



**XXIII SNPTEE
SEMINÁRIO NACIONAL
DE PRODUÇÃO E
TRANSMISSÃO DE
ENERGIA ELÉTRICA**

FI/GSE/23
18 a 21 de Outubro de 2015
Foz do Iguaçu - PR

GRUPO – VIII

GRUPO DE ESTUDO DE SUBESTAÇÕES E EQUIPAMENTO DE ALTA TENSÃO - GSE

**DETECÇÃO DE DEFEITOS EM ISOLADORES DE SUBESTAÇÕES DE ALTA TENSÃO
BASEADA NA ANÁLISE DO RUÍDO AUDÍVEL.**

Leonardo Antonio Barbosa Lasalvia (*)
CHESF

Tarso Vilela Ferreira
UFCG

Edson Guedes da Costa
UFCG

Marcus Tullius Barros Florentino
Copele - UFCG

RESUMO

Este trabalho apresenta o aperfeiçoamento de uma técnica de manutenção preditiva utilizando o método de emissão acústica para extração de atributos do sinal sonoro baseada na análise do ruído audível para classificação do estado de integridade de isoladores de porcelana. Dessa maneira, foram realizados ensaios de emissão acústica em campo, na subestação de Jardim, da Companhia Hidroelétrica do São Francisco, para obtenção dos ruídos audíveis que, por sua vez, foram armazenados, tratados e agrupados em banco de dados para posterior implementação computacional. O sinal sonoro foi decomposto numa análise multiresolucional utilizando a Transformada *wavelet Packet* para gerar as matrizes de energia dos coeficientes *wavelet*. Por fim, para validar o método utilizado e agregar confiabilidade, automação, capacidade de generalização e adaptação a novas situações, as matrizes de energia foram apresentadas a uma Rede Neural Artificial *perceptron* de três camadas associada ao algoritmo de aprendizagem *Resilient Propagation*, classificando os equipamentos em dois padrões desejados: isoladores íntegros e isoladores com defeito, obtendo, assim, uma taxa de acerto de aproximadamente 85%.

PALAVRAS-CHAVE

Emissão Acústica, Isoladores, Redes Neurais Artificiais, Ruído Audível, Transformada *wavelet Packet*.

1.0 - INTRODUÇÃO

A energia elétrica é um insumo imprescindível para os diversos sistemas da sociedade moderna, e necessário para o desenvolvimento do país. A interrupção no fornecimento desta energia causa grandes transtornos à população, que se encontra cada vez mais exigente em relação à qualidade dos serviços prestados pelas concessionárias de energia elétrica. Isso é um fator importante para a imagem e, como consequência, para a saúde financeira destas empresas. Aliado a isso, as novas regras do setor elétrico, como a licitação das novas obras na área de geração e transmissão de energia elétrica, a criação dos Produtores Independentes de energia, o livre acesso aos sistemas de transmissão e distribuição e a liberdade dos consumidores em escolher seus próprios fornecedores de energia elétrica, aumentam as responsabilidades sobre as empresas envolvidas. Dentro deste novo cenário, a Companhia Hidro Elétrica do São Francisco (Chesf) e demais empresas do setor elétrico iniciaram um movimento de reestruturação com foco na modicidade tarifária, e para isso, dentre outras ações, foi necessário aperfeiçoar os processos de manutenção com o desafio de diminuir os custos, mantendo a qualidade dos serviços prestados e o compromisso de melhorar o controle e acompanhamento dos seus ativos, investindo em novas tecnologias e melhorando a confiabilidade do Sistema Elétrico de Potência (SEP).

