



Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Departamento de Engenharia Elétrica



Trabalho de Conclusão de Curso

DIAGNÓSTICO DE FALHA EM TRANSFORMADOR IMERSO A ÓLEO ISOLANTE USANDO UMA REDE NEURAL ARTIFICIAL

Pedro Henrique Cassimiro Caldeira

João Monlevade, MG
2019

Pedro Henrique Cassimiro Caldeira

**DIAGNÓSTICO DE FALHA EM
TRANSFORMADOR IMERSO A ÓLEO
ISOLANTE USANDO UMA REDE NEURAL
ARTIFICIAL**

Trabalho de Conclusão de curso apresentado à Universidade Federal de Ouro Preto como parte dos requisitos para obtenção do Título de Bacharel em Engenharia Elétrica pelo Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto.
Orientador: Prof. Dr. Juan Carlos Galvis Manso

**Universidade Federal de Ouro Preto
João Monlevade
2019**

C345d Cassimiro Caldeira, Pedro Henrique.
Diagnóstico de falha em transformador imerso a óleo isolante usando uma rede neural artificial [manuscrito] / Pedro Henrique Cassimiro Caldeira. - 2019.

52f.: il.: color; graf; tabs.

Orientador: Prof. Dr. Juan Carlos Galvis Manso.

Monografia (Graduação). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Departamento de Engenharia Elétrica.

1. Transformadores elétricos. 2. Isoladores e isolamentos elétricos - Óleos.
3. Redes neurais (Computação). I. Manso, Juan Carlos Galvis . II. Universidade Federal de Ouro Preto. III. Título.

CDU: 621.314



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE OURO PRETO
REITORIA
INSTITUTO DE CIÊNCIAS EXATAS E APLICADAS
DEPARTAMENTO DE ENGENHARIA ELETRICA



FOLHA DE APROVAÇÃO

Pedro Henrique Cassimiro Caldeira

DIAGNÓSTICO DE FALHA EM
TRANSFORMADOR IMERSO A ÓLEO
ISOLANTE USANDO UMA REDE NEURAL
ARTIFICIAL

Membros da banca

Marcelo Moreira Tiago - Doutor - Universidade Federal de Ouro Preto
Francisco Ricardo Abrantes Couy Baracho - Doutor - Universidade Federal de Ouro Preto
Juan Carlos Galvis Manso - Doutor - Universidade Federal de Ouro Preto

Versão final
Aprovado em 12 de dezembro de 2019

De acordo

Juan Carlos Galvis Manso



Documento assinado eletronicamente por **Juan Carlos Galvis Manso, PROFESSOR DE MAGISTERIO SUPERIOR**, em 29/12/2019, às 11:22, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0030320** e o código CRC **FCE12C8F**.

Referência: Caso responda este documento, indicar expressamente o Processo nº 23109.204286/2019-14

SEI nº 0030320

R. Diogo de Vasconcelos, 122, - Bairro Pilar Ouro Preto/MG, CEP 35400-000
Telefone: - www.ufop.br

Agradecimentos

Agradeço a Deus por ter saúde e força para nunca desistir dos meus sonhos e objetivos.

Agradeço de forma especial à minha família, à Lorena e ao professor Juan. Aos amigos Gerdau, pelo apoio e incentivo. Vocês fazem parte da minha história.

Resumo

O monitoramento e diagnóstico de falhas incipientes em transformadores de potência imersos em óleo isolante relaciona-se à avaliação das condições do sistema de isolamento. Esse sistema necessita de um programa de manutenção periódico que visa detectar possíveis falhas, tais como: deterioração da celulose do isolamento dos enrolamentos, curto circuito entre espiras e gases dissolvidos no óleo devido à sua degeneração, entre outros. Esses programas de manutenção preventiva evitam que essas falhas provoquem a retirada do equipamento em operação, o que acarretaria em grandes perdas, principalmente em casos não planejados. Uma maneira utilizada para se diagnosticar transformadores em funcionamento é o método de análise cromatográfica do líquido isolante, por exemplo o Método de Rogers. Utiliza-se esse tipo de análise devido ao contato direto do óleo isolante com a parte ativa do equipamento e, de acordo com a quantidade de gases imersas nesse óleo, é possível diagnosticar falhas específicas no equipamento. Existem alguns métodos que visam padronizar o diagnóstico, tais como os métodos de: Duval, Dornenburg e de Rogers. Para evitar avaliações equívocos na hora de diagnosticar e interpretar laudos cromatográficos, técnicas de inteligência artificial (IA) que fazem o uso de redes neurais artificiais podem auxiliar na definição e classificação do resultado final. Assim a rede apresenta importância para a confiabilidade do sistema elétrico de potência, pois se apresenta como uma ferramenta para auxiliar técnicas preditivas de manutenção em transformadores imersos em óleos isolantes, garantido a vida útil do dispositivo. Diante do exposto, este trabalho investigou o uso das redes neurais artificiais (RNA) no diagnóstico de falhas de transformadores imersos em óleo isolante. A RNA foi treinada e validada, a partir de dados de combinações de concentrações gasosas do óleo isolante disponíveis de uma empresa do ramo siderúrgico. Para implementação da RNA foram utilizadas duas abordagens: a primeira implementando a rede via código em ambiente Matlab e a segunda usando o *Toolbox* para RNAs do próprio Matlab. Ambas as redes utilizadas conseguiram um nível de acerto acima de 80 por cento e conseguiram diferenciar quanto ao tipo de falha (elétrica ou química) e se o transformador se encontra ou não em falha.

Palavras-chave: Transformador, diagnóstico, óleo isolante, rede neural.

Abstract

Monitoring and diagnosis of incipient faults in insulating oil immersed power transformers is related to the assessment of the insulation system conditions. This system needs a periodic maintenance program to detect possible failures such as: cellulose deterioration of winding insulation, short circuit between turns and gases dissolved in the oil due to its degeneration, among others. These preventive maintenance programs prevent these failures from causing the equipment to be taken out of operation, which would result in large losses, especially in unplanned cases. One way used to diagnose transformers in operation is the chromatographic analysis method of the insulating liquid, for example the Rogers Method. This type of analysis is used due to the direct contact of the insulating oil with the active part of the equipment and, according to the amount of gases immersed in this oil, it is possible to diagnose specific equipment failures. There are some methods that aim to standardize the diagnosis, such as: Duval, Dornenburg and Rogers. To avoid misleading assessments when diagnosing and interpreting chromatographic reports, artificial intelligence (AI) techniques that use artificial neural networks can assist in defining and classifying the final result. Thus the network is important for the reliability of the power system, as it is a tool to assist predictive maintenance techniques in transformers immersed in insulating oils, ensuring the useful life of the device. Given the above, this work investigated the use of artificial neural networks (RNA) in the diagnosis of transformer failures immersed in insulating oil. RNA was trained and validated from data on gaseous concentrations of insulating oil available from a steel company. For the implementation of the RNA two approaches were used: the first one implementing the network via code in Matlab environment and the second one using the Toolbox for Matlab's own RNAs. Both networks used achieved a level of accuracy above 80 percent and were able to differentiate as to the type of failure (electrical or chemical) and whether or not the transformer is in failure.

Keywords: Transformer, diagnosis, oil insulation, neural network.

Lista de ilustrações

Figura 1 – Parte interna do transformador com deslocamento do óleo para refrigeração.	12
Figura 2 – Vazamento no comutador expondo o equipamento à umidade.	14
Figura 3 – Principais tipos de materiais celulósicos.	15
Figura 4 – Arco elétrico na parte ativa imersa em óleo isolante.	17
Figura 5 – Descarga parcial de baixa energia na parte ativa do transformador. . .	18
Figura 6 – Aquecimento na parte externa do transformador devido à ineficácia do óleo isolante.	18
Figura 7 – Tonalidades de óleos isolantes coletados em transformadores.	19
Figura 8 – Desenho esquemático do sistema de um cromatografo a gás.	20
Figura 9 – Neurônio e seus componentes.	25
Figura 10 – Esquemático geral de uma rede neural.	26
Figura 11 – Tipos de função de ativação.	27
Figura 12 – Arquitetura de rede.	29
Figura 13 – Arquitetura de rede.	29
Figura 14 – Primeira situação de programação.	32
Figura 15 – Segunda situação de programação.	33
Figura 16 – Desempenho da RNA programada com diferentes neurônios.	35
Figura 17 – Erro médio quadrático Vs Épocas.	36
Figura 18 – Resultado da validação da RNA para uma saída.	37
Figura 19 – Treinamento e validação simulado via <i>Toolbox</i> uma saída.	38
Figura 20 – Desempenho da RNA programada com diferentes neurônios.	39
Figura 21 – Erro médio quadrático Vs Épocas.	39
Figura 22 – Resultado da validação da RNA para quatro saídas.	40
Figura 23 – Treinamento e validação simulado via <i>Toolbox</i> quadro saída.	41
Figura 24 – Exemplo de laudo usado para construção da rede.	45
Figura 25 – Trafos usados para construção da RNA.	51
Figura 26 – Esquema elétrico dos transformadores imerso ao óleo isolante.	52

Lista de Siglas

RNA	Redes Neurais Artificiais
NBR	Norma Brasileira Regulamentada
IEC	<i>International Electrotechnical Commission</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
IA	Inteligência Artificial
ANEIS	<i>Adaptive Neuro-Fuzzy Inference Systems</i>
CG	Cromatografia Gasosa
MLP	Perceptron Multicamadas
FM	Fase Móvel
FE	Fase Estacionária
CGL	Cromatografia Gás-Líquido
ASTM	<i>American Society for Testing and Materials</i>
TGC	Total de Gases Combustíveis
AGD	Análise de Gases Dissolvidos em Óleo
TDCG	Total de Gases Combustíveis Dissolvidos
H₂	Hidrogênio
O₂	Oxigênio
N₂	Nitrogênio
CH₄	Metano
CO	Monóxido de Carbono
CO₂	Dióxido de Carbono
C₂H₆	Etano
C₂H₄	Etileno
C₂H₂	Acetileno

Sumário

1	INTRODUÇÃO	9
1.1	Motivação	9
1.2	Revisão Bibliográfica	9
1.3	Objetivo	10
1.3.1	Objetivo geral	10
1.3.2	Objetivos específicos	10
2	TRANSFORMADORES SUBMERSOS EM ÓLEO ISOLANTE	12
2.1	Função do óleo isolante	12
2.1.1	Tipos de óleo isolante	13
2.1.2	Fase de decomposição do óleo isolante	13
2.2	Isolamento sólido do transformador	15
2.3	Vida útil	16
2.4	Falhas comuns em transformadores	16
2.4.1	Arco elétrico	16
2.4.2	Descarga parciais	17
2.4.3	Aquecimento	18
2.4.4	Superaquecimento	19
2.4.5	Más condições de óleo isolante	19
2.5	Cromatografia em óleo isolante para transformador	20
2.5.1	Análise de gases dissolvidos em óleo (DGA)	21
2.5.2	Método das razões de Rogers	22
3	METODOLOGIA	25
3.1	Rede neural artificial	25
3.2	Características e tipos de RNAs	25
3.2.1	Aplicação da rede para diagnóstico da falha	31
3.2.2	Levantamento das análises cromatográficas	31
3.2.3	Definição da topologia da rede	31
3.2.4	Treinamento da rede neural artificial	33
4	RESULTADOS	35
4.1	Desempenho da RNA de uma saída:	35
4.1.1	Resultados RNA programada:	35
4.1.2	Resultado RNA usando <i>toolbox</i> :	37
4.2	Desempenho da RNA de quatro saídas:	38

4.2.1	Resultados RNA programada:	38
4.2.2	Resultado usando <i>toolbox</i>	41
5	CONCLUSÃO	42
	REFERÊNCIAS	43
	ANEXO A – LAUDO PARA CONSTRUÇÃO DA REDE	45
	ANEXO B – ANEXO	46
	ANEXO C – ANEXO	51
	ANEXO D – ANEXO	52

1 Introdução

O transformador de potência é um dos equipamentos de maior importância estratégica e de investimento, sendo o ativo mais caro dentro de uma subestação. Por esse motivo, o prazo de aquisição de um transformador não é imediato. Nesse sentido, o interesse pelos índices de desempenho e confiabilidade de transformadores vêm crescendo nos últimos anos (BENGTSSON, 1996).

1.1 Motivação

Uma falha que venha a retirar um transformador de operação pode causar transtornos de ordem política, econômica, financeira dentre outras, visto que a estabilidade e a confiabilidade do sistema é afetada, podendo surgir consequências tanto para a empresa quanto para o responsável pelo equipamento, como por exemplo, o pagamento de multas.

Nesse cenário, torna-se fundamental o monitoramento constante de transformadores abaixadores/elevadores em usinas e subestações. O cuidado e a manutenção preventiva são essenciais para uma correta funcionalidade, buscando evitar ocorrências de superaquecimentos, arcos ou descargas parciais, deterioração acentuada da isolação, formação excessiva de gases, etc. Esses problemas são oriundos de esforços térmicos, mecânicos, elétricos e de reações físico-químicas que ocorrem internamente no transformador. Existem, também, outras avarias possíveis em transformadores de potência imersos em óleo isolante, de origem externa, tais como: presença de animais, árvores, comutadores (tap's) e falhas externas causadas ou não pelo modo de operação. Além disso, uma falha de grande porte, normalmente envolvendo a parte ativa do transformador, pode acarretar explosões e incêndios, colocando em risco vidas humanas e, provocando avarias em outros equipamentos adjacentes, além de graves prejuízos ao meio ambiente (no caso de ocorrer vazamento de óleo mineral isolante). A expectativa de vida de um transformador é de aproximadamente 40 anos desde a data de fabricação, o que demanda um acompanhamento regular (BENGTSSON, 1996).

1.2 Revisão Bibliográfica

Diversos trabalhos envolvendo o estudo de transformadores já foram relatados na literatura. No trabalho de Ahmed et al. (2015), foi utilizada uma técnica de detecção de falha em um motor e sua classificação usando dados de vibração. Utilizou-se um conjunto com redes neurais artificiais (RNAs), aplicados para detectar falhas em motores a gasolina (quatro tempos) construídos para experimentação.

