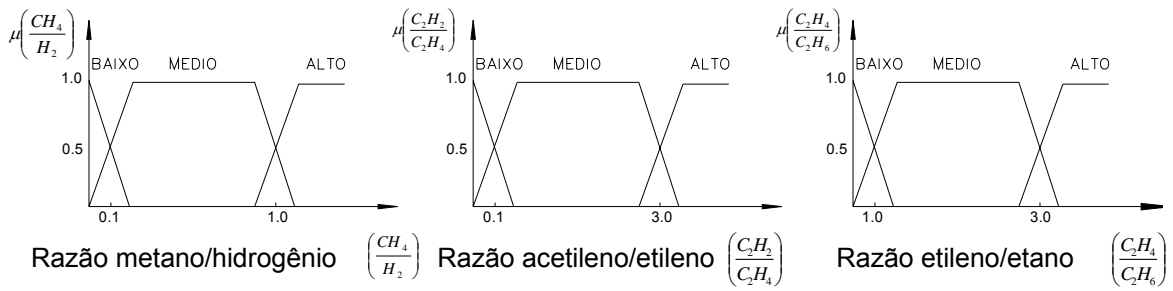


Figura 15 – Diagramas fuzzy para cada razão de gás

As regras são testadas conforme ilustra a figura abaixo sendo que a regra que possuir maior grau de ativação será associada ao diagnóstico final.

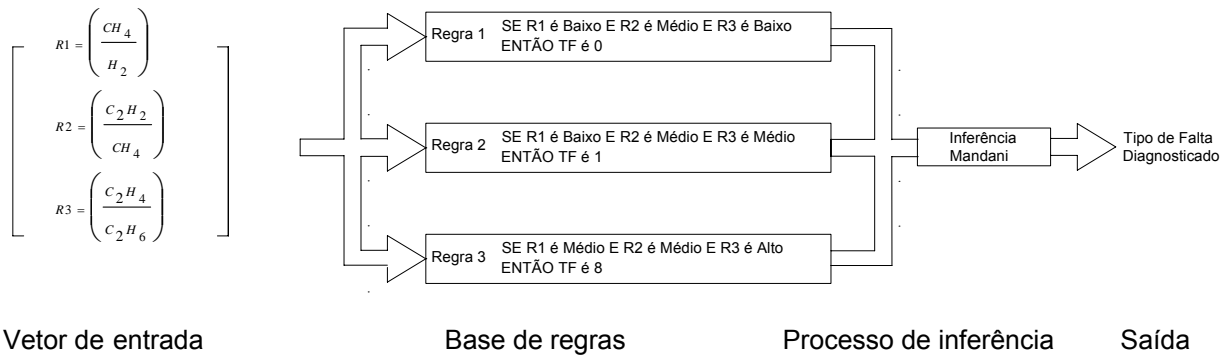


Figura 16 – Sistema de inferência para diagnóstico de falhas em transformadores para Rogers

A saída fuzzy será um dos tipos de falta classificados na tabela 20 [IEC 10A 53] recomendada pelo IEEE onde L, M, e N são os conjuntos fuzzy Baixo, Médio e Alto.

Código de Faixas de Razão		Razão de Gases Característicos		
		C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>	CH <sub>4</sub> /H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>
< 0.1		0 (L)	1 (L)	0 (L)
0.1 a 1.0		1 (M)	0 (M)	0 (L)
0.1 a 3.0		1 (M)	2 (H)	1 (M)
> 3.0		2 (H)	2 (H)	0 (L)
Código da Falta	Tipo de Falta Característica			
0	Operação Normal	0 (L)	0 (M)	0 (L)
1	Falta Térmica de Baixa Intensidade < 150°C	0 (L)	0 (M)	1 (M)
2	Falta Térmica de Baixa Intensidade 150° a 300°C	0 (L)	2 (H)	0 (L)
3	Falta Térmica de Média Intensidade 300° a 700°C	0 (L)	2 (H)	1 (M)
4	Falta Térmica de Alta Intensidade > 700°C	0 (L)	2 (H)	2 (H))
5	Descargas Parciais de Baixa Intensidade	0 (L)	1 (L)	0 (L)
6	Descargas Parciais de Alta Intensidade	1 (M)	1 (L)	0 (H)
7	Descargas de Baixa Intensidade	1-2 (M-H)	0 (M)	1-2 (M-H)
8	Descargas de Alta Intensidade	1 (M)	0 (M)	2 (H)

Tabela 20 – Código para Gases Dissolvidos em Óleo Mineral – IEC 10A 53

### **2.8.3 Redes neurais**

Dukarm tentou usar redes neurais artificiais (ANN) para o diagnóstico de falhas em transformadores no início dos anos 90 sem seguir adiante, provavelmente devido à falta de qualidade dos dados [Dukarm, 93].

Houve alguns estudos ao final dos anos 90 [Esp, 98], [Yang, 98], [Gao, 98], mas foram atividades separadas que não constituíram uma séria consideração do problema.

Em meados dos anos 90 iniciaram-se esforços de pesquisa na Universidade de Tecnologia da Virgínia, [Ding, 95], [Zhang, 96], [Zhang, 97], [Wang, 97], [Wang, 98]. Estes esforços incluíram não só estudos metodológicos, mas também coleta de dados e testes industriais. Como resultado, um sistema de diagnóstico foi desenvolvido com tecnologias ANN e um sistema especialista [Wang, 98].

Uma importante vantagem baseada no diagnóstico de falhas ANN é que ele pode aprender diretamente a partir de amostras de treinamento, e atualizar seus conhecimentos quando necessário. A alta capacidade de mapeamento não linear dos neurônios garante um desempenho quase sempre superior às soluções dos sistemas fuzzy. A complexidade computacional das ANN não é tão grande, no processo de teste (diagnóstico). Como este método é o proposto para o desenvolvimento desta dissertação, será mais extensamente tratado no próximo capítulo.

#### **2.8.4 Sistemas híbridos**

Buscando obter melhor desempenho dos sistemas inteligentes de diagnósticos vários pesquisadores têm desenvolvido sistemas híbridos que combinam dois ou mais métodos de IA para a solução de diagnósticos complexos para falhas em transformadores isolados com óleo isolante. Encontramos na literatura a combinação de sistemas especialistas e lógica fuzzy, sistemas especialistas e redes neurais, redes neurais e lógicas fuzzy, algoritmo genético e redes neurais e outras associações. Porém todos utilizam os resultados e dados dos métodos tradicionais e o conhecimento de especialistas como dados de entrada para estes sistemas.

## CAPÍTULO 3

### 3. Redes Neurais Artificiais

#### 3.1 Introdução

Há mais de meio século o homem busca modos de resolução de problemas cotidianos, extremamente complexos ou nem tanto, através de métodos que tentam imitar o funcionamento do cérebro biológico. Após o surgimento da eletrônica e principalmente como o seu desenvolvimento, era natural esperar do ser humano a busca de uma simulação do funcionamento do cérebro, através da construção de circuitos que tentassem imitar suas funções. Neste capítulo pretendemos apresentar as características das chamadas Redes Neurais Artificiais (RNA), que são modelos matemáticos inspirados no sistema nervoso biológico, e como elas podem ser utilizadas para o diagnóstico de problemas. Redes Neurais é uma sub-especialidade da Inteligência Artificial (IA) também chamada de Sistemas Inteligentes. Um sistema inteligente deve ser capaz de adaptar-se a novas situações, realizar interações, entender relações entre fatos, descobrir significados, reconhecer padrões e aprender com base em sua experiência. No próximo capítulo iremos implementar uma concepção de rede neural visando agilizar o diagnóstico de falhas incipientes em transformadores imersos em óleo isolante.

### 3.2 Histórico

O homem estuda o cérebro há várias centenas de anos tentando entender o seu funcionamento. Mas foi em 1943 que um neurologista americano chamado Warren McCulloch e um matemático de nome Walter Pitts escreveram o possível funcionamento dos neurônios modelando uma rede neural simples através de circuitos eletrônicos. Donald Hebb em seu livro intitulado *Organization of Behaviour* reforçou este conceito apontando as interligações neuronais e aplicabilidade e cada vez são mais usadas.

Nathaniel Rochester da IBM, á partir do advento dos computadores nos anos 50, foi o primeiro a tentar simular o funcionamento neuronal tentando modelar o rudimento destas teorias. A primeira tentativa foi frustrante, mas tentativas posteriores, bem mais tarde tiveram sucesso. A ênfase no desenvolvimento da computação da época deixou o problema em segundo plano. Mas em 1956 o projeto de pesquisa de verão em Inteligência Artificial do Dartmouth College deu um grande impulso tanto à inteligência artificial ou AI, como era conhecida na Indústria, quanto às redes neurais estimulando a pesquisa.

Nos anos seguintes, John von Neumann sugeriu imitar o funcionamento de um neurônio simples utilizando relés telegráficos e válvulas. Também Frank Rosenblatt, um neuro-biologista da Universidade de Cornell começou a trabalhar em um projeto conhecido por Perceptron. Ele estava intrigado com o processo de vôo de uma mosca, pois parecia este estar ligado ao olho dela. O resultado desta pesquisa,

o Perceptron, foi o hardware por ele construído é a rede neural mais antiga e que é utilizada até hoje.

