

UNIVERSIDADE FEDERAL DE MINAS GERAIS - UFMG
DEPARTAMENTO DE ENGENHARIA ELETRÔNICA
PROGRAMA DE PÓS-GRADUAÇÃO
EM AUTOMAÇÃO INDUSTRIAL

Ronilson de Lima

Diagnóstico de Falhas em Transformadores de Potência pela Análise
de Gases Dissolvidos em óleo Isolante com a utilização de Redes
Neurais

Belo Horizonte – MG
Dezembro de 2016

UNIVERSIDADE FEDERAL DE MINAS GERAIS - UFMG
DEPARTAMENTO DE ENGENHARIA ELETRÔNICA
PROGRAMA DE PÓS-GRADUAÇÃO
EM AUTOMAÇÃO INDUSTRIAL

**Diagnóstico de Falhas em Transformadores de Potência pela
Análise de Gases Dissolvidos em óleo Isolante com a utilização
de Redes Neurais**

Ronilson de Lima

Monografia submetida à banca Examinadora designada pela Comissão Coordenadora do Curso de Especialização em Automação Industrial, como parte dos requisitos necessários à obtenção do Certificado de Especialista em Automação Industrial.

Orientador: Antônio de Pádua Braga
Co-orientador: Frederico Coelho

Belo Horizonte – MG
Dezembro de 2016

“Diagnostico de Falhas em Transformadores de Potência pela Análise de Gases Dissolvidos em óleo Isolante com a utilização de Redes Neurais”

Ronilson de Lima

Monografia submetida à banca Examinadora designada pela Comissão Coordenadora do Curso de Especialização em Automação Industrial, **como parte dos requisitos necessários à obtenção do Certificado de *Especialista em Automação Industrial*.**

Aprovada em 12 de Dezembro de 2016.

Por:

Antônio de Pádua Braga

Prof. Nome do Orientador

(Orientador)

Frederico Coelho

Prof. Nome do Relator

(Relator)

AGRADECIMENTOS

Agradeço a Deus por dar-me as capacidades para viver e para aprender. Aos meus pais, José e Maria, e aos meus irmãos, meu agradecimento especial pela compreensão, carinho e suporte.

Sou grato ao professor Antonio Braga pelas inúmeras vezes em que a mim confiou desafios, tarefas e a amizade. Inúmeras foram às vezes em que a sua ajuda paciente e entusiasmada me mostraram caminhos novos. Agradeço também aos colegas de trabalho da CEMIG pela convivência bem humorada e atenciosa. Não posso deixar de agradecer aos amigos, colegas e professores do curso de pós- graduação do CEAI.

A Todas as pessoas que, direta ou indiretamente, contribuíram para a realização desse trabalho.

Resumo

O principal objetivo deste trabalho é desenvolver um método utilizando redes neurais artificiais, para executar o mapeamento dos gases gerados no óleo isolante dos transformadores de potência, provenientes de faltas como arco elétrico, efeito corona, sobrecargas e dentre outros.

Descreveremos também sobre os métodos de detecção de gases dissolvidos em óleo empregados atualmente. A vantagem de fazer uso de redes neurais em relação aos métodos existentes é devido o método ser totalmente numérico, bem adaptado às modernas praticas de soluções computacionais, não necessitar de intervenções humanas especializadas e as análises são processadas rapidamente.

Para o sistema proposto utilizamos uma rede neural Perceptron de múltiplas camadas, treinada pelo algoritmo de Levenberg-Marquardt, por ser um sistema não linear, os resultados obtidos foram comparados com os dos critérios de diagnósticos utilizados atualmente para óleo isolante chegando à conclusão que os sistemas propostos possuem alta precisão no diagnostico de faltas, atendendo todos os requisitos e expectativas.

Do ponto de vista do planejamento da manutenção é verificado que um cronograma de manutenção bem definido para esses equipamentos significa redução de custos, eficiência operacional dos mesmos e boa qualidade aos serviços prestados para a sociedade. Vale lembrar que os diagnósticos utilizados nos processos de treinamento e validação dos sistemas desenvolvidos foram obtidos a partir da aplicação de norma internacional, a que muita das vezes não se adequa á realidade brasileira.

Um objetivo futuro deste trabalho é empregar os sistemas de diagnostico propostos tomando-se como saídas desejadas diagnósticos reais de falta, colhidos em campo.

Palavras-Chave: transformador de potência; Análise de gás; controle do gás dissolvido em óleo; arco elétrico; rede neural artificial.

Abstract

The main objective of this work is to develop a method using artificial neural networks, to perform the mapping of the gases generated in the insulating oil of the power transformers, coming from faults such as electric arc, corona effect, overloads and others.

We will also describe the methods of detection of dissolved gases in oil currently used. The advantage of using neural networks over existing methods is because the method is fully numerical, well adapted to modern computational solutions practices, does not require specialized human interventions, and the analyzes are processed quickly.

For the proposed system we used a multi-layer Perceptron neural network, trained by the Levenberg-Marquardt algorithm, because it is a nonlinear system, the results obtained were compared with the diagnostic criteria currently used for insulating oil, arriving at the conclusion that the systems Proposed have high accuracy in the diagnosis of faults, meeting all requirements and expectations.

From a maintenance planning point of view, a well-defined maintenance schedule for these equipments means that costs are reduced, their operational efficiency and good quality of service rendered to society. It is worth remembering that the diagnoses used in the training and validation processes of the developed systems were obtained from the application of an international standard, which often does not fit the Brazilian reality.

A future objective of this work is to employ the proposed diagnostic systems, taking as the desired outputs real diagnoses of lack, collected in the field.

Keywords: power transformer; Gas analysis; Control of gas dissolved in oil; electric arc; Artificial neural network.

Sumário

Lista de abreviaturas e siglas	ii
Lista de Ilustrações.....	iii
Lista de Tabelas.....	iv
Introdução	5
1.1. Considerações Gerais.....	7
1.2. Resenha Bibliográfica.....	7
1.3. Objetivo.....	8
1.4. Escopo do trabalho	8
Diagnóstico de Falhas em Transformadores	9
2.1 Materiais e Líquidos Isolantes	10
2.2 Análise de falhas.....	12
2.3 Métodos de Detecção de Falhas	16
2.4 Métodos de Interpretação.....	17
2.5 Aplicação do método Dornenburg	17
2.6 Aplicação do método de Rogers Modificado:.....	19
2.7 Aplicação do método de IEC:	21
2.8 Aplicação do método de CSUS:	21
2.9 Redes neurais	21
3.1 Sistema de Diagnósticos Propostos.....	23
3.2 Base de Dados Utilizados.....	23
3.2 Sistema de Simulação de Diagnostico	24
3.3 Técnicas de Inteligência Computacional no Diagnostico de Falhas	25
3.4 Rede Neural MLP Aplicada no Diagnóstico de Falhas em Transformadores de Potencia.	26
3.5 O Algoritmo de Levenberg-Marquardt	32
3.6 Simulações e Resultados	33
3.7 Estruturando as Redes Neurais no toolbox.....	34
3.8 Treinamento das Redes Neurais	38
3.9 Estrutura 1 – pós-treinamento e distribuição de 70/15/15(%)	40
3.10 Estrutura 2 - pós-treinamento e distribuição de 70/15/15(%)	41
3.11 Estrutura 3- pós-treinamento e distribuição de 70/15/15(%)	43
3.12 Estrutura 1 – pós-treinamento e distribuição de 70/15/15(%)	44
3.13 Estrutura 2 - pós-treinamento e distribuição de 70/15/15(%)	45
3.3 Estrutura 3- pós-treinamento e distribuição de 70/15/15(%)	46
Referencias Bibliográficas	52

Lista de abreviaturas e siglas

<i>ABNT</i>	<i>Associação Brasileira de Normas Técnicas</i>
<i>AGD</i>	<i>Análise de Gases dissolvidos ou DGA Dissolved gás analysis</i>
<i>ANEEL</i>	<i>Agência Nacional de Energia Elétrica</i>
<i>ANSI</i>	<i>American National Standards Institute</i>
<i>ASTM</i>	<i>American Society for Testing and Materials</i>
<i>CEMIG</i>	<i>Companhia Energética de Minas Gerais</i>
<i>CSUS</i>	<i>California State University, Sacramento</i>
<i>IEC</i>	<i>International Electrotechnical Commission</i>
<i>IEEE</i>	<i>Institute of Electrical and Eletronics Engineers</i>
<i>NBR</i>	<i>Norma Brasileira</i>
<i>OMI</i>	<i>Óleo mineral isolante</i>
<i>PPM</i>	<i>Partes por milhão</i>
<i>RNAs</i>	<i>Redes Neurais Artificiais</i>
<i>SE</i>	<i>Subestação de energia elétrica</i>
<i>TDCG</i>	<i>Gás combustível total dissolvido</i>
<i>CH₄</i>	<i>Gás Metano</i>
<i>C₂H₆</i>	<i>Gás Etano</i>
<i>C₂H₄</i>	<i>Gás Etileno</i>
<i>C₂H₂</i>	<i>Gás Acetileno</i>
<i>H₂</i>	<i>Hidrogênio</i>
<i>CO</i>	<i>Monóxido de carbono</i>
<i>CO₂</i>	<i>Dióxido de carbono</i>

Lista de Ilustrações

Figura 1 -Transformador de potência	9
Figura 2 -Partes constituintes de um transformador a óleo	10
Figura 3-Gases típicos gerados durante faltas	15
Figura 4 -Solubilidade relativa como função da temperatura	15
Figura 6-Fluxograma de Aplicação do Método das Razões de Dornenberg	18
Figura 7- RNA para diagnóstico dos principais tipos de falta proposta por Zhang	22
Figura 8 - RNA para diagnóstico de degradação da celulose proposta por Zhang.....	22
Figura 10 - Fluxograma do Sistema de Simulação de Diagnóstico	25
Figura 11 - Primeira Estrutura de Rede Neural MLP implementada.....	27
Figura 12 - Função de Transferência Sigmoidal	28
Figura 13-Estrutura da Segunda Rede Neural MLP Proposta.....	29
Figura 14- Estrutura da Terceira Rede Neural MLP	31
Figura 15 - Arquitetura da Rede Neural Feed –Forward de dupla camada	32
Figura 16 - Interface Principal da toolbox de Redes Neurais Artificiais do MATLAB	34
Figura 17- Fitting Tool (nftool) - Aspectos Gerais Sobre a Arquitetura da Rede	35
Figura 18 - Fitting Tool – Seleção das Matrizes de Dados de Treinamento	35
Figura 19 - Separação Aleatória dos Blocos de Treinamento, Validação e Teste.	37
Figura 20 - Interface Pré – Treinamento da Rede Neural Artificial	38
Figura 21 - Estrutura 1, Rede com 3/ 7 /1 neurônios.	40
Figura 23 - Estrutura 1, Rede com 3/7/1 neurônios.....	41
Figura 25 – Estrutura 2, Rede com 3/7/4 neurônios.	42
Figura 27 – Estrutura 2, Rede com 3/7/4 neurônios.	42
Figura 29 – Estrutura 3, Rede com 3/7/9 neurônios.	43
Figura 31 – Estrutura 3, Rede com 3/7/9 neurônios.	43
Figura 22 - Estrutura 1, Rede com 3/10/1neurônios.	44
Figura 24 - Estrutura 1, Rede com 3/10/1 neurônios.	44
Figura 26 – Estrutura 2, Rede com 3/10/4 neurônios.....	45
Figura 28 – Estrutura 2, Rede com 3 /10/4 neurônios.	45
Figura 30 – Estrutura 3, Rede com 3/10/9 neurônios.....	46
Figura 32 – Estrutura 3, Rede com 3/10/9 neurônios.....	46

Lista de Tabelas

Tabela 1- razões entre as concentrações dos gases	17
Tabela 2-Limites de Concentração	17
Tabela 3 -Faixas das razões para os gases chaves-Doernenburg[9]	18
Tabela 10- Correlação entre os Tipos de Falta e a Saída da Primeira Rede Neural MLP	29
Tabela 11 - Os parâmetros usados no treinamento	29
Tabela 12-Correlação entre os Tipos de Falta e a saída da Rede Neural MLP	30
Tabela 13 -Parâmetros Usados na Rede Neural MLP	30
Tabela 14 - Parâmetros Usados na Rede Neural MLP.....	31
Tabela 15 - Exemplo de concentrações de gases usadas no treinamento da rede	38
Tabela 16 - Erro Médio Quadrático (MSE) e Correlação (R) para as Redes Neurais Artificiais Criadas e Treinadas nos Esquemas Propostos	47
Tabela 17 - Desempenho das Redes Neurais Artificiais Propostas	48
Tabela 18 - Resultados Obtidos para a Segunda Rede Neural MLP	49
Tabela 19 - Resultados Obtidos para a Terceira Rede Neural MLP.....	50

Capítulo 1

Introdução

Nos últimos anos ocorreu uma mudança de filosofia no planejamento da expansão, em que a visão expansionista cedeu lugar a uma fase de maior exploração da capacidade do sistema existente.

Em função destas mudanças as concessionárias de energia elétrica tiveram que se adequarem aos modelos propostos pelos órgãos reguladores, como a Agência Nacional de Energia Elétrica (ANEEL) levando-as a explorarem mais os seus ativos instalados, embora preservando a segurança do sistema e a qualidade do fornecimento de energia, buscando-se uma relação custo-benefício adequada.

No entanto, explorar estes ativos ao limite máximo exige atenção, pois se houver a perda de um transformador em uma subestação teremos o corte no fornecimento de energia elétrica para a população e a redução da receita para a concessionária, uma vez que o retorno de um equipamento deste para o sistema demanda tempo para substituição, além de não ser um equipamento de aquisição imediata no mercado.

Em uma subestação de energia elétrica os transformadores de potência estão na lista dos equipamentos mais caros. Nos grandes centros de cargas como Belo Horizonte, os transformadores instalados nas subestações são abaixadores, com relações de tensões de 138 mil Volts, para 13,8 mil Volts e potências geralmente de 15MVA, 25MVA chegando até 33MVA. (MVA) expressa à potência aparente do transformador e equivale a 10^6 VA.

Um transformador de potência tem vida útil aproximadamente de 30 anos e tanto os transformadores, disjuntores, religadores e as chaves utilizam o óleo isolante em seus interiores para isolar e resfriar suas partes internas. É muito importante para o planejamento da manutenção, o conhecimento das faltas incipientes que ocorrem pela formação de gases que encontram dissolvidos no óleo isolante destes equipamentos, dentro dessa perspectiva

será possível detectar os problemas no início e propor uma ação antes da queima ou retirada de um destes equipamentos de operação.

Os gases gerados no óleo isolante dos transformadores são hidrogênio, nitrogênio, oxigênio, monóxido de carbono, dióxido de carbono, metano, etano, etileno e o acetileno e estão relacionados às faltas como, Arco elétrico, aquecimento sobrecarga, corona e degradação da celulose.

Detectando esses pontos de faltas no início será possível elaborar um cronograma de manutenção mais assertivo para estes equipamentos.

As Redes Neurais Artificiais (RNA) são modelos capazes de executar o mapeamento e estabelecer ligações funcionais, desta forma suas aplicações são atrativas na busca de soluções de diversos problemas. Esta característica é particularmente importante quando o relacionamento entre as variáveis do processo é não linear e não são definidas, tornando assim difícil a sua modelagem por técnicas convencionais.

