

UNIVERSIDADE SANTA CECÍLIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA
MESTRADO EM ENGENHARIA MECÂNICA

RICARDO LUIZ NACARATO

**INVESTIGAÇÃO DE FALHA EM TRANSFORMADORES DE POTÊNCIA PELA
ANÁLISE DOS GASES DISSOLVIDOS NO ÓLEO ISOLANTE UTILIZANDO
SIMULAÇÃO EM REDES NEURAIS ARTIFICIAIS**

SANTOS/SP

2018

RICARDO LUIZ NACARATO

**INVESTIGAÇÃO DE FALHA EM TRANSFORMADORES DE POTÊNCIA PELA
ANÁLISE DOS GASES DISSOLVIDOS NO ÓLEO ISOLANTE UTILIZANDO
SIMULAÇÃO EM REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada à Universidade Santa Cecília como parte dos requisitos para obtenção de título de Mestre no Programa de Pós-Graduação em Engenharia Mecânica, sob orientação da Profa. Dra. Dorotéia Vilanova Garcia e coorientação Prof. Dr. Maurício Conceição Mario.

SANTOS/SP

2018

Autorizo a reprodução parcial ou total deste trabalho, por qualquer que seja o processo, exclusivamente para fins acadêmicos e científicos.

006.32 Nacarato, Ricardo Luiz.
N118i Investigação de falha em transformadores de potência pela análise dos gases dissolvidos no óleo isolante utilizando simulação em redes neurais artificiais.
2018.
83p.

Orientadora: Dorotéia Vilanova Garcia.
Coorientador: Maurício Conceição Mario.

Dissertação (Mestrado) -- Universidade Santa Cecília, Programa de Pós-Graduação em Engenharia Mecânica, Santos, SP, 2018.

1. diagnóstico de transformadores. 2. redes neurais clássicas. 3. transformadores de potência. 4. análise de gás dissolvido. 5. automação. I. Garcia, Dorotéia Vilanova. II. Mario, Maurício Conceição. III. Investigação de Falha em Transformadores de Potência pela Análise dos Gases Dissolvidos no Óleo Isolante utilizando Simulação Em Redes Neurais Artificiais.

Elaborada pelo SIBi – Sistema Integrado de Bibliotecas – Unisanta

DEDICATÓRIA

Dedico este trabalho à minha família, motivo único de todos os meus esforços e pensamentos.

AGRADECIMENTOS

Agradeço,

À minha orientadora, a querida mestra Prof. Dra. Dorotéia Vilanova Garcia pelo incentivo, orientação, dedicação e colaboração.

Ao meu coorientador Prof. Dr. Maurício Conceição Mario, pela amizade, paciência e por lembrar-me sempre de que a eletrônica é linda.

Ao corpo de professores, pesquisadores e funcionários da Universidade Santa Cecília – UNISANTA.

Aos colegas do Mestrado em Engenharia Mecânica da UNISANTA, pelo companheirismo, pela amizade e pelos momentos que passamos juntos, sejam em trabalhos em grupo, ou fora das salas de aula.

EPÍGRAFE

“O pessimista queixa-se do vento. O otimista espera que ele mude. O realista ajusta as velas”. Willian George Ward – Teólogo Inglês.

RESUMO

Transformadores de alta potência são peças fundamentais nos sistemas de distribuição de energia elétrica e existem inúmeras ferramentas e metodologias para o diagnóstico de falhas, tanto para a monitoração e acompanhamento do equipamento em operação (planta fixa) como àquele retirado e abrigado em laboratórios de unidades fabris. Em função dos custos envolvidos no transporte e manuseio dos equipamentos, as principais metodologias que se destacam são aquelas direcionadas ao equipamento em operação. Esta dissertação é um estudo da utilização de uma das técnicas de diagnóstico mais difundidas para a prevenção de problemas, a Análise de Gases Dissolvidos no Óleo Isolante. Este trabalho tem por objetivo utilizar as Redes Neurais Artificiais (RNA) como numa ferramenta de apoio no diagnóstico destas falhas e no auxílio as equipes dos laboratórios de teste das distribuidoras de energia elétrica. Para validação da RNA proposta, foram utilizados os dados de geração de gases e os laudos do laboratório obtidos junto a um grande concessionário do setor elétrico brasileiro. Esta base de dados contém aproximadamente três mil ensaios cromatográficos, correspondendo a transformadores de potências de 5,0 a 50 MVA, em subestações primárias de 69 e 138kV. Os resultados se mostraram bastante promissores no que diz respeito ao diagnóstico de falhas incipientes em transformadores, alcançando níveis de acertos com valores acima de 80%.

Palavras-chave: Diagnóstico de falhas. Transformadores. Análise de Gases Dissolvidos. Redes Neurais.

ABSTRACT

High-power transformers are fundamental parts of electric power distribution systems and there are numerous tools and methodologies for fault diagnosis, both for the monitoring and follow-up of the equipment in operation (fixed plant) and the one removed and housed in factory laboratories. Due to the costs involved in the transportation and handling of the equipment, the main methodologies that stand out are those directed to the equipment in operation. This dissertation is a study of the use of one of the most widespread diagnostic techniques for problem prevention, Analysis of Dissolved Gases in Insulating Oil. This work aims to use Artificial Neural Networks (RNA) as a support tool in the diagnosis of these faults and in the aid of the teams of test laboratories of the electric power distributors. For the validation of the proposed RNA, the gas generation data and laboratory reports obtained from a large Brazilian electric sector dealer were used. This database contains approximately three thousand chromatographic tests, corresponding to transformers of powers of 5 to 50 MVA, in primary substations of 69 and 138kV. The results were very promising for the diagnosis of incipient faults in transformers, reaching correct levels with values above 80%.

Keywords: Fault Diagnosis. Transformers. Dissolved Gas Analysis (DGA). Artificial neural network.

LISTA DE FIGURAS

FIGURA 1 – ILUSTRAÇÃO DOS SISTEMAS ELÉTRICOS DE POTÊNCIA.	1
FIGURA 2 – ASPECTO INTERNO DE UM TRANSFORMADOR DE POTÊNCIA TÍPICO.	4
FIGURA 3 – DESENHO ESQUEMÁTICO DO SISTEMA DE CROMATOGRAFIA A GÁS.	6
FIGURA 4 – FORMAÇÃO DOS GASES EM FUNÇÃO DA TEMPERATURA DE DECOMPOSIÇÃO.	7
FIGURA 5 – NEURÔNIO BIOLÓGICO.	8
FIGURA 6 – MODELO DE NEURÔNIO ARTIFICIAL.	9
FIGURA 7 – ARQUITETURA DA RNA COM UMA SAÍDA.	9
FIGURA 8 – <i>PERCEPTRON</i> MULTICAMADAS.	10
FIGURA 9 – FUNÇÃO DE PERDA $F(W)$	11
FIGURA 10 – ARQUITETURA DA RNA COM UMA SAÍDA.	15
FIGURA 11 – NEURAL NETWORK TRAINING (NNTRAIINTOOL).	18
FIGURA 12 – MATRIZ DE CONFUSÃO DO TREINAMENTO DA RNA.	18
FIGURA 13 – EVOLUÇÃO DO ERRO DURANTE O TREINAMENTO DA RNA.	19
FIGURA 14 – GRÁFICO DE REGRESSÃO DA RNA ANALISADA.	20
FIGURA 15 – DESEMPENHO DA RNA – CONDIÇÃO NORMAL – VALORES MÉDIOS.	23
FIGURA 16 – DESEMPENHO DA RNA – FALHA ELÉTRICA – VALORES MÉDIOS.	24
FIGURA 17 – DESEMPENHO DA RNA – FALHA ELÉTRICA – VALORES MÉDIOS.	26
FIGURA 18 – TAXA DE ACERTO DA REDE CONSOLIDADO.	27
FIGURA 19 – RESULTADO CONSOLIDADO POR CONDIÇÃO DE OPERAÇÃO.	27
FIGURA 20 – ARQUITETURA DA RNA COM TRÊS SAÍDAS.	28
FIGURA 21 – DESEMPENHO DA RNA – TRÊS SAÍDAS - CONSOLIDADO.	29
FIGURA 22 – CONDIÇÃO NORMAL – MATRIZ DE CONFUSÃO.	30
FIGURA 23 – CONDIÇÃO NORMAL – MELHOR DESEMPENHO	31
FIGURA 24 – FALHA ELÉTRICA – MATRIZ DE CONFUSÃO.	32
FIGURA 25 – FALHA ELÉTRICA – MELHOR DESEMPENHO	32
FIGURA 26 – FALHA TÉRMICA – MATRIZ DE CONFUSÃO.	33
FIGURA 27 – FALHA TÉRMICA – MELHOR DESEMPENHO	33
FIGURA 28 – FUNÇÃO DEGRAU.	67
FIGURA 29 – FUNÇÃO DEGRAU BIPOLAR.	68
FIGURA 30 – FUNÇÃO RAMPA.	68
FIGURA 31 – FUNÇÃO SIGMOIDE.	68
FIGURA 32 – FUNÇÃO TANGENTE HIPERBÓLICA.	69

LISTA DE TABELAS

Tabela 1 – Padrão de treinamento para a rede neural (vetor x).	16
Tabela 2 – Classe do padrão de treinamento para a rede neural (vetor t).	16
Tabela 3 – Treinamento da rede neural.	17
Tabela 4 – Teste da rede neural.	17
Tabela 5 – Desempenho da RNA – condição Normal – 10 ciclos.	22
Tabela 6 – Desempenho da RNA – condição Normal – 20 ciclos.	22
Tabela 7 – Desempenho da RNA – condição Normal – 30 ciclos.	22
Tabela 8 – Desempenho da RNA – condição Normal – valores médios.	22
Tabela 9 – Desempenho da RNA – condição Falha Elétrica – 10 ciclos.	23
Tabela 10 – Desempenho da RNA – condição Falha Elétrica – 20 ciclos.	23
Tabela 11 – Desempenho da RNA – condição Falha Elétrica – 30 ciclos.	24
Tabela 12 – Desempenho da RNA – condição Falha Elétrica – valores médios.	24
Tabela 13 – Desempenho da RNA – condição Falha Térmica – 10 ciclos.	25
Tabela 14 – Desempenho da RNA – condição Falha Térmica – 20 ciclos.	25
Tabela 15 – Desempenho da RNA – condição Falha Térmica – 30 ciclos.	25
Tabela 16 – Desempenho da RNA – condição Falha Térmica – valores médios.	26
Tabela 17 – Taxa de acerto da rede: Condição de saída x Algoritmo de treinamento.	26
Tabela 18 – Resultado consolidado por condição de operação.	27
Tabela 19 – Desempenho da RNA – Três saídas - 10 ciclos.	28
Tabela 20 – Desempenho da RNA – Três saídas - 20 ciclos.	28
Tabela 21 – Desempenho da RNA – Três saídas - 30 ciclos.	29
Tabela 22 – Rede com três saídas - condição de saída x Algoritmo de treinamento.	29
Tabela 24 – Condição Normal – melhor desempenho.	30
Tabela 24 – Falha Elétrica – melhor desempenho.	31
Tabela 25 – Falha Térmica – melhor desempenho.	32
Tabela 26 – Rede com três saídas – melhor desempenho.	34
Tabela 27 – Condição Normal – melhor desempenho.	34
Tabela 28 – Comparação das taxas de acerto das redes neurais.	35

LISTA DE SIGLAS

ABNT	–	Associação Brasileira de Normas Técnicas
AGD	–	Análise de Gases Dissolvidos
C ₂ H ₂	–	Acetileno
C ₂ H ₄	–	Etileno
C ₂ H ₆	–	Etano
CG	–	Cromatografia Gasosa
CH ₄	–	Metano
DGA	–	<i>Dissolved Gas Analysis</i>
EP	–	Elemento Processador
H ₂	–	Hidrogênio
IEC	–	<i>International Electrotechnical Commission</i> (Comissão Eletrotécnica Internacional)
IEEE	–	<i>Institute of Electrical and Electronics Engineers</i> (Instituto de Engenheiros Eletricistas e Eletrônicos)
MLP	–	<i>Perceptron</i> Multicamadas
NBR	–	Norma Brasileira
RNA	–	Redes Neurais Artificiais
Traingd	–	<i>Backpropagation</i> de gradiente decrescente
Traingda	–	<i>Backpropagation</i> de gradiente decrescente com taxa adaptativa
Traingdm	–	<i>Backpropagation</i> de gradiente decrescente com momentum
Traingdx	–	<i>Backpropagation</i> de gradiente decrescente com momentum e taxa adaptativa
Trainlm	–	<i>Backpropagation Levenberg-Marquardt</i>

SUMÁRIO

1. INTRODUÇÃO	1
1.1. OBJETIVOS	2
1.1.1. Objetivo Geral	2
1.1.2. Objetivos Específicos	2
1.2. JUSTIFICATIVA E RELEVÂNCIA DA DISSERTAÇÃO	3
1.3. ORGANIZAÇÃO DO TRABALHO.....	3
1.4. FUNDAMENTAÇÃO TEÓRICA.....	3
1.4.1. Transformadores de Potência.....	3
1.4.2. Métodos de diagnóstico de Transformadores de Potência	5
1.4.3. Análise Cromatográfica	5
1.4.4. Redes Neurais Artificiais.....	8
1.4.5. Algoritmo de treinamento.....	11
2. MATERIAIS E MÉTODOS	13
2.1. ALGORITMO BACKPROPAGATION.....	13
2.2. ARQUITETURA DA REDE PROPOSTA	14
2.2.1. Modelagem da Rede Neural	15
2.2.2. Preparação dos dados	16
2.2.3. Treinamento da rede	17
2.2.4. Testando a rede	17
2.2.5. Implementando a rede.....	18
3. RESULTADOS	21
3.1. CONDIÇÃO NORMAL	21
3.2. CONDIÇÃO FALHA ELÉTRICA	23
3.3. CONDIÇÃO FALHA TÉRMICA.....	25
3.4. VALORES CONSOLIDADOS	26
3.5. REDE NEURAL COM TRÊS SAÍDAS.....	27
4. DISCUSSÃO	30
4.1. CONDIÇÃO NORMAL	30
4.2. FALHA ELÉTRICA.....	31
4.3. FALHA TÉRMICA.....	32
4.4. REDE NEURAL COM TRÊS SAÍDAS	33
4.5. CONCLUSÕES FINAIS PARA UMA ÚNICA SAÍDA.....	34
5. CONCLUSÕES	36
6. VERSÃO COMPACTA.....	37
REFERÊNCIAS	42
APÊNDICE A. UTILIZANDO A REDE NEURAL NO MATLAB	45
APÊNDICE B. DADOS PARA TESTE DA REDE NEURAL.....	46
ANEXO A. ENSAIOS ESPECIAIS.....	49
ANEXO B. ANÁLISE FÍSICO-QUÍMICA	53
ANEXO C. MÉTODO DE ROGERS	55
ANEXO D. MÉTODO DE DOERNENBURG.....	58

ANEXO E. NORMA NBR 7274	59
ANEXO F. TRIANGULO DE DUVAL.....	60
ANEXO G. DETALHAMENTO DO ALGORITMO BACKPROPAGATION.....	61
ANEXO H. ALGORITMOS DE TREINAMENTO DA RNA	66
ANEXO I. FUNÇÕES DE ATIVAÇÃO	67

1. INTRODUÇÃO

Na sociedade moderna, o constante aumento da demanda por eletricidade tem provocado a elevação dos custos com sistemas de geração e transmissão de energia elétrica. A eletricidade é responsável por grande parte da energia consumida no Brasil. De acordo com estudos da Empresa de Pesquisa Energética (EPE, 2009), a eletricidade representa cerca de 17% do consumo energético final do país (QUEIROS, 2010).