O trabalho de Arruda (2011), relatou o reconhecimento de padrões e classificação de imagens termográficas utilizando redes neurais, convertendo as imagens geradas em laboratório em dados para treinamento e classificação de padrões. Algumas características observadas no transformador em operação como o sobreaquecimento e algum tipo de centelhamento interno podem ser diagnosticadas via câmera termográfica, ou em uma rotina preditiva de inspeção sensível. Sendo assim, existem oportunidade em detectar falhas e observar as características físicas e químicas do óleo isolante.

Alguns trabalhos sobre redes neurais artificiais aplicadas a detecção de padrões em transformadores já foram realizados.

O trabalho de Silva I. N. Spatti (2010), relata o mapeamento de óleo mineral em processos de contaminação física, utilizando RNA onde os autores relataram a perda das características isolantes do óleo utilizado.

Outros trabalhos utilizaram RNAs em combinação com outras técnicas de IA. Neste contexto, citam-se, por exemplo, os sistemas Neuro-Fuzzy que agregam características para sistemas inteligentes, (MENDONÇA, 2011).

O trabalho de Tomsovic (1993), utilizou um sistema ANFIS (*Adaptive Neuro-Fuzzy Inference Systems*) para diagnóstico de falhas de transformadores. Foram identificadas e diagnosticadas oito falhas, de acordo com a norma IEC-60599 (*International Electrotechnical Commission*), guia utilizado para interpretar e analisar gases dissolvidos em óleo mineral isolante.

1.3 Objetivo

1.3.1 Objetivo geral

Este trabalho tem como objetivo definir e utilizar uma rede neural artificial para identificar via análise cromatográfica (Método de Rogers) o correto diagnóstico de falha descrito pelas normas, bem como o uso da mesma rede neural para extrapolar os diagnósticos mais prováveis das amostras cromatográficas que não apresentam diagnósticos definidos ou tabelados, tendo como referência a rotina do dia a dia em diagnósticos esperados pelo especialista da engenharia de manutenção dessa área.

1.3.2 Objetivos específicos

- Estudar os principais tipos de falhas existentes em transformadores em operação.
- Estudar os métodos de monitoramento e diagnóstico de transformadores existentes na literatura.
- Treinar uma Rede Neural Artificial - (RNA) com 4 entradas e 1 saída como classificador de falha, usando dados reais de análises cromatográficas.

- Treinar uma Rede Neural Artificial - (RNA) com 4 entradas e 4 saídas como classificadores de tipos de falhas mais comuns de se encontrar em transformadores, usando dados reais de análises cromatográficas.

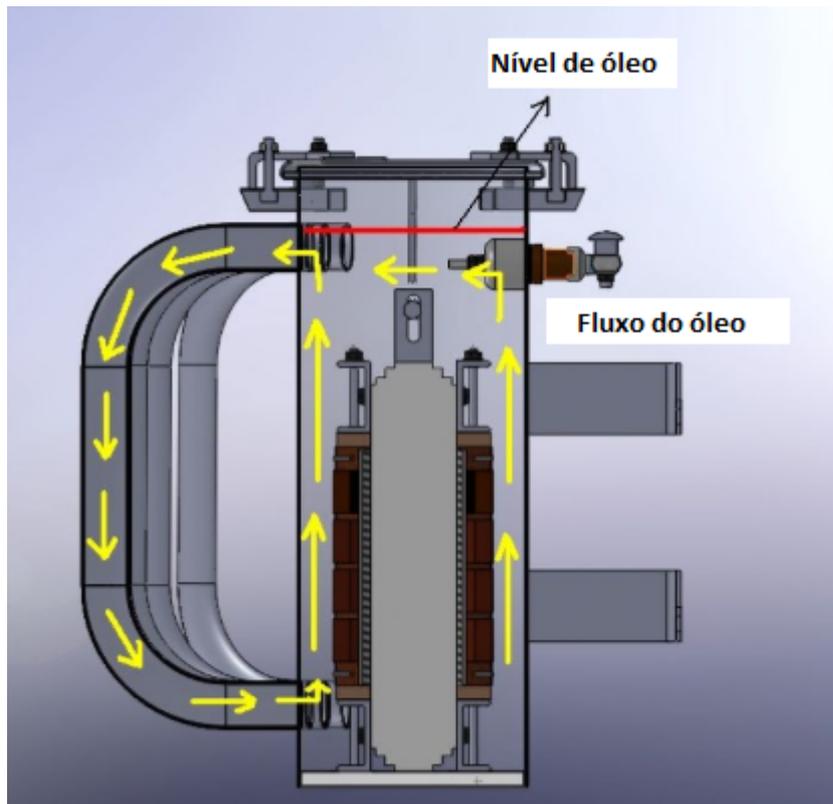
2 Transformadores submersos em óleo isolante

Este capítulo apresenta uma revisão dos mecanismos da decomposição do óleo e da isolação, além dos métodos tradicionais de detecção de gases dissolvidos no óleo.

2.1 Função do óleo isolante

Na Figura 1, é possível observar a função de um óleo isolante em transformadores que é garantir o isolamento elétrico entre suas partes energizadas, permitindo refrigeração interna destas partes através da transferência de calor com o meio externo, substituindo ainda o possível ar existente entre aquelas partes proporcionando alta rigidez dielétrica e baixa condutividade entre si.

Figura 1 – Parte interna do transformador com deslocamento do óleo para refrigeração.



Fonte: Retirado de (DATALINK, 2019).

2.1.1 Tipos de óleo isolante

Os óleos minerais isolantes são utilizados em transformadores, reatores, disjuntores e religadores de alta potência. Os óleos de origem naftênica e parafínica são os tipos mais encontrados nas jazidas do Brasil. Esses óleos possuem baixo ponto de fluidez que, por sua vez, dificultam a sua utilização, mas tem ótimas características isolantes para transformadores, desde que o dispositivo elétrico opere em condições normais. Investimentos em pesquisa tem sido feitos para esses tipos de óleos, levando à obtenção de materiais mais adequados para a utilização em aparelhos e equipamentos elétricos. Esses dois tipos de óleos apresentam características distintas, porém apresentam a mesma aplicação como isolantes de partes internas e construtivas de um transformador (MYERS, 2004).

O estudo feito por Zhenyuan (2000), diz respeito aos óleos minerais parafínicos que são frequentemente encontrados nos transformadores de grandes dimensões em sistema elétrico de potência.

2.1.2 Fase de decomposição do óleo isolante

Segundo Myers (2004), o óleo isolante e demais materiais de isolamento elétrico utilizados em transformadores podem se decompor sob condições normais de operação, devido a estresses térmico e elétrico. Três fases indicam o estado de decomposição e degradação do óleo.

- Fase inicial: caracterizada pela formação de peróxidos quimicamente instáveis. Os peróxidos são compostos com ação oxidante e ligações do tipo O-O. Esses compostos podem se decompor e formar espécies radiculares, que por sua vez, podem formar compostos oxi-celulósicos devido à interação do radical formado com o papel isolante.

- Fase intermediária: caracterizada pela formação de gases dissolvidos no óleo, como por exemplo, Hidrogênio (H_2), Nitrogênio (N_2) e Etano (C_2H_6).

- Fase final: quando ocorre a formação de uma substância resinosa que se acumula no fundo do tanque do transformador. Essa resina é resultado do processo de polimerização de compostos presentes no óleo. Consequentemente, observa-se o aumento da concentração (ppm) das outras fases citadas em composição dos gases mencionados. A fase final de decomposição pode ser crítica para um transformador em operação.

O foco desse estudo concentra-se no estado intermediário, quando ainda é possível tomar providências, sem envolver maiores custos e sem risco de retirada do equipamento do sistema.

A degradação do transformador ocorre principalmente devido a arcos e descargas elétricas na parte ativa, podendo provocar a formação de partículas de carvão e também de ácidos, provocando a liberação de gases no óleo isolante.

Com o passar do tempo, a cor do óleo muda e escurece devido a degradação. Com o envelhecimento do óleo pode-se observar um maior aparecimento de dióxido de carbono

(CO₂), devido à deterioração de papéis celulósicos (isolação).

Os piores inimigos da isolação térmica em transformadores, capazes de deteriorar o isolamento, são a água e calor. Podem servir como catalisadores, juntamente com os metais presentes no transformador, tais como o ferro e cobre, diminuindo o poder dielétrico do óleo mais rapidamente. Logo é possível dizer, que, como consequência, podem ocorrer os processos a seguir (MYERS, 2004):

- Pirose: calor no papel/óleo. Esse calor faz com que moléculas de hidrogênio e oxigênio se encontrem dissolvidas junto ao óleo isolante;
- Oxidação: ocorre devido a presença de oxigênio dissolvido no óleo;
- Acidez: quando o óleo se oxida, o mesmo se torna mais ácido e perde força dielétrica, processo onde ocorre uma diminuição da força e o óleo perde sua característica isolante. Esse processo pode levar à condução entre bobinas, através do rompimento da rigidez dielétrica.
- Umidade: na Figura 2, observa-se, devido ao incorreto processo de secagem ou por vazamento no tanque.

Figura 2 – Vazamento no comutador expondo o equipamento à umidade.



Fonte: Elaborada pelo autor.

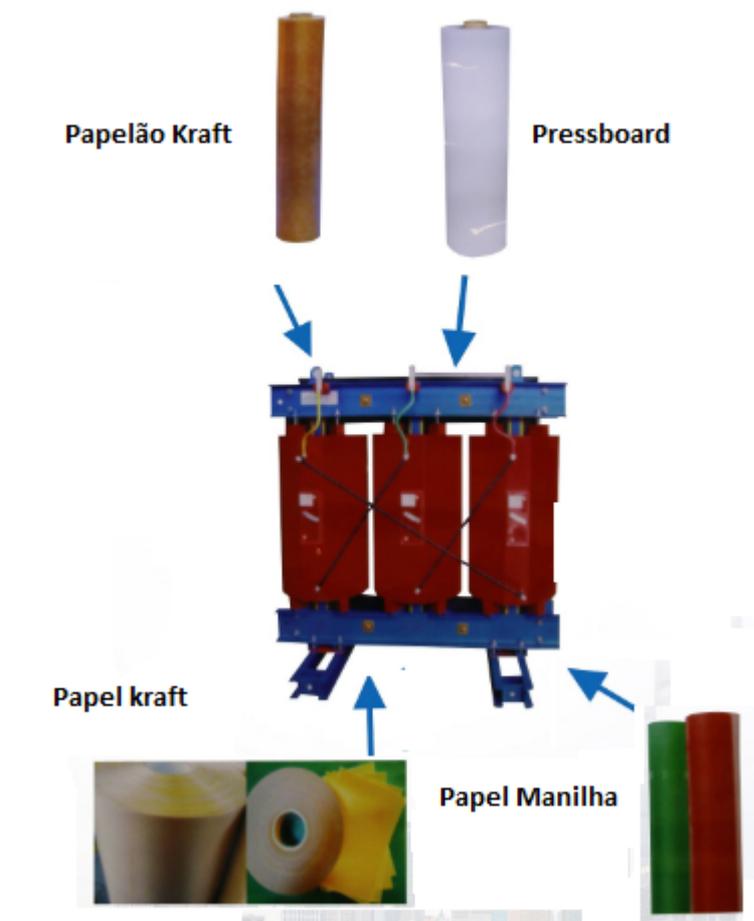
Em caso de mistura de dois tipos de óleo, por exemplo óleo novo e óleo velho, a mistura apresentará características médias dos valores de seus componentes. Essas características podem ser observadas em um laudo cromatográfico do transformador. Entretanto, não é aconselhado misturar o óleo degradado com óleo novo.

2.2 Isolamento sólido do transformador

A maior parte do isolamento de transformadores é constituída de papel e, portanto, de natureza celulósica. Esses materiais possuem elevada resistência de isolamento quando secos (0,5 a 1 por cento de umidade) e são altamente higroscópicos e absorvem umidade e óleo (ARRUDA, 2011).

Na Figura 3, observa-se os principais tipos de materiais celulósicos usados para isolamento de transformadores são:

Figura 3 – Principais tipos de materiais celulósicos.



Fonte: Retirado de Transpaper (2013).

- Papel *Kraft* – Constituído por fibras de madeiras.
- Papel Manilha – Constituído por fibras de madeira e cânhamo.
- *Pressboard* – Constituído por papelão com fibras de algodão.

O uso específico para cada tipo de papel vai de acordo com as características construtivas, projeto e operação do transformador.

O papel *kraft*, muito utilizado na maioria dos transformadores, é muito poroso, estimando-se que contenha de 80 a 90 por cento de ar. Ele absorve cerca de 10 por cento

do volume do óleo contido no tanque do transformador. O papel isolante utilizado em transformadores é, depois de seco, impregnado de verniz ou resina isolante e posteriormente por óleo isolante (ARRUDA, 2011).

Sua impregnação com verniz ou resina não impede, mas retarda a penetração de água. A impregnação do papel com verniz que contém um solvente volátil pode dar origem à formação de cavidades na massa isolante, favorecendo a formação de descargas parciais, que podem ser avaliadas pela medição do fator de potência do isolamento.

2.3 Vida útil

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

Não há uma quantidade ou faixa de gases estabelecidas ou pré-determinadas que se encontram em contato com o óleo, depende de como o transformador está operando, o local de instalação, a qualidade e a quantidade de óleo que se encontra na parte ativa e em seu reservatório.

Assim, a vida útil de um transformador dependerá das condições de sua operação e manutenção. Essa vida, estimada entre 25 e 30 anos, poderá ser prolongada em até 50 anos com um programa de acompanhamento preditivo em operação e manutenção adequados (ARRUDA, 2011).