As redes neurais são interessantes na detecção de problemas lineares e não lineares, porque são dotadas de habilidade de aprendizado em função de treinamento, proporciona eficiência mesmo em processos onde há ausência de conhecimento explícito sobre como identificar uma solução factível, além de serem modelos imunes a ruídos [1].

1.1. Considerações Gerais

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

1.2. Resenha Bibliográfica

Diante do contexto apresentado, buscamos por meios de leituras de artigos [5] a [9] abranger os conhecimentos sobre como tratar o problema de detecção dos gases incipientes em óleo isolante de transformadores. Destacamos como referencia para o desenvolvimento deste trabalho as pesquisas realizadas por Guardado, como a abordagem da eficiência das redes neurais em diagnósticos de transformadores de potência empregando Analise de Gases Dissolvidos (DGA).

Nos sistemas de diagnósticos proposto por Guardado as redes neurais foram treinadas com base em cinco critérios de diagnósticos, os métodos de Dörnenburg, Rogers modificado, Rogers, International Electrotechnical Commission (IEC) e Califórnia State University, Sacramento (CSUS).

Nos quatro primeiros métodos foi estabelecido que as variáveis de entrada fossem as relações gasosas e no caso do ultimo, as concentrações individuais de gases.

Nesses métodos as redes foram estruturadas por três camadas e o número de neurônios da camada oculta variando para cada critério utilizado, os resultados obtidos para estes modelos foram aceitáveis e com uma taxa de acerto de diagnóstico acima de 87% em todos os casos.

1.3. Objetivo

O objetivo geral deste trabalho é desenvolver um sistema com a aplicação de técnica de inteligência computacional que terá por finalidade diagnosticar faltas incipientes em transformadores de potência por meio da análise dos gases que se encontram dissolvidos no óleo isolante. Os resultados obtidos com a aplicação de Redes Neurais serão comparados com o diagnóstico de um dos métodos tradicionais existente, a fim de comprovar se a aplicação do método proposto é conveniente ou não na detecção destas faltas.

1.4. Escopo do trabalho

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

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 e que são utilizados nos transformadores. Esclarece ainda os tipos de faltas mais frequentes em transformadores de potência e suas prováveis causas a partir da análise do gás de decomposição dissolvido no óleo isolante.

O capítulo 3 introduz a teoria das redes neurais artificiais RNA, relatando seu histórico de desenvolvimento e suas aplicações. 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 4 apresento as conclusões sobre o método proposto e sugestões para trabalhos futuros.

Capítulo 2

Diagnóstico de Falhas em Transformadores

Apresento a seguir um diagnóstico de falhas em transformadores de potência baseado em análise de gases dissolvidos em óleo isolante. Na figura 1 é mostrado um transformador de potência 138 -13,8kV de 25 MVA.

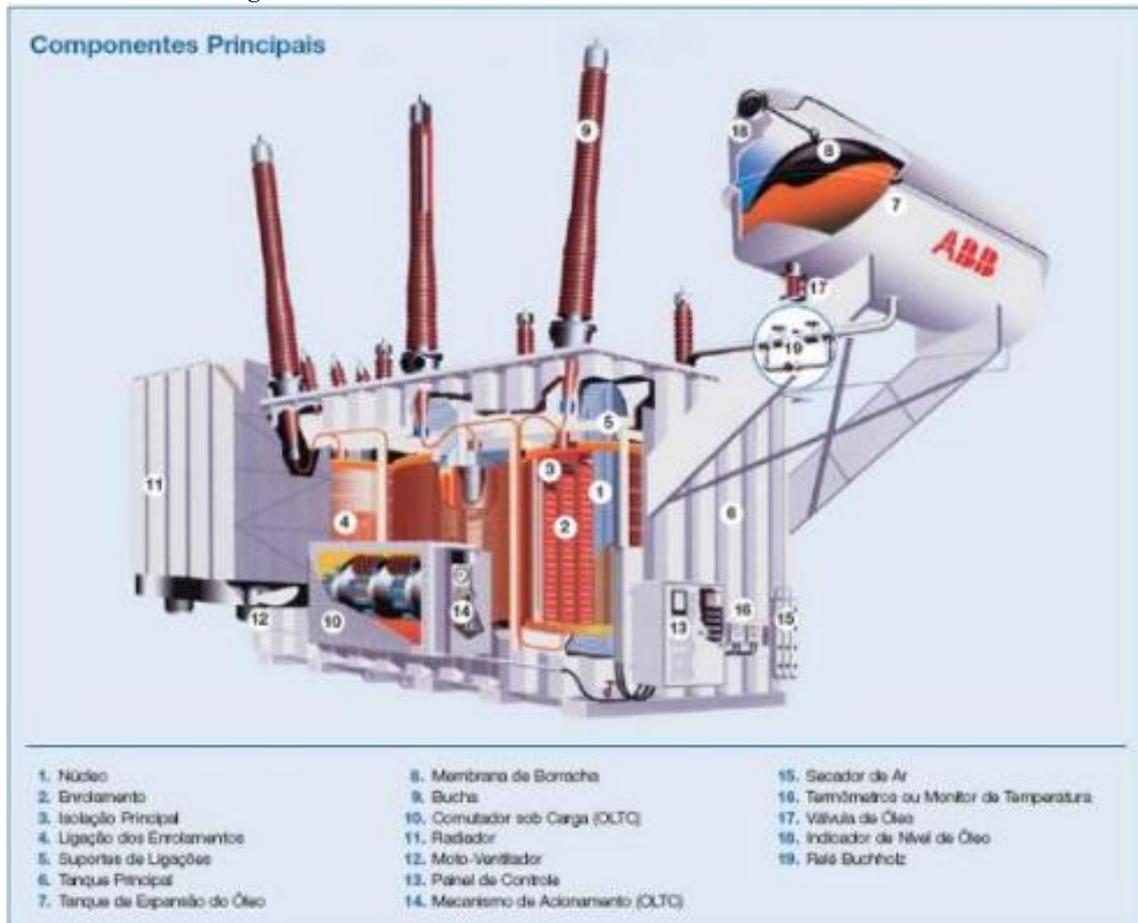
Figura 1 -Transformador de potência



Fonte: (CEMIG) Manual de Instalação e manutenção para transformadores a óleo

Na figura 2, são mostrados as partes constituintes de um transformador de potência.

Figura 2 -Partes constituintes de um transformador a óleo



Fonte: (ABB) - Asea Brown Boveri

2.1 Materiais e Líquidos Isolantes

Os equipamentos que se encontram instalados no sistema elétrico de potência, como os transformadores, reatores de potência, capacitores de alta tensão, chaves, comutadores e dentre outros equipamentos, utilizam o óleo isolante provindo de base de óleo mineral, estes fluidos são estáveis a altas temperaturas mantendo também as características de isolantes. As funções principais do óleo isolante são garantir o isolamento elétrico, extinguir descargas elétricas parciais e arcos elétricos servindo como meio de troca térmica para a refrigeração dos equipamentos.

O papel isolante também é um dos principais componentes utilizados para a isolação dos enrolamentos e partes ativas no interior dos transformadores de potência, sendo que o principal inconveniente da sua

utilização está nas condições de temperatura às quais o papel pode ser submetido. No caso de ocorrências de sobreaquecimento acima do nominal no papel ira provocar um envelhecimento precoce deste material, como apresentado na IEEE C57.91 (1995).

A vida útil dos transformadores esta muito ligada ao estado de degradação do isolamento sólido e da determinação do nível de degradação deste.

Os sistemas isolantes destes equipamentos são constituídos por óleo isolante e papel isolante e sofrem degradações, mesmo em condições de serviço normais. O óleo destes equipamentos pode ser facilmente substituído, sempre que tal se justifique, no decurso da vida do transformador, o que não acontece com o isolamento sólido.

Os isolamentos sólidos dos transformadores de potência geralmente são constituídos por papel Kraft, sendo este fabricado a partir de mistura de fibras de celulose curtas e longas, provenientes de polpas de madeiras macias. Esta mistura de fibras confere a este tipo de papel características de resistência mecânica com bom desempenho para o seu processamento em maquinas e uma relativa maciez e também apresentam alta resistência de isolamento quando secos (0,5% a 1% de umidade) e são higroscópicos, isto é absorvem umidade e óleo.

2.2 Análise de faltas

As falhas incipientes quando não são detectadas no início podem evoluir e levar á retirada de serviço os transformadores de potência de uma subestação. Falhas incipientes entendem-se aquelas que estão em um estágio inicial e promovem a decomposição do material isolante e, portanto, estão associadas ás concentrações de gases formados no interior dos transformadores.

As faltas que venham a ocorrer no sistema poderão resultar em interrupções da transmissão de energia, causando assim prejuízos financeiros para diversos setores da economia. Por isso um grande esforço vem sendo empregado a fim de se prever e corrigir possíveis falhas nestes equipamentos antes da ocorrência de uma falta que o retire de operação.

Atualmente as concessionárias de energia estão empenhadas em buscar soluções técnicas de diagnóstico de falhas incipientes mais assertivas devido ás mudanças estruturais no setor de energia elétrica, que promovem a competição em todos os níveis e estabelecem índices mais rigorosos de qualidade técnica e de serviço.

Na atual conjuntura este ambiente é altamente regulado sendo necessário melhorar o desempenho operacional e a confiabilidade dos transformadores que encontram instalados no sistema elétrico, principalmente porque tais equipamentos operam hoje em condições muito mais severas do que quando foram instalados, sejam por razões técnicas associadas ao envelhecimento natural, regimes de carregamento ou desgastes promovidos por esforços elétricos e mecânicos.

Dentre as praticas de monitoramento utilizam-se tanto os ensaios elétricos quanto fazem o acompanhamento do estado do óleo isolante através de análise físico-química e cromatográfica, como das convencionais de manutenção de transformadores e que em casos especiais requerem que estes sejam tirados de operação, para que seja feito o diagnóstico das suas condições de funcionamento.

Estes equipamentos em operação estão sujeitos às falhas devido aos estresses térmicos e elétricos. Essas falhas afetam principalmente a isolação, levando à decomposição do óleo mineral e da celulose, com a geração de gases que ficam dissolvidos no óleo isolante. A análise destes gases serve de indicativo para possíveis falhas.

Os gases mais comuns encontrados no óleo destes equipamentos em operação são o oxigênio (O_2), hidrogênio (H_2), monóxido de carbono (CO_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4), acetileno (C_2H_2), chamados de gases chaves e a sua presença pode indicar Hidrogênio que em grandes quantidades são relacionadas ao efeito corona, Metano, Etano, e Etileno sendo estes resultantes da decomposição térmica do óleo, o Monóxido e Dióxido de Carbono que estão relacionados a envelhecimento térmico do papel, já a produção de Acetileno esta associado a arcos elétricos no óleo. Definições:

Arco elétrico: Basicamente esse fenômeno elétrico ocorre devido uma ruptura dielétrica de um determinado gás que por consequência fará uma descarga de plasma, rompendo a isolação feita pelo ar e conduzindo elétrons de um eletrodo ao outro por meio de um fluxo de corrente, podemos comparar a um curto circuito. A formação do arco elétrico esta associado ao tipo do gás e a pressão no local, com isso podemos perceber logo porque cada arco elétrico possui temperaturas e brilhos diferentes. Quando ocorrem esses tipos de faltas teremos valores altos de hidrogênio e acetileno, já em proporções menores para o metano e o etileno. Se o arco envolve as partes isolantes dos transformadores como a celulose, os gases gerados serão o monóxido e dióxido de carbono.

Corona: Este efeito aparece na superfície dos condutores, nas ferragens e nos isoladores das linhas de transmissão de energia, bem como nas subestações e dá origem a uma perda de energia em forma de calor, luz, energia acústica e radiações eletromagnéticas. Nos transformadores de potência as descargas elétricas de baixa energia levam a produzir concentrações de hidrogênio e metano em pequenas quantidades de etano e

etileno. Quantidades significativas de monóxido e dióxido de carbono também poderão surgir se as descargas forem provocadas nas partes isolantes dos transformadores como na celulose.

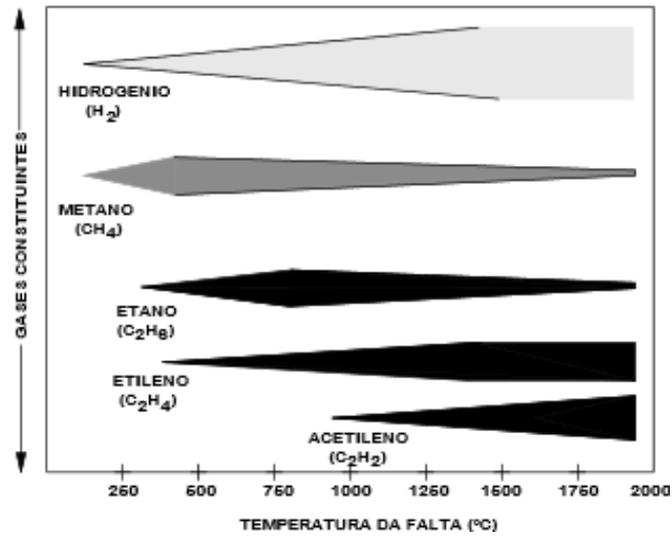
Sobre aquecimento do óleo: Conforme apresentado na ABNT NBR (5356 -2:2007) as elevações de temperatura dos enrolamentos, do óleo, das partes metálicas e de outras partes de transformadores, projetados para funcionamento nas condições normais, previstas em 4.1 da ABNT NBR 5356-1, não devem exceder os limites especificados desta norma. Quando ocorre sobre aquecimento do óleo teremos o surgimento de gases como etileno e metano e baixas concentrações de hidrogênio e etano.

Degradação da celulose: Neste caso teremos valores altos de monóxido e dióxido de carbono indicando que o problema estará associado com o sobre aquecimento das partes isolantes dos transformadores. Gases hidrocarbonetos, tais como o metano e etileno serão formados se o problema estiver relacionado com a isolação do enrolamento, normalmente papel isolante impregnado de óleo.

Eletrólise: Neste caso o óleo estará contaminado em função de água e outras substâncias, sendo que esses produtos não fazem parte da composição do óleo isolante. Devido a estas contaminações teremos o surgimento de grandes quantidades de hidrogênio, com pequenas quantidades de outros gases combustíveis em função da água associada com a ferrugem.

Algumas vantagens óbvias da análise de faltas estão relacionadas a aviso antecipado da ocorrência de faltas, evita o uso impróprio das unidades, aceitação de unidades novas ou reparadas, agendamento conveniente de manutenções, monitoramento de unidades em sobrecarga. Os gases gerados durante as faltas que são geralmente encontrados em transformadores estão ilustrados abaixo na figura 3, relacionados á temperatura em que ocorrem e á proporção do seu desenvolvimento:

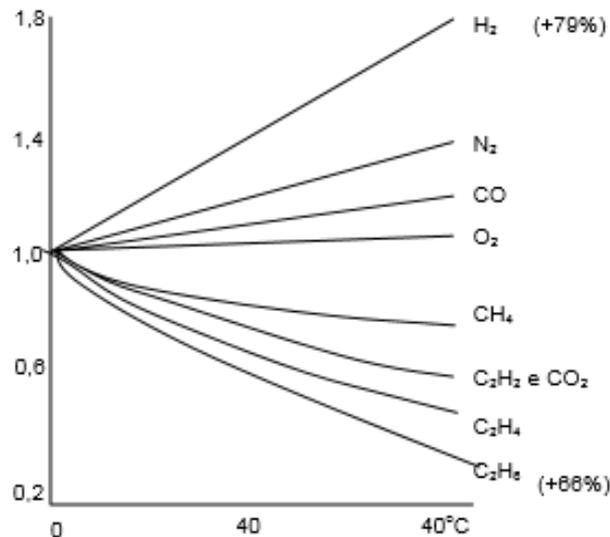
Figura 3-Gases típicos gerados durante faltas



Fonte: SNPTEE Seminário Nacional de Produção e Transmissão de Energia Elétrica, 2005, Curitiba – Paraná.