A Figura 1 representa a divisão clássica de geração de uma cadeia produtiva dos sistemas elétricos de potência.




Figura 1 – Ilustração dos sistemas elétricos de potência.

Fonte: Queiros, 2010

Os transformadores de potência são elementos fundamentais nos sistemas de transmissão de energia elétrica, permitindo que as elevadas tensões que circulam nas linhas de transmissão elétrica sejam rebaixadas a níveis adequados para utilização pela população. Durante a sua operação, são expostos a diferentes condições operativas, que podem causar degradações em suas condições operacionais e de isolamento. (MILASCH, 1984).

Costa e Brandão (2001), a partir de seus estudos, constataram que o valor anual médio da taxa de falha nos transformadores de um dado sistema é de aproximadamente 2%.

Ao longo dos anos diversos métodos para detecção de falhas nos transformadores foram desenvolvidos, dentre os quais o mais utilizado atualmente se

chama Análise de Gases Dissolvidos (AGD) no óleo isolante (DUVAL, 1989). O óleo, submetido ao calor no interior do transformador, se degrada e libera gases que permanecem dissolvidos. A partir da análise química de tais gases dissolvidos e da comparação estatística das falhas encontradas nestes transformadores foram criadas diversas técnicas de prevenção, tais como o Método de Rogers, o Método de Duval (DUVAL, 2002), o Método de Doernenburg (IEEE Standard C57.104, 1991) e a norma NBR-7274 (ABNT. NBR 7274,1984), adotada no Brasil (ARANTES, 2005).

Muito embora tais métodos tenham sido desenvolvidos, a previsão de falhas continua sem apresentar a precisão adequada, eis que nenhum deles faz uso de um modelo matemático capaz de ser empregado na construção de uma ferramenta computacional nos moldes clássicos.

1.1. Objetivos

Serão apresentados os objetivos que contemplam o desenvolvimento da dissertação, isto é, objetivo geral e objetivos específicos.

1.1.1. Objetivo Geral

Investigar as técnicas de prevenção da ocorrência de falhas em transformadores de potência através do método de análise de gases dissolvidos (AGD) no óleo isolante.

1.1.2. Objetivos Específicos

- a. Estudar os critérios de diagnóstico de transformadores de potência;
- b. Analisar as normas de ensaio dos gases dissolvidos no óleo isolante;
- c. Propor uma Rede Neural Artificial (RNA) como ferramenta auxiliar no diagnóstico de falhas em transformadores de alta potência.

1.2. Justificativa e Relevância da Dissertação

A dissertação busca o aprimoramento os processos de diagnóstico, bem como auxiliar na elaboração dos laudos, desta forma, reduzindo o impacto da indisponibilidade dos transformadores.

1.3. Organização do Trabalho

Visando cumprir tais objetivos, o presente trabalho de dissertação foi organizado, além do capítulo 1 desta introdução, os seguintes capítulos:

O capítulo 2 onde se descreve os materiais e métodos adotados no presente trabalho, o capítulo 3 onde apresenta-se os resultados dos testes com a rede neural artificial, o capítulo 4 onde apresenta-se uma discussão e análise da aplicação do método das redes neurais no diagnóstico, o capítulo 5 onde expõe-se as conclusões sobre o emprego de redes neurais artificiais no diagnóstico de falhas em transformadores de potência e sugestões de novos trabalhos.

1.4. Fundamentação Teórica

A abordagem contempla os conceitos de transformadores de potência, sua operação e eventuais casos de falhas, sendo abordado os critérios de diagnóstico e detecção de falhas. Concebendo uma ferramenta de simulação para suporte para esse diagnóstico apoiado em rede neural artificial.

1.4.1. Transformadores de Potência

Os transformadores de potência (Figura 2) representam normalmente cerca de 30% do valor do projeto de uma subestação de força; e quando se encontram danificados acarretam impactos financeiros, seja para as concessionárias elétricas pela redução da arrecadação e custos de manutenção, seja para os seus clientes, pelas perdas na parada das plantas industriais [Milasch, 1984].




Figura 2 – Aspecto interno de um transformador de potência típico.

Fonte: Empresa Siemens, 2008

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 função básica da isolação é confinar o campo elétrico gerado pela tensão aplicada ao condutor no seu interior, reduzindo ou eliminando o risco de choques elétricos, curtos-circuitos e fugas de energia.

A isolação elétrica tem a função de minimizar o fluxo de corrente entre os condutores submetidos a diferenças de potencial elétrico, suportando o campo elétrico resultante. Atua ainda na transferência de calor entre os condutores, na estabilidade térmica, nas propriedades mecânicas que permitem suportar os esforços eletromecânicos na ocorrência de transitórios e ainda na estabilidade química dentro de níveis que possam garantir suas funções como isolante elétrico (ZIRBES, 2003).

Transformadores utilizam óleo isolante mineral derivado do petróleo que desempenha uma função importante tanto no isolamento quanto no resfriamento das partes ativas de um transformador. Para um perfeito funcionamento do óleo isolante, suas características físico-químicas devem ser preservadas. Porém, as propriedades do óleo isolante podem sofrer alterações por uma série de razões, tais como a oxidação, a umidade, a temperatura, a instabilidade elétrica e pelo contato com materiais utilizados na própria confecção dos transformadores, como é o caso do papel, do verniz, da madeira, do silício e do papelão, dentre outros. Em condições normais de uso, existe ainda a degradação lenta das propriedades do óleo isolante.

Quando submetido a distúrbios elétricos e térmicos, o óleo apresenta níveis de degradação superiores gerando gases a uma taxa acima do normal (ARANTES, 2005; BAKAR, 2014).

1.4.2. Métodos de diagnóstico de Transformadores de Potência

Os principais métodos de teste de transformadores de potência utilizados nas concessionárias do setor elétrico são:

- a. Análise dos Gases Dissolvidos (AGD);
- b. Ensaio físico-químico no óleo

O Anexo A e Anexo B apresentam uma lista mais completa destes ensaios.

Através do método de Análise de Gases Dissolvidos (AGD) é possível definir a condição de operação dos transformadores de potência, permitindo a percepção de uma primeira indicação do seu mau funcionamento (MORAIS, 2004; SINGH e BANDYOPADHYAY, 2010).

A formação de gases no interior dos equipamentos pode ocorrer em decorrência de alguns problemas, como mau contato entre componentes internos, fugas de energia entre espiras, esforço às altas correntes de curto circuito e tempo de trabalho prolongado com cargas elevadas. O levantamento e diagnóstico destes gases, a partir de uma amostra de óleo, podem determinar causas e indicar medidas a serem adotadas, antecipando possíveis transtornos provocados por paradas indesejáveis do equipamento, reduzindo custos de manutenção ou perda de produção (LUI FILHO, 2006).

Dentre os métodos convencionais de diagnóstico de falhas incipientes no óleo isolante de transformadores, há os que utilizam relações de concentrações de gases, como o método de Rogers (Anexo C) utilizado e implementado neste trabalho, o método de Doernenburg (Anexo D) e o projeto de revisão da NBR 7274 (Anexo E), baseado na IEC 599/78 e aqueles que envolvem concentrações individuais de gases, como o trabalho de Duval (Anexo F).

1.4.3. Análise Cromatográfica

Através do método de Análise de Gases Dissolvidos (AGD) é possível definir a condição de operação dos transformadores de potência, podendo-se ter uma primeira

indicação do seu mau funcionamento (Morais, 2004). A formação destes gases no interior dos equipamentos pode ser causa de algum tipo de problema, como mau contato entre componentes internos, fugas de energia entre espiras, esforço às altas correntes de curto circuito e tempo de trabalho prolongado com cargas elevadas. O levantamento e diagnósticos destes gases, a partir de uma amostra de óleo, podem determinar causas e medidas a serem adotadas e com isto remediar possíveis transtornos de paradas indesejáveis do equipamento, diminuição de custos de manutenção ou então perda de produção (LUPÍ FILHO, 2006).

O processo de diagnóstico de transformadores de potência, que utilizam óleo como meio refrigerante, consiste de três etapas básicas: extração a vácuo, análise por cromatografia gasosa e separação e quantificação dos gases dissolvidos.

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 3 (FUHR, 2011).




Figura 3 – Desenho esquemático do Sistema de Cromatografia a Gás.

Fonte: Arantes, 2005

Os gases analisados pelos dois métodos são: hidrogênio (H_2), Metano (CH_4), Acetileno (C_2H_2), Etileno (C_2H_4) e Etano (C_2H_6), o que muda nos métodos são as relações entre estes gases e os seus percentuais.

A análise de gases dissolvidos no óleo pela cromatografia gasosa, AGD, tem provado ser viável e preditiva. Alguns problemas que poderiam caminhar para falhas catastróficas em transformadores que podem ser detectadas são:

- a) **Arco elétrico:** frequentemente devido à perda ou mau contato de conexões dentro dos transformadores causados por vibrações;

- b) **Corona:** descargas elétricas no enrolamento;
- c) **Sobre aquecimento do óleo:** aquecimento exagerado do óleo isolante, resultando em transferência de calor ineficiente;
- d) **Degradação da celulose:** material isolante do enrolamento das bobinas (papel) começa a se deteriorar.

Com base na temperatura de decomposição do óleo, e em função da formação de gases para essa temperatura, supõe-se que uma falha possa estar ocorrendo. Por exemplo, falhas de origem elétrica, do tipo descargas contínuas ou condição de arco elétrico, podem levar a temperatura do óleo na região em torno desta descarga a níveis elevados, alcançando 1800°C, e levar à formação significativa de Acetileno (C_2H_2) (COSTA e BRANDÃO, 2001).

A estimativa da quantidade de gases formados, bem como a sua evolução, em função da temperatura, pode ser visualizada na Figura 4.




Figura 4 – Formação dos gases em função da temperatura de decomposição.

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

Fonte: IEEE C57.104, 1991

Para temperaturas entre 150°C e 400°C os gases mais significativos são os de baixo peso molecular como o hidrogênio (H_2) e o Metano (CH_4), com concentrações mais elevadas de Metano. Um aumento mesmo que relativamente pequeno de temperatura faz com que a concentração de hidrogênio seja superior à do Metano.

Assim a relação entre os dois gases é totalmente alterada. O valor desta relação é uma evidência para discriminar entre falhas térmicas de baixa intensidade. (Abu-Siada, 2012)

1.4.4. Redes Neurais Artificiais

Um neurônio (Figura 5) é composto por um corpo celular (ou soma), um axônio tubular e várias ramificações arbóreas chamadas dendritos.




Figura 5 – Neurônio biológico.

Fonte: Arantes, 2005

Os dendritos (zonas receptivas) formam uma malha de filamentos finíssimos ao redor do neurônio. O axônio (linhas de transmissão) é um tubo longo e fino que se divide em ramos, que termina em pequenos bulbos. O pequeno espaço entre o fim do bulbo e o dendrito é conhecido como sinapse, que tem como papel fundamental a memorização da informação (BRAGA, et al., 2000).

Redes neurais artificiais são sistemas computacionais estruturados onde nós simples (ou neurônios) são interligados para formar uma rede. A inspiração original advém das estruturas cerebrais, em particular dos neurônios (FERNANDES, 2005).

A forma como os neurônios da rede neural se organizam está intimamente ligada ao algoritmo de aprendizado utilizado no treinamento da rede. Geralmente, pode-se identificar três tipos de arquiteturas de RNA's: Redes com propagação para frente de uma camada; Redes com propagação para frente de múltiplas camadas (Multicamada) e Redes Recorrentes.

O Neurônio Artificial, ou Elemento Processador (EP), é um simples dispositivo capaz de calcular o somatório de N entradas ponderadas, cujo resultado passa através de uma função não-linear. Basicamente, é caracterizado por um “*offset*” ou limiar interno e por algum tipo de função não-linear, como mostra a Figura 6.




Figura 6 – Modelo de neurônio artificial.

Fonte: Arantes, 2005

Tipicamente esses EPs estão arranados em camadas, como apresenta a Figura 7. A primeira camada é a de entrada, que recebe as informações que são processadas e enviadas à camada seguinte. A última camada, a de saída, apresenta o resultado da rede. Todas as camadas, entre a entrada e a saída (usualmente uma ou mais), são chamadas de camadas escondidas ou *hidden layer*, pois não têm contato com dados de entrada ou de saída do mundo real (FERNANDES, 2005).




Figura 7 – Arquitetura da RNA com uma saída.

Fonte: Moraes, 2004

A rede neural passa por um processo de treinamento a partir dos casos reais conhecidos, adquirindo a sistemática necessária para executar adequadamente o processo desejado dos dados fornecidos. Sendo assim, a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação programada, onde é necessário um conjunto de regras rígidas pré-fixadas e algoritmos (BARRETO, 2002).

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 (BRAGA, et al., 2000). O detalhamento das funções de ativação está descrito no Anexo I.