Em 1959, Bernard Widrow e Marcian Hoff da Universidade de Stanford desenvolveram modelos chamados de Adaline e Madaline (Multiple ADaptive LINear Elements). A primeira rede neural aplicada a um problema real, foi a Madaline simulando um filtro adaptivo que eliminava ecos em linhas telefônicas e é atualmente ainda usada.

Infelizmente o potencial das redes neurais foi exagerado pelas pessoas e devido à limitação da eletrônica e o excesso de literatura ficcional, através de livros como os de Isaac Asimov e suas máquinas pensantes que sugeriam a substituição do ser humano por robôs e do filme 2001 Uma Odisséia no Espaço, trouxe desapontamentos tanto à população quanto aos meios acadêmicos, deixando a indústria de financiar as necessárias pesquisas para continuar o desenvolvimento nesta área do conhecimento. Além disso, Minsky e Pappert publicaram em 1969 um livro intitulado “Perceptrons” onde provavam que as estruturas utilizadas nos dispositivos da época eram incapazes de aprender regras lógicas tão simples quanto à do “OU” exclusivo.

Este período obscuro da computação durou até. Em 1982 John Hopfield apresentou um artigo na Academia de Ciências que não era um simples modelo do cérebro, mas criava dispositivos úteis. Através de análise matemática ele mostrou como as redes poderiam trabalhar e o que elas poderiam fazer. Ao mesmo tempo



uma conferência em Kyoto no Japão anunciou a quinta geração de computadores o que levou a imprensa dos Estados Unidos a questionar um possível atraso na corrida do conhecimento. Isto produziu um novo fluxo de investimentos em pesquisas explorando diversas possibilidades de aplicação foram exploradas, como por exemplo, em otimização, em reconhecimento de padrões, etc., com resultados bastante encorajadores.

Em 1986 Rumelhart e McClelland, Hinton e Willians [Rumelhart, 86 ] explicaram um algoritmo de aprendizagem chamado de Backpropagation para redes do tipo Perceptron com estrutura multicamadas que colocou a área de Redes Neurais Artificiais com uma das prioritárias na obtenção de recursos. Á partir de então, com o desenvolvimento de vários projetos financiados principalmente pelo Departamento de Defesa dos Estados Unidos, as discussões sobre as redes neurais têm-se ampliado e o anúncio de novas aplicações têm sido freqüentes principalmente na indústria e constituem uma teoria para estudo de problemas ou fenômenos complexos.

Hoje, um dos fatores limitantes das pesquisas é o desenvolvimento de hardware e de software. Na tentativa de que os projetos saiam dos laboratórios para colocá-los em uso, busca-se implementar os protótipos em neuro-chips analógicos, digitais e óticos, sendo que estes últimos têm-se revelado como os mais promissores.

### 3.3 Características básicas de uma Rede Neural (RN)

Como já foi dito, as RNA são modelos matemáticos inspirados no sistema nervoso, o que as torna diferentes da computação convencional, cuja função é determinada pelas conexões entre seus elementos. É um processador distribuído que tem como tendência natural armazenar o conhecimento e torná-lo disponível para uso [Arbib, 2002].

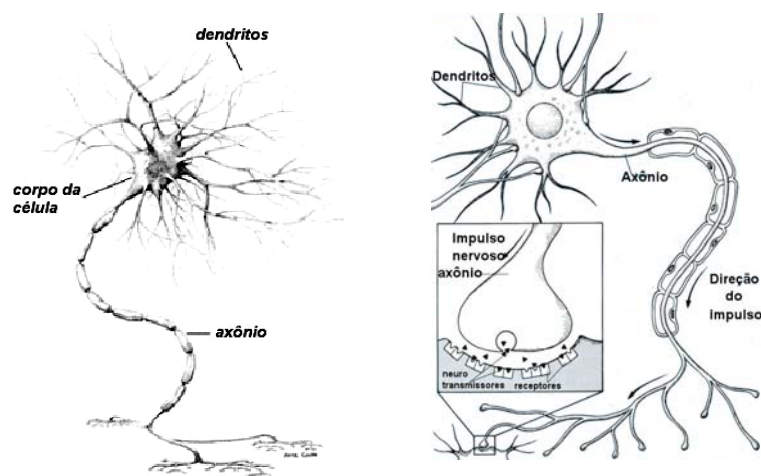


Figura 17 – Neurônio biológico

O elemento mais básico do cérebro humano é um tipo específico de célula chamado neurônio que tem a habilidade de lembrar, pensar e aplicar experiências anteriores nas mais diversas ações. Estima-se que o cérebro possua aproximadamente 10 bilhões de neurônios. Cada neurônio pode conectar-se a outros milhares através de um processo físico-químico chamado sinapse. A quantidade destas células especialistas e o número de conexões entre elas determinam o potencial do cérebro. O cérebro tem receptores sensoriais de entrada e neurônios motores para a saída. No ser humano há entre sete e um milhar de classes diferentes de neurônios já identificadas.

O sistema nervoso responde quase imediatamente a estímulos que são produzidos pelos neurônios na forma de impulsos elétricos e formam a bases estrutural e funcional deste sistema. Há várias formas de neurônios cada um com uma aparência física diferente.

Neurônios são pequenas massas de citoplasma com um núcleo central. Um sistema capilar – filamentos citoplásmicos - interligados aos neurônios e chamados de dendritos conduz os impulsos elétricos através das células do corpo humano, com uma simples e longa fibra chamada axônio que são a via de condução dos impulsos elétricos. Alguns axônios são cobertos com um revestimento de mielina recoberto por células de Schwann que também participam de sinapses.

A fibra nervosa tem a propriedade especial de transmitir impulsos elétricos muito rapidamente através de todo seu comprimento e passá-los á próxima célula nervosa interligada. O corpo da célula normalmente está no cérebro ou na coluna vertebral enquanto que o axônio ou dendrito estende-se até o órgão em questão, por exemplo, desde a base da espinha até o dedão do pé. O axônio possui uma carga elétrica que é liberada quando o nervo é estimulado e é carregada novamente antes que o próximo impulso seja enviado. Células nervosas geralmente enviam impulsos em somente uma direção.

Um simples impulso pode não ser feito através de sinapse podendo ser constituído por uma rápida sucessão de dois ou três impulsos vindos por um dendrito ou talvez por dois ou mais para iniciar a descarga para o próximo neurônio. O corpo de uma célula individual pode ter sinapses vindas de fibras próximas e é através das sinapses que as diferentes partes do corpo e do cérebro são mantidas

em comunicação. Por causa da enorme possibilidade de interconexões e desde que a chegada de impulsos simultâneos a uma célula pode estimular ou inibir a retransmissão de um impulso subsequente, a sinapse é provavelmente a unidade básica de saída do “processador” do sistema nervoso central, tornando possível uma efetiva coordenação e aprendizagem.

Uma Rede Neural Artificial (RNA ou ANN) funciona de maneira similar aos neurônios do cérebro onde a rede através do processo de aprendizagem adquire conhecimento e as forças de conexão interneural conhecidas como pesos sinápticos são usadas para armazenar o conhecimento. Redes neurais é assim uma nova técnica de processamento de informação. São simulações de sistemas nervosos vivos e baseados em computador que operam de forma bem diferente da computação convencional.

Assim, uma rede neural é uma rede de neurônios ou Elementos de Processamento (PE's) e conexões ponderadas. As conexões correspondem aos axônios e os pesos às sinapses no cérebro biológico. A PE realiza duas funções. Ela soma as entradas vindas de várias conexões e então aplica a função de transferência à soma. O valor resultante é propagado através de conexões de saída para outros PE's. Tipicamente esses PE's estão arranjados em camadas; Com a camada de entrada recebendo inputs do mundo real e cada layer sucessiva recebendo saídas ponderadas da layer precedente como inputs. Daí a criação da rede neural feedforward onde cada input alimenta a layer que sucede. A primeira e a última layer nessa configuração de rede neural são tipicamente referidas como layer de entrada e de saída. (Elementos de processamento de layers de entrada não são verdadeiramente PE's já que não executam uma computação na entrada.)

Quaisquer layers entre as layers de entrada e saída (usualmente uma ou mais) são chamadas de layers escondidas ou hidden layer porque não têm contato com dados de entrada ou de saída do mundo real.

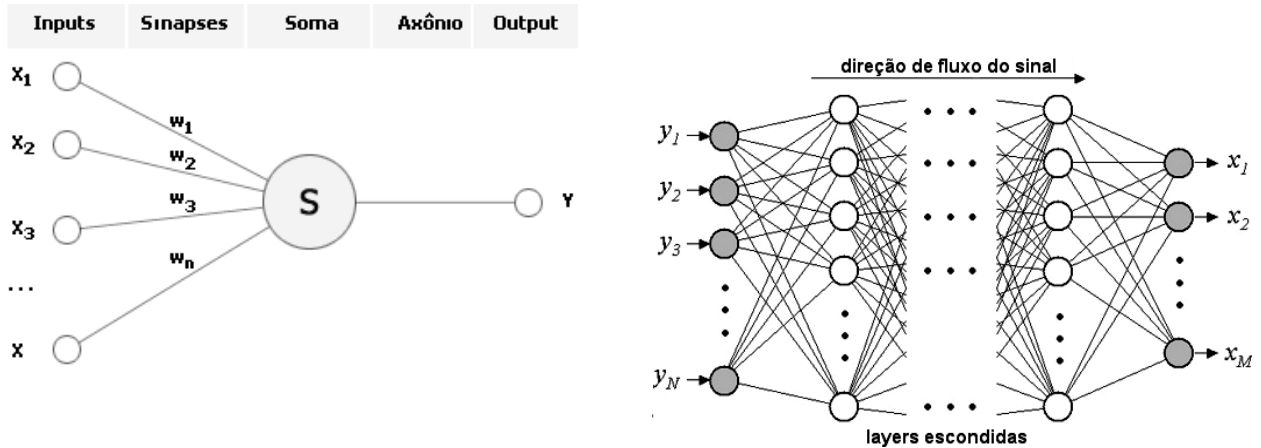


Figura 18 – Exemplos de Rede Neural Artificial

Esta estrutura é, porém, bem diferente daquela dos computadores a que estamos acostumados a usar desde os anos 40. As redes neurais são compostas não de uma ou duas, mas de muitas unidades de processamento que são conectadas entre si formando a rede.