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%, conforme ilustrados abaixo na figura 4.

Figura 4 -Solubilidade relativa como função da temperatura



Fonte: SNPTEE Seminário Nacional de Produção e Transmissão de Energia Elétrica, 2005, Curitiba – Paraná.

2.3 Métodos de Detecção de Falhas

Todos os fenômenos que estão relacionados á formação de gases em transformadores e sua correlação com as falhas incipientes são caracterizados por imprecisões, incertezas nas medidas e não-linearidades não modeladas.

Dentre os métodos citados na literatura iremos abordar três, sendo o primeiro o método da análise de gases dissolvidos no óleo (DGA), o mais utilizado atualmente pelas concessionárias de energia e no caso deste método varias técnicas também são envolvidas como IEEE C57.104-1991, Método de Doernenburg [Doernenburg,67], Método de Rogers [Rogers,75 e 78], IEC 60599 e Método dos Gases Chave [Fallou 75].

Porem o problema associado aos métodos de DGA convencional é que a decisão final sempre ficara nas mãos de um especialista, desta forma sempre haverá dependência para as tomadas de decisões.

Outro problema verificado e que, nas subestações de energia elétrica das concessionárias há transformadores de diferentes fabricantes, nível de tensão e potência, estrutura, material utilizado no sistema de isolamento, tipo de carregamento e histórico de manutenção e isto poderá apresentar diferentes características quanto à produção de gases assim necessitam, na maioria dos casos, serem considerados individualmente.

Outro fato é que o nível e período de formação destes gases dependem muito da idade dos transformadores e também da localização, natureza e severidade das falhas a que são submetidos.

O segundo método abordado é o que determina o total de gases combustíveis (TCG), porem este só consegue detectar o gás acima do nível do óleo.

O terceiro método de detecção dos gases de falta é a análise do manto de gás, na qual uma amostra do gás que se encontra acima do óleo tem sua composição analisada. Este método detecta todos os componentes individuais; porem, ele não se aplica aos equipamentos que tem tanque de expansão. Para a realização das análises necessita-se também de um laboratório bem equipado para fazer as separações e identificação dos gases.

2.4 Métodos de Interpretação

Existem métodos clássicos para classificação de transformadores a partir da quantidade e da natureza dos gases encontrados no óleo isolante.

O mapeamento correto desses gases incipientes nos dará condições de elaborar os planos de manutenção de maneira mais assertiva, representando para as concessionárias de energia, melhor eficiência operacional para os ativos instalados.

2.5 Aplicação do método Dornenburg

O método de Dornenburg baseia-se nas relações CH_4/H_2 , C_2H_2/C_2H_4 , C_2H_6/C_2H_2 , e C_2H_2/CH_4 e a aplicação deste método permite realizar três tipos de diagnósticos: descargas de baixa intensidade (efeito corona), descargas de alta intensidade (arcos elétricos) e decomposição térmica [10].

Esse método utiliza as razões R1, R2, R3 e R4 para indicar uma determinada falha dentre os três tipos de diagnostico mencionados.

Estas razões entre as concentrações dos gases encontram-se apresentados na Tabela 1.

Tabela 1- razões entre as concentrações dos gases

Razão	CH_4/H_2	C_2H_2/C_2H_4	C_2H_2/CH_4	C_2H_6/C_2H_2	C_2H_4/C_2H_6
Notação	R1	R2	R3	R4	R5

Fonte: IEEE Std C57.104-2008

A tabela 2 apresenta os valores limites para as concentrações de gases.

Tabela 2-Limites de Concentração

Gás chave	Concentrações L1[ML/L(p.p.m)]
Hidrogênio (H2)	200
Metano (CH4)	50
Acetilénio (C2 H2)	15
Etilénio(C2 H4)	60
Etano (C2H6)	15

Fonte: IEEE Std C57.104-2008

A tabela 3 apresenta as faixas das razões R1, R2, R3 e R4, definidas por Dörnenburg bem como a relativa falha associada.

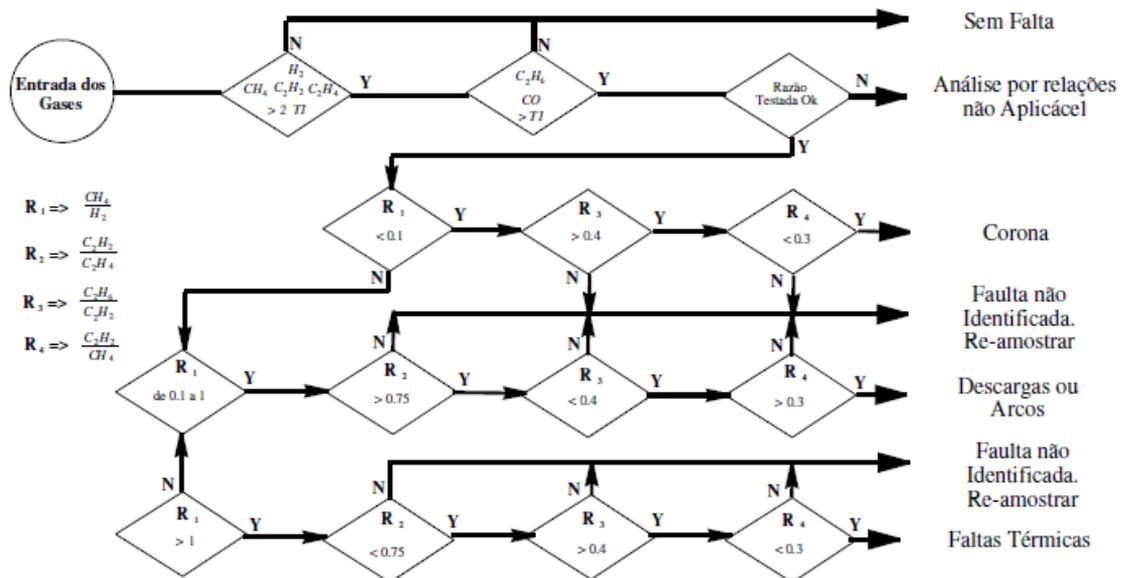
Tabela 3 -Faixas das razões para os gases chaves-Doernenburg[9]

Falha Incipiente	R1	R2	R3	R4
Decomposição térmica	>1.0	<0.75	<0.3	>0.4
Descargas de baixa	<0.1	-	<0.3	>0.4

Fonte: IEEE Std C57.104-2008

O fluxograma apresentado na figura 6 ilustra passo a passo para a aplicação do método das razões de Dornenburg.

Figura 5-Fluxograma de Aplicação do Método das Razões de Dornenburg



A seguir são descritos os passos indicados na Figura 6:

Passo 1: As concentrações dos gases são obtidas através da análise cromatográfica do óleo isolante;

Passo 2: Se ao menos uma das concentrações avaliadas para H_2 , CH_4 , C_2H_2 e C_2H_4 exceder duas vezes os valores limites apresentados na Tabela 2 o equipamento testado é considerado defeituoso e deve-se, então, prosseguir para o passo 3 para verificar a validade do método;

Passo 3: Na determinação da validade do procedimento se no mínimo um dos gases em cada relação exceder o limite da tabela 2, o procedimento das razões é considerado válido, caso contrário, as razões não são significativas e a

unidade devera ter novas amostras retiradas e ser investigada por processos alternativos.

Passo 4: Assumindo que o método de análise é válido, cada relação é comparada com os valores limites obtidos a partir das Tabelas 2 e 3;

Passo 5: Se todas as relações estiverem dentro dos limites apresentados na Tabela 3 para um tipo de falta específico, então o tipo de falta sugerido é válido.

Esse método de diagnóstico deve ser usado apenas com extrema precaução, pois os gases dissolvidos foram originados a partir de faltas que podem não persistir ao longo do tempo, estes gases de decomposição se desprendem para a superfície do óleo, expandindo-se no tanque do transformador e perdendo-se na atmosfera. Este fato pode causar distorções no diagnóstico.

2.6 Aplicação do método de Rogers Modificado:

Em 1975 Rogers (ROGERS, 1975) produziu um refinado código a partir das faixas de relação de gases, utilizando-se quatro relações, mas diagnosticando um maior número de faltas. O uso deste código facilita a programação computacional no desenvolvimento de sistemas para diagnósticos de falta. Posteriormente, com base em estudos estatísticos em mais de dez mil análises de gás em óleo isolante de transformadores, Rogers (ROGERS, 1978) mostrou que certos tipos de condições de faltas poderiam ser diferenciados em faixas mais detalhadas a partir de combinação de relações de gases. Isso foi confirmado devido a análises realizadas em transformadores suspeitos juntamente com unidades destruídas em faltas, bem como pelo estudo de pontos quentes prováveis de ocorrer em transformadores sob condições operacionais.

Com objetivos de estabelecer a identificação de faltas reais Rogers (ROGERS, 1978) realizou um estudo em cem conjuntos de análises de óleo extraídos de transformadores com conhecidos tipos de faltas a fim de avaliar a provável temperatura na qual as relações indicam mudanças significativas e diante do resultado desse estudo e de avaliações teóricas, novos valores das

relações para faltas elétricas e térmicas foram então obtidas. Assim, pôde-se estabelecer que o uso de apenas três relações simplificasse a interpretação. Para ajudar no entendimento da técnica as tabelas anteriores foram reorganizadas para indicar uma progressão mais racional de faltas, resultando no código descrito na tabela 4, com este critério podemos identificar oito tipos de faltas características.

Tabela 4 - Código para Análise de Gases Dissolvidos em óleo

Código de Faixas de Relação	Razão de Gases Característicos		
	$\frac{C_2H_2}{C_2H_4}$	$\frac{CH_4}{H_2}$	$\frac{C_2H_4}{C_2H_6}$
< 0.1	0 (L)	1 (L)	0 (L)
0.1 - 1.0	1 (M)	0 (M)	0 (L)
1.0 - 3.0	1 (M)	2 (H)	1 (M)
> 3.0	2 (H)	2 (H)	2 (H)

Código de Falta	Tipo de Falta Característica	$\frac{C_2H_2}{C_2H_4}$	$\frac{CH_4}{H_2}$	$\frac{C_2H_4}{C_2H_6}$
0	Operação Normal	0 (L)	0 (M)	0 (L)
	Falta Térmica de Baixa			
1	Intensidade < 150°	0 (L)	0 (M)	1 (M)
	Falta Térmica de Baixa			
2	Intensidade 150° - 300°	0 (L)	2 (H)	0 (L)
	alta Térmica de Média			
3	Intensidade 300° - 700°	0 (L)	2 (H)	1 (M)
	Falta Térmica de Alta			
4	Intensidade > 700°	0 (L)	2 (H)	2 (H)
	Descargas Parciais de			
5	Baixa Intensidade	0 (L)	1 (L)	0 (L)
	Descargas Parciais de			
6	Alta Intensidade	1 (M)	1 (L)	0 (L)
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)

Fonte: IEEE Transactions On Power Delivery, Vol. 16, NO. 4, October 2001

Assim, o código de Rogers passou a ser incluído no documento IEC 10A53 e também recomendado pelo IEEE como o principal código para interpretação de faltas incipientes em transformadores, usando análise de gases dissolvidos no óleo isolante.

2.7 Aplicação do método de IEC:

International Electrotechnical Commission (IEC). Este critério de diagnóstico utiliza basicamente os vetores de entradas de Rogers para as relações gasosas CH_4/H_2 , $\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$, $\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$.

2.8 Aplicação do método de CSUS:

California State University Sacramento (CSUS). Este é o único critério de diagnóstico com base em gases, as concentrações individuais são representadas em Partes Por Milhão (PPM), neste caso a entrada do vetor é construída pelos gases H_2 , CH_4 , C_2H_4 , C_2H_6 , C_2H_2 , com esse método só é possível identificar seis tipos de faltas características.

2.9 Redes neurais

As Redes Neurais Artificiais (RNAs) também têm sido utilizadas com a finalidade de diagnosticar faltas incipientes em transformadores através da análise de gases dissolvidos no óleo isolante.

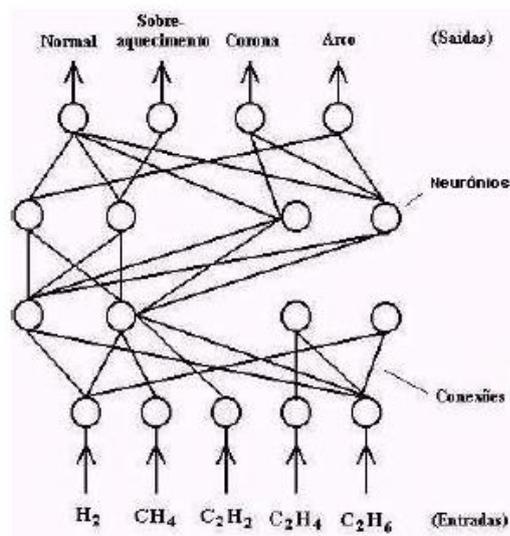
Sua aplicação é baseada no fato de que uma RNA, por intermédio de processos de treinamento, pode revelar mecanismos complexos que podem ser desconhecidos. Para tanto é necessário uma criteriosa seleção dos parâmetros da RNA a ser utilizada, tais como topologia da rede, número de camadas intermediárias, número de neurônios por camada, bem como as características de entrada e saída. Esses parâmetros podem ser obtidos experimentalmente, por meio de processos, tentativa e erro, a fim de determinar o melhor número de camadas intermediárias.

Zang et.al.(1996) mostrou que uma abordagem “dois-passos” poderia alcançar melhores performances no diagnóstico, sendo útil, também, para distinguir faltas relativas à decomposição da celulose de faltas relativas à decomposição do óleo.

Esta abordagem consiste na construção de duas RNAs distintas. A primeira tem a finalidade de diagnosticar os principais tipos de falta no transformador, tais como sobreaquecimento, corona e arcos, incluindo a condição normal. A segunda RNA tem a finalidade de diagnosticar apenas a

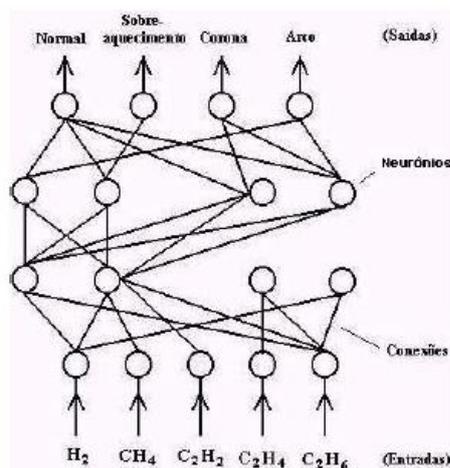
degradação da celulose. Desta forma é possível diagnosticar sete possíveis padrões de falta (incluindo a condição normal), uma vez que cada um dos principais tipos de falta pode ou não estar acompanhado de processos de degradação da celulose. As duas RNAs propostas por Zhang podem ser vistas nas Figuras 7 e 8, respectivamente.