As redes neurais oferecem uma vasta gama de aplicações, tais como armazenagem, recuperação de dados e classificação de padrões. A rede neural do tipo *Perceptron* Multicamadas (MLP) (Figura 8) é frequentemente utilizada na função de classificação. É um tipo de rede relativamente simples que pode apresentar uma não linearidade acentuada na formação de planos que definem as áreas dos grupos no espaço multidimensional (BRAGA, et al., 2000).

As redes neurais artificiais, assim como as pessoas, aprendem através de exemplos. Uma maneira de classificar as redes é quanto à forma de aprendizado: Supervisionado ou Não-Supervisionado.




Figura 8 – Perceptron Multicamadas.

Fonte: Morais, 2004.

No aprendizado supervisionado, conjuntos de padrões de entrada e seus correspondentes padrões de saída são sucessivamente apresentados à rede. 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*, *Madaline* e *Backpropagation* são leis de aprendizagem supervisionada (BRAGA, et al., 2000).

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 (BARRETO, 2002).

1.4.5. Algoritmo de treinamento

O problema de aprendizagem nas redes neurais é formulado em termos de minimização de uma função de perda, f . Esta função é, em geral, composta por um erro e uma regularização. O termo de erro avalia como uma rede neural se encaixa no conjunto de dados. Por outro lado, o termo de regularização é usado para evitar a superposição, controlando a complexidade efetiva da rede neural.

A função de perda depende dos parâmetros adaptativos (bias e pesos sinápticos) na rede neural. Estes parâmetros podem ser convenientemente agrupados em um único vetor de peso n -dimensional w . A Figura 9 abaixo representa a função de perda $f(w)$.




Figura 9 – Função de perda $f(w)$.

Fonte: MatLab

Como se pode ver na imagem, o ponto w^* é mínima da função de perda. Em qualquer ponto A , é possível calcular a primeira e a segunda derivada da função de perda. As primeiras derivadas são agrupadas no vetor de gradiente, cujos elementos podem ser escritos pela Equação (1) como:

$$\nabla f(w) = df/dw_i \quad (i = 1, \dots, n) \quad (1)$$

Da mesma forma, as segundas derivadas da função de perda podem ser agrupadas na matriz de Hessian, como mostra a Equação (2):

$$H_{i,j} f(w) = d^2 f / dw_i * dw_j \quad (i, j = 1, \dots, n) \quad (2)$$

2. MATERIAIS E MÉTODOS

Neste trabalho foram usadas informações de laudos cromatográficos a partir da análise de 224 transformadores de potência, instalados nas subestações de força de uma operadora do setor elétrico. Tais laudos, gerados pela equipe técnica responsável, a partir das normas descritas neste estudo, contêm as concentrações dos gases Hidrogênio (H_2), Metano (CH_4), Acetileno (C_2H_2), Etileno (C_2H_4) e Etano (C_2H_6), dissolvidos no óleo isolante e medidos em ppm (partes por milhão), que foram posteriormente normalizados para valores limites entre -1 e 1 para melhor aplicação da RNA.

A rede neural foi implementada usando o toolbox do Matlab, que auxilia na definição e configuração da arquitetura da RNA. O MATLAB (Matrix Laboratory), software desenvolvido pela The MathWorks, Inc, é um sistema interativo, onde as soluções e problemas são expressos em linguagem matemática. O módulo de RNA traz recursos para configuração do número de camadas da rede, tipos de funções de transferência e de algoritmos de aprendizado, parâmetros do treinamento da rede.

2.1. Algoritmo *Backpropagation*

O algoritmo *Backpropagation* (BP) provê um aprendizado supervisionado, isto é, procura achar iterativamente a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural, segundo um erro mínimo. Desta forma, ajusta os pesos entre as camadas através da retro propagação do erro encontrado em cada interação (BARRETO, 2002). No **Anexo G** pode-se encontrar o detalhamento matemático do algoritmo *Backpropagation*.

Basicamente, a rede aprende um conjunto pré-definido de pares de exemplos de entrada/ saída em ciclos de propagação/ adaptação. Depois que um padrão de entrada foi aplicado como um estímulo aos elementos da primeira camada da rede, ele é propagado por cada uma das outras camadas até que a saída seja gerada. Este padrão de saída é então comparado com a saída desejada e um sinal de erro é calculado para cada elemento de saída (MARTINEZ, 2015).

O sinal de erro é então retro propagado da camada de saída para cada elemento da camada intermediária anterior que contribui diretamente para a formação da saída. Este processo se repete, camada por camada, até que cada elemento da rede receba um sinal de erro que descreva sua contribuição relativa para o erro total. Baseado no

sinal de erro recebido, os pesos das conexões são então atualizados para cada elemento de modo a fazer a rede convergir para um estado que permita a codificação de todos os padrões do conjunto de treinamento (MARTINEZ, 2015).

A rede *Backpropagation* geralmente trabalha com a regra delta generalizada, baseada na regra delta desenvolvida por Windrow e Hoff. A regra delta padrão consiste de um método de gradiente descendente, objetivando minimizar o erro quadrado total para a função de ativação linear, como por exemplo, threshold, porém se a superfície de erro for complexa não há garantias de solução ótima, levando o algoritmo a convergir para uma solução estável (mínimos locais) (BRAGA, et al., 2000). Entretanto, a regra delta generalizada utiliza uma função de ativação semi-linear, no caso a sigmoide que é diferencial e não decrescente, e com essa função o neurônio consegue identificar o nível de atividade de sua entrada. A partir disso, é definida sua saída. O algoritmo não raro converge para os mínimos locais e para contornar esse problema, são utilizadas algumas técnicas, como por exemplo, adotar a taxa de treinamento decrescente, o termo momentum, adicionar nós intermediários e ruído aos dados. Essas soluções fazem com que a rede acelere o algoritmo *Backpropagation* reduzindo a incidência dos mínimos locais. (MARTINEZ, 2015).

A topologia de Rede Neural mais popular atualmente é a Rede Direta com Neurônios Estáticos (*Feedforward*), *Multi Layer Perceptron* com algoritmo de treinamento *Backpropagation* (ARANTES, 2005), foco deste trabalho.

2.2. Arquitetura da rede proposta

No estudo foram criadas três redes independentes, uma para cada condição testada (Normal, Falha Elétrica e Falha Térmica). Cada uma das redes processa individualmente os mesmos dados de entrada e apresenta na saída a classificação correspondente ao seu treinamento. A arquitetura desta rede é apresentada na Figura 10.




Figura 10 – Arquitetura da RNA com uma saída.

Fonte: MatLab

A rede neural utilizada neste estudo é do tipo *Perceptron* com aprendizado supervisionado, com cinco neurônios de entrada, representando cada uma das concentrações de gases utilizados na norma ABNT NBR 7274, uma camada escondida com N neurônios e um neurônio de saída, indicando a condição a ser testada (Normal, Falha Elétrica e Falha Térmica).

Os neurônios da camada escondida utilizam a função de ativação sigmoide e o neurônio de saída utiliza a função degrau, cujo número foi variado com o objetivo de analisar a sua influência e obter a rede com a melhor resposta. Foram testadas redes com 10, 20, 30, 40 e 50 neurônios. Para cada configuração de neurônios, a rede foi testada em ciclos de 10, 20 e 30 iterações para diminuir a incerteza no processo de treinamento. Os algoritmos de treinamento utilizados estão detalhados no Anexo H.

2.2.1. Modelagem da Rede Neural

No aprendizado supervisionado são apresentados à rede sucessivos conjuntos de padrões de entrada e seus correspondentes padrões de saída.

Etapas da utilização da rede são:

- a. **Treinamento:** estes são apresentados para a rede durante a formação, isto é a rede é ajustada de acordo com o seu erro;
- b. **Validação:** estes são usados para medir a generalização da rede, e para deter o treinamento quando a generalização para melhorar;
- c. **Teste:** estes têm nenhum efeito sobre a formação e assim proporcionam uma medida do desempenho da rede após a sua formação.

2.2.2. Preparação dos dados

A base do funcionamento do modelo neural é o treinamento, no qual é apresentada à rede uma sequência de padrões, conforme a Tabela 1 e a classe (resposta) a que estes pertencem, conforme a

Tabela 2.

Cada coluna da Tabela 1 de padrões de treinamento, chamada vetor padrão ou x , representa um transformador e os valores das concentrações de gases dissolvidos no óleo isolante, obtidos dos ensaios cromatográficos.

Cada coluna da

Tabela 2 chamada vetor alvo ou t , representa o laudo fornecido pelo especialista para esta concentração de gases, classificados como condição normal, condição de falha térmica ou condição de falha elétrica.

Tabela 1 – Padrão de treinamento para a rede neural (vetor x).

Transformador	Trf01	Trf02	Trf03	Trf04	Trf05	Trf06	Trf07	Trf08	Trf09
H ₂	22,0	36,0	180,0	32,0	72,0	260,0	3800,0	550,0	78,0
CH ₄	6,0	5,0	11,0	51,0	27,0	650,0	1100,0	67,0	580,0
C ₂ H ₂	4,0	0,4	0,4	0,4	140,0	3,0	1700,0	240,0	1200,0
C ₂ H ₄	6,0	20,0	27,0	51,0	220,0	950,0	1300,0	89,0	1500,0
C ₂ H ₆	5,0	6,0	18,0	52,0	26,0	220,0	300,0	30,0	130,0

Tabela 2 – Classe do padrão de treinamento para a rede neural (vetor t).

Condição	Trf01	Trf02	Trf03	Trf04	Trf05	Trf06	Trf07	Trf08	Trf09
Normal	1	1	1	0	0	0	0	0	0
Falha térmica	0	0	0	1	1	1	0	0	0
Falha elétrica	0	0	0	0	0	0	1	1	1

O vetor alvo deve possuir 1 (um) em todas as posições cujos padrões pertencerem à classe determinada, e 0 (zero) nas demais. Por exemplo, o transformador TRF03 foi classificado com condição normal e o TRF04 como tendo uma falha térmica. A relação completa de dados dos transformadores é apresentada no Apêndice B.

2.2.3. Treinamento da rede

Durante o processo de treinamento o Matlab divide a massa de dados apresentada em três conjuntos: dados de treinamento, dados para validação e dados para teste da rede, divididos conforme a quantidade total de padrões (colunas). Nos nossos testes foram definidas as proporções de 75%, 15% e 15% respectivamente, conforme a Tabela 3

Tabela 3 – Treinamento da rede neural.

Total Transformadores	Treinamento	Validação	Teste
224	158 (70%)	33 (15%)	33 (15%)

2.2.4. Testando a rede

No exemplo abaixo apresentado, na Tabela 4, foi fornecido à rede treinada um novo conjunto de transformadores, com o seu respectivo laudo fornecido pelo técnico do laboratório de análises químicas da operadora elétrica. A coluna Laudo RNA apresenta o resultado da análise feita pela rede neural e a taxa de acerto desta RNA em relação ao laudo do especialista.

Tabela 4 – Teste da rede neural.

Dados Transformadores					Laudo Técnico			Laudo RNA		
H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	Normal	Falha Elétrica	Falha Térmica	Normal	Falha Elétrica	Falha Térmica
95,0	64,0	5,0	300,0	90,0	1	0	0	0	0	0
15,0	118,0	9,0	13,0	640,0	1	0	0	1	0	0
18,0	15,0	5,0	93,0	3,0	1	0	0	1	0	0
618,0	113,0	775,0	198,0	124,0	0	1	0	0	1	0
148,0	117,0	113,0	128,0	104,0	0	1	0	0	0	0
1869,0	3272,0	166,0	8381,0	1229,0	0	1	0	0	0	1
315,0	38,0	96,0	73,0	7,0	0	0	1	0	0	0
26,0	10,0	25,0	14,0	10,0	0	0	1	0	0	0
120,0	38,0	55,0	40,0	40,0	0	0	1	0	0	0
								88,90%	77,80%	55,60%

2.2.5. Implementando a rede

A implementação da rede neural utilizou a ferramenta *Neural Pattern Recognition Tool* (nprtool) do software Matlab, versão 2011a. O Apêndice A apresenta o algoritmo desenvolvido com os recursos do MatLab.

A partir desses comandos (Apêndice A), uma janela será gerada: *Neural Network Training* (nntraintool) (Figura 11), na qual os parâmetros de treinamento da rede são mostrados, tais como números de camadas, algoritmo de treinamento, números de épocas, tempo de simulação e outros.




Figura 11 – Neural Network Training (nntraintool).

Além disso, é possível plotar algumas características da rede ao longo de seu treinamento, como por exemplo, a matriz de confusão da rede (Figura 12) e o desempenho da rede (Figura 13).




Figura 12 – Matriz de confusão do treinamento da RNA.

No gráfico da matriz de confusão, as linhas correspondem à classe prevista (Classe de saída) e as colunas mostram a classe verdadeira (Classe de Destino). As células diagonais mostram quanto (e que porcentagem) dos exemplos a rede treinada estima corretamente, enquanto as células fora da diagonal apresentam onde o classificador cometeu erros. A coluna na extrema direita traz a precisão de cada classe prevista e a linha na parte inferior do gráfico, a precisão de cada classe verdadeira. A célula no canto inferior direito mostra a precisão geral.

Resumindo, a matriz de confusão mostra as porcentagens de classificações corretas e incorretas. As classificações corretas são os quadrados verdes na diagonal das matrizes. As classificações incorretas formam os quadrados vermelhos. E as faixas cinza, os percentuais de acerto e erro para cada condição.




Figura 13 – Evolução do erro durante o treinamento da RNA.

O gráfico de desempenho da rede traça a relação entre o erro e a época do treinamento, a validação e os testes de desempenho do treinamento da rede neural.

Geralmente o erro é reduzido após várias épocas de treinamento, mas pode começar a aumentar no conjunto de dados de validação à medida que a rede começa a superar os dados de treinamento. Na configuração padrão, o treinamento para após seis aumentos consecutivos no erro de validação, e o melhor desempenho é tirado da época com o menor erro de validação.

Outro gráfico que auxilia na validação da rede é o Gráfico de Regressão apresentado na Figura 14, que mostra a relação entre as saídas da rede e os destinos.

Se o treinamento fosse perfeito, as saídas da rede e os alvos seriam exatamente iguais, mas a relação raramente é perfeita na prática.




Figura 14 – Gráfico de regressão da RNA analisada.