2.4 Falhas comuns em transformadores

2.4.1 Arco elétrico

O arco elétrico, como é possível ver na Figura 4, ocorre quando há uma ruptura dielétrica na qual é produzida uma descarga elétrica. Esse fenômeno é tão forte que consegue romper a isolação feita pelo ar ou óleo no caso do transformador, conduzindo elétrons de um ponto ao outro através de um fluxo de corrente (FREITAS, 2000). O arco elétrico ocorre frequentemente devido à perda ou mau contato de conexões dentro dos transformadores, que são evidenciadas pela: carbonização e destruição do papel, fusão de metal nas extremidades da descarga e extensa carbonização do óleo.

Os gases chave referente ao arco elétrico são Hidrogênio, Metano, Etano, Etileno, Acetileno (traços), Monóxido de Carbono e Dióxido de Carbono.

Figura 4 – Arco elétrico na parte ativa imersa em óleo isolante.



Fonte: Retirado de Freitas (2000).

2.4.2 Descarga parciais

A descarga parcial mostrado na Figura 5, é resultado do contato de um campo elétrico intenso e elevado com partículas de ar, umidade ou poeira. O resultado é a emissão de luz sempre que as partículas são ionizadas. A descarga parcial pode ter polaridade (fluxo) positivo ou negativo, dependendo da polaridade e sentido do potencial elétrico (FREITAS, 2000). A descarga parcial que ocorre dentro dos transformadores são evidenciadas por: descargas elétricas no enrolamento, descarga que cruza parcialmente o óleo isolante entre condutores dentro ou junto a um condutor, descargas em bolhas de gás ou em espaços presos ao papel, como resultado de uma secagem insuficiente ou de uma fraca impregnação de óleo e centelhas que podem produzir pequenos furos ou perfurações carbonizadas no papel (difíceis de identificar).

Os gases chave referente ao Corona são Hidrogênio, Metano, traços de Etano e Etileno (GABRIEL, 2008).

Figura 5 – Descarga parcial de baixa energia na parte ativa do transformador.

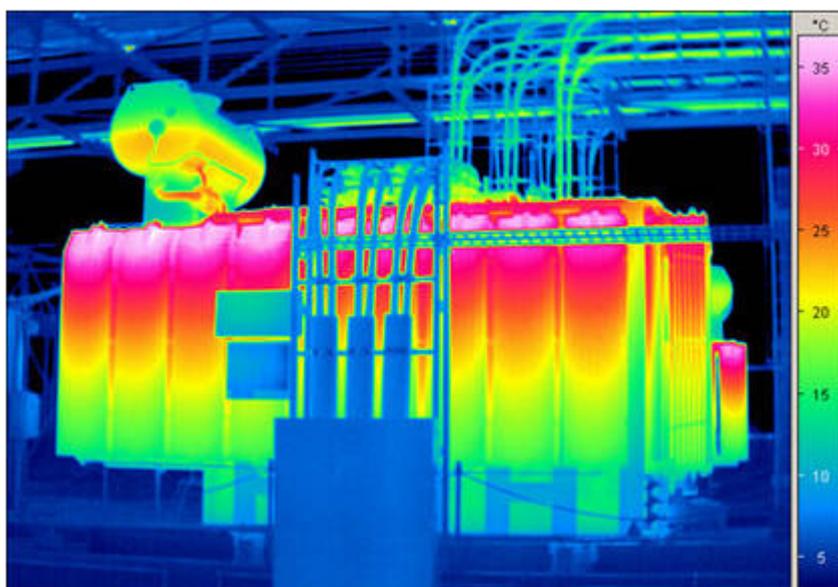


Fonte: Retirado de Gabriel (2008).

2.4.3 Aquecimento

O resultado da circulação de fluxos excessivos de correntes nos enrolamentos do transformador é o aumento adicional de temperatura como visto na Figura 6.

Figura 6 – Aquecimento na parte externa do transformador devido à ineficácia do óleo isolante.



Fonte: Retirado de Freitas (2000).

Essa alta elevação da temperatura pode causar a deterioração do material isolante, afetando a vida útil do equipamento. Em casos extremos, pode provocar a avaria definitiva

do transformador (FREITAS, 2000). O efeito do aquecimento exagerado que ocorre dentro dos transformadores, pode ser evidenciado por: aquecimento exagerado do óleo isolante e de outras partes do equipamento, no óleo ou no papel, evidenciado por grandes formações de papel carbonizado e formação de carbono no óleo e coloração do metal 800 graus celsius ou fusão do metal 1000 graus celsius.

Os gases chave referente ao aquecimento exagerado são Hidrogênio, Metano, Etano, Etileno, Acetileno, Monóxido de Carbono e Dióxido de Carbono.

2.4.4 Superaquecimento

O aquecimento do transformador está relacionado às perdas no cobre, pois as perdas no ferro dependem diretamente dos níveis de tensão aplicadas aos terminais do transformador, os quais são normalmente considerados constantes quando em operação (FREITAS, 2000). O efeito de superaquecimento que ocorre dentro dos transformadores, são evidenciadas por: sobrecarga do transformador, no papel, evidenciado pela cor de tom marrom e dutos de óleo bloqueados.

Os gases chave referentes ao superaquecimento são Hidrogênio, Metano, Etano, Etileno, Acetileno (traços), Monóxido de Carbono e Dióxido de Carbono.

2.4.5 Más condições de óleo isolante

O óleo em más condições que necessita de reciclagem ou regeneração, como visto na Figura 7, da esquerda para a direita é possível observar as perdas de suas características isolantes.

Figura 7 – Tonalidades de óleos isolantes coletados em transformadores.



Fonte: Retirado de Freitas (2000).

O óleo perde a sua coloração e tonalidade original e é possível encontrar resinas e borras na sua parte inferior. Assim, é necessária a abertura do transformador para realizar a coleta preditivamente, a fim de acompanhar a eficiência do nível de isolamento do óleo.

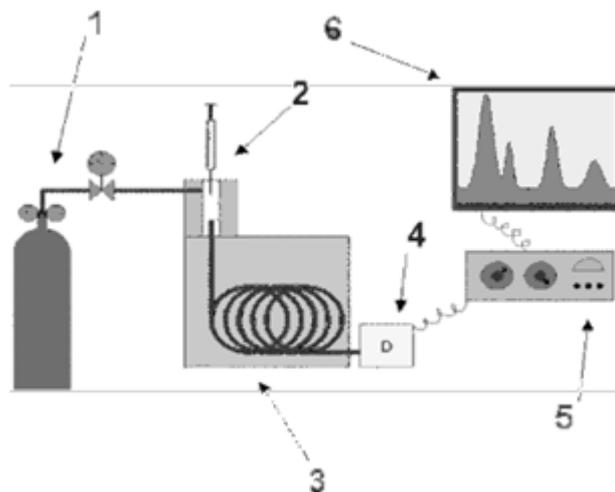
Sob condições normais de operação, os transformadores de potência isolados a óleo geram gases muito lentamente, como resultado da idade e das condições de carregamento (CARVALHO, 2000). Durante uma operação anormal, a produção de gases aumenta na relação direta da severidade do estresse elétrico ou térmico. Essa formação de gases é causada pela deterioração do óleo e da celulose isolante.

Decorrente dessa situação, é necessário que haja a coleta preventiva e preditiva para que seja acompanhada a concentração e evolução dos gases presentes no óleo. A partir do laudo emitido por um laboratório especializado, é possível diagnosticar uma condição de anormalidade na característica do óleo isolante para o transformador.

2.5 Cromatografia em óleo isolante para transformador

A Cromatografia Gasosa (CG) é uma técnica para separação e análise de misturas de substâncias voláteis. Na figura 8, é apresentado um esquema de funcionamento de uma CG. A amostra (2) é vaporizada e introduzida em um fluxo de um gás adequado denominado fase móvel (FM) ou gás de arraste (1) (CARVALHO, 2000).

Figura 8 – Desenho esquemático do sistema de um cromatografo a gás.



Fonte: Retirado de Arruda (2011).

Esse fluxo de gás com a amostra vaporizada passa por uma coluna capilar (3) que contém a fase estacionária (FE), onde ocorre a separação da mistura. A FE pode ser um sólido adsorvente (Cromatografia Gás-Sólido) ou, mais comumente, um filme de um líquido pouco volátil (4), suportado sobre um sólido inerte (Cromatografia Gás-Líquido

com Coluna Empacotada ou Recheada) ou sobre a própria parede do tubo (Cromatografia Gasosa de Alta Resolução).

De acordo com Carvalho (2000), na cromatografia gás-líquido (CGL), os dois fatores que governam a separação dos constituintes de uma amostra são:

- A solubilidade na FE: quanto maior a solubilidade de um constituinte na FE mais lentamente ele caminha pela coluna.
- A volatilidade: quanto mais volátil a substância (ou, em outros termos, quanto maior a pressão de vapor), maior a sua tendência de permanecer vaporizada e mais rapidamente caminha pelo sistema.

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

Durante a vida útil do transformador, amostras de óleo são colhidas com o equipamento em operação e enviadas a um laboratório que irá testar as condições desse óleo, cujo resultado facilitará a tomada de decisão quanto ao que fazer com o óleo ou com o equipamento.

O resultado da análise do óleo isolante é um diagnóstico do grau de envelhecimento e desgaste dos transformadores e determina a sua vida útil, o que torna importante conhecer os mecanismos da sua deterioração e os meios para a sua detecção. O método padrão e internacional de melhor reconhecimento baseado em transformadores imersos ao óleo isolante é o ASTM (*American Society for Testing and Materials*) que é capaz de extrair e medir os gases dissolvidos no óleo usando a cromatografia gasosa. Empresas que usam esse método precisam ser certificadas para prestar certo tipo de serviço (CARVALHO, 2000).

O método ASTM D3612-01, especifica a análise dos gases hidrogênio, oxigênio, nitrogênio, monóxido de carbono, dióxido de carbono, metano, etano, etileno, acetileno, propano e propileno que são os gases emitidos em um laudo cromatográfico. Essa análise possibilita caracterizar a decomposição do óleo isolante mineral em função desses elementos químicos, que devem ser obtidos para identificação e quantificação.

2.5.1 Análise de gases dissolvidos em óleo (DGA)

Um laboratório adequadamente equipado é preferido para a requerida separação, identificação e para a determinação quantitativa desses gases (ppm).

Neste método, uma amostra do óleo é retirada de uma unidade e os gases dissolvidos são extraídos do óleo. Então, os gases extraídos são separados, identificados, e quantitativamente determinados.

Atualmente essa técnica é melhor realizada em um laboratório, já que requer operações de precisão. Como esse método utiliza uma amostra de óleo, ele é aplicável a todos os tipos de unidades e, assim como o método do manto de gás, ele detecta todos os componentes individuais.

A principal vantagem da técnica DGA é que ele detecta os gases na fase de óleo, possibilitando a detecção antecipada de uma falta incipiente (ROGERS, 1978).

A técnica DGA envolve vários métodos, tais como o método das razões de Rogers e o método dos Gases-Chave (ROGERS, 1975).

2.5.2 Método das razões de Rogers

Em 1973, R. Rogers, com base no modelo termodinâmico de Halstead, desenvolveu um novo método para diagnosticar falhas em transformadores. Tal método foi aperfeiçoado nos anos de 1975 e 1977, resultando em um critério de identificação de falhas com base em correlações de razões de concentrações de gases com os tipos de falhas associados. O critério de Rogers teve grande aceitação industrial, sendo atualmente um dos mais difundidos e confiáveis métodos de DGA para identificação de falhas incipientes em transformadores.

O aspecto mais importante da análise de gases de falha é tomar os dados dos gases gerados e diagnosticar corretamente a falha que está gerando os gases que foram detectados, (ROGERS, 1975).

O método utiliza cinco gases para obtenção das correlações, dentre eles: hidrogênio (H_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4) e acetileno (C_2H_2). Tais gases são identificados pela análise cromatográfica do óleo isolante estudado.

As concentrações de gases são obtidas através da definição de quatro razões: R1, R2, R3 e R4, conforme mostrado na Tabela 1. Essas razões serão utilizadas para a codificação das falhas.

Tabela 1 – Definição pelo método de Rogers.

Razões de Gases			
R1	R2	R3	R4
$(CH_4)/(H_2)$	$(C_2H_6)/(CH_4)$	$(C_2H_4)/(C_2H_6)$	$(C_2H_2)/(C_2H_4)$

Fonte: Retirado de Freitas (2000).

Apesar das razões representarem um número adimensional, as concentrações dos gases devem ser expressas na mesma unidade.

Após determinados valores para as quatro razões, utilizam-se os dados expressos na Tabela 2 para o processo de codificação das razões. Esse processo consiste em identificar em qual intervalo cada uma das razões se adequam. À cada intervalo associa-se, diretamente um código.

Tabela 2 – Definição de código do método das razões de Rogers.

Intervalo das Razões	Código
$0 < R1 \leq 0.1$	1
$0.1 < R1 < 1$	2
$R1 = 0$	2
$1 \leq R1 < 3$	3
$R1 \geq 3$	4
$R2 < 1$	0
$R2 \geq 1$	1
$R3 < 1$	0
$1 \leq R3 < 3$	1
$R3 \geq 3$	2
$R4 < 0.5$	0
$0.5 \leq R4 < 3$	1
$R4 \geq 3$	2

Fonte: Retirado de Freitas (2000).

É importante ressaltar que, para cada razão, deve-se associar somente um único código.

Dessa forma, após relacionar os códigos com os dados expressos Tabela 2, obtém-se uma sequência de quatro códigos. Essa sequência será comparada com as possíveis sequências de códigos expresso na Tabela 3.

Na Tabela 3 são apresentados os dados que possibilitam a interpretação das sequência de código e as relaciona com o diagnóstico de falhas. É importante observar que a sequência deve ser lida da esquerda para a direita, respeitando a sequência de códigos na ordem crescente, ou seja, R1-R2-R3-R4.

Observa-se que, a Tabela 3, através da sequência de código obtida para as razões dos gases, apresenta uma descrição da possível falha que está ocorrendo num transformador.

Tabela 3 – Diagnóstico do método das razões de Rogers.

