

Uso de Redes Neurais e da Transformada Wavelet Para Classificação de Distúrbios Registrados no Sistema de Oscilografia da CHESF

Crisluci K. S. Santos^{*}, Manoel Firmino de Medeiros Jr.^{*}, José Tavares de Oliveira^{*}, Adrião D. Dória Neto^{*}, Jorge D. de Melo^{*}, Paulo S. da M. Pires^{*}, Milde M. S. Lira⁺, José Júlio A. L. Leitão⁺

^{*}*Universidade Federal do Rio Grande do Norte*
CEP: 59072-970, Natal/RN

⁺*Companhia Hidrelétrica do São Francisco*
CEP: 50761-901, Recife/PE

E-mails: crisluci@dca.ufrn.br, firmينو@dca.ufrn.br, jtavares@ct.ufrn.br, adriao@dca.ufrn.br, jdmelo@dca.ufrn.br, pmotta@dca.ufrn.br, milde@chesf.gov.br, julio@chesf.gov.br

Resumo

Análises pós-despacho de sinais oriundos de registradores de perturbações fornecem muitas vezes informações importantes para identificação e classificação de distúrbios nos sistemas, visando a uma gestão mais eficiente do fornecimento de energia elétrica. Para auxiliar nessa tarefa, faz-se necessário recorrer a técnicas de processamento de sinais, a fim de automatizar o diagnóstico sobre os tipos de distúrbio presentes nos sinais registrados. A transformada wavelet constitui-se em uma ferramenta matemática bastante eficaz na análise de sinais de tensão ou corrente, obtidos imediatamente após a ocorrência de distúrbios na rede. Este artigo apresenta uma metodologia baseada na transformada wavelet discreta e na comparação de curvas de distribuição da energia de sinais, com e sem distúrbio, para diferentes níveis de resolução de sua decomposição, com o objetivo de obter descritores que permitam a sua classificação. Os sinais analisados no presente trabalho foram obtidos por meio de equipamentos registradores, instalados no sistema CHESF, e disponibilizados pela Empresa para esse propósito.

1. Introdução

A atual complexidade do sistema elétrico, aliada às novas demandas por parte dos consumidores e à privatização do setor, tem tornado o mercado de energia cada vez mais competitivo e exigente.

Com isso, a análise mais eficiente de uma perturbação no sistema passou a ser de fundamental importância em busca de melhores índices de qualidade da energia elétrica. Para a correção desses problemas, é necessário que estes sejam previamente detectados e classificados. Entretanto, a simples inspeção do sinal pode não identificar o tipo de fenômeno presente na sua forma de onda. Um dos principais objetivos da análise consiste em extrair informações relevantes sobre o processo ao qual o sinal está associado. A transformada wavelet constitui-se em uma ferramenta matemática bastante eficaz na análise de sinais de tensão em sistemas de potência, obtidos imediatamente após a ocorrência de distúrbios na rede. Utilizando as propriedades da transformada wavelet, pode-se extrair informações importantes do sinal distorcido analisado, as quais podem ser utilizadas para se definir descritores para os principais distúrbios da perda da qualidade de energia elétrica. Entre as vantagens dessa transformada pode-se citar a

decomposição em multiresolução, a reconstrução do sinal de entrada, a utilização de funções bases suaves e obtenção de algoritmos com baixa complexidade computacional.

Neste trabalho, utilizou-se a transformada wavelet discreta (DWT) ([1]). Para tal, adotou-se o esquema lifting, no qual um sinal amostrado no tempo é transformado para o domínio wavelet através de técnicas de filtragem digital.

O objetivo desse trabalho é apresentar um procedimento alternativo, baseado em ([2]) para caracterização de distúrbios responsáveis pela perda da qualidade de energia elétrica, através da transformada wavelet e da utilização de Redes Neurais Artificiais (RNAs). Através da decomposição de um sinal em wavelets, foi possível definir descritores que permitiram chegar a um padrão característico para os principais distúrbios presentes nas ondas de tensão. Os descritores definidos pela metodologia proposta foram usados para classificar os distúrbios, utilizando uma arquitetura de Rede Neural Artificial.

