

REDES NEURAIS ARTIFICIAIS APLICADAS NO AUXÍLIO DE DIAGNÓSTICO DE FALHAS EM TRANSFORMADORES

ARTIFICIAL NEURAL NETWORKS APPLIED AS AN AID FOR TRANSFORMER FAULT DIAGNOSIS

Márcio Mendonça¹
Marco A. F. Finocchio²
Lucas Fidelis M. Gonçalves³

Data de entrega dos originais à redação em: 27/02/2015
e recebido para diagramação em: 30/03/2015.

Uma das maneiras utilizadas para diagnosticar transformadores em funcionamento são os métodos de Análise Cromatográfica do Líquido Isolante. Utiliza-se esse tipo de análise, porque o óleo isolante está em contato direto com a parte ativa do equipamento e, de acordo com a quantidade de gases imersa nesse óleo, é possível diagnosticar o equipamento com determinada falha. Existem normas que visam a padronizar o diagnóstico. Podem-se citar o Método de Duval, Método de Dornenburg, IEC e, no Brasil, a NBR 7274 – Interpretação da Análise dos Gases de Transformadores em Serviço. Este trabalho tem como objetivo utilizar Sistemas Inteligentes no diagnóstico de falhas de transformadores. Em especial, Redes Neurais Artificiais, de acordo com os parâmetros de concentração gasosa da NBR 7274, validada e testada com relatórios cromatográficos de transformadores em serviço.

Palavras-chave: Análise de Falhas em Transformadores. Análise Cromatográfica. NBR 7274. Redes Neurais Artificiais.

One of the ways used to diagnose transformers in operating are the methods of Insulating Liquid Chromatographic Analysis. We use this type of analysis, because the insulating oil is in direct contact with the active part of the equipment, and, in accordance with the amount of gas immersed in this oil, it is possible to diagnose equipment fault. There are rules intended to standardize the diagnosis. Among these rules, we can mention the Duval Method, the Dornenburg Method, IEC and, in Brazil, the NBR 7274 - Interpretation of Gases Analysis in Transformer Service. This paper aims to use Intelligent Systems for transformer fault diagnosis. In particular, Artificial Neural Networks, according to the parameters of gaseous concentration of NBR 7274, validated and tested with chromatographic reports on transformers in service.

Keywords: Fault Analysis in Transformers. Chromatographic Analysis. NBR 7274. Artificial Neural Networks.

1 INTRODUÇÃO

Os transformadores são equipamentos fundamentais no sistema elétrico, usados em subestações para baixar ou elevar as tensões. A ocorrência de falhas pode gerar prejuízos de ordem financeira as empresas (prejudicando a produção) e também colocar a vida em risco, como é o caso dos hospitais. Existem métodos de manutenção preventiva como: análise e inspeção visual dos acessórios presentes nos transformadores, reaperto de barramentos e guarnições, ou até mesmo manutenção corretiva.

Estresse térmico e elétrico resultam em fratura dos materiais isolantes, com isso há liberação de gases que contaminam o líquido isolante. A análise destes gases podem fornecer informações sobre o tipo de falha. Várias normas têm sido sugeridas para a identificação de falhas em transformadores com base na proporção de gases dissolvidos no transformador de óleo (RAHMAT, PARASTEGARI e FORGHANI, 2012).

Neste contexto pode ser citado alguns trabalhos similares na literatura.

Existem diversos trabalhos de classificação utilizando Redes Neurais Artificiais, como por exemplo o trabalho de Ahamed e colaboradores (AHAMED; et al., 2015). Neste trabalho, uma técnica de detecção de falha do motor e de classificação usando dados de vibração no domínio do ângulo de manivela é apresentado. Estes dados são utilizados em conjunto com redes neurais artificiais (RNAs), aplicados para detectar falhas em motores a gasolina quatro tempos construído para experimentação. O trabalho de (ARRUDA; et al., 2011) cujo título é Reconhecimento de Padrões e Classificação de Imagens de Escoamentos bifásicos Utilizando Redes Neurais, converte imagens de escoamento geradas em laboratório em dados para treinamento e posterior classificação de padrões. Também é possível citar alguns trabalhos sobre Redes Neurais Artificiais aplicadas a detecção de padrões em transformadores. O trabalho de Silva (SILVA, et al., 2000),

1 Laboratório de Automação e Sistemas de Controle Avançado (LASCA). Universidade Tecnológica Federal do Paraná, Campus Curitiba. Celular (43) 9639-9723 (TIM).