Interpretação da sequência de código				
R1	R2	R3	R4	Diagnóstico de Falha
2	0	0	0	Deterioração normal.
1	0	0	0	Descarga parcial (Efeito Corona).
3	0	0	0	Leve sobreaquecimento - abaixo de 150 Graus.
4	0	0	0	Leve sobreaquecimento - abaixo de 150 Graus.
3	1	0	0	Sobreaquecimento - 150 à 200 Graus.
4	1	0	0	Sobreaquecimento - 150 à 200 Graus.
2	1	0	0	Sobreaquecimento - 150 à 300 Graus.
2	0	1	0	Sobreaquecimento geral em condutores.
3	0	1	0	Corrente de circulação nas bobinas.
3	0	2	0	Corrente de circulação entre bobinas e tanque com sobreaquecimento de junções.
2	0	0	1	Descarga sem fluxo de energia.
2	0	1	1	Arco com fluxo de energia.
2	0	1	2	Arco com fluxo de energia.
2	0	2	1	Arco com fluxo de energia.
2	0	2	2	Arco com fluxo de energia.
2	0	2	2	Centelhamento contínuo para potencial flutuante.
1	0	0	1	Descarga parcial com sinal.
1	0	0	2	Descarga parcial com sinal.

Fonte: Retirado de Freitas (2000).

Observa-se também, na tabela que podem existir sequências que não estão diagnosticadas. Nesse caso o diagnóstico torna-se não conclusivo, existindo então uma indeterminação no diagnóstico de falha do transformador (IEEE, 2009).

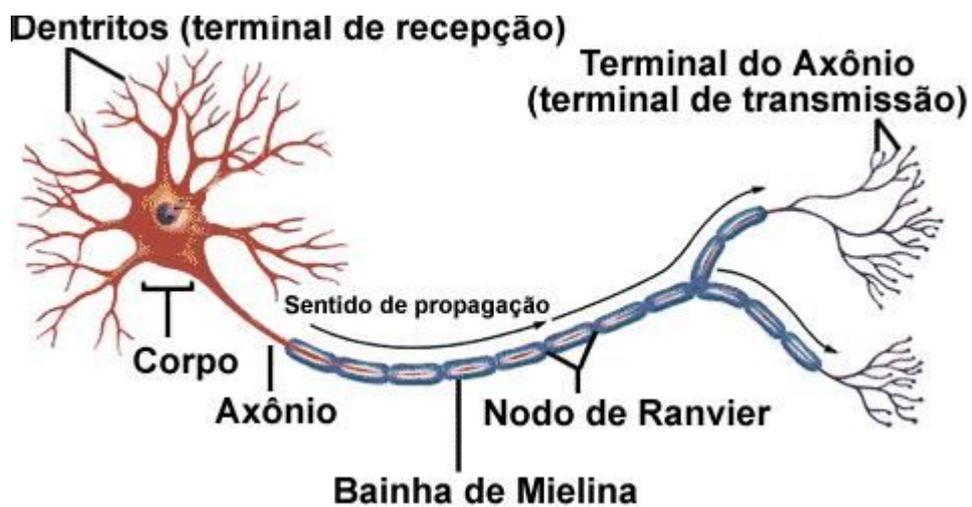
3 Metodologia

3.1 Rede neural artificial

As Redes Neurais Artificiais (RNAs) são modelos matemáticos inspirados no sistema nervoso, tornando-se diferentes da computação convencional, onde a função é determinada pelas conexões entre seus elementos (CARVALHO, 2000).

O sistema nervoso é formado por um conjunto complexo de células, os neurônios. Os neurônios são formados pelos dendritos, que são um conjunto de terminais de entrada, pelo corpo central, e pelos axônios que são longos terminais de saída, como pode ser visto na Figura 9.

Figura 9 – Neurônio e seus componentes.

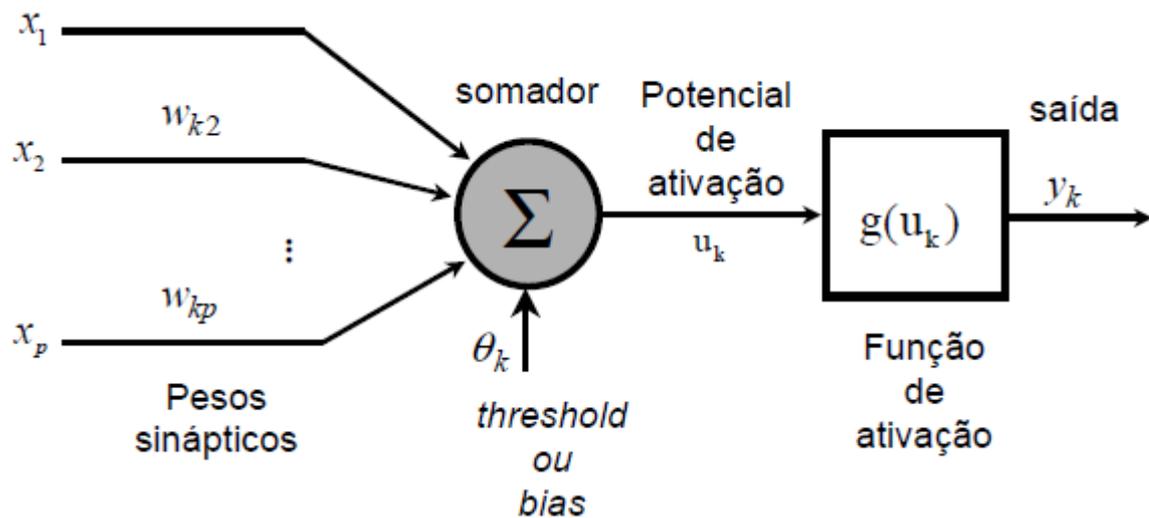


Fonte: Retirado de Geromel (2003).

3.2 Características e tipos de RNAs

O modelo de neurônio mais simples e que engloba as principais características de uma rede neural biológica, foi proposto por McCulloch e Pitts (LUX, 1999). A Figura 10, ilustra o modelo geral do neurônio artificial onde:

Figura 10 – Esquemático geral de uma rede neural.



Fonte: Retirado de Lux (1999).

X_1, X_2, \dots, X_p são os sinais de entrada.

$W_{k1}, W_{k2}, \dots, W_{kp}$ são os pesos ou conexões sinápticas.

θ_k é o limiar de ativação do neurônio; u_k é a saída do combinador linear.

$g(u_k)$ é a função de ativação (limita a saída do neurônio).

y_k é o sinal de saída do neurônio.

As equações que descrevem o comportamento do neurônio artificial são dadas por (LUX, 1999):

$$u = \sum_{i=1}^n W_i \cdot X_i \quad (3.1)$$

$$y = g(u) \quad (3.2)$$

Onde:

X_i representa a i -ésima entrada do neurônio.

W_i é o peso associado à entrada X_i .

n é o número de entradas.

$g(u)$ é a função de ativação do neurônio.

y é a saída.

A função de ativação (3.2) processa um conjunto de entradas recebidas e as transforma em estado de ativação, executando uma operação matemática no sinal de saída. 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 (ARANTES, 2005):

Função degrau: neste tipo de ativação, mostrada na Figura 11, 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.

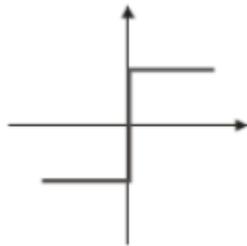
Função rampa: neste tipo de ativação, mostrada na Figura 11, a saída do neurônio pode assumir valores positivos e negativos no domínio de -1 a 1, e, no intervalo definido, a saída assume o valor da função $g(u)=u$.

Função tangente hiperbólica: neste tipo de ativação, mostrada na Figura 11, a saída do neurônio pode assumir valores reais negativos e positivos no domínio de -1 a 1.

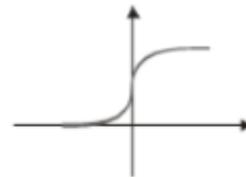
Função sigmóide: neste tipo de ativação, mostrada na Figura 11, o parâmetro que define a inclinação (ganho) conforme a figura, da função sigmóide. Nesse tipo de função, a saída do neurônio assumirá valores reais entre 0 e 1.

Figura 11 – Tipos de função de ativação.

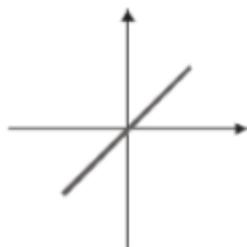
- Degrâu (ou limiar):



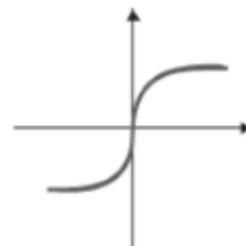
- Sigmoidal:



- Linear:



- Tangente hiperbólica:



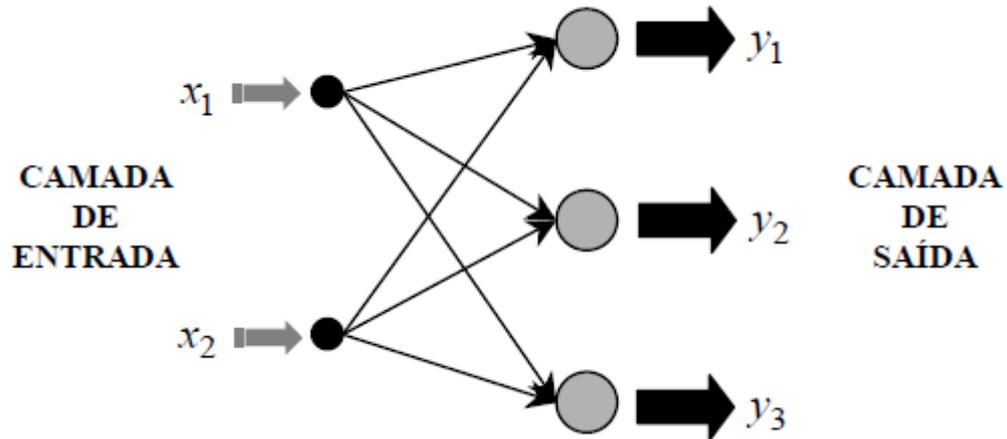
Fonte: Retirado Arantes (2005).

É comum que alguns modelos de redes neurais possuam regras de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Assim, elas aprendem através de exemplos. As arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior. A rede neural passa por um processo de treinamento a partir dos casos reais conhecidos, adquirindo, a partir daí, a sistemática necessária para executar adequadamente o processo desejado dos dados fornecidos. Sendo assim, a rede neural é capaz de extrair suas próprias regras básicas partindo de dados reais, diferindo do convencional, onde é necessário um conjunto de regras rígidas pré-fixadas e algoritmos (ARANTES, 2005).

Redes neurais são classificadas de acordo com a arquitetura em que foram implementadas, topologia, características de seus nós, regras de treinamento, e tipos de modelos de neurônios empregados na criação. Pode ser constituída de uma única camada ou múltiplas camadas. Algumas diferenças surgem quando se trata da maneira com que são feitas as conexões existentes entre os neurônios. Essas ligações podem ser no sentido de ida e, no sentido de ida e volta. Com relação à arquitetura das RNA's, tem-se (ARANTES, 2005):

- Redes *Feedforward* (camada única): são redes neurais onde se tem uma camada de entrada e uma única camada de neurônios que é a própria camada de saída, conforme é apresentado na Figura 12. Suas principais aplicações são em memórias associativas e no reconhecimento de padrões.

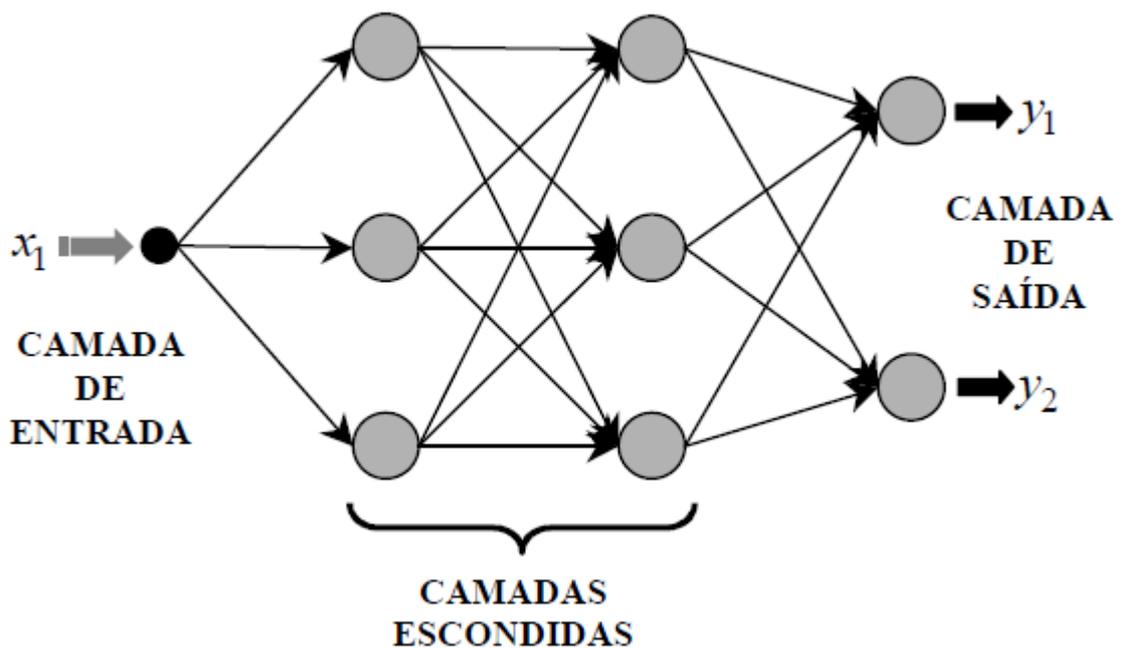
Figura 12 – Arquitetura de rede.



Fonte: Retirado de Arantes (2005).