Atualmente, a Chesf dispõe de algumas técnicas de manutenção preventiva para a detecção de defeitos em isoladores de porcelana encontrados nas suas subestações, tais como inspeções visuais, sonoras, por iluminação solar, com a utilização de isolômetro, noturna, aérea, termovisão, dentre outras. São técnicas que visam buscar um

(*) Avenida Silvério Leite Fontes, n° 233 – casa 48 - CEP 49000-001 Aracaju, SE – Brasil
Tel: (+55 79) 31142060 – Fax: (+55 79) 3114-2084 – Email: lasalvia@chesf.gov.br

diagnóstico preciso para as ações corretivas por parte das equipes de manutenção e que antecipem uma possível falha e consequente perda no fornecimento de energia elétrica e de receita para a empresa. Contudo, percebe-se que a dependência do fator humano na execução das atividades e na tomada de decisão, bem como o envelhecimento dos equipamentos, a estrutura dos planos de manutenção, os processos de contratação, dentre outros aspectos, podem afetar consideravelmente os resultados e comprometer as ações corretivas subsequentes. Como exemplo, as consequências de um curto-circuito provocado por um isolador trincado podem ser visualizadas na Figura 1.



(a)



(b)

Figura 1 – Curto-circuito provocado por uma trinca em um isolador de pedestal. (a) Visão Inferior; (b) Visão lateral.

Desta forma, verifica-se que, apesar de todas as técnicas de manutenção existentes para detecção de defeitos em barramentos de subestações, ainda se faz necessário incorporar, nos processos de inspeções e manutenções preventivas, procedimentos adicionais que permitam identificar uma possível falha antes que a mesma ocorra.

2.0 - MATERIAL E MÉTODOS

Este trabalho foi desenvolvido com o intuito de gerar padrões que identifiquem o estado de integridade dos isoladores de porcelana, amplamente utilizados nos barramentos de subestações das empresas de energia elétrica do país, utilizando uma Rede Neural Artificial (RNA). Dessa maneira, os métodos de inspeção acústica, bem como tratamento dos dados, são apresentados a seguir.

2.1 Captação dos ruídos audíveis (RA) dos isoladores de pedestal

Na tentativa de se criar um banco de dados consistente para que fosse possível fazer as comparações de padrões, os Isoladores de Pedestal Tipo Leve (IPTL), das bases de chaves seccionadoras com nível de tensão de 69 kV, foram definidos como elementos de teste. Tanto os isoladores íntegros quanto os isoladores defeituosos, utilizados nos ensaios, possuem as mesmas características técnicas, ou seja, mesma fabricação e tipificação, como pode ser visto na Figura 2. Além disso, estes equipamentos possuem histórico de falhas mecânicas e elétricas.




Figura 2 – IPTL utilizado nos ensaios de emissão acústica.

Os Ruídos Audíveis (RA) foram captados por um gravador digital acoplado ao bastão isolante, como pode ser visto na Figura 3(a), utilizando uma ferramenta de percussão denominada Maxímetro, que pode ser vista na Figura 3(b).

A sequência do ensaio é representada pela seta amarela, indicando que a percussão é realizada na primeira saia (S1) e depois na segunda saia (S2). Foram armazenadas 220 amostras para os isoladores íntegros, sendo 110 para a primeira saia e 110 para a segunda saia.



(a)



(b)

Figura 3 – Ensaio de emissão em campo. (a) Gravador digital; (b) Percussão do isolador com o Maxímetro.

O mesmo procedimento foi realizado para os isoladores defeituosos, levando em consideração a posição da trinca. As referências de posição adotadas são apresentadas na Figura 4. Isso permitiu que a RNA, no seu processo de aprendizagem, considerasse as diferenças sonoras quando uma saia fosse percutida em diferentes posições do isolador. Um total de 400 amostras foram armazenadas para os isoladores defeituosos, sendo 200 para a primeira saia e 200 para a segunda saia. Após a execução dos ensaios, os RA foram armazenados em computador e tratados para posterior análise.




Figura 4 – Distribuição dos quadrantes no isolador trincado.

2.2 Criação de banco de dados

Antes de iniciar o estudo dos sinais sonoros captados nos ensaios de emissão acústica, foi necessário desenvolver uma rotina no Matlab para executar as operações apresentadas a seguir.