Seu poder computacional depende do trabalho conjunto das muitas tarefas – isto é chamado, algumas vezes de processamento paralelo. Não há uma CPU central seguindo uma seqüência lógica de regras – ao contrário, não há um conjunto de regras ou programas como nos computadores.

O neurônio artificial ou elemento de processamento, ou ainda, unidade de processamento é um simples dispositivo capaz de calcular o somatório de  $N$  entradas ponderadas, cujo resultado passa através de uma função não-linear. Basicamente, este dispositivo é caracterizado por um “offset” ou limiar interno e por algum tipo de função não-linear, como mostra a figura.

O corpo das células dos neurônios soma os sinais que chegam dos dendritos. Um neurônio particular enviará um impulso para seu axônio se os sinais recebidos na entrada forem suficientes para estimular o neurônio a certo nível. Se as entradas não atingirem este nível ou limiar a entrada decairá e não gerará qualquer ação.

A saída  $Y$  do dispositivo é função do somatório das entradas  $x_1, x_2, \dots, x_{n-1}$ , ponderadas pelos pesos  $w_1, w_2, \dots, w_{n-1}$  menos o offset  $\theta$ .

$$y = \sum_{i=1}^n (X_i W_i) - \theta_k$$




Figura 19 – Representação de um neurônio artificial

Os valores  $x_1, x_2, x_3, \dots, x_n$  são os valores de entrada da rede. Os valores  $w_1, w_2, w_3, \dots, w_n$  são pesos associados a cada nó para determinar a intensidade do vetor linha de entrada.

Cada entrada é multiplicada pelo peso associado à conexão do neurônio  $x_i w_i$ . Dependendo da função de ativação, se o peso é positivo,  $x_i w_i$  normalmente excita o nó de saída; diferentemente, para pesos negativos,  $x_i w_i$  tende a inibir o nó de saída.

O valor de  $\theta$ , também chamado “vício” ou limiar, tem a finalidade de aumentar o número de graus de liberdade do modelo, permitindo um aumento na capacidade da rede neural para se ajustar ao conhecimento que lhe é fornecido. Ele afeta a ativação do nó de saída  $Y$ .

### 3.4 A função de ativação de uma RNA

Um dos mais influentes pesquisadores em sistemas neurológicos (Donald Hebb) propôs que a aprendizagem consiste, principalmente, da intensidade das conexões sinápticas.

Uma função de ativação executa uma operação matemática no sinal de saída. Funções de ativação mais sofisticadas podem também ser utilizadas dependendo do tipo de problema a ser resolvido pela rede. Normalmente são usadas:




Figura 20 - Tipos de função mais comuns aplicadas às Redes Neurais Artificiais

A saída de função sigmoidal é a função mais comum de ativação utilizada em

redes neurais:  $f(x) = \frac{1}{1 + e^{\alpha \cdot x}}$ ,  $0 \leq f(x) \leq 1$  Onde  $\alpha$  define a forma de  $f(x)$

Normalmente a saída depende da função de ativação escolhida. Entretanto, se não se quiser ter um bias em um neurônio em particular, ele pode ser omitido.

Tipicamente a função de transferência é escolhida pelo projetista e os parâmetros são ajustados de acordo com uma regra de aprendizagem que as relações de saída entrada/saída encontram para um caso específico.

### **3.5 Treinamento e classificação de uma RNA**

Redes Neurais Artificiais, como as pessoas, aprendem a partir de exemplos. Backpropagation é uma das possíveis regras de aprendizagem para ajustar as conexões dos pesos durante a aprendizagem por exemplos. A aprendizagem ocorre quando os pesos da rede são ajustados como uma função do erro encontrado na saída da rede. O erro é a diferença entre a saída esperada e a saída normal. Os pesos são ajustados para trás (propagados para trás) através da rede neural até que o erro esteja minimizado para o conjunto de dados de treinamento.

Existem diversos tipos de RNA e diferentes maneiras de classificá-las. Talvez a mais importante seja quanto à forma de aprendizado que pode ser supervisionada e não supervisionada.

No aprendizado supervisionado são sucessivamente apresentadas à rede conjuntos de padrões de entrada e seus correspondentes padrões de saída. Durante este processo, a rede realiza um ajustamento dos pesos das conexões entre os elementos de processamento, segundo uma determinada lei de aprendizagem, até que o erro entre os padrões de saída gerados pela rede alcance um valor mínimo desejado. Por exemplo, perceptron, adaline e madaline, backpropagation são algumas dentre as dezenas de leis de aprendizagem supervisionada.



No aprendizado não-supervisionado a rede “analisa” os conjuntos de dados apresentados a ela, determina algumas propriedades do conjunto de dados e “aprende” a refletir estas propriedades na sua saída. A rede utiliza padrões, regularidades e correlações para agrupar os conjuntos de dados em classes. As propriedades que a rede vai “aprender” sobre os dados podem variar em função do tipo de arquitetura utilizada e da lei de aprendizagem. Por exemplo, Mapa Auto-Organizável de Kohonen, Redes de Hopfield e Memória Associativa Bidirecional, são alguns métodos de aprendizado não-supervisionado.

Essencialmente o aprender de redes neurais consiste em colocar valores de conexões sinápticas. Em alguns casos estes valores são colocados representando certo conhecimento, como no caso usado em sistemas especialistas. Em outros se usa um algoritmo para encontrá-los. A este algoritmo chama-se algoritmo de aprendizagem.

A lei de Hebb é talvez a mais antiga regra de aprendizagem usada. Uma extensão desta lei é: “Ajuste a intensidade da conexão entre os neurônios A e B de uma quantidade proporcional ao valor da ativação simultânea dos dois neurônios. Se, no entanto A tenta excitar B e não consegue a conexão é enfraquecida.”

Uma característica importantíssima da lei de Hebb é que ela goza da propriedade de localidade. Isto significa que para alterar o valor de uma conexão sináptica apenas informações locais à sinapse em jogo são usadas dando plausibilidade biológica ao algoritmo. A expressão usada na Lei de Hebb é muito simplificada. Com efeito, considerando uma sinapse real tem-se:

$$\Delta w_{ij} = a_i a_j$$

O valor da modificação da intensidade da conexão sináptica para mesmas excitações dos neurônios envolvidos pode variar com o tempo. A modificação da intensidade da conexão sináptica  $\Delta w_{ij}$  de  $w_{ij}$  pode depender de  $w_{ij}$  o que será um efeito não linear (anteriormente tem-se um sistema bi-linear por apresentar um produto de duas intensidades). Isto ocorre como um efeito de saturação do valor de conexão sináptica. Pode-se imaginar que a modificação da intensidade da conexão sináptica dependa também de neurônios vizinhos.

Um modelo um pouco mais completo seria:

$$\Delta w_{ij} = \phi(x_i, d_i, w_{ij}, o_j, t)$$

Note-se que  $d_i$  não é local à sinapse, mas local com relação ao neurônio  $i$ .

Uma expressão um pouco mais simples seria obtida com a função  $\eta$  dependendo da diferença entre a excitação real do neurônio  $i$  e a que seria desejada.

Com isto tem-se a Regra de Widrow-Hoff ou Regra Delta que pode ser expressa como:  $\Delta w_{ij} = \eta(d_i - x_i)o_j$

Nesta regra de aprendizado toda a informação necessária à modificação de uma sinapse é local à sinapse, sendo portanto um regra de aprendizado plausível.

A retro-propagação ou backpropagation pode ser considerada como a da Regra Delta generalizada para redes diretas com mais de duas camadas.

No aprendizado competitivo, usado nas redes popularizadas por Kohonen, neurônios são inibidos por outros neurônios de modo a que a competição entre eles leva apenas um deles acabar excitado. Assim, enquanto uma rede neural baseada em um aprendizado Hebbiano, vários neurônios de saída podem estar simultaneamente ativos, no caso do aprendizado competitivo, somente um neurônio de saída fica ativo de cada vez. Fundamentalmente existem três elementos que caracterizam o aprendizado competitivo:

1. Existe um conjunto de neurônios idênticos, ligados por valores de conexões sinápticas de valores distribuídos de modo aleatório.
2. Existe um valor máximo bem definido para a ativação dos neurônios.
3. Existe um mecanismo que permite que os neurônios entrem em competição pelo direito de permanecerem excitados.

No aprendizado competitivo entradas possuindo alguma semelhança tendem a excitar o mesmo neurônio na saída.