- Redes *Feedforward* (multicamadas): este tipo de rede se distingue da anterior pela presença de uma ou mais camadas escondidas de neurônios, conforme apresentado na Figura 13. Assim, os neurônios que recebem sinais de excitação do meio externo estão na camada de entrada, os neurônios que estão na saída representam a camada de saída e os neurônios intermediários estão nas camadas escondidas. As principais aplicações são em reconhecimento de padrões, aproximador universal de funções e controle.

Figura 13 – Arquitetura de rede.



Fonte: Retirado de Arantes (2005).

Um dos objetivos desta pesquisa sobre redes neurais para diagnosticar falha em transformadores imersos em óleo isolante é desenvolver morfologias neurais, baseadas em modelos matemáticos, que podem ser utilizadas para classificar o transformador, indicando se o mesmo se encontra em falha ou qual tipo de falha, por exemplo: aquecimento, gases combustíveis, centelhamento, entre outros. Na maioria dos casos, modelos neurais são compostos de muitos elementos não lineares que são classificados de acordo com padrões ligados à biologia (ARANTES, 2005).

A rede deve ser treinada com base em casos reais conhecidos, como observado na prática e em operação, adquirindo, a partir daí, a sistemática necessária para executar adequadamente o processamento desejado dos dados cromatográficos fornecidos na entrada. Portanto, ela é capaz de extrair regras básicas (conjunto de pesos) em consequência dos dados reais, o que difere da computação convencional, onde são necessários conjuntos de regras rígidas pré-fixadas e algoritmos. A propriedade mais importante dessa rede neural é a habilidade de aprender com seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes (treinamento) aplicado a seus pesos. O processo de aprendizado se encerra quando a rede neural consegue generalizar soluções para uma classe de problemas, classificando e diagnosticando a falha dos transformadores.

O algoritmo de aprendizado é composto por um conjunto de regras bem definidas visando a solução de um problema de aprendizado. Há alguns algoritmos de aprendizado específicos para determinados modelos de redes neurais. Esses algoritmos diferem entre si principalmente pelo modo como os pesos são modificados, cada um com sua característica.

Algumas formas de aprendizado estão associadas a processos de ajuste de pesos da rede podendo ser divididas em:

- **Aprendizado supervisionado:** utiliza um agente externo que indica à rede um comportamento bom ou ruim, de acordo com o padrão de entrada. A rede é treinada para fornecer a saída desejada em relação a um estímulo de entrada específico. Quando um vetor de entrada é aplicado, a saída da rede é calculada e comparada ao respectivo padrão de saída. A diferença (erro) é então propagada em sentido inverso ao fluxo de informações da rede (das saídas para as entradas) e os pesos são alterados de acordo com algum algoritmo que tende a minimizar o erro. Os vetores de entrada e saída do conjunto de treinamento são aplicados sequencialmente, os erros são calculados e os pesos ajustados para cada vetor, até que o erro para o conjunto de treinamento seja aceitável (MARCOS, 2014).

- **Aprendizado não supervisionado:** não utiliza um agente externo, indicando a resposta desejada para os padrões de entrada. Entretanto, utilizam-se exemplos de coisas semelhantes para que a rede responda de maneira semelhante. A rede se auto-organiza em relação a alguns subconjuntos de entrada, cujos elementos possuem características similares. Os vetores do conjunto de treinamento consistem unicamente de vetores de entrada. O algoritmo de treinamento modifica os pesos da rede para produzir vetores de

saída que são consistentes, isto é, vetores do conjunto de treinamento que são similares entre si, produzirão o mesmo padrão de saída. Nesse tipo de aprendizagem, espera-se que o sistema deva descobrir estatisticamente características e particularidades marcantes dos dados de entrada (MARCOS, 2014).

Denomina-se ainda ciclo de aprendizado (época) como sendo uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos em um ciclo pode ser executada de dois modos. Neste trabalho, a correção de pesos baseia-se somente no erro do exemplo apresentado na iteração anterior. Assim, em cada ciclo ocorrem N correções (MARCOS, 2014).

3.2.1 Aplicação da rede para diagnóstico da falha

Este trabalho apresenta uma forma de obter o diagnóstico de falha em transformadores imersos em óleo isolante, através do treinamento de uma rede neural artificial. No aprendizado teve-se como base normas nacionais e internacionais, que visam a padronização dos diagnósticos para transformadores.

Os passos para realização do treinamento e validação dos algoritmos foram os seguintes:

- Levantamento de análises cromatográficas de transformadores em serviços.
- Definição da topologia da rede.
- Treinamento da rede neural artificial.

3.2.2 Levantamento das análises cromatográficas

Os dados utilizados na rede neural foram obtidos a partir de análises cromatográficas do óleo isolante. Um exemplo de laudo utilizado é apresentado e explicado no Anexo A. Através dessas análises foram extraídas as informações necessárias para elaboração do algoritmo.

Armazenou-se um banco de dados com análises cromatográficas de transformadores do ramo siderúrgico, que foram enviados para manutenção em uma empresa especialista do ramo de análise. Foram analisados 350 laudos de óleo isolantes no período de 2006 a 2019. O conjunto de transformadores utilizados para análise encontra-se disponível no Anexo C. Também, no Anexo D, é ilustrado o diagrama unifilar do sistema no qual estes transformadores estão inseridos.

A partir dessas informações utilizou-se laudos que apresentavam os perfis de falhas que eram desejados para validação da RNA treinada.

3.2.3 Definição da topologia da rede

Foram utilizadas duas abordagens para implementação da RNA:

- A primeira via programação de uma rede com uma única camada oculta. O código implementado está descrito no Anexo B.

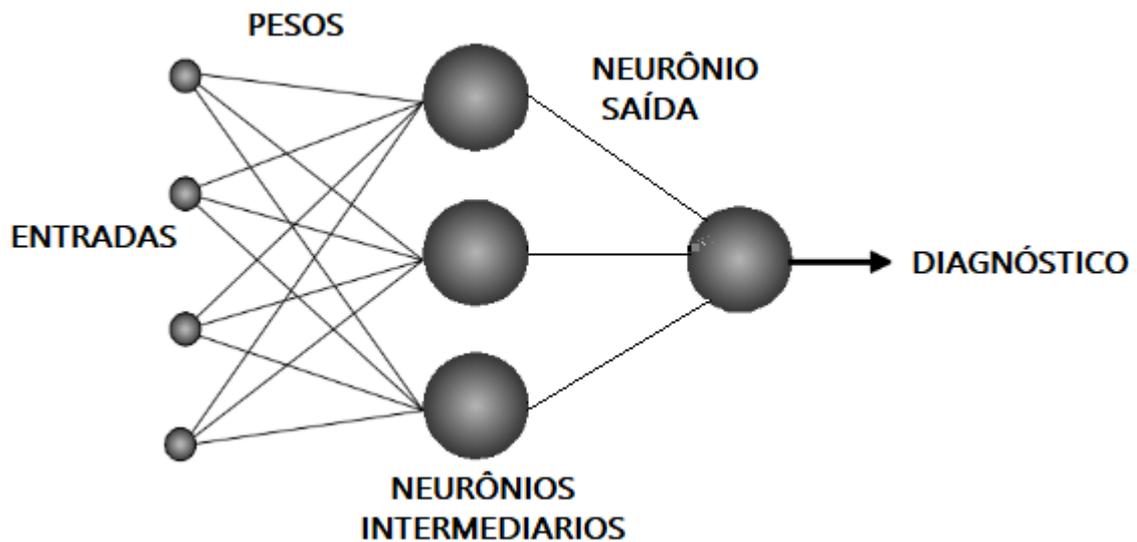
- A segunda por meio uso do *toolbox* de RNA do Matlab, o qual possui funções prontas para a implementação.

Ambas RNAs (a programada e a que usa o *toolbox*) utilizam treinamento por retropropagação do erro.

Para as duas abordagens descritas anteriormente, foram consideradas dois tipos de arquiteturas de RNA:

- Uma RNA com quatro entradas, uma camada oculta e uma saída, sendo a saída uma resposta binária que indica se o transformador encontra-se em falha ou não, (Figura 14).

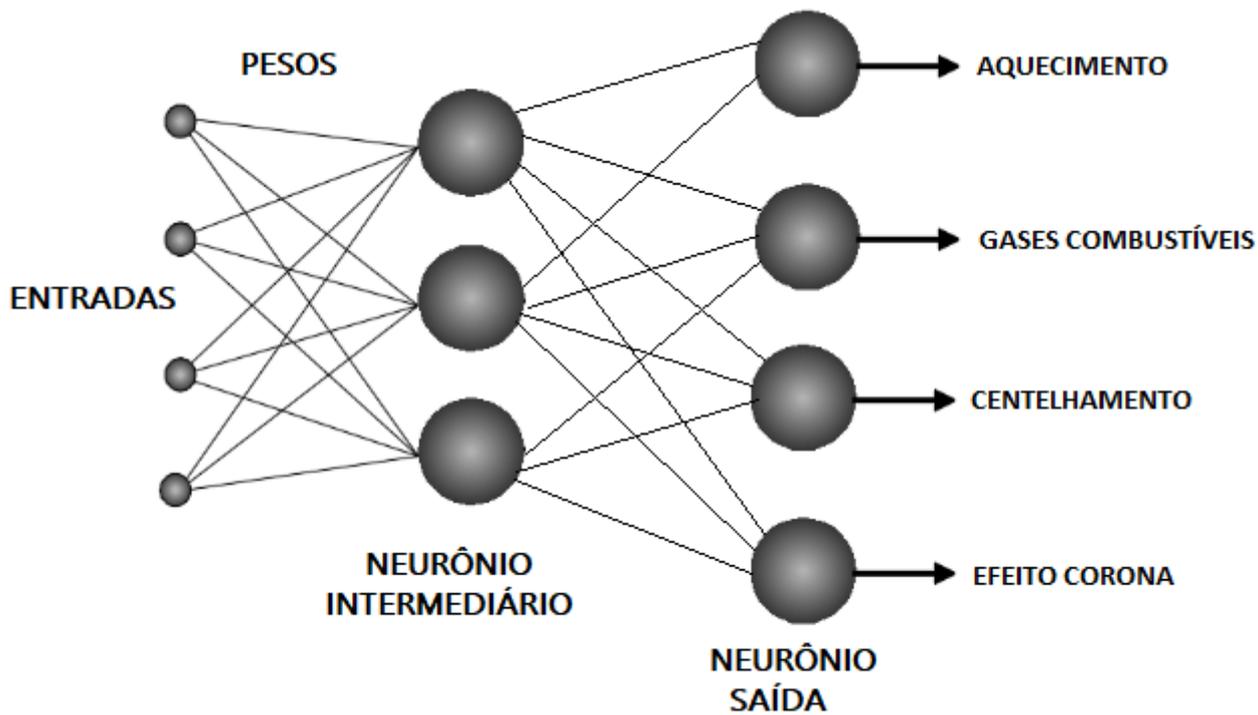
Figura 14 – Primeira situação de programação.



Fonte: Elaborada pelo autor.

- Uma RNA com quatro entradas, uma camada oculta e quatro saídas, na (Figura 15).

Figura 15 – Segunda situação de programação.



Fonte: Elaborada pelo autor.

- Quatro saídas: é uma resposta pelo programa no qual é possível identificar se o transformador encontra-se em falha e qual o tipo dessa falha. As falhas podem ser: aquecimento, gases combustíveis, centelhamento ou efeito corona.

As entradas para ambos os casos são as razões dos gases:

- Entrada um: Acetileno (C_2H_2)/Etileno (C_2H_4).
- Entrada dois: Metano (CH_4)/Hidrogênio (H_2).
- Entrada três: Etileno (C_2H_4)/Etano (C_2H_6).
- Entrada quatro: Etano (C_2H_6)/Metano (CH_4).

Neste trabalho foi utilizado o aprendizado supervisionado para que a medida que fossem realizadas iterações, o erro fosse reduzido, a fim de garantir uma assertividade e precisão no diagnostico de falhas em transformadores. .

3.2.4 Treinamento da rede neural artificial

Para o desenvolvimento utilizou-se 15 por cento dos laudos para validação da rede, 15 por cento dos laudos para teste e 70 por cento dos laudos para treinamento na rede, usando a ferramenta RNA do *toolbox* do Matlab. Para a rede programada utilizou-se

350 laudos para treinamento e 51 dados para serem validados e comparados com laudos emitidos pela empresa especialista.

4 Resultados

Nesta seção, apresentam-se dois cenários como resultados de diagnóstico de falha: o primeiro usa a RNA da Figura 14 e o segundo a RNA da Figura 15. Em ambos os cenários foi realizada a comparação entre a RNA programada e a RNA que utiliza o *toolbox* do Matlab.

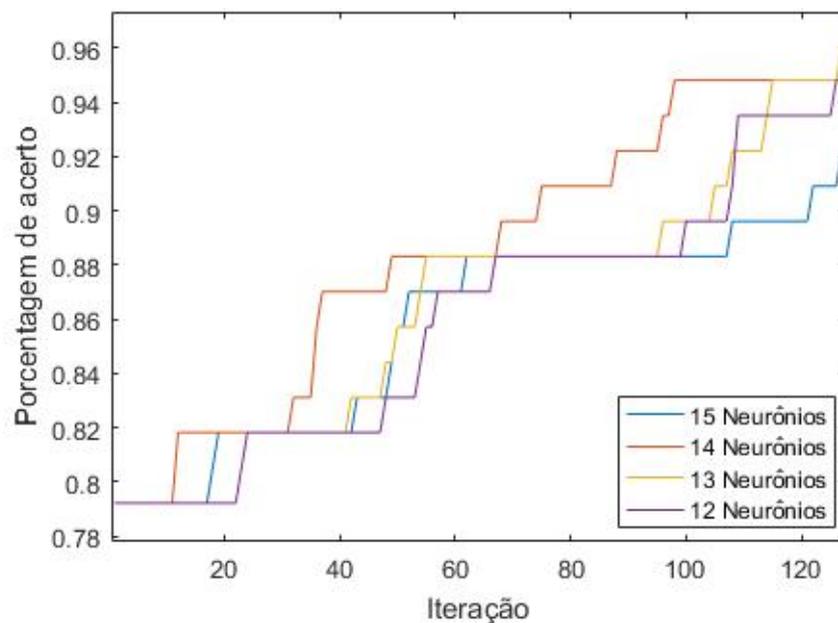
Para essa seção, espera-se resultados com valores próximos ao laudo emitido pela empresa especialista e a aplicação direta do Método de Rogers.