2. Sinais analisados

A princípio, os sinais utilizados na base de dados foram capturados através dos RDPs (Registrador Digital de Perturbações) tipo ION 7700 da Rede de Qualimetria da CHESF (Companhia Hidro Elétrica do São Francisco). O ION 7700 apresenta uma taxa de amostragem máxima de 128 amostras/ciclo e registra o sinal durante 14 ciclos. Devido ao reduzido número de IONs configurados para capturar sinais de distúrbios nesta taxa de amostragem, optou-se pelo uso dos sinais registrados através da Rede de Oscilografia, também da CHESF. Esta rede de monitoração é composta atualmente por 370 oscilógrafos, cuja taxa de amostragem varia de 20 a 256 amostras/ciclo. A base de dados possui sinais de distúrbios de tensão em vários pontos do sistema de transmissão da CHESF nos níveis de 69 kV, 230 kV e 500 kV, coletados a uma taxa de amostragem de 128 amostras/ciclo durante 14 ciclos ([3]).

Analisaram-se, através dos sinais de tensão registrados, quatro tipos de distúrbios na rede: transitórios, distorções harmônicas, elevação e afundamento de tensão. A título de exemplo, as Figuras 1 e 2 mostram os gráficos gerados por sinais registrados para os eventos de elevação e afundamento de tensão.

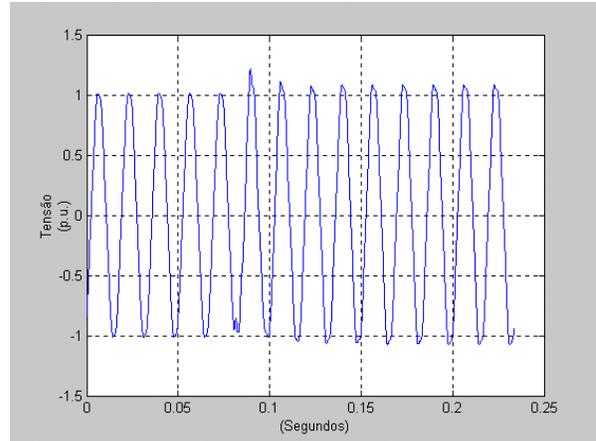


Figura 1. Gráfico de tensão obtido para um sinal com elevação de tensão.

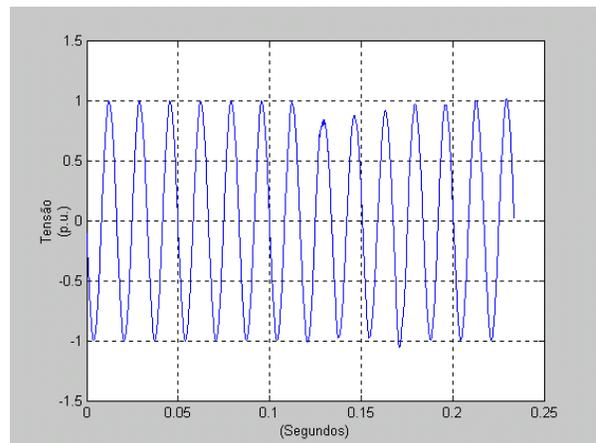


Figura 2. Gráfico de tensão obtido para um sinal com afundamento de tensão.

3. Fundamentos da teoria wavelet

Um dos principais objetivos da análise de sinais é extrair informações relevantes sobre o processo ao qual o sinal está associado. Geralmente, a análise é associada a uma transformação, a qual está fundamentada em técnicas de representação e reconstrução de sinais. A análise wavelet ([1]), da mesma forma que a análise de Fourier, se fundamenta na utilização de funções-base. A Teoria de Fourier utiliza as funções seno e cosseno. Já na análise wavelet, pode-se escolher a função base a ser utilizada. Tais funções são designadas wavelets de análise ou wavelets mães.