2 Laboratório de Segurança Iluminação e Eficiência Energética (LABSIEE). Universidade Tecnológica Federal do Paraná, Campus Cornélio Procopio.

3 Departamento de Engenharia Elétrica, UTFPR-CP. Universidade Tecnológica Federal do Paraná, Campus Cornélio Procopio.

diz respeito ao mapeamento de óleo mineral em processos de contaminação através Redes Neurais Artificiais e pode ser visto como uma ferramenta eficiente, oferecendo alternativas às metodologias convencionais, tendo como atrativos a geração de resultados atraentes, principalmente devido às características intrínsecas da técnica, tais como a capacidade de generalização e facilidade de integração com outras ferramentas computacionais. De um modo geral, uma Rede Neural Artificial é um sistema computacional com capacidade de aprendizado através de dados (HAYKIN, 2001,d), diferentemente de outras técnicas computacionais inteligentes como por exemplo, Sistemas Fuzzy, que utilizam conhecimento (ZADEH, 1968). Neste contexto, podemos citar sistemas Neuro-Fuzzy que agregam características dos dois sistemas inteligentes (MENDONÇA, 2011).

O trabalho de Rahmat (RAHMAT, PARASTEGARI E FORGHANI, 2012) utiliza um sistema ANFIS (*Adaptive Neuro-Fuzzy Inference Systems*) para diagnóstico de falhas de transformadores; oito falhas são identificadas e diagnosticadas pelo método da IEC (*International Electrotechnical Commission*).

Um dos métodos clássicos utilizados para avaliação de transformadores imersos em óleo é chamado de Análise Cromatográfica do Óleo Isolante, este tipo de método visa diagnosticar o transformador através dos gases contidos no líquido isolante. Existem inúmeras normas que padronizam a interpretação de falhas de transformador; no Brasil a norma que tem este objetivo chama-se NBR 7274.

Outro método clássico é o Método de Duval e o Método de Doernenburg, que normatiza as concentrações de gases extraídas do laudo cromatográfico do equipamento, diagnosticando com uma possível falha.

O principal objetivo deste trabalho é apresentar diagnósticos de transformadores através do Treinamento de uma Rede Neural Artificial *Perceptron* Multicamadas (MLP). O treinamento mais comum deste tipo de rede é o *back-propagation*, com diferentes algoritmos de treinamento. Nesse trabalho foi utilizado o método de *Levenberg Marquadt* (AHMED; et al., 2001).

O Método de Duval foi criado e desenvolvido por Michel Duval em 1974 para análise e interpretação de líquido isolante em equipamentos de alta tensão (Duval, 1974). Este método é baseado principalmente na análise de três gases, são eles: Acetileno, Etileno e Metano.

Duval é baseado em duas análises, a primeira é apresentada na Tabela 1, está cita a taxa de geração em ppm (pontos por minuto). Se todos os gases apresentam a taxa de geração maior ou igual (maior ou igual ao que?) é possível analisar o líquido isolante do equipamento de acordo com a Figura 1.

A segunda etapa do diagnóstico leva em consideração apenas os três gases citados anteriormente. Cada vértice do Triângulo de Duval representa um gás e as variações de cores representam falhas. Na Figura 1 são apresentadas as relações dos gases em porcentagem. A conversão (SETAYESHMEHR, BORSI e GOCKENBACH, 2008), pode ser vista na Equação 1, Equação 2 e Equação 3, onde G1, G2 e G3 representa cada um dos três gases.