Figura 6- RNA para diagnóstico dos principais tipos de falta proposta por Zhang



Fonte: Zang et.al.(1996)

Figura 7 - RNA para diagnóstico de degradação da celulose proposta por Zhang



Fonte: Zang et.al.(1996)

Com as estruturas propostas por Zang et.al.(1996) foram obtidas grande precisão no diagnóstico, porém, para efeitos reais, essa precisão depende, em grande parte, da consistência e do volume dos dados de treinamento.

Capítulo 3

3.1 Sistema de Diagnósticos Propostos

O capítulo 3 é dedicado a apresentar os sistemas de diagnósticos desenvolvidos neste trabalho, bem como o procedimento de aplicação da norma ANSI/IEEE Std C57.104 - (19991) ao conjunto de dados, fornecidos pela Companhia Energética de Minas Gerais (CEMIG), referente á análise cromatográfica realizada em óleo isolante de seus transformadores de potencia, para obtenção dos diagnósticos de falta nestes equipamentos. Estes dados foram utilizados nos processos de aprendizado dos sistemas desenvolvidos.

3.2 Base de Dados Utilizados

A base de dados utilizados no diagnóstico proposto foi fornecida pela CEMIG e foram extraídas de amostras de óleo isolante de transformadores de potência instalados em todo o estado de Minas Gerais, coletadas no período entre 2013 até dezembro de 2015. Estas informações constavam de concentração, em PPM, dos onze principais gases que normalmente se encontravam dissolvidos em óleo isolante, conforme mostrado na Tabela 15, extraídos a partir de análises cromatográficos.

O procedimento de análise cromatográfico neste caso foi executado segundo a norma ANSI/IEEE Std (57.104-(1978)).

Por serem considerados como irrelevantes no processo de diagnostico (Dornenburg e STRITTMATTER, 1974), (FALLOU, 1975), o Propano (C_3H_8) e o Propileno (C_3H_6) foram desconsiderados desta base de dados.

Contudo, para a utilização dos dados desta base no desenvolvimento dos sistemas de diagnósticos necessitou-se não apenas das concentrações dos gases que se encontravam dissolvidos no óleo, mas também dos diagnósticos relativos a tais amostras, para que assim fosse possível se proceder ao treinamento e ajuste dos sistemas desenvolvidos. Como não foi possível obter

tais informações, foi desenvolvido um sistema que, a partir das informações das concentrações dos gases, pudesse simular um diagnóstico para cada uma das amostras da base de dados. Este sistema foi desenvolvido conforme normatização internacional, sendo apresentado na próxima seção.

3.2 Sistema de Simulação de Diagnóstico

Para que os procedimentos de treinamento dos sistemas de diagnósticos pudessem ser implementados, foi inicialmente necessário o desenvolvimento de um algoritmo que a partir das informações referentes às análises cromatográficas, gerasse um diagnóstico, que seria tomado como referência para o sistema em desenvolvimento.

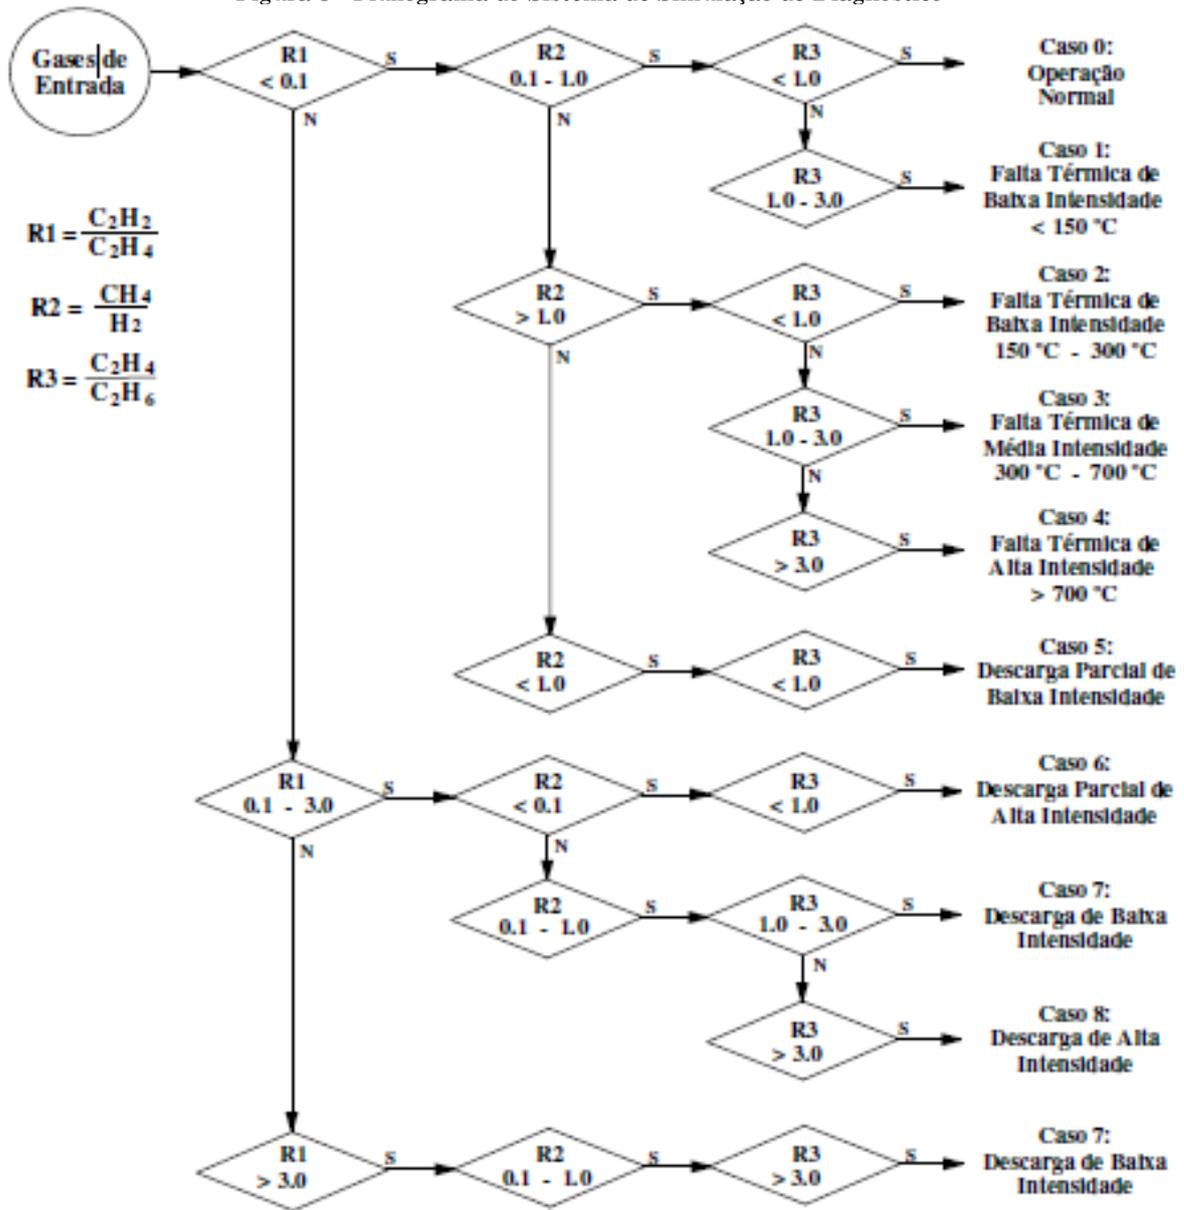
Desta forma, foi necessário adotar um critério de diagnóstico de faltas a partir da análise de gases dissolvidos, descritos no Capítulo 2, para que este servisse de base para o sistema de simulação proposto.

Uma vez que o método dos gases chave e o método das razões de Dornenburg diagnosticam apenas um limitado número de faltas.

O método das razões de Rogers foi tomado como base deste sistema, sendo que este método é, também, o recomendado pela normalização internacional (ANSI/IEEE Std C57.104-1991).

O sistema de simulação de diagnóstico com a finalidade de automatizar o método das razões de Rogers foi implementado segundo o fluxograma apresentado na Figura 10 que serviu de referência para a validação dos resultados obtidos pelos sistemas de diagnóstico propostos neste trabalho.

Figura 8 - Fluxograma do Sistema de Simulação de Diagnóstico



Fonte: (ANSI/IEEE Std C57.104 -1991)

3.3 Técnicas de Inteligência Computacional no Diagnóstico de Falhas

Para resolver o problema de identificação de falhas em transformadores de potencia a partir da análise de gases dissolvidos em óleo isolante, será aplicada a técnica de inteligência computacional e o desempenho de cada estrutura será avaliado e comparado a seguir.

3.4 Rede Neural MLP Aplicada no Diagnóstico de Falhas em Transformadores de Potencia.

A justificativa de obter-se uma estrutura de sistema de diagnóstico de falta em transformadores de potencia usando uma rede neural Perceptron de Múltiplas Camadas (MLP) foi devido ao seu campo de aplicação bastante amplo e sua grande capacidade de generalização.

Para estes casos as entradas para o sistema de diagnostico utilizando a rede MLP foram tomadas como sendo as relações de gases que fazem parte do método das Razões de Rogers, ou seja, C_2H_2/C_2H_4 , CH_4/H_2 e C_2H_4/C_2H_6 e a saída àquelas obtidas por meio do sistema de simulação de diagnóstico da Figura 10.

O processo de treinamento foi construído utilizando-se o algoritmo Levenberg-Marquardt. Este algoritmo de treinamento de Redes Neurais é um dos mais utilizados em aplicações em que a função possui características não lineares.

Sobre os procedimentos para se definir o tamanho da rede neural foi levado em consideração o numero de camadas intermediarias e o numero de neurônios em cada uma dessas camadas. Estes números devem conter um compromisso entre convergência, que é a capacidade da Rede Neural de aprender todos os padrões do conjunto de treinamento, e generalização, que é a capacidade de responder corretamente a padrões nunca vistos.

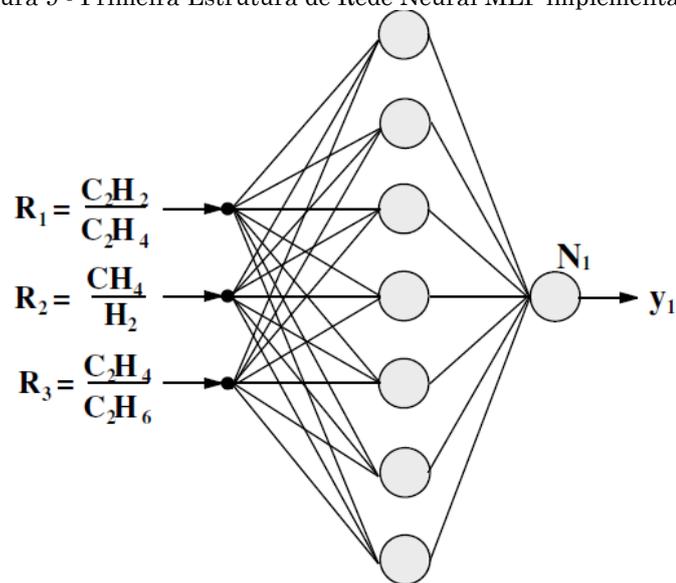
Se a rede neural for pequena, não será capaz de armazenar todos os padrões necessários, por outro lado se a rede for muito grande (muitos parâmetros = pesos), esta poderá não responder corretamente aos padrões nunca vistos.

Uma das maneiras de se resolver este problema é a utilização da métrica de Hecht-Nielsen (HECHT-NIELSEN, 1990), baseado no teorema de Kolmogorov-Nielsen (1957), que afirma que com apenas uma camada oculta já é possível calcular uma função arbitrária qualquer a partir de dados fornecidos. De acordo com esta métrica, a camada oculta deve ter por volta de $2n+1$ neurônios, onde n é o número de variáveis de entrada.

Desta forma, a estrutura da rede MLP a ser utilizada estava praticamente definida, faltando apenas o número de neurônio de saída. Este parâmetro foi definido empiricamente, por meio dos testes de desempenho de três possíveis estruturas.

Assim, a primeira destas estruturas a ser testada foi uma rede com 3 neurônios de entrada, 7 neurônios na camada intermediária e apenas 1 saída, conforme mostrado na figura 11.

Figura 9 - Primeira Estrutura de Rede Neural MLP implementada

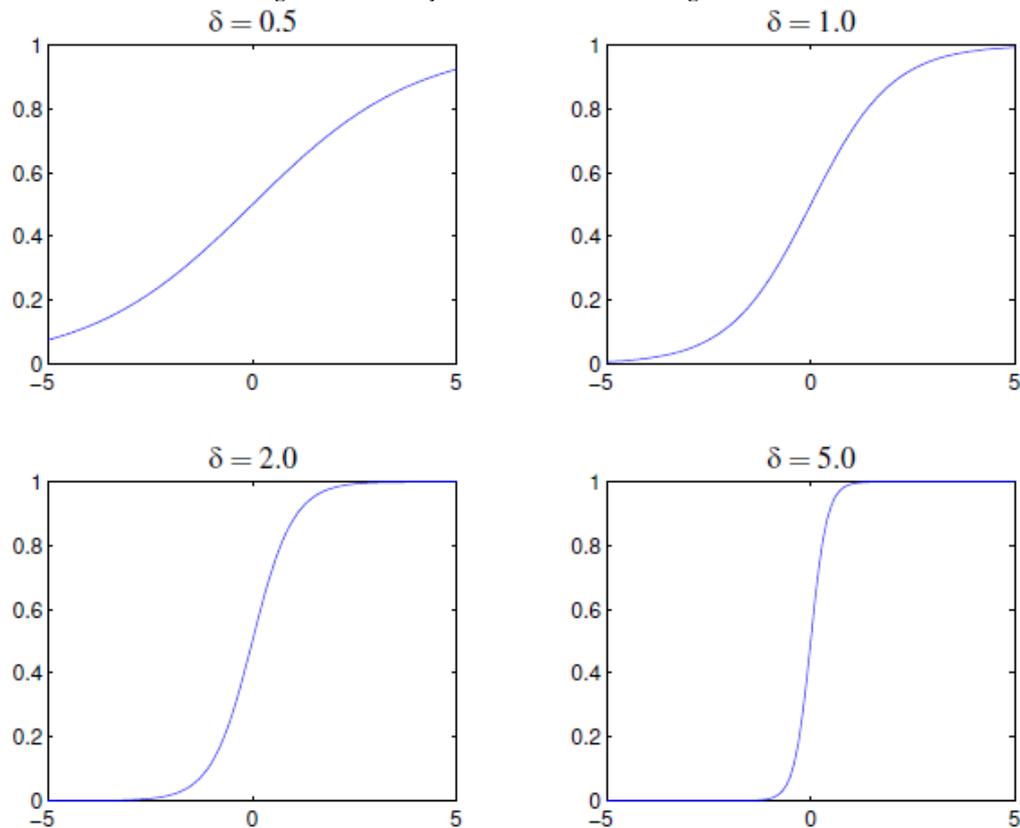


Nesta rede, todos os neurônios foram estruturados usando uma função de transferência do tipo sigmoidal, apresentada na Equação a seguir.

$$y_j^{(\ell)} = \frac{1}{1 - e^{-\delta \times v_j^{(\ell)}}}$$

Onde $y_j^{(\ell)}$ é a saída do neurônio j da camada. O sigma representa a inclinação da função, conforme mostrado na figura 12:

Figura 10 - Função de Transferência Sigmoidal



Uma vez que o neurônio de saída y_1 também executava uma função sigmoidal, a saída da rede estava compreendida no intervalo entre $[0,1]$.