- i. Abrir cada arquivo sonoro;
- ii. Ajustar o tamanho de todos os arquivos;
- iii. Separar os arquivos em quatro classes, representadas da seguinte forma:

- bdS1B: Banco de dados com todos os RA extraídos da primeira saia de todos os isoladores bons. Resultou numa matriz de 9312 linhas por 110 colunas, como pode ser visualizado na Figura 5(a);
- bdS2B: Banco de dados com todos os RA extraídos da segunda saia de todos os isoladores bons. Resultou numa matriz de 9312 linhas por 110 colunas;
- bdS1R: Banco de dados com todos os RA extraídos da primeira saia de todos os isoladores ruins. Resultou numa matriz de 9312 linhas por 200 colunas, como pode ser visualizado na Figura 5(b);
- bdS2R: Banco de dados com todos os RA extraídos da primeira saia de todos os isoladores ruins. Resultou numa matriz de 9312 linhas por 200 colunas.




Figura 5 – Sinais de detecção de Ruído Audível. (a) RA extraídos da primeira saia de todos os isoladores íntegros.
(b) RA extraídos da primeira saia de todos os isoladores defeituosos.

2.3 Estudo da *wavelet*-mãe

A fim de possibilitar a melhor caracterização ou extração de atributos do sinal sonoro captado, realizou-se um estudo para definir qual a *wavelet* mãe mais adequada para o processamento deste tipo de sinal não estacionário. A análise de um sinal de acordo com uma escala, multi-escalas ou ainda sub-bandas de frequência é a ideia fundamental da teoria Wavelet. A Transformada Wavelet propicia a decomposição de uma função Wavelet através de escalamentos e translações. Essas escalas comprimem ou dilatam uma *Wavelet-mãe* $\psi_{a,b}(t)$ definida em (1).

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi_{a,b} \left(\frac{t-b}{a} \right); a, b \in \mathbb{R}, a \neq 0, \quad (1)$$

em que a variável contínua a está relacionada a resolução em frequência e realiza o escalamento da *Wavelet*-mãe ($\psi_{1,0}$); a variável contínua b está relacionada a resolução temporal e realiza a translação da *Wavelet*-mãe; o fator multiplicador $1/\sqrt{|a|}$, normaliza a energia wavelet através das diferentes escalas e translações.

O procedimento consiste em calcular o coeficiente C de correlação entre o trecho do sinal e a *wavelet* escolhida, onde C é a Transformada *Wavelet* Contínua (TWC) definida em (2). Quanto maior o valor de C , maior será a similaridade entre o sinal de entrada e a *wavelet* escolhida.

$$TWC_x(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \psi \left(\frac{t-b}{a} \right) dt \quad (2)$$

Para este estudo, uma amostra de RA foi escolhida aleatoriamente dentre os 620 RA gravados nos ensaios de emissão acústica. Tal amostra foi decomposta empregando-se a TWC para as famílias *wavelets* implementadas em *Matlab*, *Daubechies*, *Coiflets*, *Symlets*, *Discrete Meyer*, *Biorthogonal* e *Reverse Biorthogonal*, com o propósito de identificar a *wavelet* que guarda a maior correlação com o tipo de sinal analisado, garantindo assim boa eficiência na transferência de energia para as sub-escalas a serem obtidas na Transformada Wavelet Packet (TWP). As matrizes com os valores de coeficiente de correlação entre o sinal sonoro escolhido e cada família *wavelet* foram geradas. Como o sinal sonoro possui 9312 elementos e foram realizadas 50 escalas, é gerada uma matriz com todos os valores da TWC para cada elemento em cada escala realizada, como pode ser visualizado na

Figura 6. Como critério de escolha, foi considerado o valor médio de todos os coeficientes de correlação gerados pela TWC.




Figura 6 – Distribuição dos valores da TWC para 9312 elementos do RA escolhido, com 50 escalas.

2.4 Cálculo das energias dos coeficientes *wavelet* associado à Rede Neural Artificial

Após definição da *wavelet*-mãe, utilizou-se a Transformada *Wavelet Packet* (TWP) para o cálculo da energia dos coeficientes *wavelet* a partir da análise multi-resolucional destacando as características do sinal sonoro em todo seu espectro. Foram realizadas decomposições em dois níveis, o que na TWP origina seis coeficientes *wavelet*, divididos nos ramos de detalhe e aproximação (A, D, AA, AD, DA e DD), obtidos pela convolução dos coeficientes de aproximação com os filtros passa-alta e passa-baixa, respectivamente, o que pode ser visto na Figura 7.