A transformada wavelet se mostra uma poderosa ferramenta para análise de sinais de sistemas de potência. Entre as vantagens da transformada wavelet se pode citar a decomposição em multiresolução, reconstrução do sinal de entrada, funções bases suaves e algoritmos com baixa complexidade computacional ([4]).

3.1. A transformada wavelet de segunda geração

A transformada wavelet discreta (DWT) consiste em transformar um sinal discreto no domínio do tempo para o domínio wavelet.

Para tal, utiliza-se o esquema *lifting*, no qual um sinal amostrado no tempo é transformado para o domínio wavelet através de técnicas de filtragem digital. A principal característica do esquema *lifting* é que todas as construções são derivadas no domínio do tempo, contrastando com a abordagem tradicional, a qual é no domínio da frequência. O esquema *lifting* é um algoritmo originalmente projetado para computar *wavelets* de segunda geração de uma maneira eficiente ([5]).

Wavelets de primeira geração são funções wavelets tradicionalmente definidas como dilatações e translações de uma função particular, a wavelet-mãe. Quando as wavelets não são necessariamente transladadas e dilatadas de uma determinada função, mas mantém, todavia, as propriedades das *wavelets* da primeira geração são chamadas de wavelets de segunda geração ([6]).

A principal diferença para a construção clássica é que o esquema *lifting* não é introduzido usando a transformada de Fourier, o que, então, pode ser usado para construir *wavelets* da segunda geração.

Esse esquema, ilustrado na Figura 3, envolve três etapas principais: SPLIT, PREDICT e UPDATE ([7]).

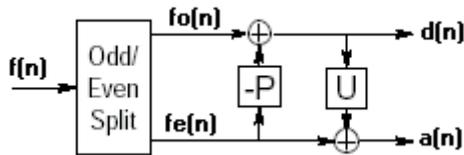


Figura 3. Esquema Lifting.

A etapa SPLIT divide o sinal de entrada, $f(n)$, em dois subconjuntos, um com os elementos de índice par, $f_e(n)$, e outro com os elementos de índice ímpar, $f_o(n)$.

$$\begin{aligned} f_e(n) &= f(2n) \\ f_o(n) &= f(2n+1) \end{aligned}$$

Na etapa PREDICT são gerados os coeficientes wavelets $d(n)$ pela diferença de $f_o(n)$ com $f_e(n)$ usando o operador de predição P :

$$d(n) = f_o(n) - P(f_e(n)).$$

A etapa UPDATE gera os coeficientes wavelets $a(n)$ que representam uma aproximação do sinal original $f(n)$. Este coeficiente é obtido pela soma de $f_e(n)$ com o operador update U para $d(n)$:

$$a(n) = f_e(n) + U(d(n)).$$

Uma explanação detalhada do processo de *lifting* pode ser encontrada em ([6]) e ([7]).

3.2. A metodologia utilizada

Utilizando as propriedades da transformada wavelet, pode-se extrair informações importantes do sinal distorcido, as quais podem ser utilizadas para identificar os principais distúrbios da qualidade de energia. A metodologia proposta ([8]), foi desenvolvida adotando um esquema de *lifting* e foi programada para utilização em plataforma Scilab (<http://www.scilab.org>). Os procedimentos podem ser resumidos em quatro etapas:

- Etapa 1: constitui-se em decompor o sinal com distúrbio em diferentes níveis de resolução. Isso é conseguido mediante a determinação dos coeficientes wavelet do sinal;
- Etapa 2: compreende o cálculo da energia concentrada em cada um dos níveis de decomposição;