4.1 Desempenho da RNA de uma saída:

4.1.1 Resultados RNA programada:

Na Figura 16, apresentam-se os resultados de 4 simulações com valores de neurônios diferentes na camada oculta da rede, uma taxa de aprendizado igual à 1, e o número de iteração (épocas) igual a 130. Para qual a rede foi simulada, obteve-se esse resultado.

Figura 16 – Desempenho da RNA programada com diferentes neurônios.

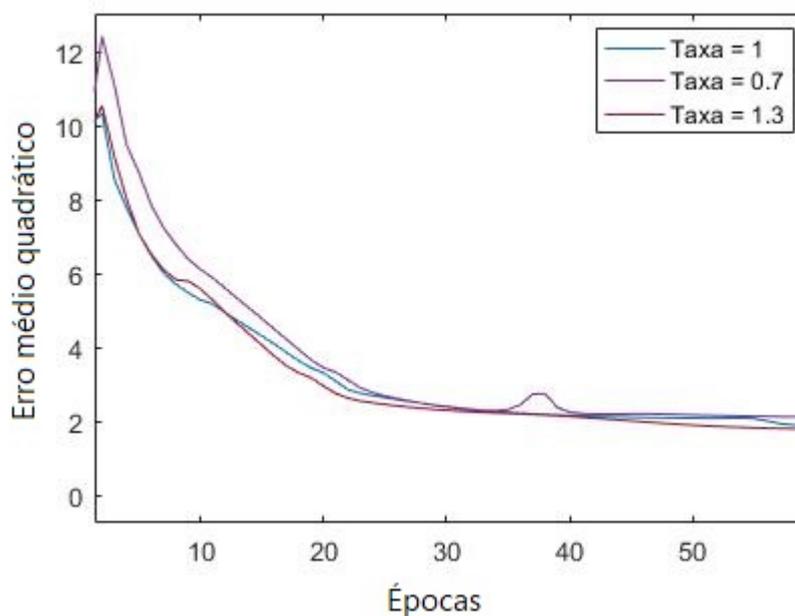


Fonte: Elaborada pelo Autor.

Foi possível visualizar uma resposta para saída, onde a porcentagem de acerto aumenta com a quantidade de iterações. Assim, mesmo que uma quantidade maior de iterações gaste um tempo computacional maior, é possível obter esse resultado demonstrado no gráfico, visando o melhor custo benefício entre tempo de treinamento e acerto na saída.

Na figura 17, é possível observar a convergência do algoritmo de treinamento de forma quantitativa, na medida que o erro médio quadrático vai diminuindo ("correção do erro") e o aumento da quantidade de iterações que comprovam à melhora na taxa de acerto, evidenciando a performance do treinamento. Porém a partir da iteração 30 é possível observar uma estabilidade onde não há uma variação tão significativa. Para alcançar esses dados realizou-se as simulações com diferentes valores para taxa de aprendizado, que demonstram uma convergência mais rápida ou mais lenta.

Figura 17 – Erro médio quadrático Vs Épocas.



Fonte: Elaborada pelo autor.

Na Figura 18, para o teste de validação, mostram-se os transformadores que a rede conseguiu acertar classificando de forma correta e os transformadores que foram classificados erroneamente.

Figura 18 – Resultado da validação da RNA para uma saída.

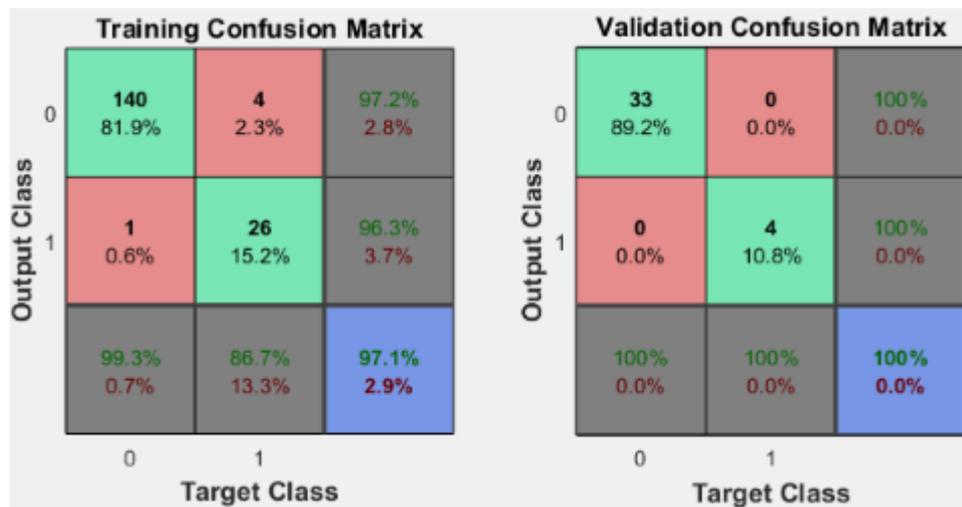
TRAFO	DIAGNÓSTICO PELA EMPRESA	DIAGNÓSTICO PELA REDE
TM 5A1	FALHA	CLASSIFICOU
TM 6A5	NORMAL	CLASSIFICOU
TM6C2	NORMAL	CLASSIFICOU
TM6C2	NORMAL	CLASSIFICOU
TM6C2	NORMAL	CLASSIFICOU
Reator	NORMAL	CLASSIFICOU
SE3B	NORMAL	CLASSIFICOU
SE3B	NORMAL	CLASSIFICOU
TM5A1	NORMAL	ERROU
TM5A1	FALHA	ERROU
TM6A5	NORMAL	CLASSIFICOU
TM6A5	NORMAL	CLASSIFICOU
TM6A5	NORMAL	CLASSIFICOU
TM5A3	NORMAL	CLASSIFICOU
TM5A3	NORMAL	CLASSIFICOU
TM3B1	NORMAL	CLASSIFICOU
TM3B1	NORMAL	CLASSIFICOU
TM5A2	NORMAL	CLASSIFICOU
TM3B1	NORMAL	CLASSIFICOU
TM5A2	NORMAL	ERROU
TM5A2	FALHA	CLASSIFICOU
TM5A7	NORMAL	CLASSIFICOU
TM5A7	NORMAL	CLASSIFICOU
TM5A7	FALHA	CLASSIFICOU
TM5A6	FALHA	CLASSIFICOU
TM5A6	NORMAL	CLASSIFICOU
TM4A1	FALHA	CLASSIFICOU
TM6C6	FALHA	CLASSIFICOU

Fonte: Elaborada pelo autor.

De acordo com a Figura 18, a taxa de acerto no teste de validação foi de $32/35 = 0,92$.

4.1.2 Resultado RNA usando *toolbox*:

Na Figura 19, apresenta-se a matriz de confusão, ferramenta muito usada para avaliação e classificação em linguagem de máquinas. Observa-se a classificação correta, dizendo quanto o modelo acertou para cada tipo de resposta possível emitido pela rede. Observando-se a quantidade e porcentagem de acertos no treinamento e validação, assim, sendo possível garantir a veracidade dos resultados, confirmando 97,1 por cento de acertos no treinamento e 100 por cento na validação. Conclui-se que essa rede consegue auxiliar um profissional da área e diagnosticar um transformador imerso em óleo isolante.

Figura 19 – Treinamento e validação simulado via *Toolbox* uma saída.

Fonte: Elaborada pelo autor.

A taxa de acerto durante o treinamento da rede programada (Figura 16) ficou entre 92 e 96 por cento. Já a taxa de acerto durante o treinamento fornecido pelo *toolbox* do Matlab foi de 97,1 por cento. No teste de validação, as taxas de acerto foram 92 e 100 por cento respectivamente para a rede programada e a rede que utiliza o *toolbox* do Matlab.

4.2 Desempenho da RNA de quatro saídas:

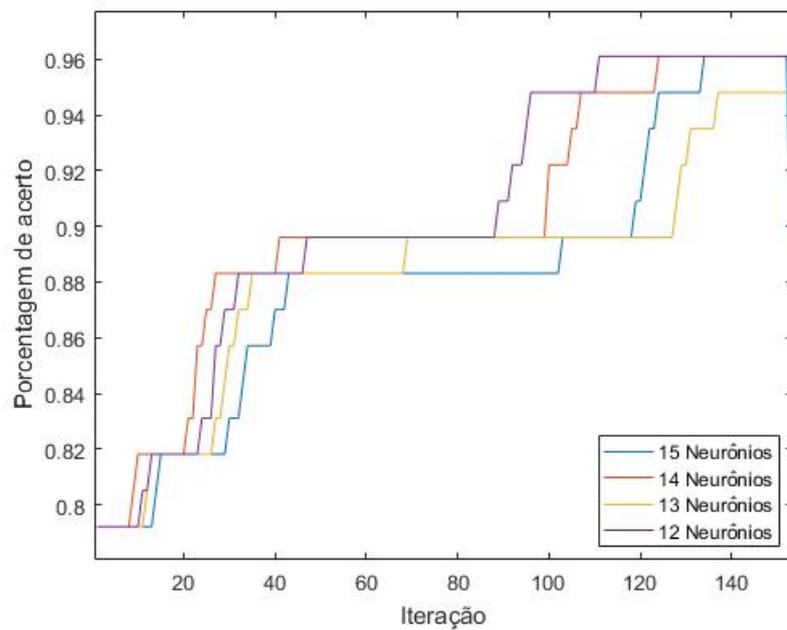
4.2.1 Resultados RNA programada:

A RNA com quatro saídas para diagnosticar qual tipo de falha eminente no transformador, baseia-se nos mesmos dados do primeiro cenário para treinamento de rede com uma saída.

Na Figura 20, apresentam-se o resultados de 4 simulações com valores de neurônios diferentes na camada oculta da rede, uma taxa de aprendizado igual à 1, e o número de iteração (épocas) igual a 150.

Na Figura 20, taxa de acerto, do treinamento da rede foi entre 94 à 96 por cento da quantidade de laudos validados, para cada tipo de falha apresentado a saída da rede.

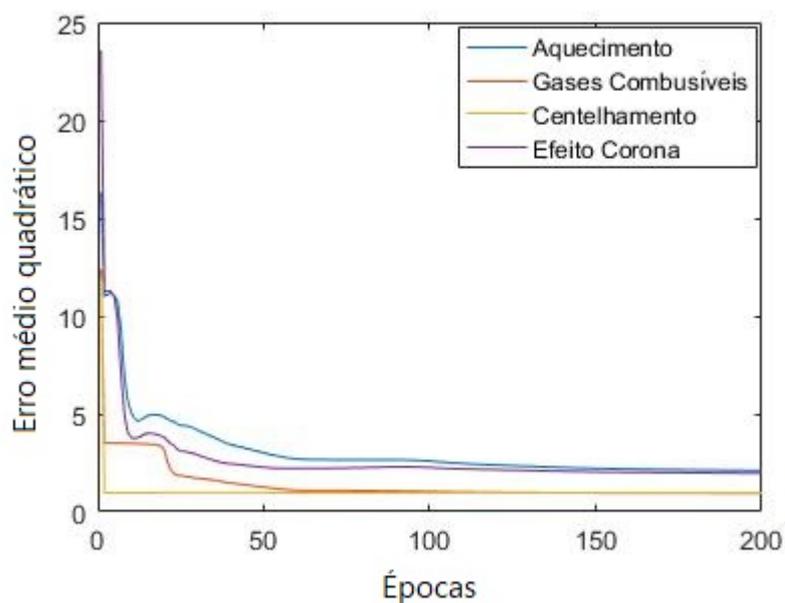
Figura 20 – Desempenho da RNA programada com diferentes neurônios.



Fonte: Elaborada pelo autor.

É possível visualizar na Figura 21, o decaimento do erro médio quadrático, a medida que as iterações (épocas) aumentam. Observa-se o comportamento e característica de cada tipo de falha apresentada no transformador imerso em óleo isolante.

Figura 21 – Erro médio quadrático Vs Épocas.



Fonte: Elaborada pelo autor.

Após a execução da rede com 4 saídas, na Figura 22, foi possível comparar os laudos emitidos pela empresa especialista e suas respectivas falhas, com os classificados pela rede.

Figura 22 – Resultado da validação da RNA para quatro saídas.