De acordo com as variações dos gases encontrados é possível estabelecer cada falha do

Tabela 1 - Geração de Gases Método de Duval

Gás	Limites L1(ppm)	Limites G2(ppm)
H ₂	100	50
CH ₄	75	38
CH ₂	3	3
C ₂ H ₂	75	38
C ₂ H ₆	75	38
CO	700	350
CO ₂	7000	3500

Fonte: Autoria Própria

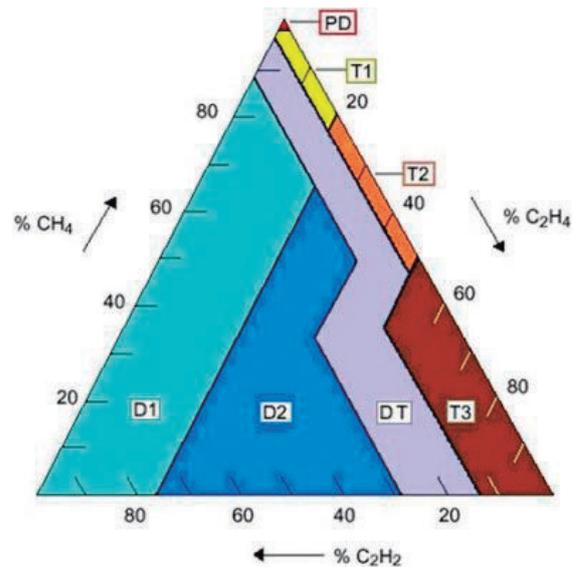


Figura 1 - Variação da concentração de gases segundo Método de Duval

$$P1 = \%C_2H_2 = 100 \times \frac{G3}{(G1 + G2 + G3)} \quad (1)$$

$$P2 = \%C_2H_4 = 100 \times \frac{G2}{(G1 + G2 + G3)} \quad (2)$$

$$P3 = \%CH_4 = 100 \times \frac{G1}{(G1 + G2 + G3)} \quad (3)$$

equipamento. No geral as falhas são classificadas entre térmicas, falhas ocasionadas por descargas parciais ou até mesmo falhas que apresentam características térmicas e descargas parciais simultaneamente.

A Tabela 2 apresenta as prováveis falhas, de acordo com o método Duval.

Tabela 2 - Falhas de acordo com Método de Duval

ABREVIÇÃO	PROBLEMA
DP	Descargas Parciais
DT	Arco elétrico e falta térmica
D1	Centelhamento
D2	Descarga de alta energia
T1	Sobreaquecimento t < 300 °C
T2	Sobreaquecimento 300 °C < t < 700°C
T3	Sobreaquecimento t > 700°C

Fonte: Autoria Própria

1.2 Análises Cromatográficas Baseada na NBR 7274

A norma NBR 7274 de 2012 descreve como a concentração de gases livres ou dissolvidos são interpretados para diagnosticarem as condições de equipamentos elétricos em serviço e sugerir ações futuras. Os equipamentos elétricos são preenchidos com óleo mineral isolante e isolado com papel e papelão, ou seja, utilizam a celulose como base. Na Tabela 3 é possível observar as falhas diagnosticadas por esta norma.

A Tabela 4 é utilizada na interpretação da análise dos gases dissolvidos. As relações descritas abaixo são consideradas valores médios que devem ser atingidos pelo equipamento. O valor NS é o valor esperado de Acetileno, devendo ser abaixo do limite de detecção do método utilizado. Alguma superposição entre os problemas D1 e D2 significa uma dupla interpretação e neste caso a norma recomenda considerar o caso de maior gravidade.

1.3 Método de Dornenburg

O Método de Doernenburg foi desenvolvido de forma empírica e baseia-se na existência de limites mínimos de concentrações dos gases, para que o método possa ser aplicado. De acordo com a norma IEEE C57.104/2004, a execução do método deve seguir alguns procedimentos. O primeiro procedimento (RODRIGUES, 2011) é validar o método de acordo com uma variação de gases expressa nesta norma. O segundo procedimento é analisar a variação das quatro relações de gases, se atentando ao fato de que pelo menos um gás de cada relação deve atingir um limite determinado pela Norma IEEE C57.104/2004.