Os quatro gráficos representam os dados de treinamento, validação, teste e a resposta final da rede. A linha tracejada em cada gráfico representa o resultado perfeito - saídas = alvos. A linha sólida representa a linha de regressão linear de melhor ajuste entre saídas e alvos. O valor R é uma indicação da relação entre as saídas e os alvos. Se $R = 1$, isso indica que existe uma relação linear exata entre saídas e alvos. Se R for próximo de zero, não existe uma relação linear entre saídas e alvos.

3. RESULTADOS

Neste capítulo serão analisados os resultados da utilização de uma rede neural artificial na classificação das condições de operação dos 224 transformadores de potência, instalados nas subestações de força de uma operadora do setor elétrico.

Durante a fase de treinamento da rede foram realizadas variações entre a quantidade de neurônios da cama oculta e o algoritmo de treinamento, com o objetivo de identificar qual das opções seria capaz de apresentar uma melhor resposta. Após o treinamento da rede (RNA), foi possível utilizá-la para determinar a condição de operação de qualquer outro transformador.

A literatura consultada recomenda redes de 10 até 20 neurônios na camada oculta. Optou-se por testar a RNA com até 50 neurônios, visto que os tempos de teste da rede não cresceram muito. Para diminuir a incerteza do treinamento, foram feitos testes com 10, 20 e 30 ciclos.

Cada rede construída testava uma dada condição dos transformadores:

- 1) Normal;
- 2) Falha Elétrica;
- 3) Falha Térmica.

Entre os vários recursos que as bibliotecas de redes neurais do Matlab fornecem, um deles é o Índice de Classificação Correta da rede. Estes índices foram anotados para cada conjunto de: Algoritmo de treinamento x Número de neurônios x Ciclos de teste.

São apresentados a seguir os resultados destes testes das redes neurais descritas com apenas uma condição de saída. Os dados utilizados estão descritos no Apêndice B.

3.1. Condição Normal

As tabelas 5, 6 e 7 mostram os resultados em Condição Normal, com 10, 20 e 30 ciclos, respectivamente.

Tabela 5 – Desempenho da RNA – condição Normal – 10 ciclos.

Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	72,8%	72,0%	66,4%	71,0%	74,5%
20	74,6%	71,2%	76,0%	76,4%	73,7%
30	76,3%	77,7%	76,2%	75,4%	75,2%
40	75,6%	74,9%	72,4%	76,6%	77,1%
50	76,8%	75,7%	76,8%	75,8%	76,3%

Tabela 6 – Desempenho da RNA – condição Normal – 20 ciclos.

Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	72,9%	72,1%	76,0%	72,5%	75,5%
20	76,0%	74,1%	77,4%	77,1%	75,3%
30	73,4%	77,1%	76,4%	74,9%	75,5%
40	77,4%	76,9%	76,3%	73,4%	76,6%
50	75,5%	76,7%	73,5%	76,5%	75,0%

Tabela 7 – Desempenho da RNA – condição Normal – 30 ciclos.

Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	75,9%	76,5%	75,9%	77,2%	76,1%
20	76,4%	76,9%	74,5%	62,9%	73,4%
30	73,8%	72,5%	76,1%	76,5%	77,1%
40	77,1%	76,9%	76,9%	76,9%	76,1%
50	76,4%	75,5%	77,0%	76,2%	75,9%

A Tabela 8 mostra os valores médios referentes ao desempenho da RNA em condição normal.

Tabela 8 – Desempenho da RNA – condição Normal – valores médios.

Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	75,9%	76,5%	75,9%	77,2%	76,1%
20	76,4%	76,9%	74,5%	62,9%	73,4%
30	73,8%	72,5%	76,1%	76,5%	77,1%
40	77,1%	76,9%	76,9%	76,9%	76,1%
50	76,4%	75,5%	77,0%	76,2%	75,9%

A Figura 15 apresenta o gráfico dos valores médios obtidos no desempenho da RNA em condição normal.




Figura 15 – Desempenho da RNA – condição Normal – valores médios.

3.2. Condição Falha Elétrica

As tabelas 9, 10 e 11 mostra os resultados obtidos em Condição de Falha Elétrica, com 10, 20 e 30 ciclos, respectivamente.

Tabela 9 – Desempenho da RNA – condição Falha Elétrica – 10 ciclos.

Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	87,0%	87,3%	87,2%	88,2%	85,3%
20	88,4%	88,7%	88,8%	85,7%	85,5%
30	87,4%	86,6%	88,1%	86,4%	89,0%
40	88,1%	86,8%	83,8%	88,3%	87,4%
50	87,3%	86,7%	88,0%	85,4%	87,5%

Tabela 10 – Desempenho da RNA – condição Falha Elétrica – 20 ciclos.

Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	87,1%	87,9%	87,0%	88,3%	88,4%
20	88,8%	88,6%	88,8%	87,7%	89,2%
30	88,1%	87,6%	85,8%	88,0%	88,0%
40	86,1%	88,9%	88,5%	88,1%	87,9%
50	88,3%	88,3%	87,0%	88,1%	85,7%

Tabela 11 – Desempenho da RNA – condição Falha Elétrica – 30 ciclos.


Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	89,2%	88,3%	87,7%	89,1%	89,3%
20	88,3%	88,2%	88,7%	88,4%	88,9%
30	89,6%	88,1%	89,0%	88,7%	88,2%
40	89,0%	87,8%	88,3%	86,4%	88,0%
50	88,5%	89,0%	87,6%	89,0%	87,5%

A Tabela 12 mostra os valores médios referentes ao desempenho da RNA em condição Falha Elétrica.

Tabela 12 – Desempenho da RNA – condição Falha Elétrica – valores médios.

Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	87,9%	87,8%	87,3%	88,5%	87,6%
20	88,5%	88,5%	88,8%	87,3%	87,9%
30	88,0%	87,4%	87,6%	87,7%	88,4%
40	87,7%	87,9%	86,9%	87,6%	87,8%
50	88,0%	88,0%	87,5%	87,5%	86,9%

A Figura 16 apresenta o gráfico dos valores médios obtidos no desempenho da RNA em Falha Elétrica.

**Figura 16 – Desempenho da RNA – Falha Elétrica – valores médios.**

3.3. Condição Falha Térmica

As tabelas 13, 14 e 15 mostra os resultados obtidos em Condição de Falha Térmica, com 10, 20 e 30 ciclos, respectivamente.

Tabela 13 – Desempenho da RNA – condição Falha Térmica – 10 ciclos.

Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	70,6%	82,6%	73,5%	77,1%	73,3%
20	75,2%	79,4%	73,6%	64,3%	78,4%
30	73,6%	74,7%	70,0%	78,2%	72,6%
40	72,0%	75,3%	71,3%	77,3%	75,4%
50	74,2%	72,3%	73,0%	71,4%	76,5%

Tabela 14 – Desempenho da RNA – condição Falha Térmica – 20 ciclos.

Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	64,3%	77,7%	78,4%	77,2%	79,1%
20	81,0%	77,9%	73,1%	82,3%	75,3%
30	79,8%	74,6%	72,6%	71,1%	76,2%
40	73,5%	80,7%	77,0%	76,6%	78,2%
50	79,4%	77,4%	79,6%	81,0%	79,5%

Tabela 15 – Desempenho da RNA – condição Falha Térmica – 30 ciclos.


Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	79,1%	75,3%	82,1%	78,6%	82,7%
20	76,9%	76,0%	76,5%	77,4%	76,4%
30	77,9%	83,7%	76,8%	78,1%	64,6%
40	75,0%	80,4%	76,4%	76,3%	80,2%
50	78,6%	76,4%	77,6%	80,7%	75,5%

A Tabela 16 mostra os valores médios referentes ao desempenho da RNA em condição Falha Térmica.

Tabela 16 – Desempenho da RNA – condição Falha Térmica – valores médios

Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	79,1%	75,3%	82,1%	78,6%	82,7%
20	76,9%	76,0%	76,5%	77,4%	76,4%
30	77,9%	83,7%	76,8%	78,1%	64,6%
40	75,0%	80,4%	76,4%	76,3%	80,2%
50	78,6%	76,4%	77,6%	80,7%	75,5%

A Figura 17 apresenta o gráfico dos valores médios obtidos no desempenho da RNA em Falha Térmica.

**Figura 17 – Desempenho da RNA – Falha Elétrica – valores médios.**

3.4. Valores consolidados

Com base nos resultados dos ensaios anteriores, gerou-se a tabela a seguir, com a média simples, agrupada por condição de saída e algoritmo de treinamento, apresentados na Tabela 17 e o gráfico na Figura 18.

Tabela 17 – Taxa de acerto da rede: Condição de saída x Algoritmo de treinamento.

	Trainlm	Traingdx	Traingd	Traingda	Traingdm	Média
Normal	75,4%	75,3%	75,6%	75,2%	75,7%	75,4%
Falha Elétrica	88,2%	87,3%	87,0%	87,8%	87,8%	87,6%
Falha Térmica	76,7%	78,1%	77,0%	77,4%	76,9%	77,1%




Figura 18 – Taxa de acerto da rede consolidado.

Com estes resultados, chega-se à média das taxas de acerto das redes neurais implementada por condição de operação, respectivamente na Tabela 18 e Figura 19.

Tabela 18 – Resultado consolidado por condição de operação.

Condição de Saída	Média
Normal	75,4%
Falha Elétrica	87,6%
Falha Térmica	77,1%




Figura 19 – Resultado consolidado por condição de operação.

3.5. Rede Neural com três saídas

Apenas para efeito de comparação, foi criada uma quarta rede com três saídas, identificando as condições Normais, Falha Térmica e Falha Elétrica.

A arquitetura desta rede é apresentada na Figura 20.




Figura 20 – Arquitetura da RNA com três saídas.

A utilização de uma arquitetura de rede com o uso de múltiplas saídas para identificação dos diagnósticos simultaneamente não apresentou bons resultados, a exemplo do relatado em casos publicados na literatura.

Os resultados desta rede estão são apresentados nas Tabelas 19, 20 e 21. Os dados utilizados estão descritos no Apêndice B.

Tabela 19 – Desempenho da RNA – Três saídas - 10 ciclos.

Neurônios	trainlm	traingdx	traingd	traingda	traingdm
10	70,1%	66,6%	65,8%	66,5%	71,0%
20	71,5%	68,0%	70,8%	66,1%	63,1%
30	71,8%	68,6%	68,9%	65,8%	67,0%
40	64,3%	65,1%	65,6%	70,9%	72,0%
50	68,7%	73,4%	66,1%	69,0%	73,3%

Tabela 20 – Desempenho da RNA – Três saídas - 20 ciclos.

Neurônios	Trainlm	Traingdx	Traingd	Traingda	Traingdm
10	65,1%	68,0%	67,1%	68,6%	66,2%
20	68,9%	64,2%	71,7%	64,9%	68,5%
30	66,3%	66,6%	71,4%	68,3%	67,9%
40	69,6%	69,5%	70,0%	71,0%	71,6%
50	72,5%	71,3%	71,4%	70,2%	56,7%

Tabela 21 – Desempenho da RNA – Três saídas - 30 ciclos.


Neurônios	Trainlm	Traingdx	Traingd	Traingda	Traingdm
10	70,8%	66,3%	70,3%	68,8%	71,1%
20	52,2%	71,3%	67,9%	63,6%	67,0%
30	71,9%	66,1%	69,3%	70,8%	69,0%
40	52,2%	72,6%	71,3%	67,5%	70,2%
50	71,0%	70,8%	73,1%	69,4%	72,5%

A Tabela 22 apresenta os resultados consolidados das três saídas quanto ao desempenho da RNA.

Tabela 22 – Rede com três saídas - condição de saída x Algoritmo de treinamento.

	Trainlm	Traingdx	Traingd	Traingda	Traingdm	Média
RNA com três saídas	67,1%	68,6%	69,4%	68,1%	68,5%	68,3%

A Figura 21 apresenta os resultados do desempenho da RNA com Três saídas, consolidados com o Valor Médio de 68,9 %.

**Figura 21 – Desempenho da RNA – Três saídas - Consolidado.**

4. DISCUSSÃO

É apresentado a seguir uma análise dos resultados apresentados pelas redes neurais implementadas, discutindo-se qual configuração obteve os melhores índices de acerto para os laudos dos transformadores de potência.

4.1. Condição Normal

Analisando-se os dados obtidos para a condição de saída Normal (tabelas 5, 6 e 7) identifica-se que o melhor resultado foi obtido pela rede neural utilizando o algoritmo traingdx, com uma camada escondida de 3 neurônios (Tabela 23).

Tabela 23 – Condição Normal – melhor desempenho.

Condição	Algoritmo Treinamento	Neurônios Camada Interna	Melhor taxa de acerto
Normal	traingdx	30	77,68 %

No gráfico da matriz de confusão (Figura 22) observa-se a taxa de acerto de 77,68% da rede.




Figura 22 – Condição Normal – matriz de confusão.

O gráfico de desempenho (Figura 23) informa que a rede alcançou a sua estabilidade após 133 épocas de treinamento.




Figura 23 – Condição Normal – melhor desempenho

4.2. Falha Elétrica

Analisando-se os dados obtidos para a condição de saída Falha Elétrica (tabelas 9, 10 e 11) identifica-se que o melhor resultado foi obtido pela rede neural utilizando o algoritmo trainlm, com uma camada escondida de 3 neurônios (Tabela 23).

Tabela 24 – Falha Elétrica – melhor desempenho.

Condição	Algoritmo Treinamento	Neurônios Camada Interna	Melhor taxa de acerto
Falha Elétrica	trainlm	30	89,6 %

No gráfico da matriz de confusão (Figura 24 – Falha Elétrica – matriz de confusão.) observa-se a taxa de acerto de 89,6% da rede.




Figura 24 – Falha Elétrica – matriz de confusão.

O gráfico de desempenho (Figura 25) informa que a rede alcançou a sua estabilidade após 66 épocas de treinamento.




Figura 25 – Falha Elétrica – melhor desempenho

4.3. Falha Térmica

Analisando-se os dados obtidos para a condição de saída Falha Térmica (tabelas 13, 14 e 15) identifica-se que o melhor resultado foi obtido pela rede neural utilizando o algoritmo trainlm, com uma camada escondida de 3 neurônios (Tabela 25).

Tabela 25 – Falha Térmica – melhor desempenho.

Condição	Algoritmo Treinamento	Neurônios Camada Interna	Melhor taxa de acerto
----------	-----------------------	--------------------------	-----------------------

Falha Térmica	trainlm	30	89,6 %
---------------	---------	----	--------

No gráfico da matriz de confusão (Figura 26) observa-se a taxa de acerto de 89,6% da rede.