A determinação das energias está fundamentada no *teorema de Parseval* ([8]), que estabelece: “a energia contida no sinal distorcido é igual à soma das energias concentradas nos diferentes níveis de resolução da sua transformada wavelet”. Isso significa que a energia do sinal pode ser decomposta em termos dos seus coeficientes wavelets, na forma:

$$\sum_{n=1}^N |f(n)|^2 = \sum_{n=1}^N |a_j(n)|^2 + \sum_{j=1}^J \sum_{n=1}^N |d_j(n)|^2 \quad (1)$$

As variáveis utilizadas nessa equação têm o seguinte significado:

$f(n)$: representa o sinal distorcido, amostrado no domínio do tempo;

N : corresponde ao número total de amostras do sinal;

$\sum_{n=1}^N |f(n)|^2$: energia do sinal analisado;

$\sum_{n=1}^N |a_j(n)|^2$: energia concentrada na versão aproximada de nível “j” do sinal analisado;

$\sum_{j=1}^J \sum_{n=1}^N |d_j(n)|^2$: energias concentradas nas versões detalhadas de níveis de 1 a “j” do sinal analisado.

•Etapa 3: consiste na repetição das etapas 1 e 2, porém apenas para a componente senoidal do sinal em análise. Esta componente foi obtida no ATP simulando a rede analisada sem nenhum defeito;

•Etapa 4: finalmente, faz-se uma comparação entre as energias concentradas em cada um dos níveis do sinal com distúrbio (obtida na etapa 2) e do sinal senoidal (obtida na etapa 3). Esta comparação é feita através do cálculo da diferença percentual entre as distribuições das energias dos sinais com distúrbio e senoidal de referência. O cálculo é feito segundo a relação:

$$dp(j)(\%) = \left[\frac{en_dis(j) - en_ref(j)}{\max(en_ref)} \right] * 100 \quad (2)$$

sendo,

j : nível da transformada;

$dp(j)(\%)$: diferença percentual entre as distribuições de energias dos sinais com distúrbio e senoidal sem distúrbio em cada nível da versão detalhada;

$en_dist(j)$: energia concentrada em cada nível da versão detalhada do sinal com distúrbio;

$en_ref(j)$: energia concentrada em cada nível da versão detalhada do sinal senoidal de referência;

$\max(en_ref)$: maior energia dos dez níveis do sinal senoidal de referência.

A Figura 4 mostra o gráfico da diferença percentual das energias dos sinais com e sem distúrbio nos diferentes níveis da versão detalhada.

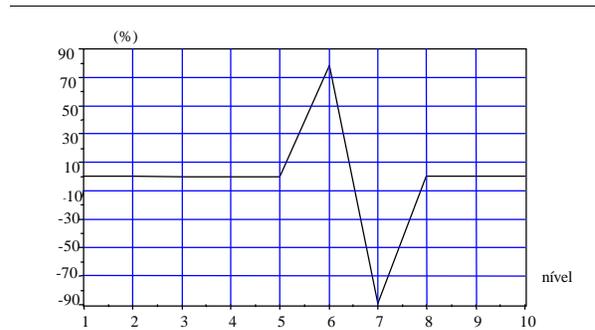


Figura 4. Gráfico da diferença percentual das energias dos sinais com e sem distúrbio nos diferentes níveis da versão detalhada para o caso de uma elevação de tensão no sistema.

Através da metodologia apresentada, foi possível definir descritores que permitiram chegar a um padrão característico para os tipos de distúrbios estudados ([2]).

4. Utilização de redes neurais para classificação dos distúrbios

O procedimento utilizado na classificação dos distúrbios é baseado nos descritores obtidos da decomposição dos sinais usando *wavelets*. Para os distúrbios estudados neste trabalho os descritores utilizados foram definidos da seguinte forma:

$$desc = \begin{bmatrix} desc_1 \\ desc_2 \\ \vdots \\ desc_8 \end{bmatrix}$$

onde:

Tabela 1 – Descritores

Descritores	
$desc_1$	Maior diferença percentual de energia (em módulo) entre os diferentes níveis da decomposição wavelet dos sinais com e sem distúrbio;
$desc_2$	Nível onde ocorreu a maior diferença percentual;
$desc_3$	Segunda maior diferença percentual (em módulo) ;

