

## Aplicação de Redes Neurais Artificiais Especialistas na Classificação de Falhas em Transformadores

Wendler Luis Nogueira Matos<sup>1</sup>

Jean Chaves Batista<sup>2</sup>

Carlos Henrique Gurjão Lopes<sup>3</sup>

Daniel Takashi Né do Nascimento Suzuki<sup>4</sup>

Orlando Fonseca Silva<sup>5</sup>

Universidade Federal do Pará, FEEB, PET-EE, Belém, PA

Esse trabalho se propõe a apresentar um método eficaz para um problema nos Sistemas Elétricos de Potência: classificar as falhas em transformadores. A partir de uma base de dados contendo relações de gases dissolvidos no óleo desses equipamentos e aplicando-se um algoritmo conhecido como Redes Neurais Artificiais Especialistas [5], objetivou-se conseguir uma alta acurácia na classificação dessas falhas, ou seja, a rede deve aprender a respeito dos dados e classificar corretamente qual a provável falha no equipamento, que será confirmada por um responsável técnico. O modelo construído será então um auxiliador de tomada de decisão.

Analisando os sistemas elétricos, percebe-se que os transformadores são equipamentos fundamentais para o correto funcionamento da rede de energia [3]. Quando a concentração dos gases dissolvidos nos transformadores a óleo excedem níveis padrões, provavelmente ocorrerão falhas nos mesmos. Definido o problema, o objetivo é aplicar redes especialistas para, a partir de um processo de aprendizagem dos dados de entrada, ter como saída a possível falha que o equipamento possui.

O processo de aprendizagem de uma Rede Neural Artificial (RNA) inicia na propagação (*forward*), onde um padrão de atividade é aplicado aos nós da rede, propagando-se pelas camadas, com pesos sinápticos fixos e inicializados aleatoriamente. Depois ocorre a retropropagação (*backpropagation*), onde os pesos são ajustados a partir da Regra Delta, de forma que o erro entre a saída real e a obtida pela rede tenda a zero no decorrer das iterações de épocas [1]. Quanto ao modelo proposto, o diferencial é a característica de se ter redes especialistas para cada classe de dados [5]. Para implementar o algoritmo, usou-se a *Toolbox* NNET do *Software* MATLAB [2].

A base de dados consiste em uma matriz [300,4], na qual em uma coluna tem-se a saída (5 classes), e nas demais uma razão entre gases, sendo as 3 seguintes: acetileno ( $C_2H_2$ ) e etileno ( $C_2H_4$ ); metano ( $CH_4$ ) e hidrogênio ( $H_2$ ); etileno ( $C_2H_4$ ) e etano ( $C_2H_6$ ). Além disso, cada linha está relacionada a uma falha específica, de 5 catalogadas: descarga parcial, descarga de baixa energia, descarga de alta energia, falha térmica  $< 300^\circ C$  e falha térmica  $\geq 300^\circ C$  [4]. Utilizou-se 70% dos dados para treino e 30% para teste (90 linhas).

O modelo proposto consiste em 5 redes especialistas, cada uma treinada com uma classe específica, buscando alcançar (para essa classe), um mapeamento correto, na saída, da classe de entrada. Após o aprendizado, o teste em cada rede é feito apresentando todas as classes. Ao final, se terá 5 colunas (devido a existência de 5 redes) com 90 linhas (cada rede com um vetor de saída).

---

<sup>1</sup>wendler.matos@itec.ufpa.br

<sup>2</sup>jeanbatista8@hotmail.com

<sup>3</sup>carloslopes801@gmail.com

<sup>4</sup>danieltakashi4@gmail.com

<sup>5</sup>orfosi@ufpa.br

Com base no valor mínimo de erro para cada linha (comparando com a saída da base de dados), um vetor de saída final será obtido. A função de ativação para todas as redes foi a *tansig* (tangente sigmóide). Todas as redes foram inicializadas com 3, 5, 10, 15 e 20 neurônios na camada oculta. Quanto ao número de épocas, variou-se (com espaçamento de 500), de 500 até 4000. Já com relação a taxa de aprendizagem, testou-se 0,1 e 0,01. Os melhores parâmetros encontrados, com base na métrica de acurácia, para as 5 redes (de acordo com a classe especializada), são mostrados na Tabela 1. A média de 10 inicializações resultou na acurácia de 86%. Na Figura 1, observa-se as saídas desejadas e as saídas obtidas pela rede, no melhor desempenho obtido, de 96,66% (apenas 3 erros).

Tabela 1. Parâmetros das redes.

Redes	Neurônios	Épocas	Taxa
Rede 1	10	1000	0,1
Rede 2	5	1000	0,1
Rede 3	3	3000	0,1
Rede 4	5	2000	0,01
Rede 5	5	4000	0,1

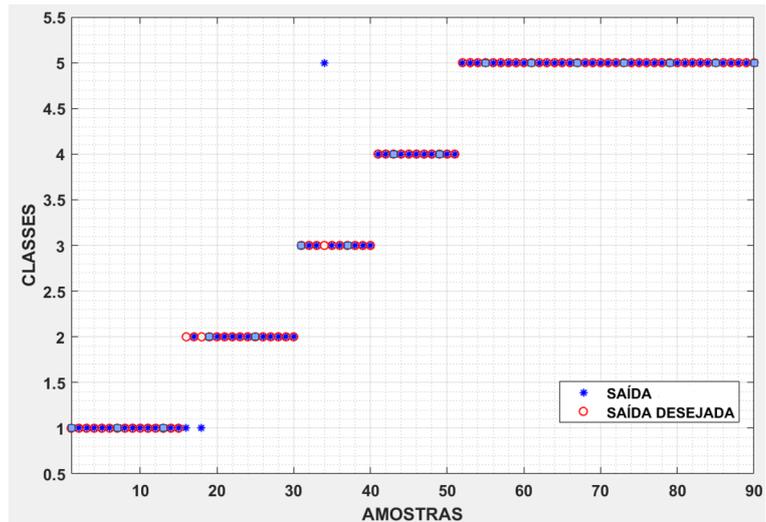


Figura 1: Saída do modelo x Saída desejada.

Percebe-se, então, que a técnica proposta de Redes Neurais Artificiais Especialistas obteve boa acurácia na classificação de falhas em transformadores a óleo, podendo ser utilizada como auxiliadora de tomada de decisão por parte do engenheiro/técnico responsável pela manutenção dos equipamentos. O objetivo é ser capaz de evitar grandes prejuízos e custos operacionais desnecessários, a partir de um monitoramento adequado. Para trabalhos futuros, pretende-se aplicar outras técnicas de inteligência artificial, para comparação de desempenho.

## Referências

- [1] Haykin, S. *Redes Neurais, 2a. edição*. Bookman, 2001.
- [2] MathWorks. *Software MATLAB*. Disponível em: <<https://www.mathworks.com/>>.
- [3] Milasch, M. *Manutenção de Transformadores em Líquido Isolante, 1a. edição*. Blucher, 1984.
- [4] Moraes, H. R. S. *Redes Neurais Profundas Aplicadas ao Diagnóstico de Falhas Incipientes em Transformadores Imersos em Óleo Isolante*. Dissertação de Mestrado. Universidade Federal do Pará. 2019.
- [5] Souza Filho, J. B. O. *Classificação Neural de Sinais de Sonar Passivo*. Dissertação de Doutorado. Universidade Federal do Rio de Janeiro. 2007.