Na Tabela 5 é possível observar as relações e suas respectivas falhas. A Falha 1 tem como diagnóstico a decomposição ocasionada por elevações térmicas, a Falha 2 tem seu diagnóstico é dado por Descargas Parciais de baixa intensidade.

Por fim, a Falha 3 representa seu diagnóstico como sendo a Descarga Elétrica de Alta intensidade, que é um exemplo de descargas atmosféricas ou até mesmo do transformador trabalhando muito tempo com carga além da sua capacidade nominal.

2 REDES NEURAIIS ARTIFICIAIS EM ANÁLISE DE FALHAS EM TRANSFORMADORES IMERSOS EM ÓLEO

O método apresentado neste trabalho utilizou Rede Neural Artificial (RNA) aplicado no diagnóstico de transformadores. Os neurônios artificiais utilizados nos modelos de redes neurais artificiais são não lineares, fornecem saídas tipicamente contínuas e realizam funções simples, como coletar sinais existentes em suas entradas, agregá-los de acordo com sua função operacional e produzir uma resposta, levando em consideração sua função de ativação inerente (SILVA, SPATTI e FLAUZINO, 2010).

Este trabalho apresenta uma forma de obter o diagnóstico de transformadores imersos em líquido isolante, através do treinamento de uma Rede Neural Artificial. O aprendizado teve como base a norma ABNT

Tabela 3 - Falhas de acordo com a Norma NBR 7274

CASO	FALHA
DP	Descargas Parciais.
C1	Centelhamento
D1	Descarga de baixa energia
D2	Descarga de alta energia
T1	Sobreaquecimento $t < 300^\circ\text{C}$
T2	Sobreaquecimento $300^\circ\text{C} < t < 700^\circ\text{C}$
T3	Sobreaquecimento $t > 700^\circ\text{C}$

Fonte: Autoria Própria

Tabela 4 - Variação dos Gases de acordo com a NBR 7274

CASO	C_2H_2/C_2H_4	CH_4/H_2	C_2H_4/C_2H_6
DP	NS	$< 0,1$	$< 0,2$
C1	0 – 0,6	0,1 - 1	< 1
D1	> 1	0,1 – 0,5	> 1
D2	0,6 – 2,5	0,1 - 1	> 2
T1	$< 0,01$	> 1	< 1
T2	$< 0,1$	> 1	1- 4
T3	$< 0,1$	> 1	> 4

Fonte: Autoria Própria

NBR 7274, esta norma visa padronizar os diagnósticos de transformadores no Brasil.

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

- Levantamento de Análises Cromatográficas de transformadores em serviços;
- Elaboração do Algoritmo;
- Treinamento da Rede Neural Artificial;
- Validação da RNA;
- Estratégia de Treinamento. (A RNA já não foi treinada?)

2.1 Levantamentos de Análises Cromatográficas

Os dados utilizados na Rede Neural foram basicamente Análises Cromatográficas de óleo isolante. Através destas análises foram extraídas as informações necessárias para elaboração do algoritmo.

Foram coletadas aproximadamente 60 análises cromatográficas de transformadores que foram enviados para manutenção em uma empresa do ramo de transformadores. A partir destas informações foram utilizadas treze análises que apresentavam os perfis de falhas que era desejado para validação e testes da RNA treinada.

Com isso, pode-se avaliar se o laboratório está apresentando diagnósticos de maneira correta.

Tabela 5 - Relações gasosas segundo o Método de Doernenburg

CH_4/H_2	C_2H_2/C_2H_2	C_2H_2/CH_4	C_2H_6/C_2H_2	FALHA
$> 1,0$	$< 0,75$	$< 0,3$	$> 0,4$	1
$< 1,0$	NS	$< 0,3$	$> 0,4$	2
$> 0,1$ e $< 1,0$	$> 0,75$	$> 0,3$	$< 0,4$	3

Fonte: Autoria Própria

Outra funcionalidade para este algoritmo é através das concentrações de gases, analisar o material sem necessitar de um laboratório específico para diagnosticar a falha do equipamento, com isso, diminuindo o excesso de tempo que levaria para levar a amostra do óleo até um laboratório padrão.

As concentrações de gases utilizadas no algoritmo podem ser visualizadas nos itens abaixo.