A camada de saída da rede neural MLP representa o código de diagnóstico do método das razões de Rogers apresentado na Tabela 10, porém de forma binária. Assim, para obter-se os vetores de treinamento utilizados no processo de aprendizado é necessário converter os códigos de falta relativos às amostras de entrada em números binários.

Da mesma forma, para se extrair o código de falta após a aplicação de um padrão de entrada na rede é necessário converter o número binário gerado na saída da rede em um decimal.

Tabela 4- Correlação entre os Tipos de Falta e a Saída da Primeira Rede Neural MLP

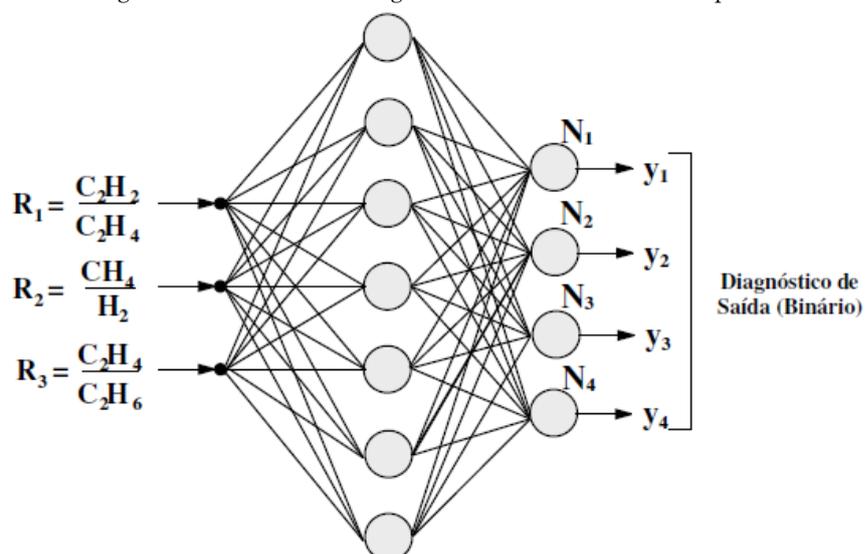
Tipo de Falta	N_1
0	0.0
1	0.1
2	0.2
3	0.3
4	0.4
5	0.5
6	0.6
7	0.7
8	0.8

Tabela 5 - Os parâmetros usados no treinamento

Parâmetro	Valor
Número de Camadas	3
Número de Neurônios na Camada 1	3
Número de Neurônios na Camada 2	7
Número de Neurônios na Camada 3	1
Tolerância de Erro	10^{-5}
Taxa de Aprendizado	Adaptativa
Coefficiente δ da Função de Ativação	1
Coefficiente de Momento	0.9

Assim, a segunda estrutura testada foi uma rede com 3 neurônios de entrada, 7 na camada intermediária e 4 na saída, conforme mostrado na figura 13.

Figura 11-Estrutura da Segunda Rede Neural MLP Proposta



As relações de correspondência entre a saída da segunda Rede Neural proposta e o tipo de falta associado a ela pode ser visto na Tabela 12.

Tabela 6-Correlação entre os Tipos de Falta e a saída da Rede Neural MLP

Tipo de Falta	N_1	N_2	N_3	N_4
0	0	0	0	0
1	0	0	0	1
2	0	0	1	0
3	0	0	1	1
4	0	1	0	0
5	0	1	0	1
6	0	1	1	0
7	0	1	1	1
8	1	0	0	0

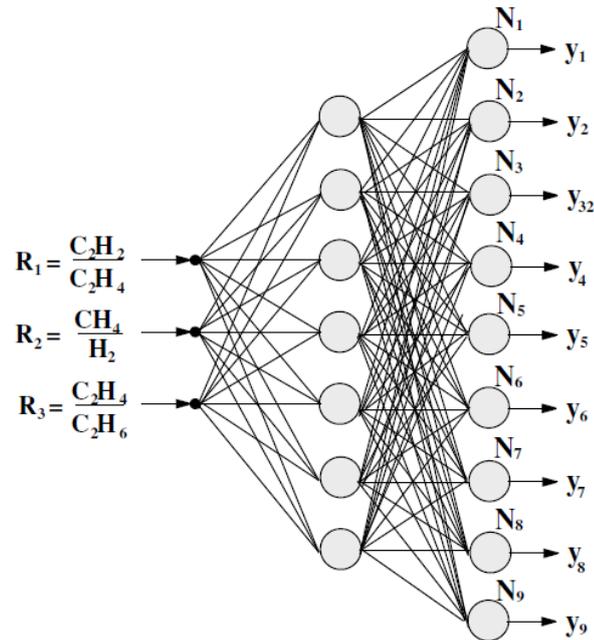
A configuração e os parâmetros usados na segunda rede neural são ilustrados na Tabela 13. A função de ativação utilizada também foi à sigmoïdal. Para se obter o valor final na camada de saída, as saídas dos neurônios desta camada passam por um arredondamento, que toma como saída final o valor inteiro mais próximo da saída dos neurônios da camada de saída, garantindo que a saída da rede seja sempre binária.

Tabela 7 -Parâmetros Usados na Rede Neural MLP

Parâmetro	Valor
Número de Camadas	3
Número de Neurônios na Camada 1	3
Número de Neurônios na Camada 2	7
Número de Neurônios na Camada 3	4
Tolerância de Erro	10^{-2}
Taxa de Aprendizagem	Adaptativa
Coefficiente δ da Função de Ativação	1
Coefficiente de Momento	0.9

A terceira estrutura testada foi uma rede com 3 neurônios de entrada, 7 na camada intermediária e 9 na camada de saída, onde cada uma das saídas representava um determinado tipo de falta. Esta estrutura é apresentada na Figura 14.

Figura 12- Estrutura da Terceira Rede Neural MLP



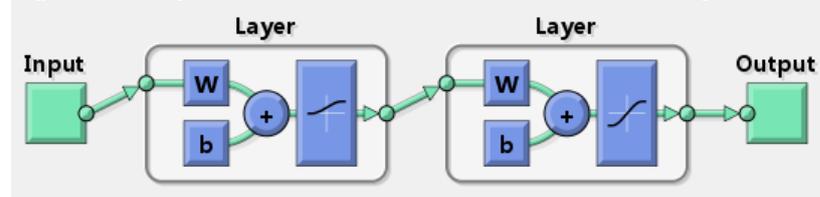
Da mesma forma que para as redes anteriores, na terceira estrutura também foi utilizada a função de transferência sigmoideal. Os parâmetros desta rede são os apresentados na Tabela 14.

Tabela 8 - Parâmetros Usados na Rede Neural MLP

Parâmetro	Valor
Número de Camadas	3
Número de Neurônios na Camada 1	3
Número de Neurônios na Camada 2	7
Número de Neurônios na Camada 3	9
Tolerância de Erro	10^{-2}
Taxa de Aprendizagem	Adaptativa
Coefficiente δ da Função de Ativação	1
Coefficiente de Momento	0.9

Apresentamos na Figura 15, a arquitetura das redes neurais utilizada neste trabalho.

Figura 13 - Arquitetura da Rede Neural Feed-Forward de dupla camada



Fonte: (MATHWORKS, 2016)

3.5 O Algoritmo de Levenberg-Marquardt

O algoritmo de Levenberg-Marquardt tornou-se a técnica padrão para localização de mínimos em problemas em que a função possui características não lineares. Particularmente, esta característica surge em problemas de interpolação em ambientes em que se dispõe de pontos e deseja-se encontrar uma função que a eles se ajuste. Para que se tenha uma condição não linear nesta problemática basta que a função de interpolação apresente parâmetros não lineares. Trabalhando-se com espaços de estado tal condição não é difícil de apresentar. Tipicamente tratam-se de sistemas superdeterminados, em que se conhecem mais relações entrada-saída do que seu número de saídas. Esta é uma das premissas sobre as quais se desenvolveram os Métodos de Mínimos Quadrados para nortear a aproximação de funções. De uma forma simplificada, a solução é encontrada minimizando-se a soma dos quadrados dos erros dos resultados de cada equação do sistema superdeterminado de uma forma iterativa. Em se tratando de Redes Neurais Artificiais não é aconselhável pressupor que o espaço de estados a ela apresentado seja linear, mas que tal rede seja capaz de aprender funções não lineares multivariáveis com precisão. É interessante que se desenvolva o treinamento de forma que não seja necessário introduzir conhecimento sobre a estrutura do sistema em investigação, assim permitindo que a própria rede deduza o acoplamento entre as variáveis de estado disponíveis durante o treinamento. (RANGANATHAN, 2004)

Naturalmente pode-se perceber que, para a Rede Neural Artificial, a dedução dos parâmetros de saída a partir das informações de entrada possui natureza aleatória e possivelmente não linear. Desta forma é imprescindível que o algoritmo de treinamento possua garantia de convergência independente de não linearidades, deixando a questão de tempo de treinamento em segundo

plano, embora ainda importante. O Método de Levenberg-Marquardt, conforme dito cumpre estas exigências muito bem, e daí advém sua adoção como padrão para aplicações de interpolação por funções.

O algoritmo de Levenberg-Marquardt pode ser visto como uma combinação do aclamado Método de Gauss-Newton para localização de mínimos e o Método de Gradiente Descendente em um ambiente multivariáveis. Sua grande virtude é a garantia de convergência, que pode tomar certo tempo caso a iteração atual estiver longe da solução, mas com rapidez semelhante ao método de Gauss-Newton quando estiver já próxima dela. Estas características fazem dele uma escolha natural para o treinamento de Redes Neurais Artificiais. (LOURAKIS, 2005).

A demonstração matemática da composição do algoritmo de Levenberg-Marquardt a partir do Método de Gauss-Newton em conjuntura com o Método de Gradiente Descendente pode ser verificada em GAVIN (2011).

3.6 Simulações e Resultados

Neste item será introduzida a parte prática deste trabalho com Redes Neurais Artificiais levando em consideração também a implementação dos testes que foram realizados para esta investigação. Com base nas redes neurais que foram propostas, na detecção de gases dissolvidos em óleo optou-se por apresentar os resultados típicos dos treinamentos para uma rede com arquitetura de sete neurônios, e outra com dez deles. No entanto, é possível realizar testes com a toolbox com quantos neurônios se desejarem, num intervalo de 1 a 10000 neurônios.

Ambas foram submetidas a treinamentos nas duas separações aleatórias dos dados a Seguir:

- 70% dos dados para treinamento, 15% para validação e 15% para teste;
- 80% dos dados para treinamento, 10% para validação e 10% para teste.

3.7 Estruturando as Redes Neurais no toolbox

A partir da janela de linha de comando (Command Window) do MATLAB, pode-se invocar a toolbox de Redes Neurais Artificiais com o comando `nnstart`, seguido da tecla Enter. Este comando retomará a tela apresentada na figura 16.

Figura 14 - Interface Principal da toolbox de Redes Neurais Artificiais do MATLAB

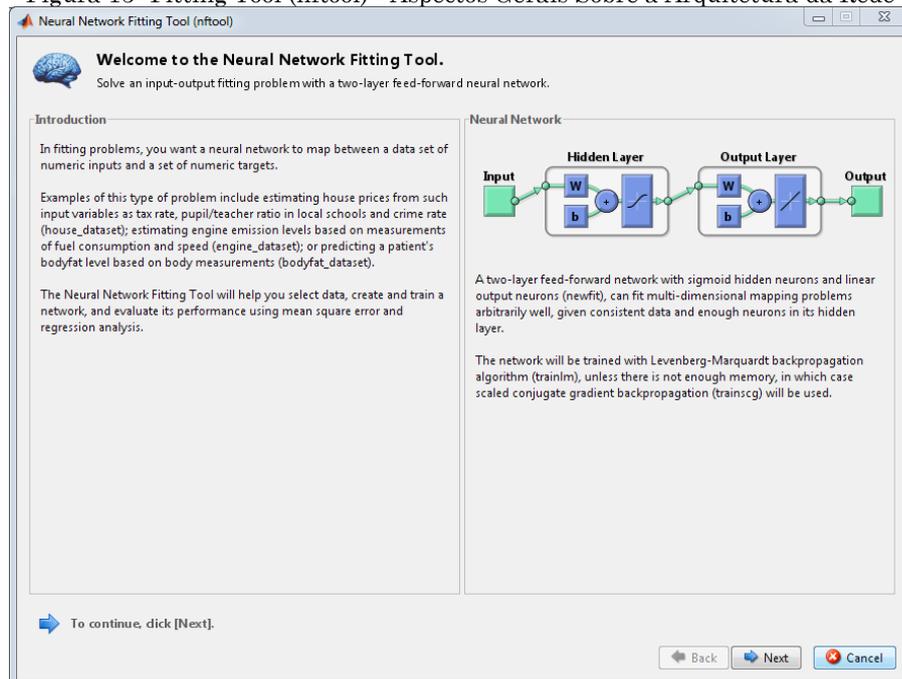


Fonte: simulação realizada, 2016

A partir desta ferramenta gráfica disponível, no caso deste trabalho interessa-nos a denominada Fitting Tool (`nftool`). Alternativamente, a partir da janela de linha de comando (Window), `nftool`, seguido da tecla Enter). A seguir, passaremos ao procedimento experimental e descrição da utilização da ferramenta Fitting Tool (`nftoolHyperMatrix`; Seus autovalores correspondentes formam o denominado `MiHyperTarget`).

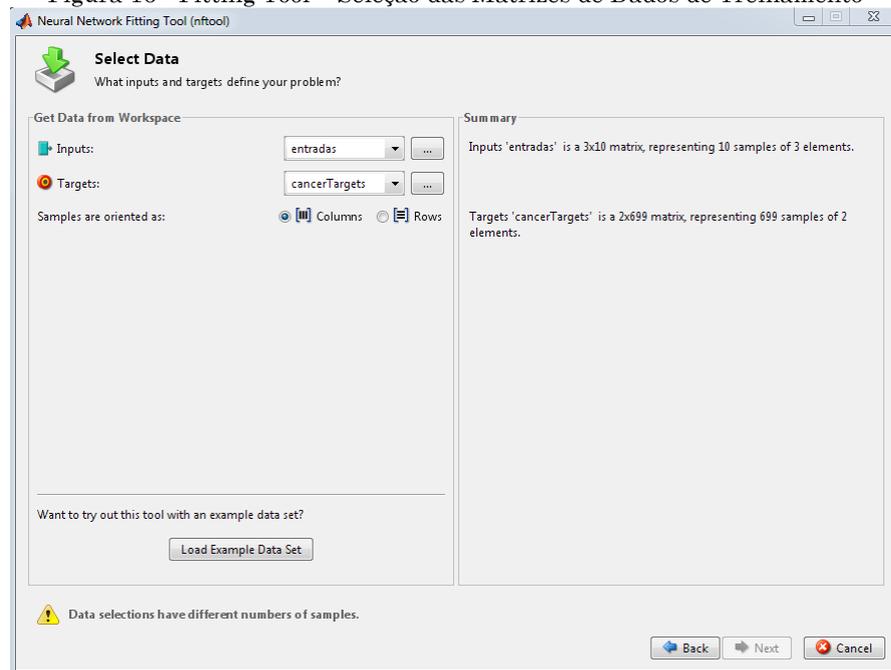
Codes presente na mesma pasta em que `SystemAcquire`.TM (Command Window) do `nnstart`, toolbox de Redes Neurais Artificiais do MATLAB pode-se utilizar uma das quatro ferramentas que interessa-nos a primeira opção, `nftool`), descrita como "Input-output and Curve Fitting". (pode-se invocar diretamente a rotina Figura 17 – Interface Pré – Treinamento da Rede Neural Artificial Fitting Tool pelo comando `nftool`).