<i>desc₄</i>	Nível onde ocorreu a segunda maior diferença percentual;
<i>desc₅</i>	Terceira maior diferença percentual (em módulo) ;
<i>desc₆</i>	Nível onde ocorreu a terceira maior diferença percentual;
<i>desc₇</i>	Quarta maior diferença percentual (em módulo) ;
<i>desc₈</i>	Nível onde ocorreu a quarta maior diferença percentual;

Com o objetivo de proporcionar à rede neural um aprendizado mais rápido e eficiente, tais descritores foram normalizados e descorrelacionados através da *análise de componentes principais* (também conhecida como a *transformação de Karhunen-Loève* na teoria de comunicação), ([9]).

Foram definidas ainda 4 classes de distúrbios, assim caracterizadas:

$$classe_{dist} = \begin{bmatrix} classe_1 \\ classe_2 \\ classe_3 \\ classe_4 \end{bmatrix}$$

onde:

Tabela 2 – Classes

Descritores	
<i>classe₁</i>	Afundamento de tensão
<i>classe₂</i>	Elevação de tensão
<i>classe₃</i>	Transitórios
<i>classe₄</i>	Harmônicos

Para classificação foi usada uma rede neural do tipo Perceptron de Múltiplas Camadas - PMC com aprendizagem baseada na retro-propagação do erro ([9]). Foram analisados quatro tipos de arquiteturas para a rede PMC (8:20:20:4, 8:50:50:4, 8:100:100:4 e 8:150:150:4), onde para cada arquitetura o primeiro número indica o número de neurônios na camada de entrada, o segundo número indica o número de neurônios na primeira camada oculta e assim sucessivamente até o número de neurônios da camada de saída.

Tanto para o conjunto de treinamento como para o conjunto de validação da rede neural foram utilizados dados reais obtidos do sistema elétrico da CHESF,

sendo usado para o treinamento um total de 800 amostras e para validação 344 amostras. Para treinamento do PMC utilizou-se o *Toolbox Neural Networks* do MATLAB™. Na tabela abaixo estão resumidas as porcentagens de acertos obtidas para o conjunto de validação considerando diferentes épocas e arquiteturas da rede neural PMC:

Tabela 3 – Porcentagem de acertos para diferentes arquiteturas e épocas da rede PMC

Arquitetura \ Épocas	Épocas				
	1000	5000	10000	20000	40000
8:20:20:4	68,89%	77,62%	77,91%	82,85%	84,59%
8:50:50:4	76,74%	78,20%	81,69%	85,46%	85,75%
8:100:100:4	77,32%	79,94%	82,56%	85,46%	85,92%
8:150:150:4	78,78%	82,85%	84,59%	84,01%	86,05%

A partir da análise dos resultados da Tabela 3 pode-se verificar que o maior índice de acertos, em torno de 86%, é obtido para a rede neural com arquitetura do tipo 8:150:150:4 considerando um número de 40000 épocas. Para esse caso, a Tabela 4 mostra o índice de acerto individual de cada classe.

Tabela 4 – Resposta da Rede Neural PMC do tipo 8:150:150:4

Distúrbio	Acertos	Erro	Porcentagem de acertos (%)
Afundamento	84	2	97,6744%
Elevação	66	20	76,7442%
Transitórios	74	12	86,0465%
Harmônicos	72	14	83,7209%
Total:	296	48	86,0465%

A classe 1, afundamento de tensão, é o tipo de distúrbio que apresenta o maior índice de acerto – 97,6744%. Já o caso de elevação de tensão é o tipo de distúrbio que apresenta a maior dificuldade de se realizar a classificação, apresentando uma porcentagem de acerto de 76,7442%.