- C_2H_2 - Acetileno.
- C_2H_4 - Etileno.
- CH_4 - Metano.
- H_2 - Hidrogênio.
- C_2H_6 - Etano.

2.2 Arquiteturas da Rede Neural Artificial

Para elaboração do programa desenvolveu-se uma RNA de topologia *feed-forward* com treinamento por retro propagação do erro.

Na Figura 2 é apresentada a topologia da RNA, na qual, a concentração 1 (C_2H_2/C_2H_4), concentração dois (CH_4/H_2) e concentração três (C_2H_4/C_2H_6) representam as entradas da rede, que são as concentrações de gases extraídas das Análises Cromatográficas. Já os sete neurônios de saída representam o diagnóstico da rede, ou seja, são as sete falhas conforme a NBR 7274.

2.3 Treinamento e Validação da RNA

Um dos destaques relevantes das RNAs está na capacidade de aprender a partir da apresentação de amostras (padrões) que exprimem o comportamento do sistema, sendo que, em seguida, após a rede ter aprendido o relacionamento entre as entradas e as saídas, está é capaz de generalizar soluções. A rede será então capaz de produzir uma saída próxima daquela esperada, a partir de quaisquer sinais inseridos em sua entrada (SILVA, SPATTI e FLAUZINO, 2010).

A etapa de aprendizado de uma RNA consiste em processo iterativo de ajuste de parâmetros de rede, os pesos das conexões, ou seja, o aprendizado é o processo pelo qual os parâmetros livres de uma Rede Neural são ajustados por meio de uma forma continuada de estímulo pelo ambiente externo sendo o tipo específico de aprendizado definido pela maneira particular de como ocorrem os ajustes dos parâmetros livres (BRAGA, CARVALHO e LUDEMIR, 2007).

Para efetuar o treinamento foram utilizados aproximadamente 125 exemplos divididos entre as falhas que a Norma NBR 7274 ilustra. Estes exemplos foram adquiridos através dos parâmetros de concentrações de gases dado pela norma e apresentados à rede, conforme a Tabela 6. Com isso pode-se assegurar que o aprendizado do algoritmo deve como padrão a norma vigente de diagnóstico de equipamentos preenchido com óleo mineral isolante.

Depois de treinada a rede, o procedimento seguinte foi à obtenção da validação do algoritmo. Nesta etapa foi apresentada aproximadamente 20 concentrações, na qual, treze são dados reais de transformadores em funcionamento. Obtendo o resultado da validação foi possível comparar com os diagnósticos apresentados pelo laboratório.

2.4 Estratégias de Treinamento

Uma tarefa importante no projeto de uma rede neural artificial é a escolha da topologia da rede, isto é, os números de camadas e os números de neurônios por camada. Isto é feito experimentalmente através de processos repetitivos com o objetivo de obter a precisão desejada através da quantização do número de neurônios e camadas (*layers*) escondidos (ARANTES, 2005).

A camada de entrada será igual ao número de informações de entrada e o número de neurônios na *layer* da saída será definido de acordo com o número de respostas. Neste trabalho foi apresentado três informações de entrada que são as relações de gases. A saída foi definida com as sete falhas do equipamento a ser diagnosticado conforme a NBR 7274.

A utilização de uma grande quantidade de camadas escondidas não é recomendada a uma grande maioria dos problemas de classificação de padrões, pois a maioria utiliza apenas uma camada escondida ou duas camadas escondidas dependendo da complexidade do problema (HAYKIN, 2001).