Figura 26 – Falha Térmica – matriz de confusão.

O gráfico de desempenho (Figura 27) informa que a rede alcançou a sua estabilidade após 27 épocas de treinamento.




Figura 27 – Falha Térmica – melhor desempenho

4.4. Rede neural com três saídas

Analisando-se os dados obtidos pela rede neural para a condição de três saídas (Normal, Falha Elétrica e Falha Térmica) (tabelas 19, 20 e 21) identifica-se que o

melhor resultado foi obtido pela rede neural utilizando o algoritmo *traingdx*, com uma camada escondida de 50 neurônios (Tabela 26).

Tabela 26 – Rede com três saídas – melhor desempenho.

Condição	Algoritmo Treinamento	Neurônios Camada Interna	Melhor taxa de acerto
Três saídas	<i>traingdx</i>	50	73,4%

4.5. Conclusões Finais para uma única saída

Observa-se que no estudo de saída única com camada interna de 30 neurônios, na condição normal o algoritmo que apresentou melhor taxa de acerto foi *traingdx*. Na condição de falha elétrica e falha térmica o algoritmo *trainlm* foi o que apresentou taxa de acerto mais expressiva.

Para a rede com três saídas o algoritmo que obteve a melhor taxa de acerto foi o *traingdx*.

Desta forma, se for analisado cada condição individualmente convém a seleção adequada do algoritmo a ser utilizado para o devido ajuste nas taxas de acerto, conforme pode ser observado na tabela 27.

Tabela 27 – Condição Normal – melhor desempenho.

Condição	Algoritmo Treinamento	Neurônios Camada Interna	Melhor taxa de acerto
Normal	<i>traingdx</i>	30	77,6 %
Falha Elétrica	<i>trainlm</i>	30	89,6 %
Falha Térmica	<i>trainlm</i>	30	89,6 %
Três saídas	<i>traingdx</i>	50	73,4%

A Tabela 28 apresenta a comparação das taxas de acerto médias nas redes neurais (RNA).

Tabela 28 – Comparação das taxas de acerto das redes neurais.

Método	Diagnóstico Individual			Três saídas
	Normal	Falha Elétrica	Falha Térmica	
RNA	75,4 %	87,6 %	77,1 %	68,3%

Nesta comparação entre as 4 redes construídas nota-se a as redes que tratam as falhas individualmente obtiveram um índice de acerto muito superior à rede que tratava as três falhas globalmente.

5. CONCLUSÕES

Como um importante ativo para a economia, as concessionárias elétricas têm se empenhado na garantia da qualidade do fornecimento de energia elétrica para os seus clientes. A confiabilidade de um sistema elétrico é aprimorada quando defeitos e falhas incipientes nos seus equipamentos são detectados antes que o problema evolua e possa causar uma interrupção no sistema em questão.

Os métodos de diagnóstico de falhas incipientes em transformadores através da análise dos gases dissolvidos no óleo isolante obtiveram indiscutível sucesso durante os últimos 30 anos, ainda se constituindo em uma poderosa ferramenta para avaliar preditivamente o real estado operacional dos transformadores.

Com os resultados obtidos o uso de técnicas de inteligência artificial, mais precisamente de redes neurais artificiais (RNA), se mostrou bastante útil como ferramenta auxiliar no processo de diagnóstico, podendo ser empregada como ferramenta de apoio à decisão.

Uma contribuição importante para este trabalho é a necessidade de se aprimorar o processo de coleta das amostras de óleo isolante para posterior análise cromatográfica. Os métodos existentes de extração do óleo isolante são suscetíveis de falha, ocasionando a contaminação das amostras e causando a necessidade de descarte e nova coleta, atrasando o diagnóstico e a consequente correção dos problemas que possam estar ocorrendo com o transformador de potência.

Como contribuição para o futuro, torna-se necessário estudar meios de medir as concentrações de gases dissolvidos sem a necessidade da extração destas amostras, tais como a detecção on-line dos gases e suas concentrações, utilizando um dispositivo acoplado diretamente ao tanque do transformador.

Embora as taxas de acerto dos diagnósticos das redes neurais artificiais tenham ficado dentro do esperado, há ainda espaço para melhorias na sua construção. Uma das melhorias possíveis seria a utilização de redes com mais de uma camada escondida. Na literatura utilizada é recomendado no máximo duas camadas escondidas, visto que o aumento implicaria em um maior tempo para o balanceamento da rede, sem um aumento significativo na precisão.

6. VERSÃO COMPACTA

Utilização de Redes Neurais Artificiais no diagnóstico de falha em transformadores de alta tensão

USE OF ARTIFICIAL NEURAL NETWORKS IN FAULT DIAGNOSIS IN HIGH VOLTAGE TRANSFORMERS

Ricardo Luiz Nacarato.
ricardo.nacarato@gmail.com

Resumo: No presente trabalho, em sua introdução, são abordados alguns aspectos dos transformadores de alta potência, peças fundamentais nos sistemas de distribuição de energia elétrica, fundamentando teoricamente os transformadores de potência, os métodos de diagnóstico de transformadores de potência e as redes neurais artificiais (RNA). Este trabalho tem por objetivo principal descrever a utilização de uma Rede Neural Artificial (RNA) do tipo multicamada e sua viabilidade como ferramenta auxiliar no diagnóstico de falhas em transformadores de alta potência, e específicos, a análise dos gases dissolvidos no óleo, propor uma solução de análise automática dos exames efetuados nas amostras de óleo de transformador e avaliar a possibilidade de disponibilizar ferramentas para a emissão rápida e precisa de laudos e pareceres. O capítulo matérias e métodos detalha a rede neural que foi implementada, usando o *toolbox*, na análise de 224 transformadores de potência instalados nas subestações de força de uma operadora do setor elétrico. A partir dos resultados se verificou que a arquitetura que obteve as melhores taxas de identificação dos diagnósticos dos transformadores foram as redes com condições identificadas individualmente. O foco deste projeto é a prevenção de problemas nos transformadores de potência através da técnica de gases dissolvidos no óleo refrigerante, concluindo que as redes neurais podem auxiliar no aprendizado dos técnicos de laboratório neste processo de análise.

Palavras-chave: Diagnóstico de falhas, Transformadores, Análise de Gases Dissolvidos, Redes Neurais.

Abstract: In the present work, in its introduction, some aspects of the high power transformers, fundamental parts in the electric power distribution systems, are presented, theoretically grounding the power transformers, the power transformers diagnostic methods and the artificial neural networks (RNA). The main objective of this work is to describe the use of an artificial neural network (RNA) of the multilayer type and its feasibility as an auxiliary tool in the diagnosis of faults in high power transformers, and specific, the analysis of the dissolved gases in the oil, propose a solution for the automatic analysis of the tests performed on the transformer oil samples and to evaluate the possibility of providing tools for the rapid and accurate emission of reports and opinions. The materials and methods chapter details the neural network that was implemented, using the *toolbox*, in the analysis of 224 power transformers installed in the power substations of an electric sector operator. From the results it was verified that the architecture that obtained the best rates of identification of the diagnoses of the transformers were the networks with individually identified

conditions. The focus of this project is the prevention of problems in power transformers through the technique of dissolved gases in the soda oil, concluding that the neural networks can aid in the learning of laboratory technicians in this process of analysis.

Keywords – Fault Diagnosis, Transformers, Dissolved Gas Analysis (DGA), Artificial neural networks.

INTRODUÇÃO

Na nossa sociedade moderna o constante aumento da demanda de eletricidade tem causado aumento nos gastos com sistemas de geração e transmissão de energia elétrica [1]. Os transformadores de potência são elementos fundamentais nos sistemas de transmissão de energia elétrica (Figura 1).




Figura 1 - Ilustração dos sistemas elétricos de potência.

Fonte: Queiros, 2010

Através do método de Análise de Gases Dissolvidos (AGD) é possível definir a condição de operação dos transformadores de potência, podendo-se ter uma primeira indicação do seu mau funcionamento.

As redes neurais podem ser aplicadas a uma grande variedade de problemas, tal como armazenagem, recuperação de dados e classificação de padrões. A rede neural do tipo *Perceptron* Multicamadas (MLP) é frequentemente utilizada para a função de classificação. É um tipo de rede relativamente simples que pode apresentar

uma não linearidade acentuada na formação de planos que definem as áreas dos grupos no espaço multidimensional [2].

OBJETIVO

Este trabalho descreverá a utilização de redes neurais artificiais (RNA) do tipo multicamada e a sua viabilidade como ferramenta auxiliar no diagnóstico de falhas em transformadores de alta potência e a sua acuidade na detecção das falhas apresentadas pelos métodos tradicionais.

MATERIAIS E MÉTODOS

A rede neural utilizada neste estudo é do tipo *Backpropagation* com aprendizado supervisionado, composta por: com cinco neurônios de entrada, representando cada uma das concentrações de gases utilizados na norma ABNT NBR 7274, uma camada escondida com quinze neurônios, e um neurônio de saída, indicando a condição a ser testada.

Neste estudo foram treinadas três redes, onde os dados relativos à relação de concentração de gases de um caso representam o vetor de entrada e com uma única saída, identificando uma dada condição (normal, falha térmica, falha elétrica). Cada uma das redes processa individualmente os mesmos dados de entrada e apresenta na saída a classificação correspondente ao seu treinamento. Apenas para efeito de comparação foi criada uma quarta rede com três saídas, identificando as condições normais, falha térmica e falha elétrica.

Após o treinamento da rede podemos utilizá-la para determinar a condição de operação de qualquer outro transformador.


RESULTADOS

Embora as taxas de acerto dos diagnósticos das Redes RNA tenham ficado dentro do esperado há ainda espaço para melhorias na construção das redes neurais artificiais em estudo.

A comparação das taxas de acerto das três redes neurais testadas (RNA) é apresentada na Tabela 1 e o gráfico do desempenho da rede é apresentado na Figura 2.

Tabela 1 – Comparação das taxas de acerto das redes neurais.

Método	Diagnóstico Individual		
	Normal	Falha Elétrica	Falha Térmica
RNA	75,4 %	87,6 %	77,2 %

**Figura 2 – Desempenho da RNA – Três saídas - Consolidado.**

Como pode ser verificada, a arquitetura que obteve as melhores taxas de identificação dos diagnósticos dos transformadores foi a das redes em que cada uma das condições é identificada individualmente.

Diante de tais resultados pode-se concluir que uma das melhorias possíveis seria a utilização de redes neurais com mais de uma camada escondida.

Outra melhoria seria treinar a rede com uma massa de dados maior, uma vez que a rede aprende a identificar os diagnósticos baseado nos exemplos que são apresentados.

A principal vantagem da utilização das redes neurais no contexto deste projeto de pesquisa é que o algoritmo utilizado tem a capacidade de aprender a reconhecer os padrões que caracterizam as condições de operação dos transformadores.

Desta maneira o diagnóstico da rede tende a ser aproximar do diagnóstico do especialista, aprendendo com o mesmo, pois a cada novo ensaio cromatográfico que é submetido para análise da rede e consequente confirmação ou não do laudo pelo especialista é um novo dado a ser utilizado em análises futuras.

CONCLUSÕES

Com os resultados obtidos, pode-se dizer que a rede neural artificial pode ser empregada como ferramenta de apoio à decisão por concessionárias de energia elétrica, além de servir como uma alternativa aos métodos convencionais fortemente recomendados para a análise dos gases dissolvidos no óleo de transformadores de potência. Desta forma, vislumbra-se para trabalhos posteriores, o desenvolvimento de uma etapa de pré-processamento dos dados, com o intuito de se extrair características que auxiliem no processo de classificação dos gases.

Uma contribuição importante para este trabalho, baseado na experiência profissional do autor, e na análise de papers existentes, é que não 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, acarretando na obtenção de valores muito discrepantes das concentrações dos gases. Daí a necessidade de descarte da amostra e nova coleta de óleo, atrasando o diagnóstico e consequente correção dos problemas que possam estar ocorrendo com o transformador de potência.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] QUEIROS, L. M. O. **Estimação e Análise das Perdas Técnicas na Distribuição de Energia Elétrica**. Universidade Estadual de Campinas, Campinas-SP, Brasil, 2010.
- [2] FERNANDES, A. M. da R. **Inteligência Artificial: noções gerais**. Florianópolis: VisualBooks, 2005.

REFERÊNCIAS

- ABU-SIADA A., Islam S. **A new approach to identify power transformer criticality and asset management decision based on dissolved gas-in-oil analysis**. IEEE Transactions on Dielectrics and Electrical Insulation, 19, 1007-1012, 2012.
- ARANTES, J. G. **Diagnóstico de falhas em transformadores de potência pela análise de gases dissolvidos em óleo isolante através de redes neurais**. Universidade Federal de Itajubá, Itajubá-MG, Brasil, 2005.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 7274: Interpretação da Análise dos Gases de Transformadores em Serviço**. Rio de Janeiro, RJ, 1982.
- BAKAR, N. A. **A review of dissolved gas analysis measurement and interpretation techniques**. IEEE Electrical Insulation Magazine, May 2014
- BARRETO, J. M. **Introdução às Redes Neurais Artificiais**. UFSC – Departamento de Informática e de Estadística, São Carlos-SP, Brasil 2002.
- BRAGA, A. P.; CARVALHO, A. P. L. F. de; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações** – Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora S.A., 2000.
- COSTA, S. BRANDÃO JR., A. F. **Monitoramento de Transformadores de Potência com Base nas Condições**. Eletricidade Moderna, p. 152-162; 2001.
- DUVAL, M. **A Review of Faults Detectable by Gas-in-Oil Analysis in Transformers**. IEEE Electrical Insulation Magazine, vol. 18, nº 3, p. 8-17; 2002.
- DUVAL, M. **Dissolved Gas Analysis: It Can Save Your Transformer**. IEEE Electrical Insulation Magazine, vol. 5, nº6, p. 22-27, 1989.
- FERNANDES, A. M. da R. **Inteligência Artificial: noções gerais**. Florianopolis: VisualBooks, 2005.
- FUHR, J. **Condition based maintenance for power transformers in service: Application of conventional and advanced diagnostic methods**. Electrical Insulation Conference (EIC 2011), pp. 271-275, 5-8 June, 2011.
- HAYKIN, S. **Neural networks and learning machines**. 3rd ed. Upper Saddle River, New Jersey: Pearson Education Inc., 2009. 906 p.
- IEEE Standard C57.104. IEEE. **Guide for the Interpretation of Gases Generated in Oil - Immersed Transformers**. 1991.