Figura 7 – Coeficientes da TWP nos ramos de aproximação e detalhe.

Desta forma, utilizando a TWP para a *wavelet*-mãe escolhida, as matrizes de energia S1B, S2B, S1R e S2R foram geradas para os bancos de dados bdS1B, bdS2B, bdS1R e bdS2R, constituindo assim as entradas da RNA, como exemplificadas na Figura 8.

As matrizes de energia foram processadas por uma rede MLP (*Multilayer Perceptron*) de três camadas, sendo uma camada de entrada representada por seis unidades sensoriais, uma camada oculta representada por 15 neurônios e uma camada na saída representada por 2 neurônios de saídas complementares, ou seja, exclusivas entre si. Utilizou-se uma função de ativação linear na saída da rede e para a camada oculta foi escolhida a função tangente hiperbólica. A arquitetura da rede foi mantida para todas as execuções realizadas e pode ser visualizada na Figura 9.

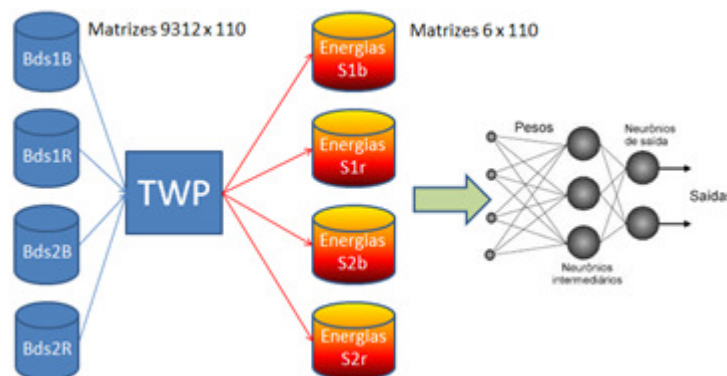


Figura 8 – Processo de geração das energias dos coeficientes *wavelet*.

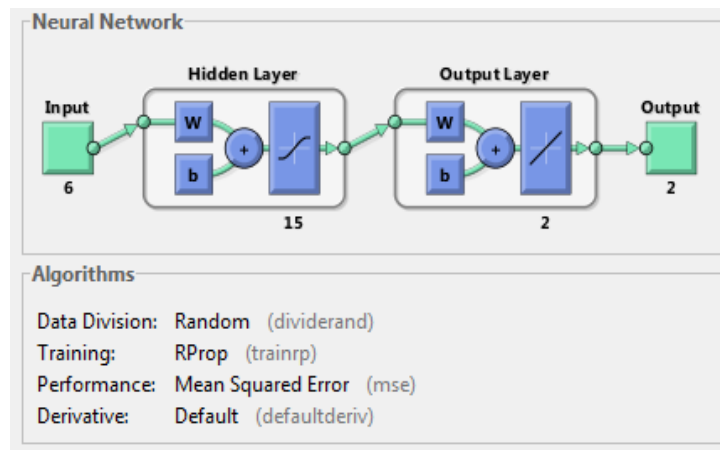


Figura 9 – Arquitetura da Rede Neural.

Estipulou-se uma série de dez execuções da RNA para cada família mais bem sucedida na análise realizada pela TWC, com o intuito de verificar a consistência dos resultados obtidos. Foram direcionados 70% dos padrões apresentados para treinamento e 30% para teste e validação. O algoritmo *Resilient Propagation* foi empregado para treinamento da RNA.

3.0 - RESULTADOS OBTIDOS

Os primeiros resultados das energias dos coeficientes wavelet já se mostraram promissores devido à caracterização das amostras referente aos padrões íntegros e defeituosos dos sinais de áudio captados nos ensaios de emissão acústica. Pode-se observar, nas Figuras 10(a) e 10(b), a diferença gráfica referente ao valor de energia do elemento quatro (coeficiente de detalhe do primeiro coeficiente de aproximação). Este comportamento reforça a correlação com o som emitido pela saia percussionada, uma vez que isoladores trincados emitem um som mais grave (presença de baixas frequências).