Figura 15- Fitting Tool (nftool) - Aspectos Gerais Sobre a Arquitetura da Rede



Fonte: simulação realizada, 2016.

Figura 16 - Fitting Tool – Seleção das Matrizes de Dados de Treinamento



Fonte: simulação realizada, 2016.

Definidas quais as matrizes de dados de treinamento a serem utilizadas pela ferramenta pelo passo anterior, segue-se procedendo à separação do bloco de dados disponíveis em três outros blocos menores, separando-se as amostras do bloco original de forma aleatória e distribuindo-as nestes novos três blocos,

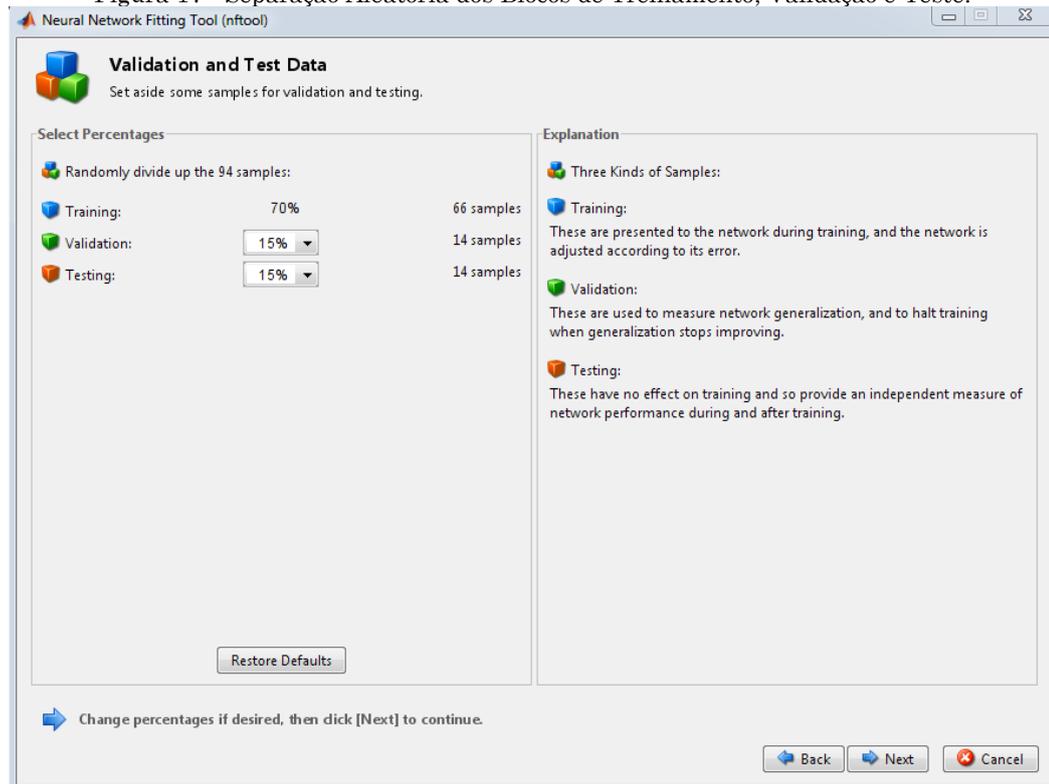
cada um dos três novos blocos de dados recebe um nome específico, de acordo com sua finalidade.

Bloco de Treinamento – utilizado no treinamento da rede, em que esta é ajustada iterativamente a fim de minimizar o gradiente de erro entre suas inferências e os resultados reais fornecidos pelos dados deste bloco;

- Bloco de Validação – verifica o poder de generalização da rede neural, interrompendo o treinamento somente quando não mais se verificar um ganho de poder de generalização entre duas iterações consecutivas;
- Bloco de Teste – não utilizado durante o treinamento, como os blocos anteriormente descritos, este bloco destina-se somente à realização de um teste de desempenho da rede já treinada, a fim de se verificar se o resultado atingido é desejável ou são necessárias alterações no treinamento e/ou estrutura neural.

A separação padrão do bloco de dados em blocos de treinamento, validação e teste é respectivamente de 70% - 15% - 15%. Conforme figura 19, no entanto, visto que esta proporção é alterável pelo usuário, neste trabalho também foram feitos testes com as Redes Neurais Artificiais criadas na proporção 80% -10% -10%.

Figura 17 - Separação Aleatória dos Blocos de Treinamento, Validação e Teste.



Fonte: simulação realizada, 2016.

A estrutura da Rede Neural Artificial disponibilizada pela ferramenta Fitting Tool (nftool) já foi discutida anteriormente. Neste ponto pode-se adicionar a descrição estrutural o fato de que a camada linear de saída da rede possuirá necessariamente tantos neurônios quanto forem as suas saídas, ainda, a camada oculta tem o número de neurônios alteráveis pelo usuário, sendo o padrão de 10 neurônios.

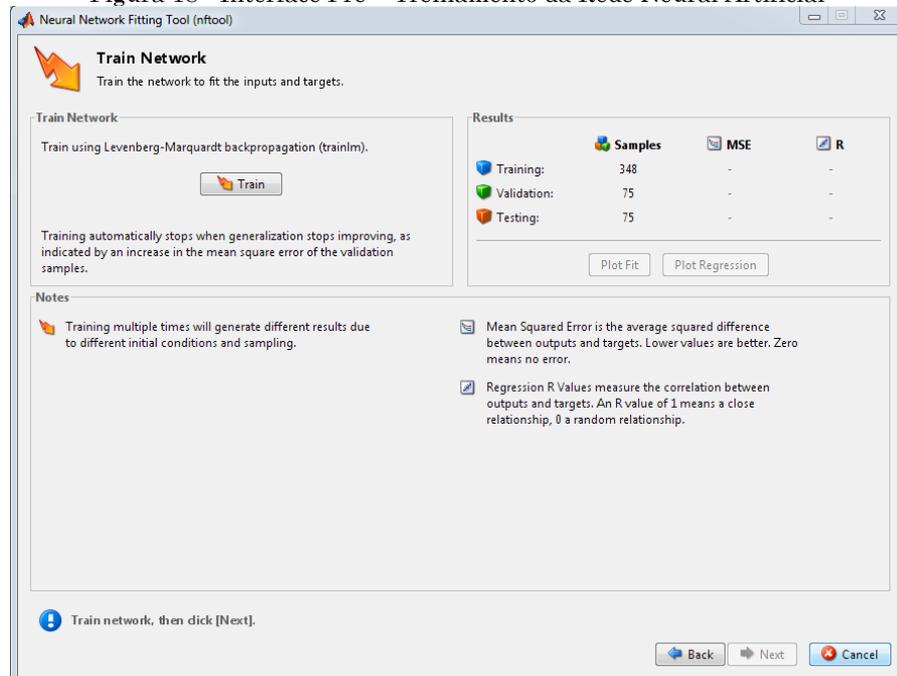
Ambas as redes serão treinadas com as duas distribuições de blocos de dados estabelecidas, reiterando-se que a distribuição dos dados entre tais blocos é aleatória, para evitar a tendência ao aprendizado por apresentação sequencial das redes neurais envolvidas.

Os valores apresentados conforme figura 20 correspondem ao Erro Médio Quadrático (MSE - Mean Square Error) e à Correlação de Regressão (R), e estão separados por blocos de dados de treinamento, validação e teste.

Naturalmente, tanto o MSE quanto a correlação do bloco de treinamento sempre apresentará os menores valores dentre os blocos de dados, uma vez que estes valores foram apresentados diretamente a Rede

Neural Artificial durante seu treinamento, e ela foi ajustada pelo algoritmo de treinamento para acertar estes valores com uma precisão muito alta.

Figura 18 - Interface Pré – Treinamento da Rede Neural Artificial



Fonte: simulação realizada, 2016.

3.8 Treinamento das Redes Neurais

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 tabela 15 seguinte ilustra como exemplo, 10 dos padrões usados no treinamento.

Tabela 9 - Exemplo de concentrações de gases usadas no treinamento da rede

Teores de Gases dissolvidos em (ppm)																
Data	Amostra	Temperatura óleo (c°)	Temperatura Enrol (c°)	Padrões	H2 Hidrogênio	O2 Oxigênio	N2 Nitrogênio	CH4 Metano	CO Monóxido de carbono	CO2 Dióxido de Carbono	C2H4 Etileno	C2H6 Etano	C2H2 Acetileno	Gás Combustível	Diag.	Recom.
11/11/2015	300588	50	58	1	ND	15644	40459	ND	105	734	1,9	ND	ND	106,9	18	14
06/08/2015	337129	29		2	ND	2823	9516	ND	1	14	ND	ND	ND	1	17	20
04/08/2015	337094	58		3	ND	3688	12383	ND	1	9,3	ND	ND	ND	1	17	50
03/08/2015	337098	52		4	3	14617	51364	ND	1	28	ND	ND	ND	4	17	50
30/07/2015	3E+06	24		5	ND	8240	18462	ND	3	119	0,5	0,2	ND	3,7	17	50
10/07/2015	336194	67	72	6	14	24041	66878	3	457	3464	33	0,9	ND	507,9	58	50
23/04/2015	333038	47	50	7	21	19678	59378	4	494	3190	28	0,9	ND	547,9	18	14
14/10/2014	325995	53	58	8	23	21420	63060	4	530	3147	34	1	ND	592	18	14
15/04/2014	319136	50	54	9	18	21223	72832	3	391	2166	24	0,8	ND	436,8	18	14
30/10/2013	313232	43	49	10	17	31412	83540	3	386	2588	31	0,7	ND	437,7	18	14

Teores de Gases dissolvidos em (ppm)																
Data	Amostra	Temperatura óleo (c°)	Temperatura Enrol (c°)	Padrões	H2 Hidrogênio	O2 Oxigênio	N2 Nitrogênio	CH4 Metano	CO Monóxido de carbono	CO2 Dióxido de Carbono	C2H4 Etileno	C2H6 Etano	C2H2 Acetileno	Gás Combustível	Diag.	Recom.
11/11/2015	340586	60	60	1	18	9031	29580	4	384	1259	0,4	0,8	ND	407,2	18	14
23/04/2015	333028	40	45	2	29	18483	71931	6	437	1746	0,1	ND	ND	472,1	18	14
14/10/2014	326000	49	56	3	19	6711	23431	1	255	712	0,2	0,1	ND	275,3	18	14
30/062014	321761	44	49	4	28	5872	21901	2	303	841	ND	0,5	ND	333,5	18	14
15/04/2014	319176	51	60	5	35	18123	61566	2	267	924	ND	0,4	ND	304,4	18	14
07/03/2014	317303	49	58	6	34	5116	20341	1	280	659	ND	0,3	ND	315,3	18	14
04/02/2014	316735	16	52	7	21	13474	51166	1	135	409	0,1	0,2	ND	157,3	18	14
30/10/2013	313230	39	44	8	30	2307	17696	3	216	637	ND	0,8	ND	249,8	18	14
02/06/2013	307072	45	48	9	19	3202	10874	1	52	168	ND	ND	ND	72	18	14
18/04/2013	305432	42	51	10	32	3422	15071	1	113	363	ND	ND	ND	146	18	14

Teores de Gases dissolvidos em (ppm)																
Data	Amostra	Temperatura óleo (c°)	Temperatura Enrol (c°)	Padrões	H2 Hidrogênio	O2 Oxigênio	N2 Nitrogênio	CH4 Metano	CO Monóxido de carbono	CO2 Dióxido de Carbono	C2H4 Etileno	C2H6 Etano	C2H2 Acetileno	Gás Combustível	Diag.	Recom.
11/11/2015	340737	60	60	1	ND	19053	39390	ND	1	546	6,8	ND	ND	7,8	18	14
07/07/2015	336724	58	44	2	ND	9312	20391	ND	3	85	0,6	ND	ND	3,6	18	14
10/06/2015	334970	30		3	ND	3149	10115	ND	6	67	0,2	ND	ND	6,2	17	20
02/06/2015	334730	26		4	ND	15105	30069	6	14	601	3,5	3,9	ND	27,4	17	50
02/06/2015	334728	26		5	ND	15926	38636	ND	2	80	0,3	ND	ND	2,3	17	50
14/05/2015	333888	23	26	6	11	3008	57643	84	349	3560	12	13	ND	469	18	20
23/04/2015	333029	51	63	7	15	15116	90181	74	245	2876	9,7	10	ND	353,7	18	14
14/10/2014	326006	55	68	8	6	5843	41126	84	207	2220	9,7	7,1	ND	313,8	18	14
30/10/2013	313231	50	63	9	20	12606	85479	96	425	4585	14	20	ND	575	18	14

Fonte: CEMIG (2016).

Como pode ser observado na tabela 15 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.

A partir da observação dos indicadores de desempenho e precisão para esta rede foram escolhidas duas topologias, a saber:

- 70% Treinamento – 15% Validação – 15% Teste.
- 80% Treinamento – 10% Validação – 10% Teste

Esta separação distinta visa investigar um aspecto importante do treinamento da rede:

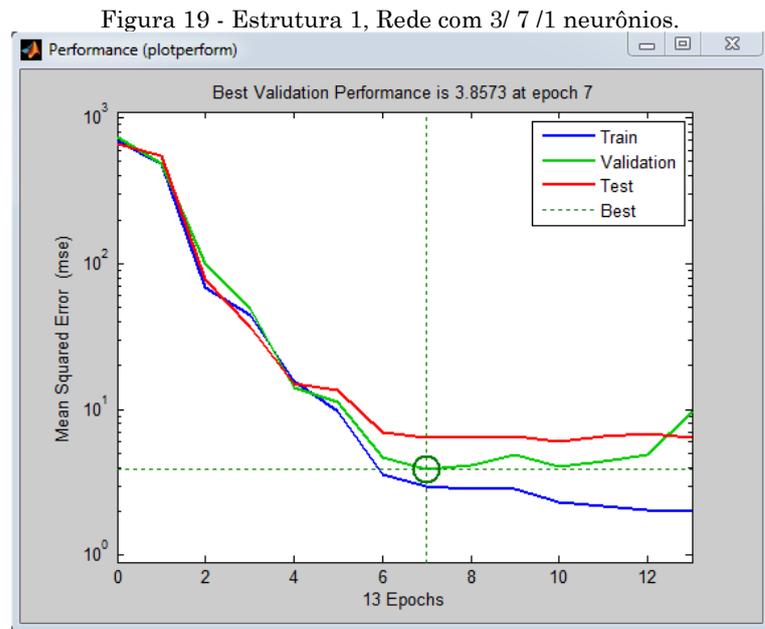
O quanto o numero de amostras reservadas ao treinamento melhora na precisão da rede Neural Artificial treinada em operação, e também qual o tamanho adequado para o bloco de validação.