LUPI FILHO, G. **Um estudo comparativo entre abordagens convencionais e redes neurais artificiais para diagnóstico de transformadores de potência.** CPFL – Companhia Paulista de Força e Luz, São Paulo-SP, Brasil, 2006.

MARTINEZ, S. C. **Neurocontrolador de Velocidade Microprocessado.** Universidade Santa Cecília, Santos-SP, 2015.

MILASCH, M. **Manutenção de Transformadores em Líquido Isolante.** São Paulo: Escola Federal de Engenharia de Itajubá: Edgar Blücher, 1984.

MORAIS, D. R. **Ferramenta Inteligente Para Detecção De Falhas Incipientes Em Transformadores Baseada Na Análise De Gases Dissolvidos No Óleo Isolante.** Universidade Federal De Santa Catarina, Florianópolis-SC, Brasil, 2004.

QUEIROS, L. M. O. **Estimação e Análise das Perdas Técnicas na Distribuição de Energia Elétrica.** Universidade Estadual de Campinas, Campinas-SP, Brasil, 2010.

SINGH, S.; BANDYOPADHYAY, M.N. **Dissolved gas analysis technique for incipient fault diagnosis in power transformers: A bibliographic survey.** IEEE Electrical Insulation Magazine, v. 26, n. 6, pp. 41-46, 2010.

ZIRBES, R. **Metodologias para Avaliação e Diagnóstico do Estado de Isolamentos de Papel Impregnado com Óleo Mineral.** Florianópolis. Dissertação (Mestrado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina, 2003.

Thank you for your submission to Revista IEEE-AL. Below is a copy of the information you submitted for your records.

Paper ID: 6586

Title : Failure Investigation in Power Transformers by Dissolved Gases Analysis in Isolating Oil Using Simulation with Artificial Neural Networks

Title : Investigação de falhas em transformadores de potência pela análise dos gases dissolvidos no óleo isolamento utilizando simulação com redes neurais artificiais

Author1

Name : Ricardo Luiz Nacarato

Org : Universidade Santa Cecília UNISANTA

Country : Brazil

Email : ricardo.nacarato@gmail.com

Author2

Name : Dorotéia Vilanova Garcia

Org : Universidade Santa Cecília UNISANTA

Country : Brazil

Email : dora@unisanta.br

Author3

Name : Mauricio Conceição Mario

Org : Universidade Santa Cecília UNISANTA

Country : Brazil

Email : cmario@unisanta.br

Author4

Name : João Inácio da Silva Filho

Org : Universidade Santa Cecília UNISANTA

Country : Brazil

Email : inacio@unisanta.br

Contact Author #: 1

Keywords: Diagnosis; Transformers; Dissolved Gas Analysis; Artificial neural networks

Abstract: High-power transformers are key components in electric power distribution systems and there are numerous tools and methodologies for fault diagnosis. Due to the costs involved in the transportation and handling of the equipment, the main methodologies that stand out are those directed to the equipment in operation. This paper is a study of the use of one of the diagnostic techniques for problem prevention, Analysis of Dissolved Gases in Insulating Oil and the use of Artificial Neural Networks (RNA) as a support tool in the identification of these failures. For the validation of the proposed RNA, the gas generation data and laboratory reports obtained from a Brazilian electric power company were used. The results for the diagnosis of incipient failures, reaching overall accuracy with values above 80%.

Paper: included

APÊNDICE A. UTILIZANDO A REDE NEURAL NO MATLAB

Script em MATLAB® do Modelo em Estudo

```
%Definindo parâmetros de treinamento
net.trainParam.epochs = 100;           % Número de epochs
net.trainParam.goal = 1e-8;            % Erro final desejado
net.trainParam.lr = 0.01;              % Taxa de aprendizado
net.trainParam.show = 25;              % Atualização da tela (epochs)
net.trainParam.mc = 0.9;               % Taxa de momentum
net.trainParam.lr_inc = 1.05;          % Taxa de incremento da l.r.
net.trainParam.lr_dec = 0.7;          % Taxa de decremento da l.r.
net.trainParam.max_perf_inc = 1.04;    % Incremento máximo do erro

% Inicializa a rede neural
net = newff([min(P)' max(P)'], [10 1], {'tansig' 'logsig'}, 'traingd');
net.trainParam.goal = 1e-8;

% Treina a rede iterativamente, de 5 em 5 epochs,
% até o total de 100 epochs, calculando os erros
Nepoch = 5;
NN = 20;
mape_min = 1e38;

for i = 1:NN,

    net.trainParam.epochs = Nepoch;
    net = train(net, Ptrain, Ttrain);
    Ctrain = sim(net, Ptrain);
    Cvalid = sim(net, Pvalid);

    % Calcula os erros MAPE para os padrões de treinamento e validação
    mape_train(i) = 100*mean(abs((Ttrain-Ctrain)./Ttrain))
    mape_valid(i) = 100*mean(abs((Tvalid-Cvalid)./Tvalid))

    % encontra o número de epochs ótimo
    if (mape_valid(i) < mape_min)
        mape_min = mape_valid(i);
        net_opt = net;
        Noptim = Nepoch * i;
    end

end

% Melhor rede:
net = net_opt;

% Testa a rede com os 3 conjuntos de padrões
Ctrain = sim(net, Ptrain);
Cvalid = sim(net, Pvalid);
Ctest = sim(net, Ptest);
```

APÊNDICE B. DADOS PARA TESTE DA REDE NEURAL

Neste apêndice são apresentados os dados utilizados para treinamento e teste da rede neural. Os grupos de dados representam uma parte de um banco de dados de uma operadora do serviço elétrico de fornecimento de energia. Para a apresentação dos mesmos, eles foram divididos em função da natureza das condições estabelecidas em inspeção e testes realizados por especialistas.

Dados de concentração de gases referentes aos estados identificados com a condição de normalidade (valores de concentração dos gases em ppm) (Tabela A1).

Tabela A1 - Dados de concentração de gases – condição normal.

#	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	#	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆
1	22,0	6,0	4,0	6,0	5,0	36	3,0	1,0	1,0	1,0	0,4
2	36,0	5,0	0,4	20,0	6,0	37	23,0	8,0	1,0	8,0	9,0
3	180,0	11,0	0,4	27,0	18,0	38	11,0	23,0	0,4	36,0	9,0
4	100,0	62,0	0,4	7,0	12,0	39	19,0	140,0	0,4	20,0	330,0
5	12,0	6,0	0,4	25,0	1,0	40	35,0	8,0	0,4	3,0	3,0
6	12,0	13,0	1,0	58,0	18,0	41	22,0	19,0	0,4	40,0	75,0
7	30,0	6,0	0,4	0,4	5,0	42	30,0	8,0	1,0	200,0	96,0
8	64,0	48,0	49,0	160,0	26,0	43	15,0	2,0	6,0	48,0	3,0
9	1600,0	2200,0	74,0	2700,0	430,0	44	62,0	11,0	0,4	59,0	8,0
10	48,0	20,0	120,0	130,0	21,0	45	20,0	29,0	130,0	77,0	5,0
11	7,0	2,0	0,4	2,0	1,0	46	22,0	4,0	0,4	8,0	12,0
12	32,0	6,0	0,4	7,0	5,0	47	20,0	40,0	0,4	62,0	5,0
13	23,0	6,0	0,4	2,0	3,0	48	8,0	4,0	0,4	4,0	9,0
14	9,0	5,0	0,4	17,0	4,0	49	23,0	30,0	0,4	86,0	14,0
15	140,0	110,0	74,0	250,0	36,0	50	61,0	310,0	330,0	3000,0	570,0
16	14,0	200,0	0,4	41,0	520,0	51	88,0	6,0	0,4	15,0	23,0
17	10,0	24,0	3,0	24,0	12,0	52	350,0	350,0	5,0	860,0	290,0
18	34,0	5,0	0,4	5,0	3,0	53	28,0	6,0	2,0	5,0	4,0
19	17,0	4,0	0,4	11,0	2,0	54	9,0	4,0	0,4	15,0	3,0
20	7,0	8,0	0,4	3,0	13,0	55	21,0	8,0	0,4	17,0	25,0
21	150,0	54,0	0,4	9,0	61,0	56	69,0	43,0	0,4	20,0	32,0
22	82,0	61,0	8,0	35,0	130,0	57	50,0	50,0	5,0	66,0	36,0
23	82,0	20,0	74,0	33,0	16,0	58	430,0	2300,0	10,0	3000,0	1900,0
24	40,0	62,0	1,0	11,0	51,0	59	25,0	3,0	0,4	2,0	1,0
25	20,0	3,0	0,4	5,0	2,0	60	16,0	3,0	0,4	4,0	10,0
26	19,0	9,0	0,4	7,0	20,0	61	110,0	8,0	0,4	10,0	4,0
27	13,0	10,0	0,4	55,0	3,0	62	1,0	1,0	0,4	0,4	0,4
28	290,0	16,0	0,4	12,0	24,0	63	52,0	3,0	0,4	4,0	3,0
29	14,0	3,0	0,4	12,0	3,0	64	430,0	2300,0	10,0	3000,0	1900,0
30	11,0	79,0	0,4	14,0	130,0	65	7,0	0,4	0,4	0,4	0,4
31	49,0	14,0	1,0	24,0	12,0	66	48,0	29,0	0,4	20,0	17,0
32	8,0	3,0	0,4	4,0	2,0	67	30,0	76,0	0,4	48,0	220,0
33	610,0	1800,0	270,0	6300,0	960,0	68	600,0	1800,0	130,0	3800,0	520,0
34	5,0	0,4	1,0	1,0	1,0	69	16,0	1,0	0,4	1,0	1,0
35	22,0	6,0	4,0	6,0	5,0	70	48,0	12,0	0,4	18,0	14,0

Dados de concentração de gases referentes aos estados identificados com a condição de falha por sobreaquecimento (valores de concentração dos gases em ppm) (Tabela A2).

Tabela A 2 - Dados de concentração de gases - falha por sobreaquecimento.

#	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	#	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆
1	25,0	18,0	1,0	39,0	33,0	32	57,0	46,0	0,4	14,0	58,0
2	590,0	8400,0	710,0	62000,0	92000,0	33	17,0	3,0	1,0	4,0	9,0
3	260,0	100,0	26,0	2200,0	210,0	34	110,0	2,0	3,0	15,0	2,0
4	150,0	340,0	14,0	1400,0	220,0	35	66,0	38,0	0,4	39,0	120,0
5	1700,0	1600,0	0,4	2100,0	440,0	36	6000,0	14000,0	47,0	19000,0	18000,0
6	980,0	1800,0	22,0	3200,0	460,0	37	410,0	90,0	0,4	36,0	53,0
7	1,0	1800,0	5,0	6100,0	3400,0	38	410,0	11,0	30,0	330,0	300,0
8	87,0	430,0	0,4	190,0	570,0	39	2500,0	3200,0	220,0	5300,0	620,0
9	42,0	320,0	0,4	840,0	820,0	40	12,0	5,0	1,0	4,0	3,0
10	4800,0	39000,0	20,0	70000,0	19000,0	41	64,0	160,0	0,4	68,0	1200,0
11	300,0	1400,0	9,0	2100,0	720,0	42	4,0	19,0	0,4	20,0	1,0
12	64,0	840,0	37,0	5100,0	800,0	43	7,0	22,0	0,4	32,0	35,0
13	430,0	450,0	0,4	2000,0	1000,0	44	450,0	250,0	510,0	300,0	130,0
14	380,0	280,0	0,4	330,0	280,0	45	82,0	13,0	0,4	8,0	23,0
15	460,0	570,0	38,0	720,0	100,0	46	20,0	11,0	1,0	14,0	14,0
16	150,0	380,0	49,0	2300,0	320,0	47	110,0	46,0	0,4	9,0	52,0
17	46,0	960,0	0,4	1000,0	720,0	48	1400,0	460,0	0,4	310,0	940,0
18	420,0	800,0	0,4	370,0	100,0	49	1400,0	3500,0	3600,0	7900,0	2500,0
19	99,0	480,0	0,4	220,0	2600,0	50	13,0	290,0	13,0	4100,0	2400,0
20	290,0	110,0	0,4	14,0	320,0	51	220,0	750,0	7,0	1200,0	300,0
21	47,0	74,0	0,4	100,0	150,0	52	250,0	430,0	9,0	700,0	120,0
22	200,0	1200,0	75,0	2700,0	800,0	53	36,0	250,0	0,4	410,0	130,0
23	190,0	820,0	0,4	1500,0	780,0	54	27,0	130,0	1,0	280,0	110,0
24	51,0	53,0	0,4	29,0	200,0	55	2200,0	120,0	0,4	5,0	63,0
25	45,0	900,0	3,0	8700,0	7900,0	56	23,0	5,0	1,0	8,0	6,0
26	28,0	320,0	13,0	1200,0	250,0	57	54,0	3300,0	0,4	3000,0	2200,0
27	170,0	1200,0	24,0	5200,0	940,0	58	11,0	8,0	6,0	39,0	11,0
28	280,0	160,0	39,0	1000,0	610,0	59	580,0	880,0	160,0	1100,0	190,0
29	6,0	2,0	0,4	7,0	5,0	60	300,0	250,0	32,0	560,0	160,0
30	30,0	520,0	0,4	1000,0	310,0	61	12,0	110,0	1,0	660,0	190,0
31	1600,0	55000,0	9300,0	74000,0	42000,0	62	1000,0	1200,0	1200,0	2000,0	140,0

Dados de concentração de gases referentes aos estados identificados com a condição de falha por descargas elétricas (valores de concentração dos gases em ppm) (Tabela A3).

Tabela A 3 - Dados de concentração de gases - falha por descargas elétricas..