Figura 10 – (a) Energia dos coeficientes wavelet para **bdS1B**; (b) Energia dos coeficientes wavelet para **bdS1R**.

Pode-se observar na Figura 11, a relação entre o estudo da *wavelet*-mãe com os resultados da TWC, correlacionados com as taxas de acerto em teste da RNA, considerando as energias dos coeficientes *wavelet* para as famílias *Haar*, *Daubechies*, *Symlet*, *Coiflet*, *Discrete Meyer*, *Biorthogonal* e *Reverse Biorthogonal*.




Figura 11 – Valor médio para taxas de acerto para treinamento e teste versus valor da TWC.

Os melhores resultados obtidos pela RNA foram relacionados com a Família Wavelet Discrete Meyer, conforme visualizado na Tabela 1. As taxas de acerto médio em teste ficaram acima de 85%, convergindo em poucas épocas de treinamento.

Tabela 1 – Resultados RNA – Energias geradas pela TWP – família *Discrete Meyer*.

EXECUÇÕES	TREINAMENTO (%)	TESTE (%)	ERRO (EMS)
1	88,31	90,90	0,0978
2	83,44	83,33	0,1815
3	79,22	81,81	0,0969
4	89,61	90,90	0,1080
5	87,01	89,39	0,0885
6	82,79	87,87	0,1302
7	88,31	80,30	0,1215
8	88,31	83,33	0,0960
9	88,63	89,39	0,1142
10	89,61	81,81	0,1553
MÉDIA	86,52	85,90	0,1190

4.0 - CONCLUSÕES

Este trabalho apresentou um estudo sobre a caracterização de ruídos audíveis gerados a partir dos ensaios de emissão acústica realizados com o Maxímetro em isoladores de pedestal de porcelana de 69 kV, utilizando a Transformada *Wavelet Packet* associada a uma Rede Neural Artificial.

Verificou-se que os ensaios de emissão acústica realizados em campo, propiciaram a aquisição de dados confiáveis, através de uma técnica segura, de baixo custo, com independência da percepção humana, sem trazer qualquer tipo de risco ou influência para as pessoas e para o sistema elétrico de potência. Observou-se a boa aceitação do uso da Transformada *Wavelet Packet* para a extração de atributos dos ruídos audíveis captados nos ensaios em campo.

Foram realizadas execuções da Rede Neural Artificial, considerando as energias dos coeficientes *wavelet* produzidas pela TWP para as famílias *Haar*, *Symlet 1*, *Coiflet 1*, *Daubechies 4*, *Discrete Meyer*, *Biorthogonal 3.1*, *Biorthogonal 3.3*, *Biorthogonal 3.5*, *Reverse Biorthogonal 1.1*, *Reverse Biorthogonal 1.3*, *Reverse Biorthogonal 1.5* e *Reverse Biorthogonal 3.9*, com resultados satisfatórios de taxas de acertos em teste. Contudo, mesmo alcançando bons resultados, verificou-se que o estudo da TWC não foi conclusivo em relação ao desempenho da RNA, ou seja, valores altos da TWC, para determinadas famílias *wavelet*, não garantiram o melhor desempenho da rede neural. É preciso melhorar, dentre outros aspectos, na definição das escalas e na identificação do melhor trecho do sinal sonoro a ser processado pela TWC. Melhorias devem e podem ser implementadas no sentido de

melhorar as taxas de desempenho da RNA como, padronização no procedimento de aquisição dos ruídos audíveis, geração de bancos de dados de energia dos coeficientes das demais famílias *wavelet*, aumentar o número de execuções da RNA, utilizar o estudo de probabilidade associado aos resultados obtidos e modificações na própria arquitetura da RNA. Entretanto, pode-se afirmar que a determinação de isoladores íntegros ou defeituosos, utilizando a análise dos sinais sonoros pela TWP associados a rede neural artificial, é viável e de fácil operacionalização, além de ser uma técnica de baixo custo e extremamente importante na prevenção de falhas para o sistema elétrico de potência.

