

# REDE BAYESIANA PARA ESTIMAÇÃO DE FALHAS INCIPIENTES EM TRANSFORMADORES DE POTÊNCIA UTILIZANDO DETECÇÃO DE DESCARGAS PARCIAIS POR EMISSÃO ACÚSTICA

Pedro Henrique da S. PALHARES<sup>1</sup>, Leonardo da C. BRITO<sup>1</sup>, Cacilda de J. RIBEIRO<sup>1</sup>, André P. MARQUES<sup>2,3</sup>, Cláudio Henrique B. AZEVEDO<sup>2</sup>.

<sup>1</sup>Escola de Engenharia Elétrica e de Computação, Universidade Federal de Goiás

<sup>2</sup>CELG Distribuição, <sup>3</sup>Instituto Federal de Goiás

palhares@posgrad.ufg.br, brito@eeec.ufg.br, cacilda@eeec.ufg.br,

andre.pm@celg.com.br, claudio.hb@celg.com.br

**Palavras Chave** – redes bayesianas, redes neurais, degradação, transformadores de potência.

## 1 Introdução

De fundamental importância para a transmissão e distribuição de energia elétrica, os transformadores de potência são equipamentos de custo elevado. Durante sua operação, podem surgir defeitos em sua isolação, provocando uma diminuição de sua capacidade dielétrica. Segundo [1], a diminuição desta capacidade pode provocar o surgimento de descargas parciais (DPs) dentro do transformador de forma inesperada e de difícil detecção. Detectar defeitos incipientes de funcionamento nesses transformadores é de interesse econômico e operacional, uma vez que permite intervenções preventivas que evitem danos graves ao transformador o que, por conseqüência, garante maior continuidade e elevam a confiabilidade do fornecimento de energia elétrica aos – cada vez mais exigentes – consumidores.

Atualmente, têm-se utilizado vários métodos de detecção de descargas parciais: o elétrico, o químico (análise de gases dissolvidos ou AGD) e o acústico. Neste trabalho destacamos o método de detecção por emissão acústica que apresenta a vantagem de localização da descarga dentro do equipamento sem que haja a necessidade de se retirá-lo de operação [1], evitando-se descontinuidade no fornecimento da energia elétrica. Vários trabalhos na literatura, [2]-[4], abordam o problema da identificação de DPs. Nesses trabalhos, apresentam-se métodos

computacionais dirigidos à identificação dos possíveis defeitos no interior dos transformadores aplicando Redes Bayesianas (RB) e Redes Neurais (RN). Diferentemente dos trabalhos referenciados, este propõe prover ao engenheiro de manutenção uma metodologia capaz de auxiliá-lo na tomada de decisões quanto à manutenção preventiva dos transformadores, indicando provável severidade de degradação da isolação do transformador e, conseqüentemente, sugerindo uma ação preventiva. Neste caso, a tomada de decisão subjetiva, caracterizada como um processo de inferência probabilística, é realizada por meio de uma Rede de Crença Bayesiana, a qual apresenta as seguintes vantagens qualitativas frente à abordagem por RN: i) uma RN tem uma representação limitada, mapeando entrada-saída unidirecionalmente na forma de uma “caixa-preta”, impossibilitando a identificação de correlações entre as variáveis do problema de decisão; e ii) uma RB permite constatar essas correlações diretamente, além de explicitamente trabalhar com probabilidades (graus de crença) reais. Investiga-se também o desempenho quantitativo da RB frente a uma RN.

## **2 Material e Métodos**

Devido à grande dificuldade e custo da interrupção do funcionamento dos transformadores, tornou-se necessário o desenvolvimento de um método que fosse capaz de detectar descargas parciais (DPs) sem que houvesse o desligamento dos transformadores, surgindo então o método da Emissão Acústica (EA), descrito em [1]. Cada DP age como uma fonte de ondas acústicas as quais propagam no interior do transformador, através do óleo, e podem ser detectadas nas paredes exteriores do tanque do equipamento [1]. Como são utilizados diversos sensores (quatorze, neste trabalho), torna-se possível a triangulação do sinal.

É sabido que as descargas mais intensas ocorrem nos picos e vales de tensão, ou seja, a  $90^\circ$  e a  $270^\circ$  da tensão senoidal de fornecimento de energia elétrica, respectivamente. Os eventos que ocorrem em ângulos diferentes são considerados ruído. Tendo-se a quantidade de descargas ocorridas, o nível de ruído e o montante de energia, é possível então criar um método para identificação dos transformadores em melhor estado e os de estado mais precário, sob a ótica de descargas parciais.

### **2.1 Rede Bayesiana**

A utilização de Rede Bayesiana (RB) é particularmente adequada ao processo de identificação de transformadores defeituosos, pois se configura como uma ferramenta probabilística de representação do conhecimento. Em geral, uma RB é representada por sua estrutura, um grafo acíclico direcional (GAD), e por seus parâmetros que são constituídos de probabilidades condicionais. Cada nó do GAD representa uma variável estocástica e cada aresta representa dependências condicionais observáveis no mundo real. É possível aprender tanto a estrutura, quanto os parâmetros de uma RB, desde que se tenha uma base de treinamento representativa da mesma.