TRAFO	DIAGNÓSTICO PELA EMPRESA	DIAGNÓSTICO PELA REDE
TM 5A1	LIGEIRO AQUECIMENTO NO ÓLEO	CLASSIFICOU
TM 6A5	SOBREAQUECIMENTO NO ÓLEO	CLASSIFICOU
TM6C2	CENTELHAMENTO/GÁS	CLASSIFICOU
TM6C2	CENTELHAMENTO/GÁS	CLASSIFICOU
TM6C2	CENTELHAMENTO/GÁS	CLASSIFICOU
Reator FP	CENTELHAMENTO/GÁS	CLASSIFICOU
SE3B	CURVA CRESCENTE NO SOMATÓRIO DE GASES COMBUSTÍVEIS	CLASSIFICOU
SE3B	CURVA CRESCENTE NO SOMATÓRIO DE GASES COMBUSTÍVEIS	CLASSIFICOU
TM5A1	DESCARGA PARCIAL CORONA	ERROU
TM5A1	DESCARGA PARCIAL CORONA	ERROU
TM6A5	LIGEIRO AQUECIMENTO NO ÓLEO	CLASSIFICOU
TM6A5	LIGEIRO AQUECIMENTO NO ÓLEO	CLASSIFICOU
TM6A5	LIGEIRO AQUECIMENTO NO ÓLEO	CLASSIFICOU
TM5A3	CENTELHAMENTO/GÁS	CLASSIFICOU
TM5A3	CENTELHAMENTO/GÁS	CLASSIFICOU
TM3B1	CENTELHAMENTO/GÁS	CLASSIFICOU
TM3B1	LIGEIRO AQUECIMENTO NO ÓLEO	CLASSIFICOU
TM5A2	LIGEIRO AQUECIMENTO NO ÓLEO	CLASSIFICOU
TM3B1	CURVA CRESCENTE NO SOMATÓRIO DE GASES COMBUSTÍVEIS	ERROU
TM5A2	CURVA CRESCENTE NO SOMATÓRIO DE GASES COMBUSTÍVEIS	ERROU
TM5A2	LIGEIRO AQUECIMENTO NO ÓLEO	CLASSIFICOU
TM5A7	LIGEIRO AQUECIMENTO NO ÓLEO	CLASSIFICOU
TM5A7	LIGEIRO AQUECIMENTO NO ÓLEO	CLASSIFICOU
TM5A7	LIGEIRO AQUECIMENTO NO ÓLEO	CLASSIFICOU
TM5A6	CENTELHAMENTO/GÁS	CLASSIFICOU
TM5A6	CENTELHAMENTO/GÁS	CLASSIFICOU
TM4A1	CENTELHAMENTO/GÁS	CLASSIFICOU
TM6C6	LIGEIRO AQUECIMENTO NO ÓLEO	CLASSIFICOU

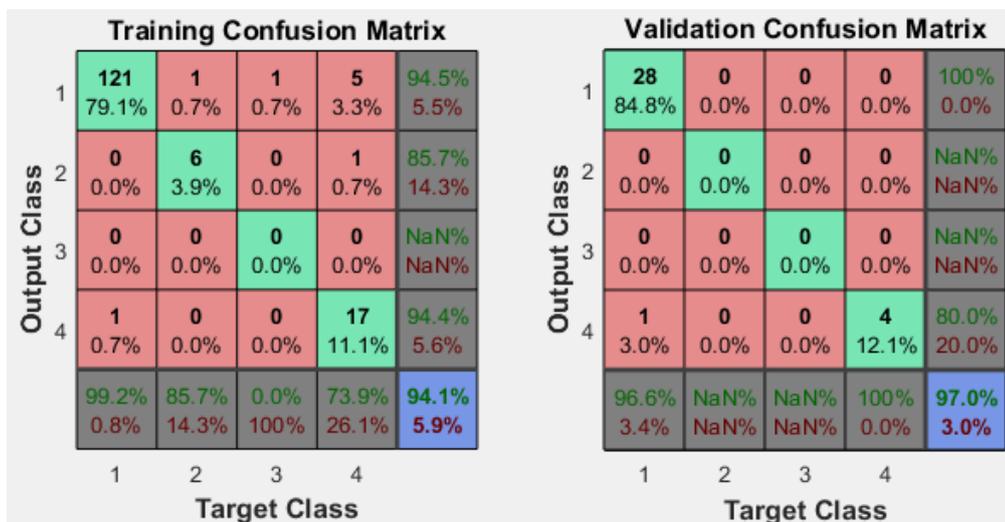
Fonte: Elaborada pelo autor.

4.2.2 Resultado usando *toolbox*

Na Figura 23, observa-se a matriz de confusão para os quatro tipos de falhas apresentados a saída da RNA, comprovando se o modelo acertou o tipo de resposta pela rede em seu treinamento e validação, garantido assertividade e veracidade.

As taxas de acerto foram próximo do *toolbox*. A rede teve um treinamento de 94.4 por cento e uma validação de 97 por cento como pode ser visto na Figura 23, na ferramenta utilizada para comparação igual ao primeiro cenário.

Figura 23 – Treinamento e validação simulado via *Toolbox* quadro saída.



Fonte: Elaborada pelo autor.

A taxa de acerto durante o treinamento da rede programada (Figura 20) ficou entre 94 e 96 por cento. Já a taxa de acerto durante o treinamento fornecido pelo *toolbox* do Matlab foi de 94,1 por cento. No teste de validação, as taxas de acerto foram 88 e 97 por cento respectivamente para a rede programada e a rede que utiliza o *toolbox* do Matlab.

5 Conclusão

Apresentou-se nesse trabalho de conclusão de curso, uma revisão da detecção de falhas em transformadores imersos em óleo isolante. Discorreu-se sobre as características de óleo, transformadores e normas que diagnosticam transformadores em falha. O principal objetivo foi apresentar uma maneira alternativa de diagnosticar análises cromatográficas de transformadores imersos em líquido isolante, através do treinamento de uma RNA que obtivesse resultados coerentes.

As redes treinadas neste trabalho apresentaram resultados satisfatórios, tiveram altas taxas de acerto, embora não foram 100 por cento precisas. Algumas combinações de parâmetros dificultam o acerto, como: quantidades de dados, números de saídas, taxa de aprendizado e número de neurônios. Para o melhor resultado o valor obtido pela RNA programada foram de: 13 neurônios na camada oculta com 1.3 de taxa de aprendizado (primeiro cenário) e 12 neurônios na camada oculta com 1 de taxa de aprendizado (segundo cenário).

Apresentou-se, a validação da ferramenta RNA para diagnosticar a falha em transformadores imersos em óleo isolante, visto que conseguiu-se classificar o transformador em falha para o melhor resultado em 92 por cento (primeiro cenário), como também diagnosticou com o tipo de falha existente, para o melhor resultado em 88 por cento (segundo cenário), a partir das concentrações gasosas encontradas no óleo. Para um melhor resultado de treinamento e validação dessa rede, seria necessário uma alimentação com mais laudos de transformadores em falha, para que a rede conseguisse classificar de forma mais assertiva, sem tendenciar resultados falsos.

Referências

- AHMED, R. et al. Automotive Internal-Combustion-Engine Fault Detection and Classification Using Artificial Neural Network Techniques. *IEEE Transactions on Vehicular Technology*, v. 64, n. 1, p. 21–33, Jan 2015. ISSN 0018-9545. 9
- ARANTES, J. G. Diagnóstico de Falhas em Transformadores de Potência pela Análise de Gases Dissolvidos em Óleo Isolante Através de Redes Neurais. . *Dissertação Mestrado em Engenharia Elétrica – Universidade de Federal de Itajubá*, 2005. 27, 28, 29, 30
- ARRUDA, L. V. Reconhecimento de Padrões e Classificação de Imagens de Escoamentos Bifásicos Utilizando Redes Neurais. *Simpósio Brasileiro de Automação Inteligente (SBAI)*. , São João Del Rei – MG., Simpósio Brasileiro de Automação Inteligente (SBAI), 2011. 10, 15, 16, 20
- BENGTSSON, C. Status and trends in transformer monitoring. *IEEE Transactions on Power Delivery*, v. 11, n. 3, p. 1379–1384, Jul 1996. ISSN 0885-8977. 9
- CARVALHO, A. P. B. A. P. L. F. Redes Neurais Artificiais Teoria e Aplicações. *LTC 1ª edição*, 2000. 20, 21, 25
- DATALINK-2019. *Empresa DataLink - Engenharia Elétrica*. Disponível em: <http://datalink.srv.br>. Acesso em: 20 nov. 2019.
- FREITAS, A. A. C. Redes Neurais Artificiais Aplicadas em Transformadores de Distribuição Imersos em Óleo. *Dissertação de Mestrado, UNESP/FE/Departamento de Engenharia Elétrica.*, 2000. 16, 17, 18, 19, 22, 23, 24
- GABRIEL, V. B. A. Estudo da Viabilidade de Utilização da Técnica de Ultra-Som Associada ao Processamento Digital de Sinal (PDS) para Detecção de Pontos Quentes em Equipamentos Elétricos de Alta Tensão. *Tese Mestrado Centro Federal De Educação Tecnológica - CEFET/RJ*, 2008. 17, 18
- GEROMEL, H. L. Aplicação de Sistemas Inteligentes em Projetos de Transformadores de Potência. *Tese de Doutorado Faculdade de Engenharia Elétrica e de Computação da Unicamp*, 2003. 25
- IEEE. IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers. *IEEE Std C57.104-2008 (Revision of IEEE Std C57.104-1991)*, p. 1–36, Feb 2009. 24
- IEEE. IEEE Guide for Dissolved Gas Analysis in Transformer Load Tap Changers. *IEEE Std C57.139-2010*, p. 1–32, Feb 2011.
- LUX, D. C. A. On-line monitoring of power transformers and components: a review of key parameters. In: *Proceedings: Electrical Insulation Conference and Electrical Manufacturing and Coil Winding Conference (Cat. No.99CH37035)*. [S.l.: s.n.], 1999. p. 669–675. ISSN 0362-2479. 25, 26

- MENDONÇA, M. Uma Contribuição ao Desenvolvimento de Sistemas Inteligentes Utilizando Redes Cognitivas Dinâmicas. *Tese de Doutorado, Universidade Tecnológica Federal do Paraná*, 2011. 10
- MYERS, S. D. Transformer Maintenance Guide, Transformer Maintenance Institute. *Neurology Conference Minutes*, AAN Enterprises, v. 3, n. 10, 2004. 13, 14
- ROGERS, R. R. Experiences in the Interpretation of Incipient Faults in PowerTransformer by Dissolved Gas-in-oil Chromatography Analysis . *Minutes of Forty-Second International Conference of Doble Clients.*, IEEE, v. 90, n. 4, p. 10–201, 1975. 22
- ROGERS, R. R. IEEE and IEC Codes to Interpret Incipient Faults in Transformers, Using Gas in Oil Analysis. *IEEE Trans*, IEEE and IEC, EI-13, n. 5, p. 349–354, 1978. 22
- SILVA I. N. SPATTI, D. H. F. Redes Neurais Artificiais para Engenharia e Ciências Aplicadas. *Artiber Editora LTDA*, 2010. 10
- TOMSOVIC, M. T. T. I. K. A fuzzy information approach to integrating different transformer diagnostic methods. *IEEE Transactions on Power Delivery*, v. 8, n. 3, p. 1638–1646, July 1993. ISSN 0885-8977. 10
- TRANSPAPER2013. *Papel isolante recomendados para transformador*. Disponível em: <<<http://http://pt.senpeng-tech.com>>>. Acesso em: 3 out. 2019.
- UFPR-2014. *Site - Universidade Federal do Paraná*. Disponível em: <<http://paginapessoal.utfpr.edu.br/mafinocchio/labsi-laboratorio-de-seguranca-e-iluminacao/redes-neurais-artificiais/NOCaO%20DE%20REDES%20NEURAIIS%20ARTIFICIAIS.pdf/view>>. Acesso em: 14 dez. 2019.
- ZHENYUAN, W. Artificial Intelligence Applications in the Diagnosis of Power Transformer Incipient Faults. *Faculty of the Virginia Polytechnic Institute and State University*, Institute of Electrical and Electronics Engineers, 2000. 13

ANEXO A – Laudo para construção da rede

A figura 24, mostra um dos laudos que foi utilizados para alimentar a RNA como entradas. Esse laudo é composto por informações construtivas, localização, dados de placa e dados de execução na hora da coleta de óleo.

Figura 24 – Exemplo de laudo usado para construção da rede.

ANÁLISE CROMATOGRÁFICA NBR 7070 - Gases dissolvidos (ppm)	HISTÓRICO DE RESULTADOS			Taxa de Crescimento (% ao mês)	RESULTADO 25/04/2017
	5295/14 30/09/2014	5691/15 27/08/2015	5435/16 10/08/2016		
Hidrogênio (H2)	265	234	227	-1.43	199
Oxigênio (O2)	8420	13180	12210	0.06	12270
Nitrogênio (N2)	63180	73200	87310	-3.70	59560
Metano (CH4)	28	33	39	-2.09	32
Monóxido de Carbono (CO)	461	483	491	0.43	509
Dióxido de Carbono (CO2)	5344	5501	5587	-0.07	5552
Etileno (C2H4)	6	8	13	1.79	15
Etano (C2H6)	51	44	47	-1.24	42
Acetileno (C2H2)	ND	ND	ND	-	ND
Total de Gases	77755	92683	105924	-3.05	78179
Total de Gases Combustíveis (TGC)	811	802	817	-0.28	797

DIAGNÓSTICO DO ENSAIO FÍSICO-QUÍMICO

- Conforme a NORMA NBR-10576/2012, os resultados estão dentro dos parâmetros estabelecidos, apresentando condições satisfatórias para o óleo em operação.

- Sugerimos reamostrar em doze meses para acompanhamento.

DIAGNÓSTICO DO ENSAIO CROMATOGRÁFICO

- Resultados normais, apresentando condições satisfatórias de operação do equipamento.

Fonte: Laudo emitido pela empresa.

É possível observar cada elemento químico junto com a quantidade de gases dissolvidos no óleo isolante. Como também, uma taxa de crescimento em relação a última coleta realizada. E por fim a empresa especialista deixa uma conclusão baseado, por norma de uma possível falha. Caso o transformador esteja em boas condições ela classifica como normal e remarca uma nova coleta preditiva, como foi o exemplo dessa figura 24.

ANEXO B – Programas

O Programa 1, aplica-se as condições de alterar dados da RNA e rodar de forma cíclica para comparar todos os intervalos e gráficos usado para desenvolvimento da rede.

Programa 1: Executa_Todos_Os_Passos.

```

1 %% Laco de repeticao
2 for nn=8:1:9 % numero de neuronios da camada oculta
3     for eta=.9:.1:1.0 % taxa de aprendizado (valor baixo:
4         convergencia lenta valor alto: nao convergencia)
5         for iter_max=400:100:400 % maximo numero de iteracoes
6             para o aprendizado
7                 Nome=('Teste_nn_eta_iter.mat');
8                 ne=4; % numero de entradas
9                 ns=1; % numero de saidas
10                Rede_Neural;
11                hold on
12                if nn < 2
13                    Nome(7:8) = ['0' num2str(nn)];
14                else
15                    Nome(7:8) = [num2str(nn)];
16                end
17                if eta == 1
18                    Nome(10) = ['1'];
19                    Nome(11) = [','];
20                    Nome(12) = ['0'];
21                elseif eta>1
22                    Nome(10) = ['1'];
23                    Nome(11) = [','];
24                    ata=eta*10-10;
25                    Nome(12) = [num2str(ata)];
26                else
27                    Nome(10) = ['0'];
28                    Nome(11) = [','];
29                    ata=eta*10;
30                    Nome(12) = [num2str(ata)];
31                end
32            if iter_max < 1000
33                Nome(14:17) = ['0' num2str(iter_max)];

```

```

32     else
33         Nome(14:17) = [num2str(iter_max)];
34     end
35     save(Nome);
36     end
37 end
38         clear all;
39 end

```

O Programa 2, é o desenvolvimento da RNA para diagnosticar transformadores imerso em óleo isolante, baseando-se na função ou exclusivo.