Existem ainda o Aprendizado Reforçado ou “Reinforcement learning” consiste no aprendizado através do método da tentativa e erro de modo a otimizar um índice de performance chamado sinal de reforço. O Aprendizado Aleatório quando os passos no sentido de se obter o comportamento aprendido se baseiam em valores tomados aleatoriamente que são testados para verificar sua adaptabilidade. O Aprendizado Evolutivo que é o paradigma de aprendizado que, tirando inspiração da evolução biológica é capaz de modificar a topologia e os valores das conexões sinápticas de modo a fazer uma rede se tornar apta a resolver um problema.

Uma rede neural treinada, isto é, a uma rede que aprendeu por exemplos, pode ser aplicada a problemas do mundo real de enorme complexidade. Sua vantagem mais importante é processar dados muito complexos para as tecnologias existentes - problemas que não têm uma solução algorítmica ou para os quais este tipo de solução é complexo demais para os dados existentes.

Em geral, devido a sua abstração do cérebro biológico, as redes neurais artificiais são ajustadas aos problemas aos quais as pessoas são boas para resolver, mas computadores nem tanto. Essa classe de problemas inclui o reconhecimento de padrões a previsão de tempo e o reconhecimento de tendências nos dados.

### 3.6 Perceptron Multilayer

MLP's ou perceptrons multilayers são arranjos multicamadas de elementos de processamento não lineares.




Figura 21 - Perceptrons multicamadas

Um arranjo com somente uma layer de entrada e uma de saída é chamada simplesmente de perceptron.

Uma rede encadeada para frente ou feedforward consiste de um número de neurônios conectados por links divididos em duas layers. Um conjunto de dados entrada é aplicado de fora da rede ou de uma layer anterior.

A figura a seguir ilustra uma rede encadeada para frente ou feedforward com duas camadas.




Figura 22 – Configuração de uma rede Perceptron Multi-Camada

Quando estruturamos uma rede MLP para um objetivo específico, geralmente, os valores assumidos pelos pesos são aleatórios ou zerados.

Quando falamos em aprendizado, não estamos sendo tão abrangentes quanto o processo de aprendizado referente ao ser humano o é.

Em uma rede MLP, o processo de aprendizado se restringe a uma espécie de treinamento por inibição e reforço, onde “penalizamos” a rede se a mesma estiver fora do padrão requerido ou a “elogiamos” quando está dentro do padrão.

Em outras palavras, o aprendizado estabelece valores para os pesos de forma a dar à rede um sentido de processamento. Se você entra com dados em uma rede não treinada, a saída é aleatória e não previsível.

À medida que mostramos à rede um padrão de entrada (amostragem), mostramos também como deve ser o resultado na saída da rede.

Cada entrada dos neurônios de entrada é então multiplicada por um peso  $w$ . A soma das entradas ponderadas e o bias  $b$  formam a entrada  $n$  para a função de transferência  $f$ . Neurônios podem usar qualquer função diferencial monotônica crescente para gerar suas saídas.

As redes Back-propagation freqüentemente usam as funções de transferência log-sigmoidal e tan-sigmoidal. Para cada neurônio da primeira camada, o neurônio da camada de saída é dado por:

$$a_1 = f_1(w_1 \cdot p + b_1)$$

e a saída da segunda layer é:

$$a_2 = f_2(w_2 \cdot a_1 + b_2) = f_2((w_1 \cdot p + b_1) + b_2)$$

onde  $p$  é a entrada da primeira layer;  $f_1$  e  $f_2$  são as funções de transferência,  $b_1$  e  $b_2$  são biases e  $w_1$  e  $w_2$  são os pesos das conexões da primeira e segunda layer

respectivamente para cada um deles. A rede é treinada para aprender as relações entre as entradas e as saídas esperadas.

Para o treinamento, um número par de padrões de entrada  $p$  e de alvos  $t$  é apresentado à rede neural e então é solicitado à rede o ajuste dos pesos em todos os links de conexões e também para os biases nos nós tal que os padrões de saída desejados são produzidos para os nós de saída.

As redes neurais podem ser divididas em duas classes: rede supervisionadas e não supervisionadas. Redes neurais supervisionadas, tais como o perceptron, usam o algoritmo de treinamento, o que significa que os dados de entrada e saída são necessários durante a fase de treinamento. O algoritmo de treinamento mais comum é o backpropagation. A grande maioria das redes neurais artificiais é treinada com supervisão. Neste modo, a saída normal da rede é comparada à saída desejada. Pesos, que normalmente iniciam com valores aleatórios, são ajustados pela rede de modo que, na próxima iteração, ou ciclo, produzirá um valor mais próximo entre a entrada desejada e a saída atual. O método de aprendizagem tenta minimizar os erros correntes de todos os elementos do processamento. Esta redução do erro global criada pela continua modificação dos pesos de entrada até que uma precisão aceitável da rede é alcançada.

Por outro lado, redes neurais não supervisionadas, tais como a rede de Kohonen, requer somente dados de entrada para ser treinada. Elas auto-organizam os dados de entrada, de acordo com uma métrica de similaridade que permite a rede aprender sem saber a resposta correta.

Certos modelos teóricos de redes neurais têm sido analisados de modo a que permitam certas propriedades tais como sua máxima capacidade de armazenamento ser calculada independentemente de qualquer algoritmo de treinamento.

### 3.7 Definição do Modelo, Topologia e Parâmetros da RN

A seleção das características de entrada é um primeiro passo essencial para a configuração de uma RNA. Deve ser uma escolha muito cuidadosa de modo que estas entradas refletirão as características do problema. Uma outra tarefa importante no projeto de uma RNA é a escolha da topologia da rede.

Isto é feito experimentalmente através de processos repetitivos para otimizar o número de nós e de layers escondidas de acordo como o processo de treinamento e da precisão desejada.

O número de neurônios da layer de entrada deve ser igual ao número de dados de entrada e o número de neurônios na layer de saída é normalmente definido de acordo com o número de variáveis de controle.

A figura ao lado ilustra um exemplo de uma rede com 9 inputs, uma camada escondida com 8 neurônios e 9 outputs:




Figura 23 - Exemplo de uma rede neural artificial



### **3.8. O futuro das Redes Neurais Artificiais**

As redes nem sempre levam a resultados com grande precisão. É por isso que as redes se aplicam onde humanos não são capazes de obter resultados com precisão. As redes neurais precisam de hardware muito rápido. Cada vez mais tomam parte de sistemas híbridos que utilizam lógica fuzzy e sistemas especialistas, quando não, também, sistemas evolucionários.

## **CAPÍTULO 4**

### **4. APLICAÇÃO DE REDES NEURAIS NO DIAGNÓSTICO DE FALHAS INCIPIENTES**

Redes neurais artificiais são sistemas inspirados nos neurônios biológicos e na estrutura massivamente paralela do cérebro, com capacidade de adquirir, armazenar e utilizar conhecimento experimental. Tipicamente consistem em centenas de unidades simples de processamento interligadas, formando uma rede de comunicação complexa.

Cada unidade ou nó da rede é um modelo simplificado de um neurônio biológico que dispara (envia um novo sinal) se ele recebe um forte sinal de entrada vindo de outros nós aos quais está conectado.

Uma tarefa importante no projeto de uma Rede Neural é a escolha da topologia da rede, isto é, os números de camadas e os números de neurônios por camada.

Isto é feito experimentalmente através de processos repetitivos e técnicas construtivistas para otimizar o número de nós e de layers escondidas de acordo como o processo de treinamento e da precisão desejada.

## **4.1 Topologia**

A topologia ou estrutura da RNA que usamos é a de uma rede neural com uma só camada escondida.

A seleção das características de entrada é um primeiro passo essencial. Deve ser uma escolha muito cuidadosa de modo que estas entradas refletirão as características do problema.

O número de neurônios da layer de entrada será igual ao número de dados de entrada e o número de neurônios na layer de saída será definido de acordo com o número de variáveis de controle – as respostas desejadas.

No meu caso, cinco gases chave precursores de falhas em transformadores,  $H_2$ ,  $CH_4$ ,  $C_2H_6$ ,  $C_2H_4$  e  $C_2H_2$ , são os escolhidos como características de entrada.

Inputs: As entradas da rede serão, pois, vetores com as concentrações de  $H_2$ ,  $CH_4$ ,  $C_2H_2$ ,  $C_2H_4$  e  $C_2H_6$  em ppm. Outputs: As saídas que queremos são os tipos de faltas que aquelas entradas podem resultar, ou seja, faltas térmicas ou sobre aquecimento, descargas parciais, arco elétrico, ou ainda faltas não identificadas, além da saída normal - caso os dados de entrada não impliquem em falha no transformador.