### 2.1.1 Teorema de Bayes

O Teorema de Bayes é a base da teoria de Redes Bayesianas, fornecendo em uma fórmula matemática, uma maneira de se calcular probabilidades condicionais. Sua utilidade para Redes Bayesianas encontra-se na atualização de probabilidades de variáveis não observadas, em face de novas evidências. Sabendo que  $P(x|e)$  é probabilidade de  $x$  dada a evidência  $e$ ,  $P(e|x)$  a verossimilhança de  $P(x|e)$ ,  $P(x)$  e  $P(e)$  as probabilidades a priori de  $x$  e  $e$ , respectivamente, tem-se:

$$P(x|e) = \frac{P(e|x) \cdot P(x)}{P(e)} \quad (1)$$

### 2.1.2 Construção da Rede Bayesiana

O aprendizado da RB pode ser feito através do aprendizado de parâmetros em possíveis estruturas e posterior escolha do modelo que mais se encaixe com os dados usados para treinamento. Este trabalho utilizou o método MLE (*Maximum Likelihood Estimation*) descrito em [5] para aprendizado dos parâmetros e os métodos K2 [5] e *Hill-Climbing* [5] e [6], onde se aprende duas estruturas e a melhor delas é escolhida.

### 2.1.3 Motor de Inferência

O motor de inferência utilizado pela RB deste trabalho foi implementado utilizando o processo de eliminação de variáveis (*Variable Elimination*). É um dos métodos mais simples, porém poderoso, em que as consultas são feitas através de sucessivas eliminações de variáveis da RB [7].

## 3 Resultados e Discussão

Para se construir o classificador, foram utilizados resultados de seis ensaios realizados em transformadores, sendo que, em cada ensaio, foram monitorados dois transformadores simultaneamente. Logo, têm-se 12 amostras para se construir a RB. Foram gerados 100 casos para treinamento da RB e 88 adicionais que, em conjunto com as 12 amostras reais, foram utilizados para validar a rede.

Como é desejado detectar a possibilidade de falha nos transformadores, é importante levar em consideração a quantidade de descargas parciais, a quantidade de energia e a quantidade de ruído. A quantidade de descargas parciais em conjunto com a energia funciona como elemento indicador de defeito, enquanto que o ruído é um elemento penalizador. Assim, são definidos quatro nós: Classificação, Quantidade de Descargas Parciais, Ruído e Energia, sendo alimentados com as informações do canal com maior atividade (descargas parciais e ruído), pois é imprescindível prever o pior caso.

O procedimento proposto neste trabalho foi executado 30 vezes, sendo que se obteve uma média de acertos de 86,5%, um desvio padrão de 1,14%, obtendo uma taxa máxima de acertos de 89%.

Para comparar, uma Rede Neural (RN) *Perceptron* de Múltiplas Camadas, [8] e [9], foi implementada. Tomaram-se os valores logarítmicos de base 10 de (Energia, Quantidade de DPs, Ruído) como seu vetor de entrada e a (Classificação), cujo valor numérico é um dentre {4 – Péssimo, 3 – Ruim, 2 – Bom, 1 – Ótimo}, como sua saída. Treinou-se a RN com 100 exemplos, validou-se com mais 50 e testou-se com outros 50. Variou-se o número de neurônios sigmoidais da camada oculta de 1 a 10, executando-se 100 treinamentos independentes para cada configuração da RN, e aplicando-se o algoritmo Levenberg–Marquardt. Obteve-se um máximo de 83% de classificações corretas com 5 neurônios na camada oculta, sendo esta então inferior à abordagem por Rede Bayesiana proposta neste trabalho.

#### **4 Conclusões**

Neste resumo, descreveu-se a aplicação de uma rede bayesiana adequada à classificação de níveis de falhas incipientes em transformadores de potência, indicando o estado do transformador, mas também qual a porcentagem de crença no resultado. A metodologia proposta foi comparada à uma abordagem por Rede Neural, tendo-se obtido um melhor desempenho por parte da primeira.

Novos ensaios em transformadores estão sendo programados para serem realizados na concessionária de energia, os quais servirão para alimentar a RB. É possível que, na medida em que forem feitos novos ensaios, a metodologia seja ampliada para também identificar o tipo de defeito no transformador.

## 5 Agradecimentos

Os autores agradecem à CELG Distribuição (CELG D) por todo apoio ao trabalho e à Capes/MEC pelo suporte financeiro.

## 6 Referências Bibliográficas

- [1] E. Mohammadi, M. Niroomand, M. Rezaeian, Z. Amini, Partial Discharge Localization and Classification Using Acoustic Emission Analysis in Power Transformer, **31<sup>st</sup> International Telecommunications Energy Conference - INTELEC 2009**, 2009.
- [2] W. H. Tang, Z. Lu, Q. H. Wu, A Bayesian Network Approach to Power System Asset Management for Transformer Dissolved Gas Analysis, **third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies**, 2008.
- [3] X. Hao, S. Cai-xin, Artificial Immune Network Classification Algorithm for Fault Diagnosis of Power Transformer, **IEEE TRANSACTIONS ON POWER DELIVERY, Vol. 22, No. 2**, 2007.
- [4] C. Kuo, Artificial recognition system for defective types of transformer by acoustic emission, **Expert Systems with Applications**, 36, 2009, 10304 - 10311.
- [5] F. V. Jensen, T. D. Nielsen, Bayesian Networks and Decision Graphs. 2nd edition, **Springer**, 2007.
- [6] T. Pansombut, Learning Bayesian Belief Networks. Department of Computer Science, **North Carolina State University**, 2006.
- [7] A. Darwiche, Modeling and Reasoning with Bayesian Networks, **Cambridge University Press**, 2009.
- [8] Z. Michalewicz, D. B. Fogel, How To Solve It: Modern Heuristics, **Springer**, 2000.
- [9] S. Haykin, Redes Neurais: Princípios e Prática, **Bookman**, 1999.