5.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ABNT, NBR 50328 - Isoladores para linhas aéreas com tensões acima de 1 000 V - Isoladores de porcelana ou vidro para sistemas de corrente alternada, 2ª edição – 2004.
- [2] Araújo, M. S. **Influência de Wavelets-mãe e da ordem delas no desempenho de um localizador de faltas em linhas aéreas de transmissão de energia elétrica**. Belem. Universidade Federal do Pará, 2011.
- [3] COSTA, B. F. **Uma Técnica de Diagnóstico em Tempo Real de Distúrbios Transitórios Baseada na Transformada Wavelet para Uso em Registradores Digitais de Perturbação**. UFCG. Campina Grande, Paraíba - Brasil. 2010.
- [4] FERREIRA, V. T. **Estimação inteligente da poluição de isolamentos elétricos baseada nos VECSE do ruído ultrassônico**. Universidade Federal de Campina Grande, 2011. Tese de Doutorado.
- [5] FUCHS, Rubens Dário: **Transmissão de Energia Elétrica**: Linhas Aéreas, Rio de Janeiro, Livros Técnicos e Científicos; Itajubá, Escola Federal de Engenharia, 1977.
- [6] HAYKIN, S. **Redes neurais, princípios e prática**. 2ª Edição. ed. Porto Alegre: Bookman, 2001.
- [7] MALLAT, S. G. A theory for multiresolution signal decomposition: The wavelet representation. **IEEE Transaction on Pattern Analysis and Machine Intelligence**, 11, 1989.
- [8] POLIKAR, R. Part I: Fundamental Concepts & an Overview of the Wavelet Theory. **The Wavelet Tutorial**, 1994. Disponível em: <<http://users.rowan.edu/~polikar/WAVELETS/WTpart1.html>>.

6.0 - DADOS BIOGRÁFICOS



Leonardo Antonio Barbosa Lasalvia nasceu em 1974 em Recife, Pernambuco, Brasil. Obteve os títulos de Bacharel e Mestre em Engenharia Elétrica, respectivamente, em 2001 (UFPE) e 2014 (UFCG). Atualmente gerencia a divisão regional de operação e manutenção de Aracaju – Chesf. Seus interesses de pesquisa incluem, dentre outros, monitoramento de equipamentos de alta tensão e inteligência artificial. Leonardo é membro do CIGRÊ.

Tarso Vilela Ferreira nasceu em 1980 em Aracaju, Sergipe, Brasil. Obteve os títulos de Bacharel, Mestre e Doutor, todos em Engenharia Elétrica, respectivamente, em 2005, 2007 e 2011 (UFCG). Atualmente, ele é professor na UFCG. Seus interesses de pesquisa incluem, dentre outros, monitoramento de equipamentos de alta tensão, processamento digital de sinais, inteligência artificial, qualidade de energia e eletrônica de potência. Dr. Ferreira é membro do IEEE desde 2011.

Edson Guedes da Costa nasceu em 1954 em Ribeirão, Pernambuco, Brasil. Obteve os títulos de bacharel, mestre e doutor em Engenharia Elétrica, respectivamente em 1978, 1981 e 1999 (UFPB). Atualmente é professor Titular da Universidade Federal de Campina Grande. Ele tem participado de vários projetos de pesquisa, como coordenador e como pesquisador, também é coordenador de projetos de cooperação internacional e é Bolsista de Produtividade em Pesquisa 2 do CNPq, Orientador de Mestrado e de Doutorado. Seus interesses profissionais incluem técnicas de alta tensão, monitoramento e diagnósticos de equipamentos de alta tensão, subestações, mapeamento de campo elétrico, descargas parciais, método dos elementos finitos, para-raios, aterramentos elétricos e sistemas de isolamento. Ele também é membro do CIGRÊ, IEEE, ABENGE e SBA e é revisor de vários periódicos e congressos nacionais e internacionais.

Marcus Tullius Barros Florentino nasceu em 1991 em Princesa Isabel, Paraíba, Brasil. Obteve o título de Bacharel em Engenharia Elétrica em 2014 (UFCG). Atualmente, ele realiza Mestrado pelo Programa de Pós-Graduação em Engenharia Elétrica na UFCG. Seus interesses de pesquisa incluem, dentre outros, monitoramento de equipamentos elétricos de alta tensão, inteligência artificial e qualidade de energia.