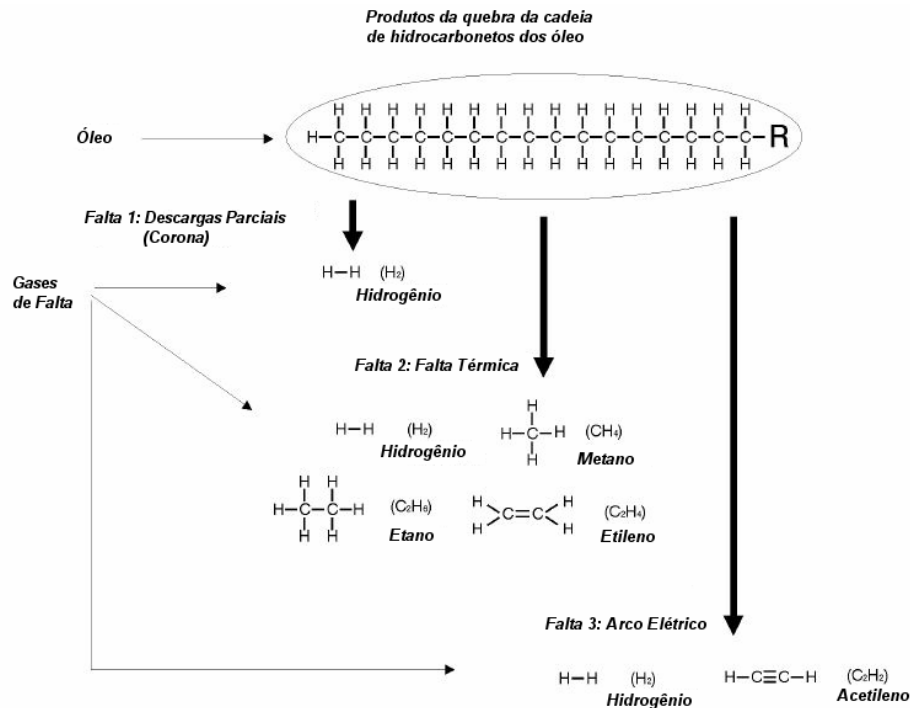


Figura 24 – Associação de gases e tipos de faltas

Hidden layer: A utilização de um grande número de camadas escondidas não é recomendada. A grande maioria dos problemas de classificação de padrões utiliza somente uma quando muito duas camadas escondidas. Aqui fez-se uso de apenas uma.

O número de neurônios na camada escondida geralmente é definido de modo empírico. Se forem utilizados neurônios demais, pode-se levar a rede a memorizar os dados do treinamento (overfitting) ao invés de extrair as características gerais que permitirão a generalização.

Neurônios a menos, podem forçar a rede a gastar tempo em demasia tentando encontrar uma representação ótima e assim a rede pode não convergir durante o seu treinamento (underfitting).

Pode-se definir este número como sendo a média geométrica entre o tamanho da entrada e o tamanho da saída ou números que podem variar de  $2n+1$  a  $2^{0.5}+1$  [Fletcher et Goss, 91] ou igual a  $3n$  onde  $n$  é o número de camadas de entrada ou de saída. Assim, poderíamos ter 5, 11 ou 15 neurônios.

Obteve-se experimentalmente a rede dessa dissertação e verificou-se que a topologia que teve o melhor desempenho, isto é, convergiu mais rapidamente com menor erro e menor número de épocas para o conjunto de dados disponíveis no estudo foi a rede com 11 neurônios. Assim:

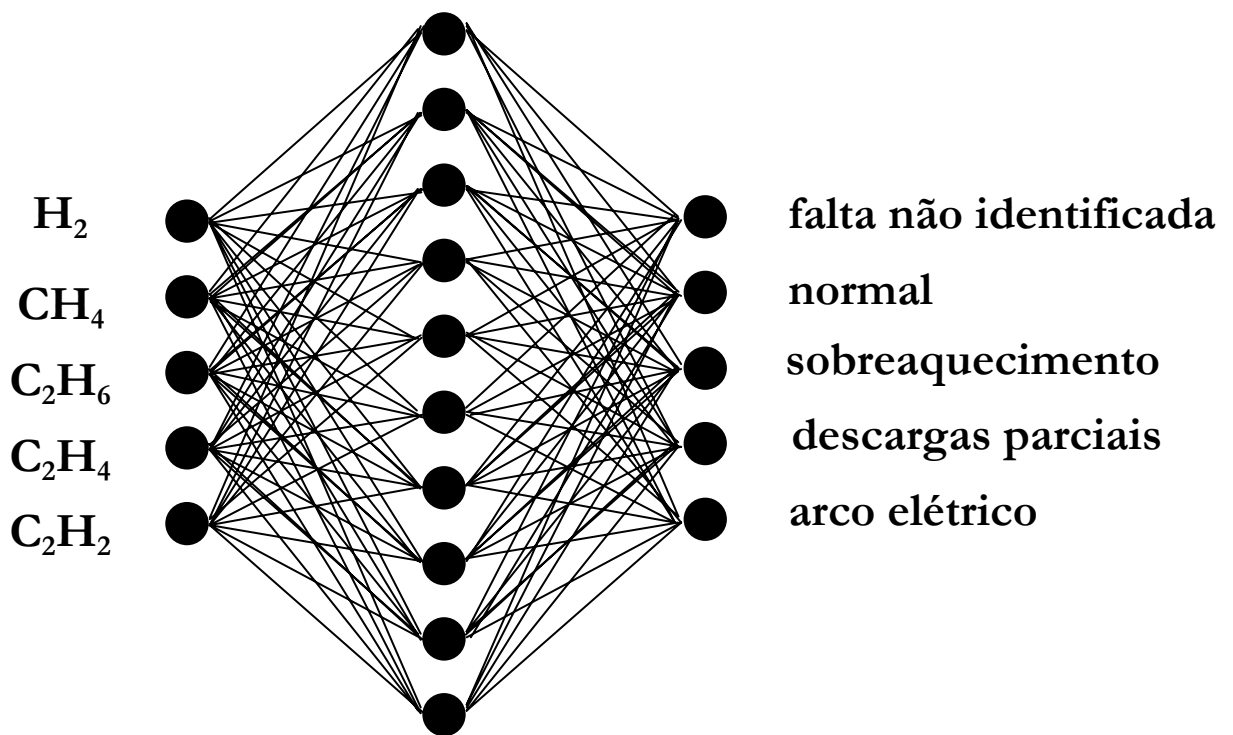


Figura 25 – Topologia da rede utilizada na dissertação

Taxa de treinamento: Configuramos para o valor 1.

Momentum: ou fator de amortecimento feito igual a 0.9.

Dados de entrada: São as concentrações dos gases encontradas no ensaio cromatográfico da análise das amostras colhidas ao longo da vida do transformador (treinamento) ou na amostra suspeita (rede em uso normal). A figura seguinte ilustra como exemplo, 10 dos padrões usados no treinamento.

Concentrações dos gases chave em ppm:

<b>Padrões</b>	<b>H<sub>2</sub></b>	<b>CH<sub>4</sub></b>	<b>CO</b>	<b>CO<sub>2</sub></b>	<b>C<sub>2</sub>H<sub>4</sub></b>	<b>C<sub>2</sub>H<sub>6</sub></b>	<b>C<sub>2</sub>H<sub>2</sub></b>	<b>TDCG</b>
<b>1</b>	101	125	100	1160	121	32	24	1663
<b>2</b>	105	348	50	1000	383	93	1	1980
<b>3</b>	170	310	50	4000	340	83	0	4953
<b>4</b>	1245	400	100	370	247	28	322	2712
<b>5</b>	99	230	191	5930	164	212	0	6826
<b>6</b>	300	300	120	1300	350	55	12	2437
<b>7</b>	321	349	100	1070	388	64	43	2335
<b>8</b>	316	342	0	0	374	58	14	1104
<b>9</b>	516	508	100	1160	639	98	23	3044
<b>10</b>	534	508	85	1050	598	91	22	2888

Tabela 21 - Exemplo de concentrações de gases usadas no treinamento da rede

Nesta tabela estão apresentadas também as concentrações de monóxido e de dióxido de carbono, pois na comparação que fiz com outros métodos utilizamos essas concentrações para obter diagnósticos de sobre aquecimento, devidos à degradação do óleo ou da celulose ou de ambos. Da mesma forma apresentou-se na coluna TDCG – total de gases combustíveis dissolvidos – o total dos gases dissolvidos para determinar o percentual de cada gás em função do TDCG para avaliar o método do gás chave que é usado como comparação nos resultados da tabela 24.

As concentrações, para efeito de normalização, devem ser divididas por 1000, pela média de cada gás ou pelo maior valor de concentração de cada gás antes de serem fornecidas à rede, pois os valores de entrada devem estar entre 0 e 1.

**Pesos:** São valores aleatórios usados para determinar a intensidade do vetor de entrada.

**Bias:** entrada de valor unitário multiplicada por valores aleatórios ajustados durante o processo de treinamento. Tem a finalidade de aumentar o número de graus de liberdade do modelo, permitindo um aumento na capacidade da rede neural para se ajustar ao conhecimento que lhe é fornecido.

**Transfer function: tangent sigmoid (tansig),** é a função mais comum de ativação utilizada em redes neurais.

$$f(x) = \tanh(\alpha \cdot x) = \frac{e^{\alpha x} - e^{-\alpha x}}{e^{\alpha x} + e^{-\alpha x}}$$
$$-1 \leq f(x) \leq 1$$




Figura 26 – Função do tipo sigmoideal

## 4.2. Treinamento da Rede Neural

Por muitos anos não houve um algoritmo ideal para o treinamento de RNA multi-layer, e assim, as aplicações de uma rede eram bastante limitadas.

A invenção do algoritmo Backpropagation desempenhou um papel vital no ressurgimento do interesse nas RNA's. Back-propagation é um método sistemático de treinamento das RNA multi-layer. Ele tem uma forte base matemática.