Obrigatoriamente devem-se destinar algumas amostras a validação, visto que não se pode comprometer o poder de generalização da Rede Neural Artificial por apresentação dos dados em iterações excessivas. Este bloco tem

esta finalidade de interrupção de treinamento e o erro associado às amostras de validação tende sempre a se enquadrar como o maior erro de inferência possível na operação da rede treinada. Em grandes blocos de dados, pode se diminuir a alocação de amostras para a validação.

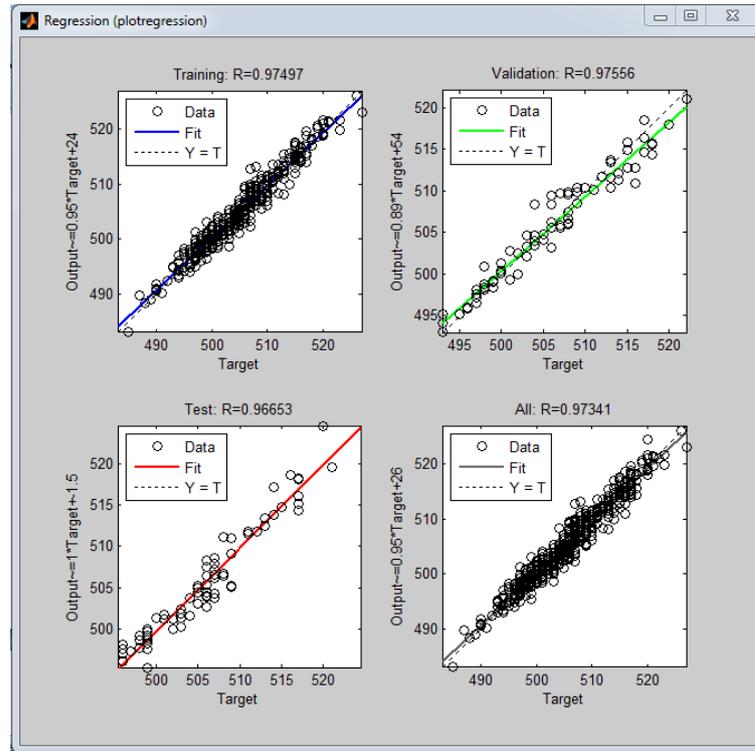
3.9 Estrutura 1 – pós-treinamento e distribuição de 70/15/15(%)

Nesta proposta foram considerados 3 neurônios de entradas, 7 neurônios na camada intermediarias e 1 neurônio na saída. A seguir serão apresentados os resultados de desempenho para a Estrutura 1.



Fonte: Autor (2016)

Figura 20 - Estrutura 1, Rede com 3/7/1 neurônios.

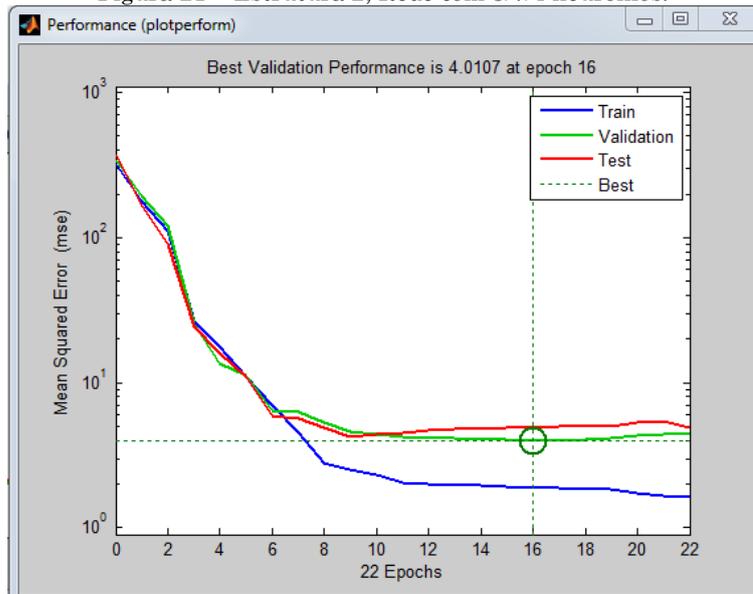


Fonte: Autor (2016)

3.10 Estrutura 2 - pós-treinamento e distribuição de 70/15/15(%)

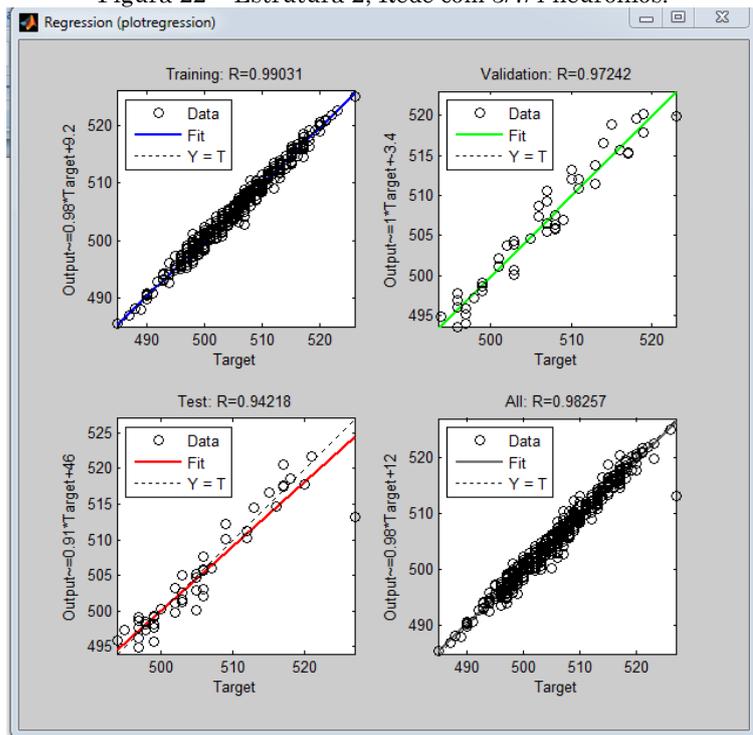
Nesta proposta foram considerados 3 neurônios de entradas, 7 neurônios na camada intermediarias e 4 neurônios de saída. A seguir serão apresentados os resultados de desempenho para a Estrutura 2.

Figura 21 – Estrutura 2, Rede com 3/7/4 neurônios.



Fonte: Autor (2016)

Figura 22 – Estrutura 2, Rede com 3/7/4 neurônios.

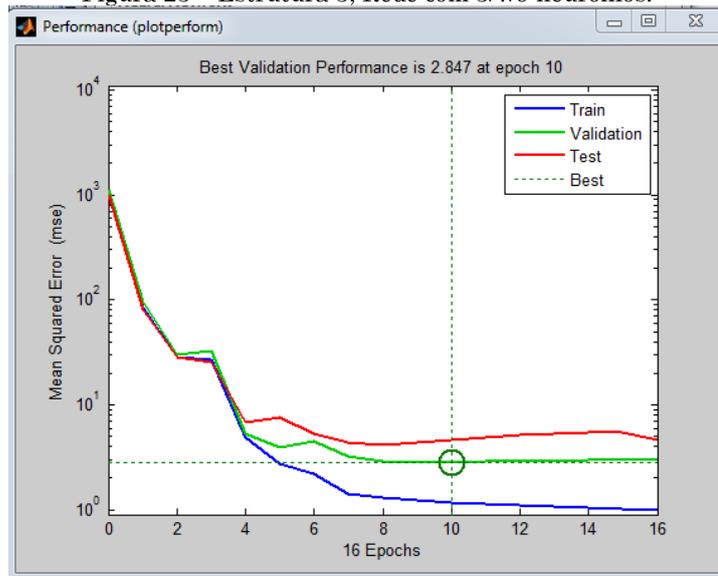


Fonte: Autor (2016)

3.11 Estrutura 3- pós-treinamento e distribuição de 70/15/15(%)

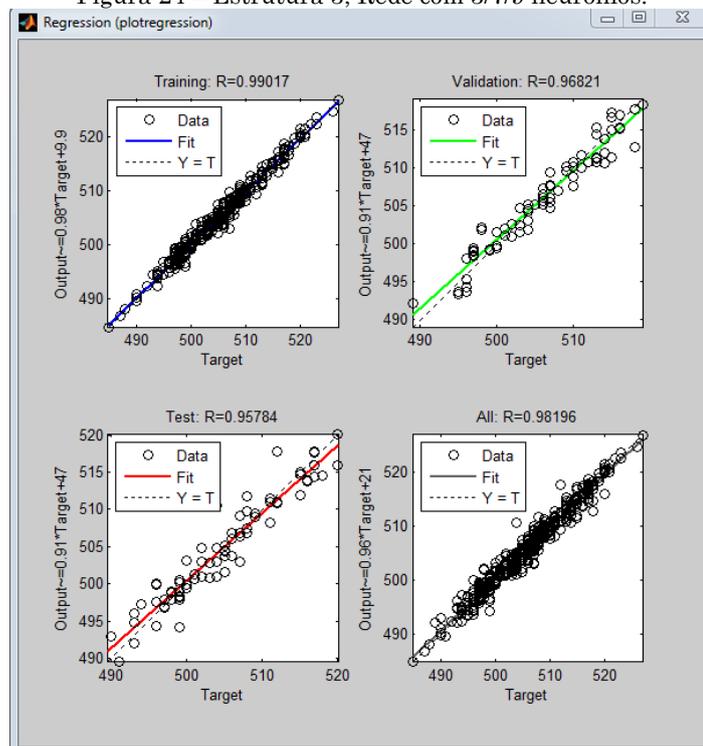
Nesta proposta foram considerados 3 neurônios de entradas, 7 neurônios na camada intermediarias e 9 saídas. A seguir serão apresentados os resultados de desempenho para a Estrutura 3.

Figura 23 – Estrutura 3, Rede com 3/7/9 neurônios.



Fonte: Autor (2016)

Figura 24 – Estrutura 3, Rede com 3/7/9 neurônios.

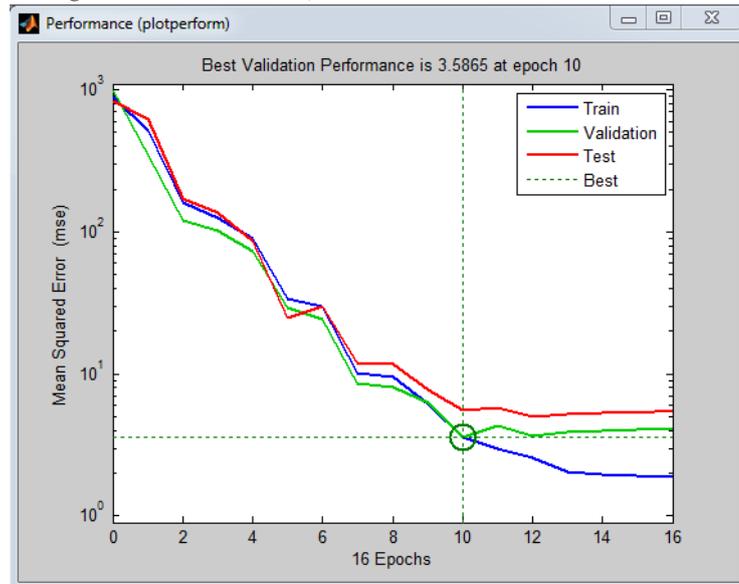


Fonte: Autor (2016)

3.12 Estrutura 1 – pós-treinamento e distribuição de 70/15/15(%)

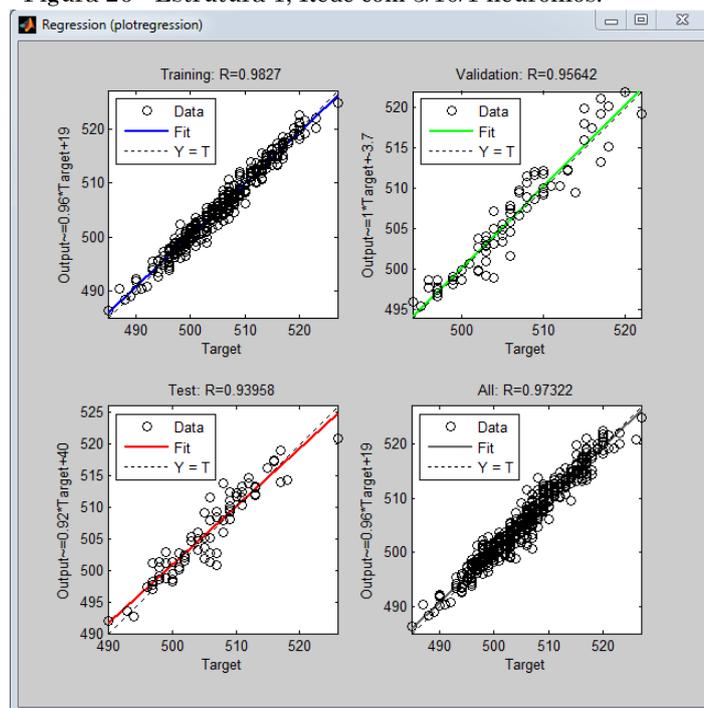
Nesta proposta foram considerados 3 neurônios de entradas, 10 neurônios na camada intermediarias e 1 neurônio na saída. A seguir serão apresentados os resultados de desempenho para a Estrutura 1

Figura 25 - Estrutura 1, Rede com 3/10/1neurônios.



Fonte: Autor (2016)

Figura 26 - Estrutura 1, Rede com 3/10/1 neurônios.

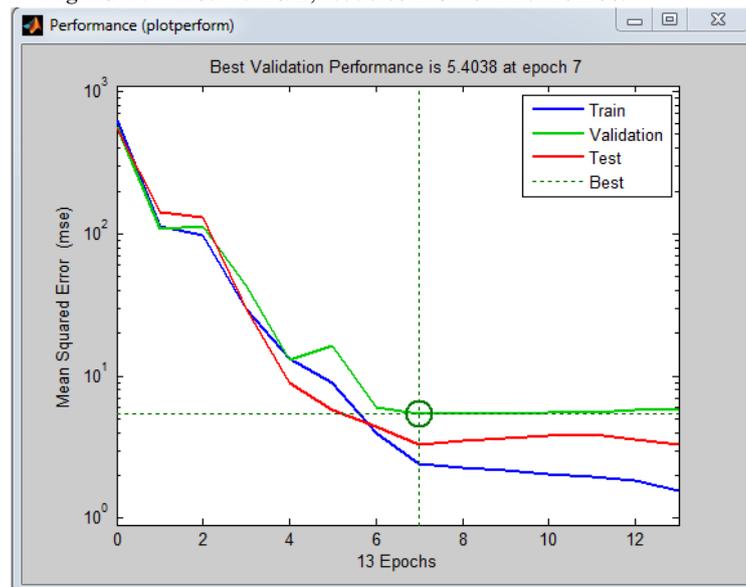


Fonte: Autor (2016)

3.13 Estrutura 2 - pós-treinamento e distribuição de 70/15/15(%)

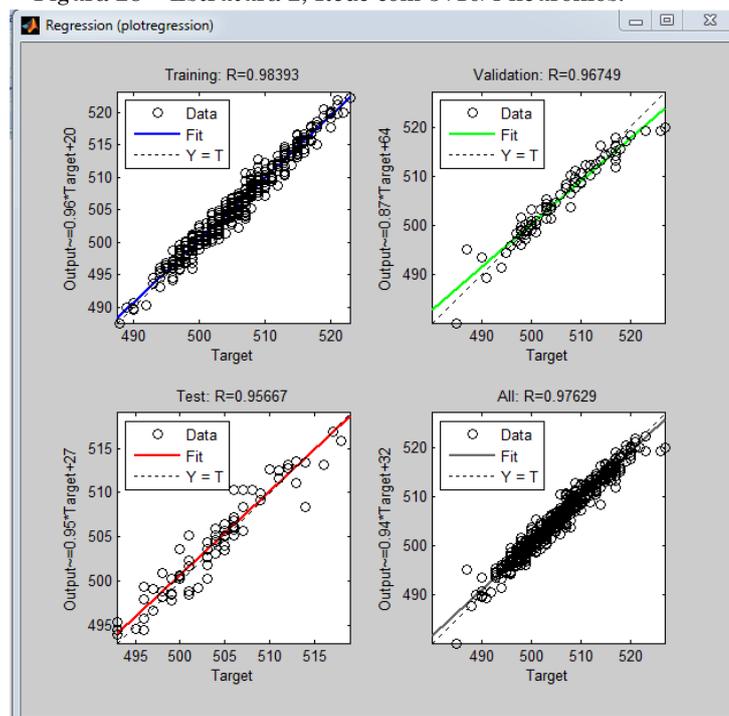
Nesta proposta foram considerados 3 neurônios de entradas, 10 neurônios na camada intermediarias e 4 neurônios de saída. A seguir serão apresentados os resultados de desempenho para a Estrutura 2.