Durante a elaboração do algoritmo foram elaboradas algumas estratégias de treinamento e validação, com o objetivo de encontrar a melhor forma de avaliação do desempenho da RNA. Foram testadas 6 rotinas de testes para encontrar o melhor resultado. Através destas rotinas foi alterado a quantidade de neurônios (ARRUDA, SANTOS e SILVA, 2011), os exemplos repassados a RNA e também os exemplos de validação. Isso tem como objetivo evitar circunstâncias de memorização excessiva da rede, ou seja, *overfitting*, em que este acaba decorando as repostas

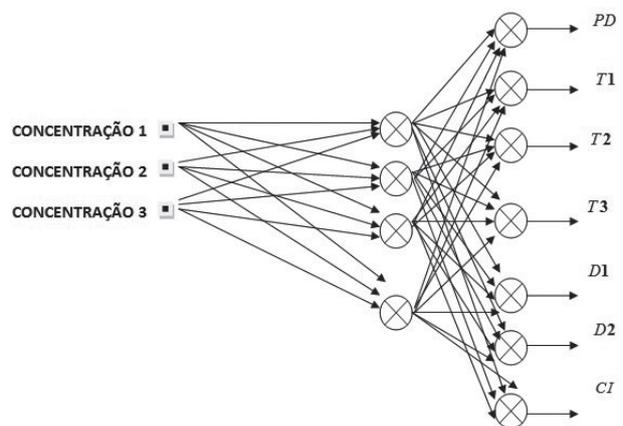


Figura 2 - Topologia da Rede Neural utilizada

Tabela 6 - Exemplos dados a rede

CONCENTRAÇÃO DE GÁS	T	T	T	D	D	C	D
	1	2	3	1	2	1	P
	1	0	0	0	0	0	0
	0	1	0	0	0	0	0
	0	0	1	0	0	0	0
	0	0	0	1	0	0	0
	0	0	0	0	1	0	0
	0	0	0	0	0	1	0
0	0	0	0	0	0	1	

Fonte: Autoria Própria

frente aos estímulos introduzidos em suas entradas (SILVA, SPATTI e FLAUZINO, 2010).

3 RESULTADOS

No total foram utilizadas seis configurações entre dados de treinamento e teste da topologia aplicada na RNA, conforme a Tabela 7. Durante a rotina de testes foi variado o número de validação e número de neurônios. Com isso pode-se analisar qual rede apresenta valores próximos aos valores reais da instrução normativa.

A Figura 3 mostra a bateria de diferentes configurações para dados de testes e treinamentos pela qual a Rede Neural Artificial com sua respectiva taxa de erro de saída 10^{-6} , visando melhor custo benefício entre tempo de treinamento e erro de saída. De acordo, com as cinco configurações avaliadas conclui-se que: 45 neurônios obtiveram como resultado uma pequena taxa de erro, ou seja, a melhor configuração de dados com a topologia treinada e utilizada. Uma alternativa seria com 35 neurônios. Já a terceira e quarta bateria de testes apresentou uma variação de erro maior em relação às duas primeiras.

Após serem encontradas as definições de topologia, foram apresentados treze laudos das concentrações gasosas de transformadores em serviço. Para avaliação, foram feitos diagnósticos e comparações com os resultados dos laboratórios avaliados, para saber se estão de acordo com a NBR 7274. Seguem na Tabela 8, as concentrações gasosas e o diagnóstico conferido pelo laboratório. Entretanto, as amostras colhidas seguiram os procedimentos da ABNT NBR 7070.

Após a verificação dos laudos dos diagnósticos pelo laboratório, o próximo passo é a utilização da RNA treinada nos limites da Norma NBR 7274; os mesmos parâmetros utilizados pelo laboratório, de acordo com a Tabela 9. O resultado obtido em vermelho representa a saída que não obteve o mesmo resultado que o laudo do laboratório. Obtendo um erro em trinta (destacado em vermelho) exemplo, da ordem de 3,33%. A tabela 8 são dados de relatório de concentração e tipo de falha. A RNA na linha 11 encontrou o tipo de falha DP (vide tabela 2), enquanto que os dados de treinamento apontam para a falha T2.

4 CONCLUSÃO

O principal objetivo foi realizar uma maneira alternativa de diagnosticar análises cromatográficas de

transformadores imersos em líquido isolante, através do treinamento de uma RNA que obtivesse resultados iniciais coerentes na avaliação de um fornecedor.