#	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	#	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆
1	3800,0	1100,0	1700,0	1300,0	300,0	30	4000,0	1200,0	4400,0	1900,0	130,0
2	550,0	67,0	240,0	89,0	30,0	31	230,0	120,0	740,0	220,0	14,0
3	78,0	580,0	1200,0	1500,0	130,0	32	6600,0	2300,0	3400,0	3500,0	210,0
4	5800,0	560,0	4700,0	830,0	31,0	33	11000,0	1300,0	4600,0	1400,0	140,0
5	430,0	40,0	480,0	68,0	13,0	34	9,0	2,0	52,0	5,0	1,0
6	3800,0	1700,0	4200,0	1300,0	200,0	35	51,0	6,0	11,0	6,0	1,0
7	6600,0	3300,0	6200,0	4200,0	620,0	36	16000,0	9400,0	22000,0	17000,0	1400,0
8	7200,0	7200,0	1100,0	7700,0	3800,0	37	7,0	2,0	0,4	1,0	1,0
9	5000,0	2000,0	5500,0	3100,0	1900,0	38	97,0	12,0	21,0	25,0	2,0
10	1500,0	110,0	910,0	91,0	140,0	39	150,0	38,0	110,0	54,0	5,0
11	7,0	4,0	60,0	94,0	49,0	40	35,0	110,0	540,0	380,0	150,0
12	2100,0	210,0	1200,0	230,0	160,0	41	32,0	32,0	29,0	47,0	5,0
13	770,0	86,0	370,0	170,0	29,0	42	79,0	100,0	230,0	83,0	410,0
14	540,0	26,0	280,0	21,0	11,0	43	20000,0	6400,0	10000,0	7100,0	2600,0
15	1500,0	640,0	1700,0	810,0	50,0	44	1300,0	8400,0	5500,0	2200,0	5900,0
16	2400,0	770,0	1900,0	850,0	68,0	45	1100,0	140,0	350,0	2,0	14,0
17	530,0	260,0	250,0	210,0	14,0	46	200,0	6,0	8,0	8,0	5,0
18	36,0	67,0	380,0	290,0	110,0	47	39,0	4,0	15,0	4,0	0,4
19	250,0	20,0	200,0	31,0	5,0	48	6000,0	1900,0	2700,0	2400,0	280,0
20	2600,0	660,0	810,0	750,0	47,0	49	81,0	21,0	29,0	46,0	11,0
21	49,0	4,0	0,4	1,0	3,0	50	14,0	7,0	22,0	15,0	1,0
22	200,0	240,0	100,0	380,0	74,0	51	19,0	0,4	0,4	4,0	0,4
23	970,0	240,0	1100,0	390,0	18,0	52	380,0	250,0	1000,0	590,0	34,0
24	1200,0	2500,0	120,0	3700,0	710,0	53	67,0	6,0	0,4	21,0	15,0
25	500,0	160,0	240,0	140,0	48,0	54	15000,0	10000,0	23000,0	21000,0	2200,0
26	630,0	670,0	1700,0	1100,0	81,0	55	4700,0	240,0	300,0	120,0	0,4
27	110,0	860,0	1800,0	1500,0	200,0	56	170,0	98,0	140,0	45,0	220,0
28	200,0	110,0	230,0	150,0	12,0	57	210,0	65,0	190,0	100,0	22,0
29	94,0	5,0	20,0	25,0	4,0						

ANEXOS

ANEXO A. ENSAIOS ESPECIAIS

Umidade, borra, compostos ácidos, aquecimento e descargas internas.

Estes são alguns dos problemas que podem estar ocorrendo com o transformador sem que se saiba, até a ocorrência de um problema mais grave. Com a análise periódica do óleo mineral isolante, é possível identificar essas anormalidades, tomar ações que evitem o desligamento e prolongar a vida útil do equipamento.

A razão dos ensaios é verificar como estão as propriedades do fluido dentro dos transformadores e tomar ações corretivas, quando necessárias, para que prolonguem a vida útil do equipamento. Os ensaios mínimos necessários são: Teor de Água, Rigidez Dielétrica, Fator de Perdas, Cor, Densidade, Acidez e Tensão Interfacial.

1. Determinação de enxofre corrosivo – ABNT NBR 10505

Determina qualitativamente os compostos corrosivos de enxofre em óleos minerais isolantes novos isentos de passivadores.

Na maioria dos casos, os óleos isolantes estão em contato contínuo com metais sujeitos à corrosão. A presença de compostos corrosivos de enxofre é prejudicial, pois resulta na deterioração desses metais a uma extensão dependente da quantidade, do tipo do agente corrosivo e dos fatores tempo e temperatura.

A avaliação dessas impurezas indesejáveis, ainda que não em termos de valores quantitativos, é um meio de reconhecer o perigo envolvido.

2. Determinação do teor de DBDS - Projeto de Norma 10.1-029 (baseado na IEC 60666)

Determina o teor de passivadores de corrosão - Benzotriazol (BTA) e Tolutriazol (TTA) por Cromatografia Líquida de Alta Eficiência (CLAE). Os passivadores têm a função de prevenir (em equipamentos novos) ou interromper (em equipamentos em serviço) a deposição de Cu_2S devido à ação do enxofre corrosivo.

3. Determinação do teor de DBDS - Projeto de Norma 10.1-029

Determina o teor de Dibenzil Dissulfeto por Cromatografia Gasosa com Detector de Captura de Elétrons (GC/ECD). O Dibenzil Dissulfeto é uma das espécies de enxofre que atua na corrosividade ao cobre. Principal agente no enxofre corrosivo.

4. Determinação do teor de DBPC - ABNT NBR 12134

Determina o teor de 2,6-di-terciário-butil paracresol por Espectrofotometria de Infravermelho por Transformada de Fourier (FT/IR). Visa determinar a quantidade de DBPC que foi adicionada ao óleo mineral isolante novo, ou regenerado, como proteção contra a oxidação ou a quantidade remanescente em um óleo usado.

5. Determinação do teor de Compostos Clorados

A determinação de PCB em líquidos isolantes não halogenados é realizada pelo método potenciométrico. É baseado na dosagem de íons cloreto oriundos das moléculas de bifenila policlorada, após reação específica. Esta dosagem é indireta e requer atenção aos procedimentos sugeridos pelos fabricantes dos equipamentos utilizados.

6. Determinação do teor de Compostos Furânicos - ABNT NBR 15349

Determina o teor de compostos furânicos por Cromatografia Líquida de Alta Eficiência (CLAE). Analisa o estado de envelhecimento do papel isolante, através da análise de derivados de furanos dissolvidos no óleo mineral isolante. Possibilita o planejamento da substituição do transformador com base em informações técnicas de envelhecimento e não da idade cronológica do equipamento.

7. Determinação do teor de PCB (Bifenilas Policloradas) - ABNT NBR 13882

Determina o teor de PCB por Cromatografia Gasosa com Detector de Captura de Elétrons (DCE). A determinação de PCB em líquidos isolantes não halogenados pelo método cromatográfico segue dosagem com utilização de padrões e comparação de áreas em curvas de calibração.

O equipamento conta com analisador automático e coluna “Fast PCB” o que diminui o tempo de análise de 1 hora para 20 minutos por amostra, trazendo rapidez com a mesma precisão e confiabilidade.

8. Determinação do Grau de Polimerização do Papel Isolante - ABNT NBR 8148

O grau de polimerização do papel isolante é medido pela viscosidade da solução de papel no solvente adequado (Etilenodiamina cúprica). Analisa o estado de envelhecimento do papel isolante. Possibilita o planejamento da substituição do transformador com base em informações técnicas de envelhecimento e não da idade cronológica do equipamento.

9. Determinação do Ponto de Fulgor - ABNT NBR 11341

Descargas elétricas no óleo ou exposição prolongada a temperaturas muito altas podem produzir quantidades suficientes de hidrocarbonetos de baixa massa molecular, causando a diminuição do ponto de fulgor do óleo.

Um ponto de fulgor baixo pode ser uma indicação da presença de produtos combustíveis voláteis no óleo. Isto pode resultar da contaminação por um solvente, mas em alguns casos, observou-se que a causa era devida a descargas com centelhamento intensivo.

10. Determinação da Viscosidade Cinemática e Dinâmica - ABNT NBR 10441

A viscosidade é um fator de controle importante na dissipação de calor. É também afetada pela temperatura. O envelhecimento e a oxidação normal do óleo não afetam de maneira significativa a sua viscosidade.

11. Determinação do Conteúdo de Partículas - ABNT NBR 14275

A presença de partículas no óleo isolante em equipamentos elétricos pode ter um grande número de fontes possíveis, dentre eles: fabricação do transformador, armazenamento e manuseio do óleo, desgaste e envelhecimento do óleo e sobreaquecimentos. O efeito de partículas suspensas na rigidez dielétrica do óleo isolante depende do tipo de partícula (metálica, fibras, borra, etc) e do seu teor de água.

12. Determinação da Compatibilidade de Materiais empregados com óleo mineral isolante - ABNT NBR 14274

A variação das propriedades elétricas do óleo mineral isolante é importante na determinação da contaminação do óleo pelo material ensaiado. As mudanças físicas no material ensaiado, tais como a dureza, inchamento ou descoloração, indicam o efeito do óleo no material ensaiado e são usadas para determinar a utilização do material em presença do óleo mineral isolante.

13. Determinação da Composição Carbônica - ASTM D 2140 -03

A composição carbônica é determinada através da viscosidade, da densidade específica e do índice de refração do óleo e é expressa em porcentagem de compostos naftênicos, porcentagem de compostos parafínicos e porcentagem de compostos aromáticos presentes no óleo mineral isolante.

14. Determinação da Estabilidade à Oxidação - ABNT NBR 10504

A capacidade do óleo mineral isolante de suportar a oxidação sob solicitação térmica e na presença de oxigênio e um catalisador de cobre é chamada estabilidade à oxidação. Esta fornece informações gerais sobre a expectativa de vida do óleo sob as condições de serviço no equipamento elétrico. A propriedade é definida como resistência à formação de compostos ácidos, borra e compostos que exercem influência no fator de perdas dielétricas sob determinadas condições.

ANEXO B. ANÁLISE FÍSICO-QUÍMICA

A análise físico-química determina a capacidade de isolamento e o estado de envelhecimento do óleo mineral. Os resultados são comparados aos valores pré-estabelecidos em normas. Valores fora dos limites especificados indicam necessidade de tratamento termo vácuo, substituição ou regeneração do óleo mineral.

Os óleos minerais nos transformadores, além da propriedade de isolamento, têm a função de resfriamento. Assim o elemento fluído transfere o calor desenvolvido e gerado nos circuitos magnéticos dos enrolamentos e também no núcleo ferro magnético, através das correntes convectivas para a carcaça do transformador e este, por sua vez transfere este calor para o meio ambiente. Como o papel é também um agente isolante, cabe ao óleo fazer o isolamento dos enrolamentos entre eles e em relação ao circuito magnético e a carcaça.

1. Cor - ABNT NBR 14483:2008 ABNT NBR 14483:2008ABNT NBR 14483:2008 ABNT NBR 14483:2008

Um rápido aumento da cor indica deterioração ou contaminação do óleo.

2. Rigidez Dielétrica - ABNT NBR IEC 60156:2004ABNT NBR IEC 60156:2004

A diminuição da rigidez dielétrica indica a contaminação do óleo. Evidencia a presença de agentes contaminantes como: água, sujeira, fibras celulósicas úmidas ou partículas condutoras.

3. Fator de Potência

A determinação do fator potência é uma indicação segura do grau de deterioração e contaminação do óleo. O aumento do fator de potência está ligado à presença de substâncias que causam condutividade. O fator de potência aumenta com a temperatura e com a quantidade de substâncias polares provenientes da deterioração do óleo.

4. Tensão Interfacial – ABNT NBR 06234:1965NBR 06234:1965

A tensão interfacial mede a concentração de substâncias polares no óleo que são responsáveis pela formação da borra. A diminuição de Tensão Interfacial indica a deterioração do óleo. Na superfície de separação entre o óleo e a água, forma-se uma força de atração entre moléculas dos dois líquidos que é chamada de tensão interfacial.

5. Índice de Neutralização ABNT NBR 14248:2009

O teste de acidez mede o teor de ácidos formados por oxidação, os quais são diretamente responsáveis pela formação da borra e pode também promover a degradação do papel. O aumento do índice de neutralização indica o envelhecimento do óleo.

6. Teor de Água ABNT NBR 07148:2001

Um elevado teor de água acelera a deterioração química do papel isolante e é indicativo de condições de operações indesejáveis, que requerem correções. Embora seja formada como subproduto da oxidação, a maior parte de água existente no óleo é absorvida do ar.

7. Densidade ABNT' NBR 07148:2001

Ensaio utilizado para identificar o tipo de óleo (parafínico ou naftênico).

ANEXO C. MÉTODO DE ROGERS

Utiliza a filosofia de diagnóstico baseado em relações entre concentrações de gases e limites de variação para estas relações. Utiliza quatro relações entre cinco gases, no estabelecimento das condições do equipamento. A forma de apresentação do método é dividida em duas tabelas. Na Tabela A5, em função das faixas de valores obtidos para as relações gasosas, estabelece-se um código (IEEE Std C57.104, 1991).

O critério de Rogers utiliza cinco gases para obtenção das correlações, os gases utilizados são: hidrogênio (H_2), Metano (CH_4), Etano (C_2H_6), Etileno (C_2H_4) e Acetileno (C_2H_2). Tais gases são obtidos pela análise cromatográfica do óleo isolante estudado. Determinadas estas relações, utiliza-se a Tabela A6 para se identificar o diagnóstico da falha.

Tabela A 4 - Tabela de definição dos códigos do método de Rogers

RELAÇÃO DE GASES	FAIXA DE VARIAÇÃO	CÓDIGO
CH_4 / H_2	≤ 0.1	5
	$> 0.1, < 1$	0
	$\geq 1, < 3$	1
	≥ 3	2
C_2H_4 / C_2H_6	< 1	0
	≥ 1	1
C_2H_4/C_2H_6	≤ 1	0
	$\geq 1, < 3$	1
	≥ 3	2
C_2H_2/C_2H_4	< 0.5	0
	$\geq 0.5, < 3$	1
	≥ 2	2

Tabela A 5 - Tabela de diagnóstico do método de Rogers em função do código

CH_4/H_2	$\text{C}_2\text{H}_6/\text{CH}_4$	$\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$	$\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$	Diagnóstico
0	0	0	0	Deterioração Normal
5	0	0	0	Descargas Parciais
1	0	0	0	Sobreaquecimento – abaixo de 150°C
2	0	0	0	Sobreaquecimento – abaixo de 150°C
1	1	0	0	Sobreaquecimento de 150°C – 200°C
2	1	0	0	Sobreaquecimento de 150°C – 200°C
0	1	0	0	Sobreaquecimento de 200°C – 300°C
0	0	1	0	Sobreaquecimento de condutores
1	0	1	0	Correntes de circulação nos enrolamentos
1	0	2	0	Correntes de circulação no núcleo e tanque, sobreaquecimento em conexões
0	0	0	1	Descarga contínua
0	0	1	1	Arco com alta energia
0	0	2	2	Arco com alta energia
0	0	2	2	Descarga contínua de baixa potência
5	0	0	1	Descarga parcial envolvendo o papel
5	0	0	2	Descarga parcial envolvendo o papel

O método previsto na NBR 7274/82, apresentado na Tabela A6, sugere a utilização de um critério semelhante ao método de Rogers, utilizando-se de três relações e cinco gases, no estabelecimento das condições do equipamento (NBR 7274/82).

