

CLASSIFICAÇÃO DE DISTÚRBIOS NA REDE ELÉTRICA USANDO REDES NEURAIS E WAVELETS

M. FIRMINO DE MEDEIROS JR., CRISLUCI K. S. S. CÂNDIDO, J. TAVARES DE OLIVEIRA

*Departamento de Engenharia da Computação e Automação, UFRN
Campus Universitário, Lagoa Nova, CEP 59078-900, Natal/RN
E-mails: firmino@dca.ufrn.br; crisluci@dca.ufrn.br; javares@ct.ufrn.br*

JOSÉ J. DE A. L. LEITÃO

*CHESF – Companhia Hidroelétrica do São Francisco
Recife/PE
E-mail: julio@chesf.gov.br*

Abstract— Post dispatch analysis of signals obtained from digital disturbances registers provide important information to identify and classify disturbances in systems, looking for a more efficient management of the supply. In order to enhance the task of identifying and classifying the disturbances - providing an automatic assessment - techniques of digital signal processing can be helpful. The Wavelet Transform has become a very efficient tool for the analysis of voltage or current signals, obtained immediately after disturbances occurrences in the network. This paper presents a methodology based on the Discrete Wavelet Transform to implement this process. It uses a comparison between distribution curves of signals energy, with and without disturbance. This is done for different resolution levels of its decomposition in order to obtain descriptors that permit its classification, using artificial neural networks.

Keywords— Quality of Energy, Artificial Neural Networks, Wavelet Transform

Resumo— Análises pós-despacho de sinais oriundos de registradores de perturbações fornecem 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, usando redes neurais artificiais.

Palavras-chave—Distúrbios, Qualidade da Energia, Redes Neurais Artificiais, Transformada Wavelet

1 Introdução

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 de um sinal não é, em geral, suficiente para identificar o tipo de fenômeno presente na sua forma de onda. Além disso, o grande volume de dados torna inviável a inspeção visual de todos os sinais registrados, exigindo assim, uma automatização do processo.

O objetivo desse trabalho é, portanto obter a classificação automática dos principais tipos de distúrbios responsáveis pela perda da qualidade de energia elétrica usando a Transformada Wavelet Discreta e Redes Neurais Artificiais (RNA).

2 Algoritmo Básico para Classificação dos Fenômenos

Resumidamente, o trabalho se divide em algumas etapas principais, conforme mostra o esquema da Figura 1 [Medeiros Jr (2006)].

A primeira etapa do trabalho consiste na obtenção de amostras de sinais de tensão reais. Após a fase de obtenção dos sinais, a fase seguinte diz respeito ao tratamento desses dados. Os sinais registrados devem ser pré-processados de forma a obter descritores que possam ser usados na etapa seguinte, que corresponde à classificação do sinal, realizada a partir do uso de redes neurais artificiais (RNA's), cujo resultado deve ser a classificação correta do distúrbio presente no sinal analisado.

2.1 Etapa 1: Obtenção do Sinal de Entrada

A base de dados utilizada neste trabalho é composta de sinais de distúrbios de tensão obtidos por meio de equipamentos registradores (oscilógrafos e qualímetros) instalados em vários pontos de um sistema real

de transmissão. Analisaram-se quatro tipos de distúrbios na rede: transitórios, distorções harmônicas, elevação e afundamento de tensão.

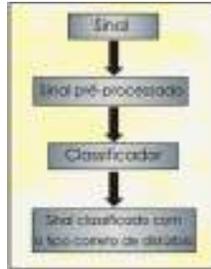


Figura 1. Diagrama esquemático das etapas desenvolvidas no trabalho.

2.2 Etapa 2: Pré-Processamento do Sinal de Entrada

Com base em pesquisas desenvolvidas no decorrer deste trabalho, é possível afirmar que esta é uma das mais importantes etapas desenvolvidas. Isso se deve ao fato de que foi a partir do estudo mais aprofundado desta que os resultados obtidos evoluíram, atingindo uma taxa de acerto na classificação próxima dos 100%.

A metodologia proposta neste trabalho [Resende(2001)] foi desenvolvida e programada para utilização no MATLAB™. Os procedimentos podem ser resumidos em quatro passos:

- Passo 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;
- Passo 2: compreende o cálculo da energia concentrada em cada um dos níveis de decomposição;

A determinação das energias está fundamentada no teorema de Parseval [HSU(1973)], 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:

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

Sendo,

$f(n)$: o sinal com distúrbio (amostrado no domínio do tempo); N : o número total de amostras do sinal;
 $\sum_{n=1}^N |f(n)|^2$: a energia do sinal analisado;
 $\sum_{n=1}^N |a_j(n)|^2$: a energia concentrada na versão aproximada de nível j do sinal analisado;
 $\sum_{j=1}^J \sum_{n=1}^N |d_j(n)|^2$: as energias concentradas nas versões detalhadas de níveis de 1 a j do sinal.

- Passo 3: consiste na repetição dos passos 1 e 2, porém apenas para o sinal de referência relativo ao sinal com distúrbio em análise;
- Passo 4: finalmente, faz-se uma comparação entre as energias concentradas em cada um dos níveis do sinal com distúrbio (passo 2) e do sinal de referência (passo 3). Essa comparação é feita através do cálculo da diferença percentual entre as distribuições das energias dos sinais com distúrbio e de referência.

A figura 2 mostra o gráfico da diferença percentual das energias dos sinais com e sem distúrbio nos diferentes níveis da versão detalhada.

A análise destas curvas de diferença percentual indica que distúrbios do mesmo tipo possuem tais curvas com características similares. Assim, é possível afirmar, que através da comparação entre as distribuições de energia do sinal em análise e o seu correspondente sinal de referência, pode-se determinar um padrão característico para cada tipo de distúrbio [Santos(2004)]. Definem-se, então, descritores que podem ser usados como padrões de entrada para a classificação por redes neurais artificiais.