É possível melhorar o desempenho do classificador neural, para isso alguns pontos estão sendo melhor analisados, tais como, os descritores utilizados para a

classificação, o número de simulações usadas para cada evento causador de distúrbio, assim como alguns dos parâmetros da rede neural utilizada e ainda uma boa inicialização para os pesos sinápticos.

5. Conclusões

O objetivo deste trabalho foi apresentar um procedimento alternativo para se caracterizar distúrbios responsáveis pela perda da qualidade de energia elétrica. A metodologia desenvolvida considerou quatro tipos de eventos causadores de distúrbios, obtidos por meio de equipamentos registradores, instalados no sistema de transmissão de energia da CHESF.

Através da análise de curvas de distribuição de energia concentrada nos diferentes níveis de resolução da decomposição wavelet de um sinal com distúrbio e o correspondente sinal sem distúrbio, foi possível definir descritores que permitiram chegar a um padrão característico para cada tipo de distúrbio da qualidade de energia elétrica que está presente na onda de tensão analisada.

Os descritores definidos pela metodologia exposta, após serem normalizados e descorrelacionados através da análise de componentes principais (PCA), foram usados para classificar os distúrbios utilizando-se de uma arquitetura de Rede Neural Artificial (RNA).

Os resultados aqui apresentados são apenas parciais, uma vez que este trabalho ainda se encontra em fase de desenvolvimento. O uso da análise de componentes principais ainda não foi o suficiente para a obtenção de acertos próximos de 100% para a classificação e por isso ainda é preciso realizar uma melhor avaliação dos descritores utilizados.

Agradecimentos

Os autores agradecem à Companhia Hidrelétrica do São Francisco – Chesf, por ter confiado o tema deste artigo, constante do seu Programa de P&D, ao Grupo de Pesquisa do qual fazem parte.

6. Bibliografia

- [1] IYENGAR, S.S.; CHO, E.C.;PHOHA, V.V. (2002) – *Foundations of Wavelet Networks and Applications*, Chapman & Hall/CRC, 2002.
- [2] DÓRIA, A. D. Neto; PIRES, P. S. M.; MELO, J. D.; SANTOS, C. K. S.; OLIVEIRA, J. T.; MEDEIROS Jr., M. F. *Disturbances Characterization in Electric Energy Networks Using Second-Generation Wavelet Transform*. VI INDUSCON – Joinville – Outubro de 2004.
- [3] MILDE M. S. LIRA; MANOEL A.C. Jr.; RONADO R. B. AQUINO; MÊUSER J. S. VALENÇA; JOSÉ J. A. L. LEITÃO. *Classificação de Distúrbios Elétricos Utilizando Wavelets, Componentes Principais e Redes Neurais Artificiais*. CBA 2004 – Gramado – Setembro de 2004.
- [4] SOARES, Luciana Reginaldo. *Wavelets na Identificação e Localização de Falhas em Linhas de Transmissão*. Recife, PE: Dezembro de 2001. 156p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Pernambuco.
- [5] UYTTERHOEVEN, Geert, ROOSE, Dirk, BULTHEEL, Adhemar. *Wavelet Transforms Using the Lifting Scheme*. Report ITA – WP1.1 (Revised version), Abril de 1997.
- [6] SWELDENS, Wim. *The Lifting Scheme: A Construction of Second Generation Wavelets*, Maio de 1995, Revisado em November de 1996. Publicado no SIAM Journal on Mathematical Analysis.
- [7] ROGER L. CLAYPOOLE, Jr.; RICHARD G. BARANIUK. *Flexible Wavelet Transforms Using Lifting*. Rice University.
- [8] RESENDE, José Wilson; PENNA, Cristiane. *Identificação de Distúrbios da Qualidade da Energia Através da Transformada Wavelet*, IV SBQEE – Porto Alegre/RS, Agosto de 2001.
- [9] S. HAYKIN, *Redes Neurais: Princípios e Práticas* Bookman Companhia Editora, RS: 1999, Segunda Edição.