O desenvolvimento do programa, foi a generalização da solução particular da função ou exclusivo como classificação, para uma rede neural com um número de entradas, camadas, neurônios e saídas variáveis.

Programa 2: Rede Neural.

```

1  % Rede Neural com uma camada oculta usando funcao sigmoidal
2  n=350;          % quantidade de dados de treinamento
3  %% entrada de dados para treinamento (funcao ou arquivo)
4  %[p,t]=dados_XOR(n); % p:entradas; t: saidas
5
6  dados = xlsread ('RN-TRAFOS.xlsx');
7
8  ch4_h2 = dados(:,14);
9  c2h6_ch4 = dados(:,15);
10 c2h4_c2h6 = dados(:,16);
11 c2h2_c2h4 = dados(:,17);
12
13 diagnostico = dados(:,10);
14
15 p=[ch4_h2 , c2h6_ch4, c2h4_c2h6, c2h2_c2h4];
16 t=diagnostico;
17
18 bias0=zeros(nn,1); % ganho de cada neuronio
19 biass=zeros(ns,1);
20
21 %% Inicializacao da rede
22 % Distribuicao aleatoria uniforme
23 W0=rand(nn,ne); %neuronios na camada oculta e numero de entradas
24 %% Pesos aleatorios camada de saida

```

```
25 %Distribuicao aleatoria uniforme
26 WS=rand(ns,nn);
27
28 %% Validacao
29 n_valida=35;      % quantidade de dados de treinamento
30
31 dados_valida = xlsread ('RN-VALIDACAO.xlsx');
32 saida_real=dados_valida(:,10);
33
34 ch4_h2_valida = dados_valida(:,14);
35 c2h6_ch4_valida = dados_valida(:,15);
36 c2h4_c2h6_valida = dados_valida(:,16);
37 c2h2_c2h4_valida = dados_valida(:,17);
38
39 p_valida=[ch4_h2_valida , c2h6_ch4_valida, c2h4_c2h6_valida,
          c2h2_c2h4_valida];
40
41 bias0_valida=zeros(nn,1); % ganho de cada neuronio
42 biass_valida=zeros(ns,1);
43
44 %% treinamento
45 iter=1; % bug
46 e2_valida=zeros(iter_max+1,1); % erro que nao acerta no
          diagnostico
47 while iter<iter_max+1
48     e2=0;    %% inicializacao do erro total de aprendizagem
49     for r=1:n    % para cada padrao
50         %% forward
51         n0=W0*p(r,:)'+bias0; % entradas liquidas de cada
          neuronio
52         a0=sigmf(n0,[1 0]);
53         ns=WS*a0+biass;
54         as=sigmf(ns,[1 0]);
55
56         %% calculo do erro
57         delta=t(r)-as;
58         delta2=delta^2;
59         ep2=0.5*delta2; %% erro medio quadratico para cada
          padrao
60         e2=e2+ep2;    %% erro total de aprendizagem
61
62         %%
```

```

63     %% backward
64     % gradiente na camada de saida
65     delta_s=der_sig(ns).*delta;
66     %delta_WS=delta_s./a0;
67     delta_WS=delta_s.*a0';
68     %gradiente na camada de entrada
69     delta_0=(delta_s'*WS)'.*der_sig(n0);
70     delta_W0=delta_0*p(r,:);
71
72     % Atualizar os pesos da rede
73     WS=WS+eta*delta_WS;
74     W0=W0+eta*delta_W0;
75 end
76
77 for r_valida=1:n_valida    % para cada padrao
78     %% forward
79     n0_valida=W0*p_valida(r_valida,:)'+bias0_valida; %
80         entradas liquidas de cada neuronio
81     a0_valida=sigmf(n0_valida,[1 0]);
82     ns=WS*a0_valida+biass_valida;
83     as_valida=sigmf(ns,[1 0]);
84     result_valida(r_valida)=as_valida;
85     if result_valida(r_valida)>0.5
86         resultado_calculado(r_valida)=1; % arredonda o
87             diagnostico.
88     else
89         resultado_calculado(r_valida)=0;
90     end
91 end
92
93 for r_valida=1:n_valida    % % testa se o valor 0 ou 1 se e
94     igual o 0 ou 1 do excel. se for diferente. Se for diferente
95     incrementa erro, quantidade de erros.
96     if resultado_calculado(r_valida)~=saida_real(r_valida)
97         e2_valida(iter,1)=e2_valida(iter,1)+1;
98     end
99 end
100 acerto_valida=(n_valida-e2_valida)/n_valida; % linha 100
101     calcula a porcentagem de acerto.
102 iter=iter+1;
103 end
104 plot(acerto_valida((1:iter-1),1))

```

```
100
101 title(['nn = ', num2str(nn) , ' eta = ', num2str(eta) , ' Iteracao
        Maxima = ', num2str(iter_max)]);
102 xlabel('Iteracao')
103 ylabel('Porcentagem de acerto')
```

ANEXO C – Lista de transformadores

Lista de transformadores usados para desenvolvimento desse trabalho e da RNA.

Figura 25 – Trafos usados para construção da RNA.

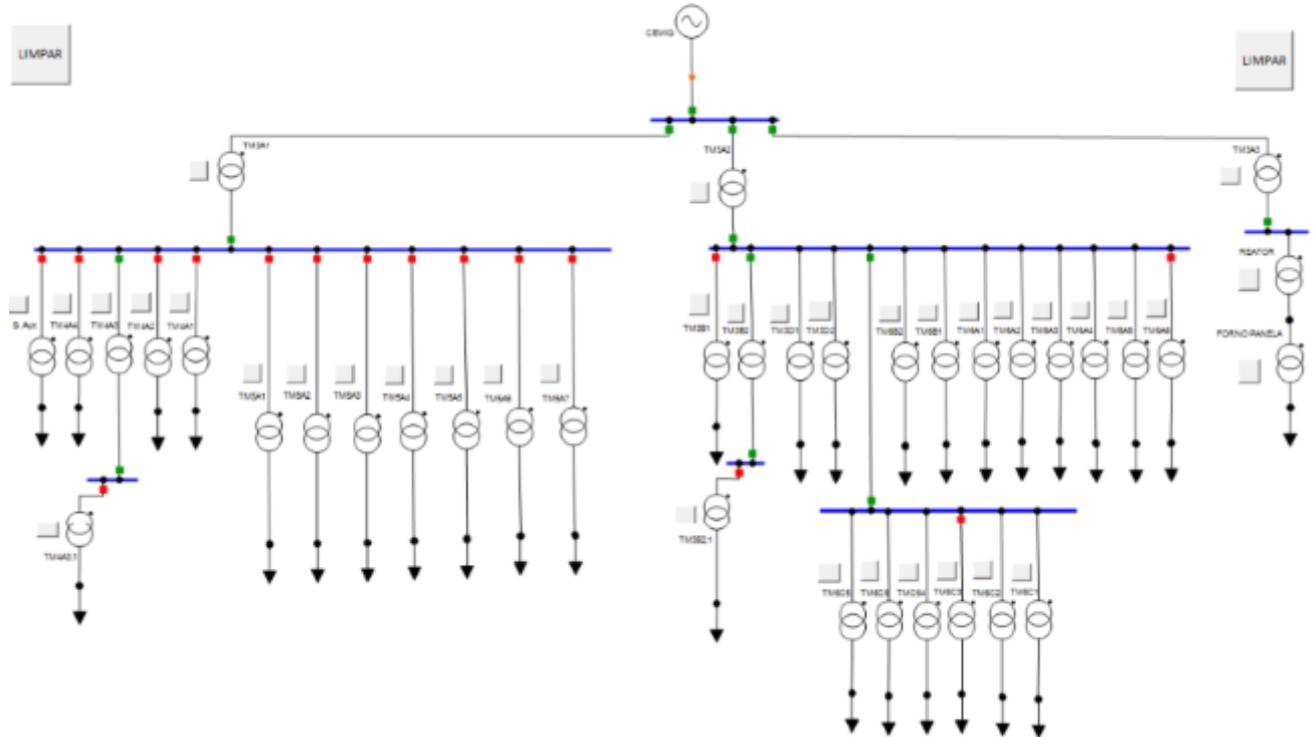
Número de Série	Equipamento	Tensão	Potência	Fabricante	Identificação	Ano Fabricação
1356	Transformador	440/230V	100 kVA	CIME	TM Dep	-
4623	Transformador	13800/2400 V	2500 kVA	BROWN BOVERI	TM 6C2	1964
12620	Reator	13800/13800 V	1200 kVA	MAG	Reator FP	2000
19037	Transformador	13800/220 V	500 kVA	ASEA	TM dep	-
27039	Transformador	69000/13800 V	9400 - 7500 kVA	INDUSELET	TM 3A1	1974
27040	Transformador	69000/13800 V	9400 - 7500 kVA	INDUSELET	TM 3A2	1974
36203	Transformador	13800/440 V	1000 kVA	TOSHIBA	TM 5A3	1974
36205	Transformador	13800/440 V	1000 kVA	TOSHIBA	TM 3B1	1974
36206	Transformador	13800/440 V	1000 kVA	TOSHIBA	TM 5A2	1974
36207	Transformador	13800/2300 V	1500 kVA	TOSHIBA	TM 5A7	1975
36208	Transformador	13800/2300 V	1500 kVA	TOSHIBA	TM 5A6	1975
36209	Transformador	13800/220 V	750 kVA	TOSHIBA	TM6C4 - Reserva	1975
36210	Transformador	13800/380 V	750 kVA	TOSHIBA	TM 6C3	1975
36493	Transformador	13800/440 V	1000 kVA	TOSHIBA	TM 4A1	1975
36494	Transformador	13800/440 V	1000 kVA	TOSHIBA	TM dep	1985
42424	Transformador	13800/245 V	500 kVA	NATIVA	TM dep	1977
47750	Transformador	69000/13800 V	9375 - 7500 kVA	ASEA	TM 3A3	1972
50044	Transformador	13800/440 V	13800/440 V	TRAFO	TM 4A3	1981
50045	Transformador	13800/440 V	1750 kVA	TRAFO	TM 4A2	1981
57213	Transformador	13800/440 V	750 kVA	TOSHIBA	TM 6C6	1977
57214	Transformador	13800/440 V	750 kVA	TOSHIBA	TM 3D1	1977
58203	Transformador	13800/440 V	1000 kVA	ASEA	TM 6A7	-
68116	Transformador	13800/2450 V	1500 kVA	NATIVA	TM 5A5	1980
69972	Transformador	13800/440 V	1000 kVA	NATIVA	TM 5A1	1980
88712	Transformador	13800/500 V	1500 kVA	WEG	TM 6A1	1994
92013	Transformador	13800/480 V	1500 kVA	WEG	TM 6B1	1993
92014	Transformador	13800/480 V	1500 kVA	WEG	TM 6B2	1993
92016	Transformador	13800/500 V	1500 kVA	WEG	TM 6A3	1993
92018	Transformador	13800/480 V	1500 kVA	WEG	TM 6A6	1993
92019	Transformador	13800/500 V	1500 kVA	WEG	TM 6A5	1993
92020	Transformador	13800/500 V	1500 kVA	WEG	TM 6A2	1993
92021	Transformador	13800/500 V	1500 kVA	WEG	TM 6A4	1993
116293	Transformador	13800/220 V	30 kVA	WEG	TM 3A4	-
125737	Transformador	13800/550 - 317 V	5000 kVA	WEG	Reserva	1998
258105	Transformador	13800/440 - 254 V	1500 kVA	WEG	Reserva	2007
405130	Transformador	13860/220 - 127 V	1500 kVA	TUSA	Reserva	1982
500218	Transformador	69000/13800V	7500 kVA	TUSA	SE3A - Reserva	1973
7360833	Comutador	220 V	9100 - 7000 kVA	ASEA	FP Comt.	1985
9021739	Transformador	13800/2400 V	2000 - 2500 kVA	TUSA	TM4A4	1990
9316771	Transformador	13800/220 V	500 kVA	TUSA	TM3C1	1993
9424902	Transformador	13800/500-289 V	1800kVA	TUSA	BTG	1994
750624192	Transformador	13800/220 V	500 kVA	TRAFO	TM 5A4	-
750624194	Transformador	440/220 V	150 kVA	TRAFO	D. Carvão	-
10100034116001	Transformador	13800/440 V	2000 kVA	SIEMENS	TM 3B2	2005
58686-C	Transformador	13800/240 - 120 V	9100 - 7000 kVA	ASEA	FP TRAFO.	1985
A-6691	Transformador	13800 V/540 V	1250 kVA	ITEL	BTG	1986
209537	Transformador	13800/380 - 220V	1000kVA	WEG	BTG - Reserva	2004
B-5891	Transformador	13800/220 V	1500 kVA	ITEL	BTG	1987
761729	Transformador	13800/220	75KVA	IG-Construções	TMGC5	1973
T-17255	Transformador	13800/2300 V	3000 kVA	GORDON	SE 4A - Reserva	1976

Fonte: Elaborada pelo autor.

ANEXO D – Esquema elétrico

Esquema elétrico unifilar de como os transformadores estão ligados. Fornecimento concessionária 69kV e 13.8kV de distribuição para as áreas produtoras da siderurgia.

Figura 26 – Esquema elétrico dos transformadores imerso ao óleo isolante.



Fonte: Elaborada pelo autor.