Tabela A 6 - Interpretação da análise dos gases para a NBR 7274

C₂H₂/C₂H₄	CH₄/H₂	C₂H₄/C₂H₆	Diagnóstico
< 0.1	0.1 a 1.0	< 1.0	Envelhecimento Normal
< 0.1	< 0.1	< 1.0	Descarga parcial baixa energia
0.1 a 3.0	< 0.1	< 1.0	Descarga parcial alta energia
> 0.1	0.1 a 1.0	> 1.0	Arco – descarga baixa energia
0.1 a 3.0	0.1 a 1.0	> 3.0	Arco – descarga alta energia
< 0.1	0.1 a 1.0	1.0 a 3.0	Sobreaquecimento com t < 150°C
< 0.1	> 1.0	< 1.0	Sobreaquecimento 150°C < t < 300°C
< 0.1	> 1.0	1.0 a 3.0	Sobreaquecimento 300°C < t < 700°C
< 0.1	> 1.0	> 3.0	Sobreaquecimento t > 700°C

ANEXO D. MÉTODO DE DOERNENBURG

O método de Doernenburg original não estabelecia critérios para a identificação de condições normais do isolamento, mas estabelecia as condições de validade para aplicação desse método de diagnóstico em função das concentrações individuais dos gases componentes das relações. O critério de identificação de falhas do método de Doernenburg pode ser visualizado na Tabela A7, onde são apresentadas as faixas de valores de relações gasosas que classificam o tipo de falha à que o equipamento está submetido (IEEE Std C57.104, 1991).

Tabela A 7 - Critério de identificação de falha de Doernenburg

Tipo de Falha	Relações principais		Relações Auxiliares	
	CH ₄ /H ₂	C ₂ H ₂ /C ₂ H ₄	C ₂ H ₆ /C ₂ H ₂	C ₂ H ₂ /CH ₄
Ponto quente	>1	<0.75	>0.4	<0.3
Descarga parcial	<0.1	Não signif.	>0.4	<0.3
Outros tipos de descarga	<1 e >0.1	>0.75	<0.4	>0.3

ANEXO E. NORMA NBR 7274

O método previsto na NBR 7274/82, apresentado na Tabela A8, sugere a utilização de um critério semelhante ao método de Rogers, utilizando-se de três relações e cinco gases, no estabelecimento das condições do equipamento (NBR 7274/82).

Tabela A 8 - Interpretação da análise dos gases para a NBR 7274

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

ANEXO F. TRIANGULO DE DUVAL

O método de Duval 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 mais 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 só se aplica a transformadores quando os três gases explosivos citados aparecem juntos, caracterizando um iminente perigo ao equipamento mesmo em concentrações moderadas.




Figura A 1 – Triângulo de Duval

Fonte: Arantes, 2005

ANEXO G. DETALHAMENTO DO ALGORITMO *BACKPROPAGATION*

Na Figura A2 abaixo é representado um neurônio básico, segundo McCulloch e Pitts.




Figura A 2 - Modelo de neurônio artificial.

Fonte: Arantes, 2005

Matematicamente, o neurônio pode ser descrito pela Equação (1):

$$y_k = \varphi\left(\sum_{j=1}^n (w_{kj}x_j + b_k)\right) \quad (1)$$

onde, n é o total de entradas do neurônio k , x_j é a entrada j do neurônio, w_{kj} é o peso da entrada j do neurônio k , b_k corresponde ao parâmetro bias, φ é a função de ativação e y_k é a saída do neurônio k .

Como descrito no capítulo anterior, o algoritmo *backpropagation* calcula o erro mínimo entre a entrada e a saída da rede utilizando a regra delta modificada, Equação (2).

$$e(n) = d(n) - y(n) \quad (2)$$

onde n representa uma amostra do conjunto de treinamento, $d(n)$ o valor desejado e $y(n)$ o valor fornecido por um neurônio. Os ajustes são aplicados de forma a minimizar a função custo, Equação (3):

$$y_k = \xi(n) = 1/2 e^2(n) \quad (3)$$

Dessa forma, o ajuste num peso w_j no passo n é definido pela Equação (4):

$$\Delta w_j(n) = \eta e(n) x_j(n) \quad (4)$$

onde η é uma constante positiva que representa a taxa de aprendizado do algoritmo e $x_j(n)$ é o sinal de entrada j da amostra n .

Por fim o ajuste dos pesos do *perceptron* é dado pela Equação (5):

$$w(n+1) = w(n) + \eta [d(n) - y(n)] x(n) \quad (5)$$

onde n representa um passo de iteração do processo de ajuste dos pesos sinápticos, $w(n)$ é o vetor de pesos corrente, $d(n)$ é o valor desejado como saída, $y(n)$ é o valor fornecido pela rede, $x(n)$ é o vetor de entrada, $w(n+1)$ corresponde ao vetor de pesos atualizado e η é a taxa de aprendizado cujo valor deve estar entre 0 e 1.

O *backpropagation* (BP) é um algoritmo de aprendizagem supervisionada baseada na generalização da regra delta onde se busca a minimização da função do erro quadrático representada pela Equação (6):

$$y_k E(n) = \frac{\sum_{j=1}^k (d_j(n) - y_j(n))^2}{2} \quad (6)$$

Onde n é a época, k é o número de neurônios da camada de saída, d_j é o valor desejado do neurônio j e y_j é a saída fornecida pelo neurônio.

Segundo Haykin (2009), o processo de treinamento é constituído de duas fases:

- a. Forward (para frente): Nesta fase ocorre a propagação do sinal de entrada ao longo da rede.
- b. Backward (para trás); Nesta fase um sinal de erro é produzido através da comparação da saída obtida com a saída desejada. Este sinal é propagado para trás ao longo da rede. Nesta fase ocorre a correção dos

Abaixo é descrito um algoritmo básico para uma rede neural com o algoritmo *backpropagation*:

Preparação: inicialização da rede neural

1.1. Inicialize os pesos (valores randômicos pequenos);

O primeiro passo do algoritmo de retropropagação é a inicialização dos pesos da rede. Como normalmente não há nenhuma informação sobre os pesos da rede, um método muito utilizado é inicializar os pesos aleatoriamente, com distribuição uniforme sobre um pequeno intervalo em torno do zero

Primeira fase: Passagem (feedforward) dos padrões de treinamento

1.2. Cada unidade de entrada (X_i , $i = 1 \dots n$) recebe um sinal de entrada x_i e o propaga para todas as unidades na camada acima (unidades escondidas).

As conexões de entrada são ponderadas por um peso sináptico. Cada sinal de entrada X_i é multiplicado pelo peso sináptico W_i , e posteriormente é conectado ao neurônio. A entrada tem um valor fixo, diferente de zero, denominada limiar de ativação.

O combinador linear é responsável pela soma dos valores de entrada ($x_1 * w_1 + x_2 * w_2 + \dots + x_n * w_n +$) gerando o potencial de ativação U .

1.3. Cada unidade escondida (Z_j , $j = 1 \dots p$) soma suas entradas pesadas Equação (7),

$$z_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (7)$$

aplica sua função de ativação para computar seu sinal de saída e envia o sinal para todas as unidades na camada acima (unidades de saída) Equação (8).

$$z_j = f(z_in_j) \quad (8)$$

1.4. Cada unidade de saída (Y_k , $k = 1 \dots m$) soma suas entradas pesadas Equação (9),

$$y_in_k = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad (9)$$

e aplica sua função de ativação para computar seu sinal de saída Equação (10),

$$y_k = f(y_in_k) \quad (10)$$

Segunda fase: cálculo e retropropagação do erro associado

- 1.5. Cada unidade de saída (Y_k , $k = 1 \dots m$) recebe uma classificação correspondente ao padrão de entrada, computa seu termo de erro de informação, Equação (11)

$$\delta_k = (t_k - y_k) f'(y_in_k) \quad (11)$$

calcula seu termo de correção de pesos, Equação (12)

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (12)$$

calcula seu termo de correção de bias e envia δ_k para as unidades da camada abaixo, Equação (13)

$$\Delta w_{0k} = \alpha \delta_k \quad (13)$$

Terceira fase: ajuste de pesos e bias

- 1.6. Cada unidade de saída (Z_j , $j = 1 \dots p$) soma suas entradas delta (vindas das unidades da camada acima) , Equação (14)

$$\delta_in_j = \sum_{k=1}^m \delta_k w_{jk} \quad (14)$$

multiplica pela derivada de sua função de ativação para calcular seu termos de erro de informação, Equação (15)

$$\delta_j = \delta_in_j f'(z_in_j) \quad (15)$$

calcula seu termo de correção de pesos, Equação (16)

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (16)$$

e calcula seu termo de correção de bias, Equação (17)

$$\Delta v_{0j} = \alpha \delta_j \quad (17)$$

- 1.7. Cada unidade de saída (Y_k , $k = 1.. m$) altera seu bias e seus pesos ($j = 0 .. p$) ,
Equação (18):

$$w_{jk}(new) = w_{jk}(old) + \Delta w_{jk} \quad (18)$$

Cada unidade escondida (Z_j , $j = 1.. p$) altera seu bias e seus pesos ($i = 0 .. p$) ,
Equação (19):

$$v_{ij}(new) = v_{ij}(old) + \Delta v_{ij} \quad (19)$$

ANEXO H. ALGORITMOS DE TREINAMENTO DA RNA

O Matlab disponibiliza em sua biblioteca uma série de algoritmos de treinamento para as redes neurais *Perceptron* do tipo *Backpropagation*.

As redes implementadas foram treinadas utilizando-se os seguintes algoritmos de treinamento (Tabela A9):

Tabela A 9 - Algoritmos de treinamento da RNA.

Nome	Descrição
trainlm	<i>Backpropagation Levenberg-Marquardt</i>
traingdx	<i>Backpropagation de gradiente decrescente com momentum e taxa adaptativa</i>
traingd	<i>Backpropagation de gradiente decrescente</i>
traingda	<i>Backpropagation de gradiente decrescente com taxa adaptativa</i>
traingdm	<i>Backpropagation de gradiente decrescente com momentum</i>

- a. **Trainlm:** Função de treinamento de rede que atualiza os valores de peso e bias de acordo com a otimização *Levenberg-Marquardt*. O algoritmo, também conhecido como o método de mínimos quadrados amortecidos, foi projetado para funcionar especificamente com funções de perda que assumem a forma de uma soma de erros quadrados. Funciona sem calcular a matriz exata de Hessian. Em vez disso, ele funciona com o vetor gradiente e a matriz jacobiana.
- b. **Traingd:** Função de treinamento de rede que atualiza os valores de peso e bias de acordo com a descida gradiente.
- c. **Traingdx:** Função de treinamento de rede que atualiza os valores de peso e bias de acordo com o impulso da descida gradiente e uma taxa de aprendizado adaptativa.
- d. **Traingda:** Função de treinamento de rede que atualiza os valores de peso e bias de acordo com a descida do gradiente com taxa de aprendizado adaptativa.
- e. **Traingdm:** Função de treinamento de rede que atualiza os valores de peso e bias de acordo com a descida do gradiente com impulso.
- f. **Trainrp:** Função de treinamento de rede que atualiza os valores de peso e viés de acordo com o algoritmo de retrocessão resiliente.

ANEXO I. FUNÇÕES DE ATIVAÇÃO

A função de ativação $g(u)$ (**Erro! Fonte de referência não encontrada.**) processa o conjunto de entradas recebidas e o transforma em estado de ativação.




Figura A 3 - Modelo de neurônio artificial.

Fonte: Arantes, 2005

Normalmente, o estado de ativação dos neurônios pode assumir os seguintes valores:

- Binários: 0 e 1;
- Bipolares: -1 e +1;
- Reais.

As funções de ativação típicas são:

a) Função degrau: neste tipo de ativação (Figura 28) a saída do neurônio assumirá o valor 1 se o nível de atividade interna total do neurônio for não negativo, caso contrário a saída do neurônio assumirá o valor 0.

$$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases}$$




Figura 28 – Função degrau.

b) Função degrau (bipolar): neste tipo de ativação (Figura 29) a saída do neurônio pode assumir valores reais negativos e positivos no domínio de -1 a +1. A saída do neurônio assumirá o valor 1 se o nível de atividade interna total do neurônio for não negativo, caso contrário a saída do neurônio assumirá o valor -1;

$$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ -1 & \text{se } u < 0 \end{cases}$$




Figura 29 – Função degrau bipolar.

c) Função rampa: neste tipo de ativação (Figura 30) a saída do neurônio pode assumir valores positivos e negativos no domínio de -1 a 1, e no intervalo definido no intervalo $\{-a, a\}$, a saída assume o valor da função $g(u)=u$;

$$g(u) = \begin{cases} 1 & \text{se } u \geq a \\ u & \text{se } -a < u < a \\ -1 & \text{se } u \leq -a \end{cases}$$




Figura 30 – Função rampa.

d) Função sigmóide: neste tipo de ativação (Figura 31) β é o parâmetro que define a inclinação (ganho) da função sigmóide. Nesse tipo de função, a saída do neurônio assumirá valores reais entre 0 e 1;

$$g(u) = \frac{1}{1 + e^{(-\beta u)}}$$




Figura 31 – Função sigmoide.

e) Função tangente hiperbólica: neste tipo de ativação (Figura 32) a saída do neurônio pode assumir valores reais negativos e positivos no domínio de -1 a 1;

$$g(u) = \tanh(u) = \frac{1 - e^{-u}}{1 + e^{-u}}$$




Figura 32 – Função tangente hiperbólica.

As funções de ativação são escolhidas em função da necessidade do problema que a rede esteja trabalhando.