Testei essa rede com os algoritmos do MatLab, o de Levenberg – Marquardt (trainlm), [Shoureshi et al., 2001] - por ser o que apresenta melhores resultados no trato de problemas não lineares e o de Sejnowski e Rosenberg [Sejnowski et Rosenberg, 86] cujo método implementa o tempo de treinamento do algoritmo backpropagation para o caso de função de ativação tangente sigmóide. Os resultados foram semelhantes.

### 4.3. Resultados

Em geral, a saída  $a_1$  da rede não será a mesma do alvo ou valores desejados  $t$ . Para cada padrão, a soma dos quadrados do Erro é:

$$SEE = \frac{1}{2} \sum \| t - a_2 \|^2$$

A principal meta do algoritmo back-propagation (BP) é ajustar os pesos  $w$  das conexões e os biases  $b$  para minimizar o erro entre a saída desejada e a saída normal da rede. Uma aproximação comum para atingir esta meta é a regra delta generalizada. O erro máximo obtido foi 0.0029.

Utilizou-se 300 padrões para treinar a rede e testou-se 20 que estão tabelados a seguir acompanhados dos resultados de saída da rede:



Padrões	H <sub>2</sub>	CH <sub>4</sub>	CO	CO <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>2</sub>
1	4	140	510	1700	10	320	0
2	370	75	700	4500	57	13	76
3	382	96	786	6520	20	133	0
4	3998	581	136	1240	431	31	788
5	83	350	800	8800	1200	230	140
6	105	43	620	4100	185	35	125
7	94	36	680	6200	59	13	190
8	60	74	690	11000	520	94	81
9	190	1100	580	5500	1900	700	12
10	110	910	450	4600	1700	660	11
11	48	43	120	1500	75	3	81
12	318	337	96	560	583	57	641
13	338	32	85	840	32	1	50
14	114	1417	100	610	2096	296	0
15	2	4	88	590	4	3	0
16	21	34	97	610	47	5	62
17	37	75	31	510	5	126	0
18	59	339	110	990	392	42	1
19	13	10	70	840	13	4	0
20	800	1393	423	2180	2817	304	3000

Tabela 22 - Dados usados para diagnóstico pela rede

Resultados dos testes:

Padrões	Não Identificado	Normal	Sobre aquecimento	Descargas parciais	Arco Elétrico
1	0.0019	0.0348	0.9901	0.0002	0.0042
2	0.0001	0.0301	0.0044	0.0000	0.9904
3	0.0021	0.9964	0.0012	0.0010	0.0015
4	0.0002	0.0011	0.0021	0.0007	0.9958
5	0.0188	0.0014	0.0017	0.0001	0.9164
6	0.0166	0.0018	0.0012	0.0003	0.9864
7	0.0100	0.0130	0.0025	0.0004	0.9936
8	0.0124	0.0032	0.8945	0.0013	0.1007
9	0.0311	0.0420	0.9822	0.0001	0.0099
10	0.0191	0.0120	0.9913	0.0011	0.0031
11	0.0002	0.0009	0.0014	0.0003	0.9968
12	0.0013	0.0019	0.0027	0.0001	0.9966
13	0.0001	0.0188	0.0000	0.0001	0.0037
14	0.0162	0.0720	0.9921	0.0000	0.0139
15	0.0018	0.9986	0.0020	0.0018	0.0011
16	0.0020	0.0013	0.0017	0.0002	0.9964
17	0.0102	0.9990	0.0002	0.0006	0.0010
18	0.0114	0.0500	0.7942	0.0000	0.1157
19	0.0109	0.9975	0.0015	0.0012	0.0001
20	0.0028	0.0030	0.0125	0.0001	0.9928

Tabela 23 - Resultados finais de saída da rede

Apresenta-se abaixo o diagnóstico obtido e o gráfico de performance da rede codificada no MatLab.

**Diagnósticos comparativos de faltas por vários métodos**

<b>Padrões</b>	<b>Diagnóstico pela RNA</b>	<b>Método do Gás Chave</b>	<b>Método de Rogers</b>	<b>Método de Dornenburg</b>	<b>Relatórios de Campo</b>
1	Sobre aquecimento	Sobre aquecimento	Sobre aquecimento	Sobre aquecimento	Sobre aquecimento
2	Arco elétrico	Arco elétrico	Arco elétrico	Não identificada	Arco elétrico
3	Normal	Sobre aquecimento	Sobre aquecimento	Normal	Normal
4	Arco elétrico	Indefinida	Arco elétrico	Não identificada	Arco elétrico
5	Arco elétrico	Indefinida	Sobre aquecimento	Sobre aquecimento	Arco elétrico
6	Arco elétrico	Indefinida	Arco elétrico	Não identificada	Arco elétrico
7	Arco elétrico	Arco elétrico	Arco elétrico	Não identificada	Arco elétrico
8	Sobre aquecimento	Indefinida	Não identificada	Normal	Sobre aquecimento
9	Sobre aquecimento	Indefinida	Sobre aquecimento	Não identificada	Sobre aquecimento
10	Sobre aquecimento	Indefinida	Sobre aquecimento	Sobre aquecimento	Sobre aquecimento
11	Arco elétrico	Normal	Arco elétrico	Arco elétrico	Arco elétrico
12	Arco elétrico	Indefinida	Sobre aquecimento	Não identificada	Arco elétrico
13	Descargas parciais	Normal	Arco elétrico	Não identificada	Descargas parciais
14	Sobre aquecimento	Indefinida	Sobre aquecimento	Sobre aquecimento	Sobre aquecimento
15	Normal	Normal	Sobre aquecimento	Normal	Normal
16	Arco elétrico	Normal	Não identificada	Não identificada	Arco elétrico
17	Normal	Normal	Sobre aquecimento	Sobre aquecimento	Sobre aquecimento
18	Sobre aquecimento	Arco elétrico	Sobre aquecimento	Sobre aquecimento	Sobre aquecimento
19	Normal	Normal	Sobre aquecimento	Normal	Normal
20	Arco elétrico	Arco elétrico	Não identificada	Não identificada	Arco elétrico

Tabela 24 – Resultados obtidos pela rede neural usada e pelos métodos tradicionais

Conclui-se que pela análise das tabelas acima que os resultados obtidos através da RN são realmente mais precisos que os outros métodos. O diagnóstico de valores de saída muito próximos uns dos outros foi resolvido forçando-se a saída da rede a passar por uma função competitiva de forma a que o neurônio que apresentou maior valor de saída foi associado à falta.

## CAPÍTULO 5

### 5. CONCLUSÃO

#### 5.1. Conclusões

Apresentou-se nessa dissertação, um histórico da detecção de falhas incipientes em transformadores isolados com óleo isolante. Discorri também as várias técnicas utilizadas no século passado, suas vantagens e desvantagens sobre os métodos ditos inteligentes que surgiram ao final do século XX e que também foram objeto de apresentação. Concluiu-se como era a proposta da dissertação, que os métodos que utilizam técnicas de Inteligência Artificial, são mais precisos e mais rápidos que os métodos tradicionais, trazendo mais segurança ao pessoal de decisão responsável pela operação e manutenção dos sistemas elétricos de potência.

Pela análise bibliográfica feita em [Dukarm, 93], [Kosko, 92], [Tomsovic 1993], [Wang, 2000], [Yan et al. 96], [Gao et al. 98] e outros, inferiu-se que as técnicas híbridas, isto é, que combinam Redes Neurais com Sistemas Especialistas, Redes Neurais com Lógica Fuzzy, Redes Neurais com Algoritmos Genéticos ou ainda a combinação de três ou mais destas técnicas, são mais eficientes, produzindo resultados com maior grau de precisão.

Uma contribuição importante para esta dissertação, baseada experiência profissional do autor e na análise de papers existentes, é a de que de nada adianta o desenvolvimento de técnicas de inteligência artificial sofisticadas se a coleta de óleo não for confiável. Os métodos existentes para tal são suscetíveis de falha produzindo a contaminação das amostras.

Da mesma forma, no laboratório, mesmo que o espectrômetro seja o mais moderno ou bem calibrado existirá sempre a possibilidade de falha humana no manuseio das amostras e utilização do aparelho. Os sistemas comerciais Hydran da General Electric Co. e TrueGas da Serveron CMS que são detectores on-line de gases e de predição de faltas ainda não empregados no Brasil resolvem em parte o problema pois captam e testam as amostras diretamente no tanque do transformador. Acreditamos, porém, que o sistema sugerido a seguir deverá apresentar melhor desempenho e confiabilidade.

## **5.2. Sugestões de Trabalhos Futuros**

Como contribuição para o futuro, se poderia procurar melhorar dispositivos os mais eficientes, tais como a detecção on-line dos gases e suas concentrações, utilizando um dispositivo acoplado diretamente ao tanque do transformador que através de ondas acústicas, a chamada Análise por Vibro-acústica, ondas essas emitidas por um sensor dentro do tanque, que retorna quais os gases dissolvidos no óleo além da sua concentração em ppm e faz a análise das falhas incipientes em tempo real devidas a descargas parciais, arco elétrico e sobre aquecimento do óleo. É um método interessante para se desenvolver embora já esteja operacional em

alguns países como os Estados Unidos da América, apesar de ter que se utilizar filtros sofisticados conjugados ao dispositivo de detecção visando eliminar fontes de interferência de harmônicos, ruídos devido ao efeito corona, fontes ambientais como a chuva, poeira, granizo, turbulência no óleo, operações do LTC, de bombas de óleo e de ventiladores, e da vibração das lâminas do núcleo além de outros, poderíamos ter um resultado verdadeiramente confiável. Pelo que se pesquisou em [EPRI 2004], [Berler et al., 98], [Golubev et al., 00] e outros mais, inferi que os dispositivos existentes para incorporar tais filtros ficariam sobremaneira dispendiosos tornando-os comercialmente inviáveis e à custa da menor eficiência do método. A espectroscopia foto-acústica é outro método recentemente desenvolvido nos Estados Unidos, mas mantém a coleta manual de óleo, o que não descarta a contaminação.