Neste trabalho foram coletados laudos cromatográficos de transformadores que apresentavam sinais de envelhecimento precoce do material isolante, contaminação do óleo, sobreaquecimento dos mais variados tipos. Todos os laudos utilizados foram de um determinado laboratório e também utilizaram a mesma instrução normativa que a RNA treinada e a ABNT NBR 7274 como o método de interpretação. Com isso, a empresa pode verificar e obter parâmetros dos laudos concedidos por este laboratório e se está dentro dos padrões esperados pela norma. A vantagem de se utilizar a RNA está na velocidade de resposta da RNA, previamente treinada, do que consultar a norma ou um método gráfico como de Duval.

Em análise aos resultados obtidos pelo teste da RNA e comparados com os obtidos pelo laboratório, é possível avaliar que em totalidade os diagnósticos obtidos foram similares, ou seja, apenas uma análise obteve diagnóstico diferente do obtido na RNA. Com isso, apesar de ser uma pesquisa ainda em fase inicial, conclui-se que está ferramenta proposta pode ao menos auxiliar na avaliação de laboratórios e fornecedores de líquido isolante em transformadores.

5 FUTUROS TRABALHOS

Como trabalho futuro, pretende-se aumentar a quantidade de dados e conseqüentemente a avaliação de outros laboratórios, visando à consolidação desta ferramenta para auxílio de diagnóstico de transformadores.

Tabela 7- Rotina de treinamento implementada

TREINO	NEURÔNIOS	VALIDAÇÃO	TESTE
1	45	10%	7%
2	35	13%	7%
3	30	15%	7%
4	25	18%	7%
5	20	20%	7%
6	15	20%	7%

Fonte: Autoria Própria

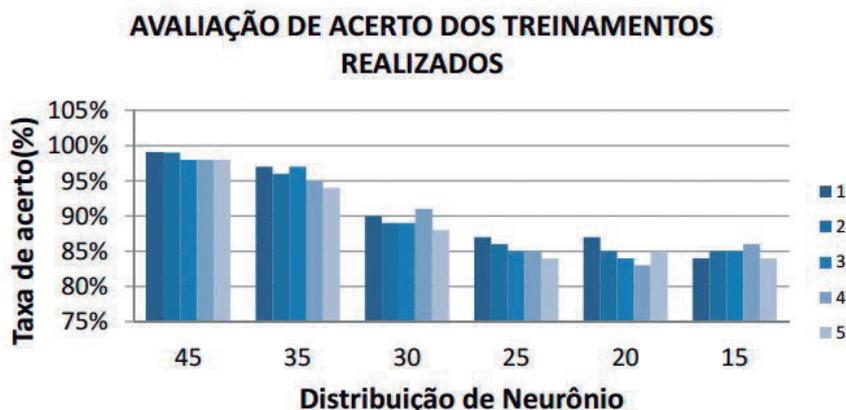


Figura 3 – Resultados das cinco configurações (1-5) de dados de testes e treinamento na RNA

Tabela 8 - Concentrações de gases utilizadas para validar a Rede Neural Artificial utilizada

1	C_2H_2/C_2H_4	CH_4/H_2	C_2H_4/C_2H_6	FALHA
2	0	0,025	0,07	DP
3	0	0,015	0,03	DP
4	0	0,06	0,16	DP
5	0	0,05	0,14	DP
6	0,2	0,3	0,2	T1
7	0,23	0,4	0,39	T1
8	0,35	0,77	0,74	T1
9	0,27	0,17	0,33	T1
10	1,7	0,2	1,7	T2
11	2,1	0,24	2,4	T2
12	4	0,17	2	T2
13	4,5	0,3	3,9	T2
14	1,7	0,51	3,3	T3
15	1,9	0,61	3,5	T3
16	2,1	0,72	3,7	T3
17	2,3	0,8	3,6	T3
18	0,0007	5,2	0,03	D1
19	0,0006	5,7	0,01	D1
20	0,003	2,7	0,8	D1
21	0,001	3,7	0,09	D1
22	0,05	4	3,5	D3
23	0,08	4,2	3,7	D3
24	0,07	1,8	1,7	D3
25	0,08	1,7	1,5	D3
26	0,3	4,2	6	DT
27	0,2	4,7	6,5	DT
28	0,35	4,5	7,0	DT
29	0,45	4,9	7,5	DT
30				