Figura 27 – Estrutura 2, Rede com 3/10/4 neurônios.



Fonte: Autor (2016)

Figura 28 – Estrutura 2, Rede com 3 /10/4 neurônios.

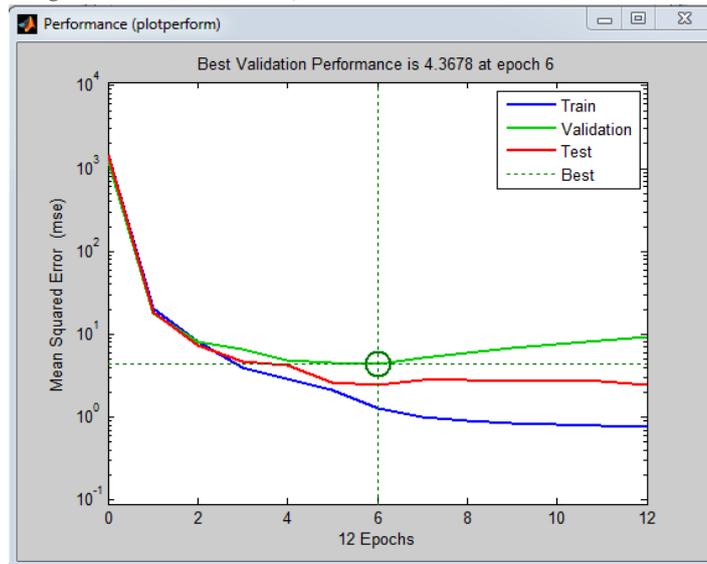


Fonte: Autor (2016)

3.3 Estrutura 3- pós-treinamento e distribuição de 70/15/15(%)

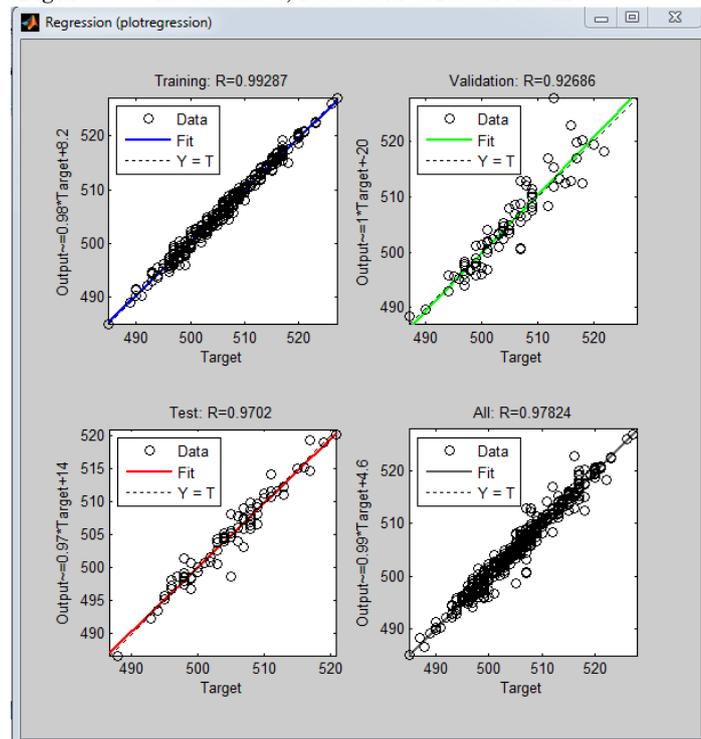
Nesta proposta foram considerados 3 neurônios de entradas, 10 neurônios na camada intermediarias e 9 saídas. A seguir serão apresentados os resultados de desempenho para a Estrutura 3.

Figura 29 – Estrutura 3, Rede com 3/10/9 neurônios.



Fonte: Autor (2016)

Figura 30 – Estrutura 3, Rede com 3/10/9 neurônios.



Fonte: Autor (2016)

Para a detecção dos gases dissolvidos no óleo verifica-se que as Estruturas 2 e 3 apresentaram resultados melhores que a estrutura 1, os valores de erros quadráticos também foram menores. Quanto aos processos de validação que mede a correlação entre as saídas e os pontos desejados, todas as Estruturas apresentaram valores de correlações estreita, nenhuma apresentou valor aleatório.

A seguir será apresentado nas tabelas 15 e 16 um resumo dos resultados obtidos com a implantação das Estruturas 1, 2 e 3.

Também será mostrado os resultados das análises de sensibilidade para o comportamento das redes quando variamos o pós-treinamento e distribuição para 80/10/10%.

Tabela 10 - Erro Médio Quadrático (MSE) e Correlação (R) para as Redes Neurais Artificiais Criadas e Treinadas nos Esquemas Propostos

Alternativas	Número de Neurônios	Esquemas de Amostragem (%)	Treinamento MSE (X10-7)	Validação			Teste	
				R (X10-1)	MSE (X10-7)	R (X10-1)	MSE (X10-7)	R (X10-1)
Estrutura 1	7	70 - 15 - 15	2.99159	9.72134	3.85734	9.66113	6.3595	9.25924
	7	80 - 10 - 10	2.92561	9.70877	4.88307	9.50594	5.17028	9.56093
	10	70 - 15 - 15	3.59749	9.68048	3.58651	9.58271	5.58454	9.39577
	10	80 - 10 - 10	1.93238	9.81520	2.64058	9.67087	3.66919	9.66159
Estrutura 2	7	70 - 15 - 15	1.89627	9.82397	4.01067	9.53858	4.92075	9.51208
	7	80 - 10 - 10	2.51545	9.76329	3.36889	9.66575	2.54254	9.75992
	10	70 - 15 - 15	1.81416	9.83316	4.08157	9.51914	6.4467	9.37030
	10	80 - 10 - 10	1.39681	9.86377	2.73299	9.68769	5.32641	9.55325
Estrutura 3	7	70 - 15 - 15	1.16515	9.88574	2.84701	9.71349	4.633507	9.57835
	7	80 - 10 - 10	200.008	980.672	354.297	9.65093	4.37191	9.57543
	10	70 - 15 - 15	1.25991	9.88674	4.36783	9.57526	2.47837	9.70198
	10	80 - 10 - 10	1.18060	9.88674	5.17481	9.39762	4.41714	9.63306

Fonte: autoria Própria, 2016

Conforme dados apresentados na tabela 17 notamos que os valores de desempenho e gradiente das redes treinadas são próximos, no entanto uma das redes apresenta o dobro do número de iteração em relação às demais.

Tabela 11 - Desempenho das Redes Neurais Artificiais Propostas

Alternativas	Número de Neurônios	Esquemas de Amostragem (%)	Performance	Gradiente		Numero de Iterações
Estrutura 1	7	70 - 15 -15	2.99	12.3	✓	13
	7	80 -10 -10	2.93	6.56	✓	17
	10	70 - 15 -15	3.60	10.1	✓	16
	10	80 -10 -10	1.93	4.41	✓	18
Estrutura 2	7	70 -15 -15	1.90	0.394	✓	22
	7	80 - 10 -10	2.52	11.6	✓	21
	10	70 - 15 -15	1.81	7.35	✓	14
	10	80 -10 -10	1.40	1.20	✓	17
Estrutura 3	7	70 -15 -15	1.17	0.901		16
	7	80 - 10 -10	2.00	10.2		15
	10	70 - 15 -15	1.26	0.697	✓	12
	10	80 -10 -10	1.18	8.08	✓	16

Tabela 16 Fonte: autoria, 2016

A Estrutura 1, apesar de apresentar uma estrutura leve e com baixo custo de treinamento, não obteve grande sucesso na identificação dos padrões de falta, uma vez que seu reduzido número de conexões não permitiu armazenar todo o comportamento não linear do problema. Em seu treinamento, os valores de tolerância de erro não foram atingidos, quando aplicados a toda a base de dados, demonstrando também um baixo poder de generalização.

Os resultados obtidos considerando treinamento com 70 amostras para a Estrutura 2 composta por um vetor 3 x 1 e saída um vetor binário 4 x 1 foram comparados com os obtidos segundo a norma ANSI/IEEE Std C57.104 –(1991) e apresentados na tabela 18.

Tabela 12 - Resultados Obtidos para a Segunda Rede Neural MLP

Código de Falta	Número de Amostras Validadas	
	Diagnóstico IIEEE	Diagnóstico MLP2
0	34	24
1	42	39
2	209	205
3	25	23
4	122	117
5	1	1
6	20	20
7	142	137
8	182	177
Total de Acertos		743
Precisão de Acertos da Rede		95,62%

Fonte: autoria, 2016

Da mesma forma que para a rede anterior, nesta estrutura também foi utilizada a função de transferência sigmoïdal e foram utilizadas 80 amostras escolhidas aleatoriamente em seu treinamento, sendo que os parâmetros da rede são apresentados na tabela 19.

A utilização desta rede apresentou vantagens tanto em relação à precisão de acertos quanto ao custo computacional, uma vez que não foi mais necessário decodificar uma saída binária para obter o diagnostico. Neste caso a saída da rede passa apenas por uma função competitiva, e o neurônio que apresenta maior valor a saída é associada ao código de falta. Desta forma, quando a saída do neurônio N1 vence sobre as demais para uma determinada amostra, o código de diagnostico relativa a esta amostra era igual a 0. Se o neurônio vencedor fosse o N2, o diagnostico para a dada amostra seria 1, e assim por diante.

Tabela 13 - Resultados Obtidos para a Terceira Rede Neural MLP.

Código de Falta	Número de Amostras Validadas	
	Diagnóstico IEEEE	Diagnóstico MLP3
0	34	34
1	42	42
2	209	209
3	25	25
4	122	122
5	1	0
6	20	0
7	142	137
8	182	182
TOTAL DE ACERTOS		751
PRECISÃO DE ACERTOS DA REDE		96,65%

Fonte: autoria, 2016

Outras configurações também foram testadas, tais como redes com um menor número de neurônios na camada intermediária e com maior número de entradas (levando-se em consideração a concentração absoluta dos gases, e não as relações). Mas a eficiência destas redes foram inferiores aos das redes aqui apresentadas.

Ao término das análises e comparações pode-se concluir que a terceira rede foi considerada, dentre as redes MLP testadas, como estrutura que apresentou os melhores resultados para a solução do problema, portando sendo a selecionada.

Levando-nos a concluir que quando definimos um bom conjunto de dados (treinamento e validação) estamos proporcionando as redes neurais uma precisão melhor, mesmo sendo necessário maior número de iterações para que realizem seus ajustes internos. É importante ter ciência de que antes de optar por expandir uma rede neural artificial em arquitetura é preciso sempre expandir o bloco de dados que se tem a disposição, sobretudo com maior precisão nas regiões de comportamento menos linear, quando forem conhecidas.

Capítulo 4

Conclusão

Este trabalho concentrou-se na solução do problema de diagnóstico de faltas em transformadores de potência com base na análise dos gases que se encontram dissolvidos no óleo isolante.

Inicialmente, demonstrou-se o processo de classificação de base de dados usada no desenvolvimento dos sistemas de diagnósticos propostos. Este processo se mostrou compatível com a realidade do conjunto de equipamentos tomados como exemplos neste trabalho.

Após este primeiro passo, mostrou-se como os diagnósticos utilizados como saída desejada nos processos de treinamento foram obtidos, tomando-se como base a normalização internacional (ANSI/IEEE Std C57.104-1991).

Apresentou-se, também, as técnicas de inteligência computacional, e discutiu-se suas capacidades de reconhecimento de faltas, chegando à conclusão que os sistemas de inteligência com a aplicação de redes neurais possuem grande precisão na solução do problema proposto.

Vale mais uma vez salientar que os diagnósticos utilizados nos processos de treinamento e validação dos sistemas desenvolvidos foram obtidos a partir da aplicação de norma internacional, a que muitas vezes não se adéqua á realidade brasileira.

Um objetivo futuro deste trabalho é empregar os sistemas de diagnóstico proposto tomando-se como saídas desejadas diagnósticos reais de falta, colhidos em campo. Neste caso específico é possível que outra técnica se mostre mais adequado do que o modelo proposto para os diagnósticos gerados pela Norma (ANSI/IEEE Std C57.104-1991).

Exemplos numéricos foram apresentados, verificando a eficiência dos sistemas de diagnóstico propostos para o diagnóstico de faltas em transformadores de potência com base na análise de gases dissolvidos.

Referencias Bibliográficas

- [1] SILVA, I. N. Uma abordagem neuro-nebulosa para otimização de sistemas e identificação robusta. Tese de Doutorado. DCA/FEE/UNICAMP, Campinas- SP, Dezembro 1997.
- [2] ANSI/IEEE Std C57. 104-1978. IEEE Guide for the detection and determination of generated gases in oil-immersed transformers and their relation to the serviceability of the equipment American National Standard –ANSI, 1978.
- [3] IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers, ANSI/IEEE Standard C57.104-1991.
- [4] DORNENBURG, E.; STRITTMATTER, W. Monitoring oil-cooled transformers by gas analysis Brown Boveri Review, v.5, n.61, p.238 -247, maio 1974.
- [5] DUVAL, M. Dissolved Gas Analysis: It can save your transformer. IEEE Electrical Insulation Magazine, v.7, n.6, p.22-27, nov./dec.1989.
- [6] 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.
- [7] S. D. Myers, J. Kelly, and R. H. Parrish, A Guide to Transformer Maintenance Ohio, USA, 1981, ch. 4, pp. 323–388.
- [8] 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
- [9] 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.
- [10] IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers, IEEE Standard C57.104-2008, Sept. 2008.

[11] 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.

[12] 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.

[13] 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.

[14] ABNT NBR 5356-2 Transformador de Potencia parte 2: Segunda edição 17.12.2007.