Preferencialmente, porém, desenvolver-se-ia um protótipo em um posterior curso de Doutorado, que utilizasse a técnica de sonda ótica, associando o laser com a espectroscopia, para a detecção on-line dos gases e sua concentração efetuando também, em tempo real, a análise das falhas incipientes através de sistemas inteligentes, emitindo assim diagnósticos rápidos, precisos e extremamente confiáveis. Permitiria assim, a manutenção preditiva com grande redução de custos e amostragem, transporte, laboratório, homens-hora, etc.

Outra técnica possível de ser pesquisada e elaborada é a da espectroscopia de ressonância magnética nuclear da amostra com detecção também on-line para evitar a possibilidade de intervenção humana e prováveis contaminações indesejáveis. Esta tecnologia está sendo aplicada em vários campos da física e

biologia, mas acreditamos que também poderia ser utilizada com adaptações na detecção de gases em óleo isolante possibilitando assim a classificação de faltas incipientes e poderá ser objeto de futuros trabalhos de pesquisa na área de diagnóstico de falhas incipientes em transformadores.

## **REFERÊNCIAS BIBLIOGRÁFICAS**

ABNT, Associação Brasileira de Normas Técnicas, Referências Bibliográficas, Rio de Janeiro, 1989. NBR 6023.

ALI M. et al., Measuring and Understanding the Ageing of Kraft Insulating Paper in Power Transformers, IEEE Electrical Insulation Magazine, Vol. 12, No.3, May/June 1996, pp. 28-34.

ARBIB A. Michael, Handbook of Brain Theory and Neural Networks, Bradford Books, Second Edition, 2002

ASTM D3612-01, Standard Test Method for Analysis of Gases Dissolved in Electrical Insulating Oil by Gas Chromatography, ASTM Book of Standards Volume 10.03, May 2002 - Electrical Insulating Liquids and Gases; Electrical Protective Equipment

BARRACLOUGH, B. et al., CEGB Experience of the Analysis of Dissolved Gas in Transformer Oil for the Detection of Incipient Faults, IEE Conference on Diagnostic Testing of High Voltage Power Apparatus in Service, March 6-8, 1973.

BATES, Danny, DGA in a Box – A Utility's Perspective, Alabam Power Company.

BELANGER, G., MISSOUT, G. and GIBEAULT, J. P., Laboratory Testing of a Sensor for Hydrogen Dissolved in Transformer Oil, IEEE Transactions on Electrical Insulation, Vol. EI-15, No. 2, April, 1980, pg. 144-148.

BERLER, Z. et al., A New Method of Partial Discharge Measurements, IEEE 1998 Conference on Electrical Insulation and Dielectric Phenomena, Atlanta, GA, USA, October 1998.

BISH, N.B., et al., Condition Monitoring of Dielectric Behavior Leading to the Diagnosis of Partial Discharge Onset Using Neural Network Analysis, University of Brighton Press, U.K.

BOSHE E.E., "Experience With the Development & Use of An Expert System for the Evaluation of Transformer Dissolved Gas Data," Proc. Electrical Electronics Insulation Conference and Electrical Manufacturing and Coil Winding Conference, Electr. Manuf. & Coil Winding Assoc., Imperial Beach, Calif., 1995, pp. 295-299

BOUTHIBA, Tahar, Artificial Neural Network-Based Fault Location in EHV Transmission Lines, University of Science and Technology of Oran, Algeria.

C57.125, IEEE PES Transformer Committee, IEEE Guide for Failure Investigation, Documentation and Analysis for Power Transformers and Shunt Reactors, IEEE Standards Board, 1991.

C57.113, IEEE PES Transformers Committee, IEEE Trial-Use Guide for Partial Discharge Measurement in Liquid-Filled Power Transformers and Shunt Reactors, IEEE/NEMA, 1998.



CAO, L., Chan T., Kong C., A Universal Neural Expert System with Self-Learning Mechanism for DGA of Power Transformer Oil, International Power Engineering Conference 1995, Nanyang Technol. Univ, Singapore, 1995, pp. 355 – 359.

CIGRE's WORK on POWER TRANSFORMERS, Paper apresentado na IX Conference Substation Equipment Diagnostics, 18-21 Fevereiro, 2001 New Orleans, Louisiana, USA.

CHEIM, L. et al., XV SNPTEE, 1999, CEPEL

COBEI – Comitê Brasileiro de Eletricidade, Curso de Óleos Isolantes Líquidos para Fins Elétricos, 1982.

COSTA JR, Pedro, Sistema de Diagnóstico de Falhas em Transformadores de Potência Imersos em Óleo, PUCMINAS, 2002

DA SILVA, Ivan N., et al., Técnicas de Sistemas Inteligentes Aplicadas na Identificação do Envelhecimento de Transformadores. XVI SNPTEE, Outubro 2001, Campinas, SP.

DIOGO, A.C.T. e CARNEIRO, E.M., IEEE em Revista, 1998 - CTEEP

DÖRNENBURG, Eberhard and GERBER O. E., Othmar E., La surveillance de l'Huile des Transformateurs en Exploitation par l'Analyse des Gaz Dissous dans l'Huile et des Gaz Libérés, Revue Brown Boveri, Tome 54, N<sup>o</sup> 213, pp. 104 -111.

DÖRNENBURG, Eberhard and GERBER O. E., Analysis of Dissolved and Free Gases for Monitoring Performance of Oil-Filled Transformers, The Brown Boveri Review, 54(2/3): 104-11, 1967.

DÖRNENBURG, Eberhard and W. Stritmatter, Monitoring Oil Oil-Cooled Transformers by Gas Analysis, Brown Boveri Review, Vol. 61, No. 5, p.238, 1970.

DONG M. et al., Aging Diagnosis of Solid Insulation for Large Oil-immersed Power Transformers.

DOS SANTOS, J. Carvalho et al., Diagnóstico de Falhas em Transformadores por Análise Cromatográfica, revista Energia Elétrica, pág. 11, Mar-Abr 1978.

DUKARM James J., Transformer Oil Diagnosis Using Fuzzy Logic and Neural Networks, Canadian Conference on Electrical and Computer Engineering, Vol. 1, pp 329-332, 1993.

DUMKE, K. and al., Influence of Stressing on Gaseous Decomposition Product in Insulation Liquids, IEEE International Symposium on Electric Insulation, 1998.

DUVAL, Michel, A Review of Faults Detectable in Gas-in-Oil Transformers, IEEE Electric Insulation Magazine, Vol.18, No. 3, pp. 8-18, 2002.

DUVAL, Michel, Fault Gases Formed in Oil - Filled Breathing E,H.V. Power Transformers The Interpretation of Gas Analysis Data, IEEE PES Summer Meeting & Energy Resources Conference, Anaheim, CA, July, 1974.

DUVAL, Michel. et al., Interpretation of Dissolved Gas-in-Oil Levels in Power Transformers, Minutes of Fifty-Fifth International Conference of Doble Clients, Sec. 10-71, 1988.

DUVAL, Michel. et DEPABLO Alfonso, Interpretation of Gas-In-Oil Analysis Using New IEC Publication 60599 and IEC TC 10 Databases, IEEE Electrical Insulation Magazine, Vol. 17, No. 2, 2001

DUVAL M., Dissolved Gas Analysis: It can Save Your Transformer, IEEE Electrical Insulation Magazine, Vol. 5, No. 6, 1989

DUVAL, Michel, New Techniques for Dissolved Gas-in-Oil Analysis, IEEE Electrical Insulation Magazine, Vol. 19, No. 2, 2003

EPRI - Electric Power Research Institute – 2004, Substation Equipment Diagnosis Conference XII “Recent developments in the Condition Assessment of Power Transformers and LTC Using Acoustic Emission (AE)”, New Orleans, Louisiana.

FALLOU B. et al., Application of Physico-Chemical Methods of Analysis to the Study of Deterioration in the Insulation of Electrical Apparatus, CIGRE 1970, Report 15-07.

GRIFFIN, Paul J., et al. A combined ANN and Expert System, Tool for Transformer Fault Diagnosis, IEEE Transactions on Power Delivery, vol.13, No. 4, October 1998.

FLETCHER, D. et GOSS, E., Neural Networks in Regional Science: An Application Using Migration Data, Proceedings of 38<sup>th</sup> North American Meeting Of Regional Science Association, 1991, p. 38.

GOULUBEV A. et Al., Increasing the Reliability of Online Insulation Condition Assessment of MV-HV Equipment, Electricity – Today, vol.12, no. 6, August, 2000, pp. 22-27.

GUARDADO, J. L et al. A Comparative Study of Neural Network Efficiency in Power Transformers Diagnosis Using Dissolved Gas Analysis, IEEE Trans. on Power Delivery. Vol. 16, No. 4, October 2001, pp. 643-647.