Fonte: Autoria Própria

Tabela 9 - Resultados Obtidos através do treinamento da RNA

1	C_2H_2/C_2H_4	CH_4/H_2	C_2H_4/C_2H_6	FALHA
2	0	0,025	0,07	DP
3	0	0,015	0,03	DP
4	0	0,06	0,16	DP
5	0	0,05	0,14	DP
6	0,2	0,3	0,2	T1
7	0,23	0,4	0,39	T1
8	0,35	0,77	0,74	T1
9	0,27	0,17	0,33	T1
10	1,7	0,2	1,7	T2
11	2,1	0,24	2,4	DP
12	C_2H_2/C_2H_4	CH_4/H_2	C_2H_4/C_2H_6	FALHA
13	4	0,17	2	T2
14	4,5	0,3	3,9	T2
15	1,7	0,51	3,3	T3
16	1,9	0,61	3,5	T3
17	2,1	0,72	3,7	T3
18	2,3	0,8	3,6	T3
19	0,0007	5,2	0,03	D1
20	0,0006	5,7	0,01	D1
21	0,003	2,7	0,8	D1
22	0,001	3,7	0,09	D1
23	0,05	4	3,5	D3
24	0,08	4,2	3,7	D3
25	0,07	1,8	1,7	D3
26	0,08	1,7	1,5	D3
27	0,3	4,2	6	DT
28	0,2	4,7	6,5	DT
29	0,35	4,5	7,0	DT
30	0,45	4,9	7,5	DT

Fonte: Autoria Própria

REFERÊNCIAS

ABNT, Associação Brasileira de Normas Técnicas, Referências Bibliográficas, Rio de Janeiro, (2012). NBR 7274.

Ahmed, R.; El Sayed, M.; Gadsden, S.A.; Jimi Tjong; Habibi, S.(2015); Automotive Internal-Combustion-Engine Fault Detection and Classification Using Artificial Neural Network Techniques, Vehicular Technology, (**IEEE Transactions on**, vol. 64, nº. 1, pp. 21,33.)

Arantes, J. G. (2005). **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, Itajubá-MG, 2005.

Arruda, L.V.; Santos, E. N.; Silva, M.J.(2011). Reconhecimento de Padrões e Classificação de Imagens de Escoamentos

bifásicos Utilizando Redes Neurais. **Simpósio Brasileiro de Automação Inteligente** (SBAI). SBAI 2011, São João Del Rei – MG.

Braga, A. P.; Carvalho, A. P. L. F.; Ludemir, T. B. (2007). **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC.

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

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

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

Haykin, S.. (2001). **Redes Neurais. Princípios e prática.** Porto Alegre, RS: Bookman.

Mendonça, M. (2011). **Uma Contribuição ao Desenvolvimento de Sistemas Inteligentes Utilizando Redes Cognitivas Dinâmicas.** Tese de Doutorado, Universidade Tecnológica Federal do Paraná, Campus Curitiba.

Rahmat, A. H. Parastegari, M.; Forghani, Z. (2012). Adaptive Neuro-Fuzzy Inference System Approach for Simultaneous Diagnosis of the Type and Location of Faults in Power Transformers. **Electrical Insulation Magazine, IEEE** (Volume: 28, Issue: 5).

Silva, I. N. Spatti, D. H.; Flauzino, (2010); R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas.** São Paulo, SP: Artiliber Editora LTDA.

Silva, I. N. Souza, A. N.; Hossri, R. M.; Hossri, J. H. C. (2000); Intelligent System Applied in Diagnosis of Transformer Oil, Dielectric Materials, Measurements and Applications, 2000. **Eighth International Conference** on (IEEE Conference), Edinburgh.

Setayeshmehr, A. Borsi, H.; Gockenbach, E. A. (2008); Software Implementation of the Duval Triangle Method. Electrical Insulation, 2008. ISEI 2008. Conference Record of the 2008 **IEEE International Symposium** on, Vancouver.

Zadeh, L.A (1968). Fuzzy algorithms, (**Info. & Ctl.**) Vol. 12, pp. 94-102.