GOULUBEV, A. et al., On-Line Vibro-Acoustic Alternative to the Frequency Response Analysis and On-Line Partial Discharge Measurements on Large Power Transformers, TechCon'99 Annual Conference of TJI/H2b, February, 18-19, 1999, New Orleans, USA.

HALSTEAD W.D., A Thermodynamic Assessment of the Formation of Gaseous Hydrocarbons in Faulty Transformers, Journal inst. Petroleum, Vol. 59, Sept. 1973, pp. 239-241.

IEC standard 599: Interpretation of the Analysis of Gases in Transformers and Other Oil Filled Electrical Equipment in Service, International Electrotechnical Commission, Geneva, Switzerland, 1978.

IEC standard 354: Loading Guide for Oil-Immersed Power Transformers, 1991.

IEC, IEC 599 – Interpretation of the Analysis of gases in Transformers and Other Oil Filled Electrical Equipment in Service, International Electrotechnical Commission, Geneva, Switzerland, 1978.

IEEE C57.104-1991, IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers, 1991.

IEEE Guide for Loading Mineral-Oil-Immersed Transformers. IEEE Std C57.91-1995.

JAKOB Fredi, Dissolved Gas Analysis - Past, Present and Future, Weidmann-ACTI Inc., [s.ed], 2001.

IEEE P1258, IEEE Trial-Use Guide for the Interpretation of Gases Generated in Silicone-Immersed Transformers, 1995.

JAIN, Anil K. et MAO, Jianchang et MOHIUDDIN, K. M., IEEE Artificial Neural Networks: A Tutorial, pp. 31-44, March, 1996.

KAWADA H. and al., Partial Discharge Automatic Monitor for Oil-Filled Power Transformer, IEEE Transactions on Power Apparatus and Systems, Vol. PAS-103, No. 2, Fev 1984, pp. 422-428.

HALSTEAD W.D., Transformer Fault Diagnosis by Oil Decomposition Product Analysis, Central Electricity Research Laboratories Note, No. RD/L/N, 66/70, 1970.

HALSTEAD W.D., A Thermodynamic Assessment of the Formation of Gaseous Hydrocarbons in Faulty Transformers, Journal Inst. Petroleum, Vol 59, pp. 239-241, Sept 1973.

HAYES T. W., Investigation to Determine the Location of a Low- Energie, Audible Electrical Arcing in a Power Transformer, Minutes of Fifty-Third International Conference of Doble Clients, 1986, Sec. 6-301.

HISAO, Kan, T. Miyamoto, Proposals for an Improvement in Transformer Diagnosis Using Dissolved Gas Analysis, IEEE – Electrical Insulation Magazine, Vol. 11, No. 6, Nov/Dez, 1995, pp. 15-21.

JALBERT J., R. Gilbert, Decomposition of Transformer Oils: A New Approach for Determination of Dissolved Gases, IEEE Transactions on Power Delivery, 1997, pp. 754-760.

LIN Cao and al., An Expert System for Transformer Fault Diagnosis Using Dissolved Gas Analysis, IEEE Transactions on Power Delivery, NY, 1993, pp. 231-238.

K. Zalis, Dielectric Diagnostics in Service – From Databases to Expert Systems, Stockholm Power Tech International Symposium on Electric Power Engineering, IEEE, NY, USA, 1995, pp. 34-38.

KOIVO, N. Heikki, Neural Networks: Basics Using MATLAB Neural Network Toolbox, [s.ed], 2000.

KOSKO, Bart, Neural Networks and Fuzzy Systems – A Dynamical Systems Approach to Machine Intelligence, Prentice-Hall International, Inc., [s.ed], 1992.

MANGER H. C., Combustible Gas Ratio and Problems Detected, Minutes of Forty-Fifth International Conference of Doble Clients, Sec. 6-1101, 1978.

MCILROY, Colin., Photo-Acoustic Spectroscopy, A New Technique for Dissolved Gas Analysis in Oil. EPRI Substation Equipment Diagnostics Conference, New Orleans, LA, USA. February 23–26, 2003

MCNAIR, H.M and BONELLI, E.J., Basic Gas Chromatography, Consolidated Printers, Berkeley, California, 5th. Edition, 1969.

MILASH Milan, Manutenção de Transformadores em Líquido Isolante. Ed. Edgard Blücher, 1984.

MILLER, George, Analyzing transformer insulating fluid, Electrical Construction & Maintenance, Nov 1, 1995.

MORGAN, James E., A Guide to Interpretation of Transformer Fault Gas, Data Bulletin MS-5, Morgan, Shaffer Corporation, Canada.

MYERS, S. D., et al., Transformer Maintenance Guide, Transformer Maintenance Institute, S. D. Myers Inc., Akron, Ohio, USA, 3ed, 2004.

NOGAMI T., Y. Yokoi, H. Ichiba, Y. Atsumi, "Gas Discrimination Method for Detecting Transformer Faults by Neural Network", Electrical Engineering in Japan, 1995, pp. 93 – 103.

P.T.M. Vaessen, E. Hanique, A New Frequency Response Analysis Method for Power Transformers, IEEE Transactions on Power Delivery; Vol .7 N° 1, January 1992, pp. 384 – 391.

PAREKH Rajesh et al., Constructive Neural-Network Learning Algorithms for Pattern Classification, IEEE Transactions on Neural Network, Vol. 11, N° 2, March 2000.

PUGH, D. R., Combustible Gas Analysis, Doble Client Conference Minutes, 42AIC73, Sec. 10-401, 1973.

RANDY, D. S. et al., Power Transformer Fault Diagnosis, IEEE PES WM. Panel Session, New York, Feb 6, 1977.



RIBEIRO Jr. Adolfo et al., Sistema de Diagnósticos para o Monitoramento de Subestações de Alta Tensão e o Gerenciamento das Atividades de Manutenção: Integração e Aplicações, Comitê A3 – Equipamentos de Alta Tensão, 2002.

ROGERS R. R., Doble Publication AIC75, Sec. 10-201.

ROGERS R. R., IEEE and IEC Codes to Interpret Incipient Faults in Transformers, Using Gas in Oil Analysis, IEEE Trans. Vol. EI-13, No. 5, Oct. 1978, pp. 349-354.

ROGERS R. R., UK Experiences in the Interpretation of Incipient Faults in Power Transformer by Dissolved Gas-in-oil Chromatography Analysis ( A Progress Report), Minutes of Forty-Second International Conference of Doble Clients. 1975, Sec. 10-201.

SHERTUKDE, H. M., J. G. Lackey, Interpretation of Results obtained from Testing of Oil filled Electrical Power Transformers in Field for several Utilities in the World, IEEE International Symposium on Electrical Insulation, Vol. 1, pp. 49-52, June 1998, Washington DC, USA.

SHOURESHI Rahmat et al., Sensor Fusion and Complex Data Analysis for Predictive Maintenance, 36th Hawaii International Conference on System Sciences, [s.ed], 2003

MORAIS, DR e ROLIM, J.G., XVII CBA 2004 - UFRGS

MURTHY T., Assessment of Transformer Insulation Condition by Evaluation of Paper-oil System, IEEE Annual Report – Conference on Electrical Insulation and Dielectric Phenomena, San Francisco, 1996, pp. 332-335.

TASSI, M.R., Pado – Programa de Análise e Diagnóstico de Óleo Isolante, XV Seminário Nacional de Energia Elétrica, 2002.

THOMAS, Waters et al., Online Measurements of Transformer Fault Gases As Measured Directly in the Headspace and in the Oil, EPRI Substation Equipment Diagnostics Conference, 2001.

TOMSOVIC K. et al., A Fuzzy Information Approach to Integrating Different Transformer Diagnostic Methods, IEEE Transactions on Power Delivery, 1993, pp. 1638-1646.

SEJNOVISKI, T.J. and ROSENBERG, R.C., Parallel Networks that Learn to Pronounce English Text, Complex System, 11, pp. 145-168, 1987.

TENBOHLEN, S. and FIGEL F., On-line Condition Monitoring for Power Transformers, IEEE Power Engineering Society Winter Meeting, Singapore, Jan. 2000.

TOMSOVIC, K. and AMAR, A., On Refining Equipment Condition Monitoring Using Fuzzing Sets and Artificial Neural Nets, Washington State University, [s.ed], 1994.

V.RENATA & O. FERNANDO, Inteligência Artificial e Sistemas Inteligentes, Unisinos.

ZHANG Yuwen, An Artificial Neural Network Approach to Transformer Fault Diagnosis, Thesis of Virginia Tech, 1996.

YAN Z. and al., Application of Expert System in Insulation Diagnosis, Proceedings of the 3<sup>rd</sup> International Conference on Properties and Applications of Dielectric Materials, IEEE, NY, USA, 1991, pp. 63-65.

WANG Zhenyuan, Artificial Intelligence Applications in the Diagnosis of Power Transformer Incipient Faults, Dissertation submitted to the Faculty of the Virginia Polytechnic Institute and State University In partial fulfillment of the requirement for the degree of Doctor of Philosophy In Electrical Engineering, [s.ed], August 2000.

WERLE P. et al., Partial Discharge Localization on Power Transformers using Neural Networks combined with Sectional Winding Transfer Functions as Knowledge Base, 12th ISH, International Symposium on High Voltage Engineering, Bangalore, India, August 2001, Ed. IEEE 2003.