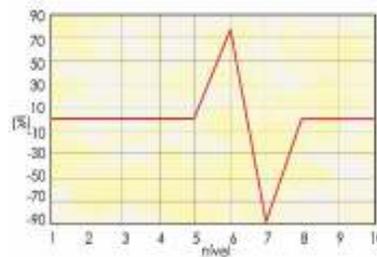


Figura 2. Gráfico da diferença percentual das energias dos sinais com e sem distúrbio para o caso de uma elevação de tensão.

2.3 Etapa 3: Classificador Neural

O procedimento utilizado na classificação dos distúrbios por meio de uma estrutura neural [HAYKIN (1999)] é baseado nos descritores obtidos da decomposição dos sinais em diferentes níveis de resolução wavelets. A tabela 1 mostra a definição de cada um dos descritores obtidos através da análise das curvas de diferença percentual.

Para o classificador neural foram definidas 4 classes, cada uma representando um tipo de distúrbio considerado (Tabela 2).

3 Pré-Processamento e sua Importância

A seguir são mostradas as principais alterações realizadas no pré-processamento, apresentando suas evoluções e a melhora dos resultados obtidos.

3.1 Mudança dos Descritores

Antes da atual definição, os descritores utilizados eram 30, cuja obtenção necessitava dispor das três fases (A, B e C) do sinal. Diferentemente desse procedimento, para obter os descritores atuais não são necessárias as três fases do sinal, mas apenas uma. Isso produz um aumento na quantidade de padrões em relação ao procedimento anterior. Além disso, os experimentos iniciais mostraram que utilizar as três fases prejudicava o desempenho da rede neural. Uma vez que, por exemplo, um afundamento de tensão presente em uma determinada fase pode ocasionar o surgimento de outro tipo de distúrbio nas outras duas. Portanto, a nova definição dos descritores apresenta melhores condições de analisar uma fase sem uma possível influência das outras.

3.2 Definição do Sinal de Referência Equações

Descrevem-se abaixo os três algoritmos adotados para a obtenção do sinal de referência:

- Inicialmente a obtenção do sinal de referência era feita sem a preocupação de caracterizar a defasagem entre os sinais comparados. Apenas reproduzia-se um sinal puramente senoidal com amplitude de 1 p.u., com a mesma taxa de amostragem e até a quantidade de ciclos que o sinal analisado com distúrbio possuía.
- Em uma nova fase do trabalho, os sinais de referência foram obtidos utilizando os próprios sinais com distúrbios. A partir destes sinais, usando o método dos mínimos quadrados para funções não lineares, realizou-se a extrapolação do primeiro ciclo do sinal, considerado um ciclo de pré-falta.
- Por fim, o sinal de referência passou a ser obtido a partir da análise de cada ciclo do seu respectivo sinal com distúrbio. Com esta análise separava-se o ciclo considerado o mais normal (em relação à amplitude e distorção). Este ciclo era então sincronizado com o primeiro ciclo do sinal com distúrbio e reproduzido até a quantidade de ciclos que este possuía.

Cada alteração feita no algoritmo de obtenção do sinal de referência aumentava o índice de acerto obtido na classificação dos distúrbios (Tabela 3).

Os sinais analisados para a obtenção destes resultados foram obtidos por oscilógrafos com taxa de amostragem de 128 amostras/ciclo registrados durante 14 ciclos. Sendo usada na classificação uma RNA do tipo Perceptron de Múltiplas Camadas (PMC) utilizando para o treinamento o algoritmo Resilient Propagation (Rprop).

Tabela 1. Tabela com a definição e cada descritor

Descritores	
descritor1	Maior diferença percentual de energia (em módulo) entre os níveis da decomposição wavelet dos sinais com e sem distúrbio
descritor2	Nível da maior diferença percentual
descritor3	Segunda maior diferença percentual de energia (em módulo) entre os níveis da decomposição wavelet dos sinais com e sem distúrbio
descritor4	Nível da segunda maior diferença percentual
descritor5	Terceira maior diferença percentual de energia (em módulo) entre os níveis da decomposição wavelet dos sinais com e sem distúrbio
descritor6	Nível da terceira maior diferença percentual
descritor7	Quarta maior diferença percentual de energia (em módulo) entre os níveis da decomposição wavelet dos sinais com e sem distúrbio
descritor8	Nível da quarta maior diferença percentual
descritor9	Quinta maior diferença percentual de energia (em módulo) entre os níveis da decomposição wavelet dos sinais com e sem distúrbio
descritor10	Nível da quinta maior diferença percentual

Tabela 2. Classes definidas para o classificador neural.

Classes	
Classe1	Afundamento de tensão
Classe2	Elevação de tensão
Classe3	Distorções harmônicas
Classe4	Transitórios

Tabela 3. Porcentagem de acerto obtido pela RNA para os três algoritmos de obtenção do sinal de referência desenvolvidos.

Arquitetura	Índice de acertos		
	Algoritmo 1	Algoritmo 2	Algoritmo 3
10:20:4	83,27%	85,34%	93,60%
10:40:4	81,69%	87,62%	94,19%
10:60:4	84,01%	87,95%	96,22%
10:80:4	85,17%	88,60%	93,02%
10:100:4	85,46%	89,25%	95,06%

É possível observar que para o algoritmo 1 o melhor índice de acerto foi 85,46%. Para o algoritmo 2 obteve-se 89,25%. Essa melhora é atribuída à redução da defasagem entre os sinais comparados que após a utilização do algoritmo 2, diminuíram.

Porém, observou-se que em alguns registros os primeiros ciclos já se iniciavam com distúrbio. Isso era um problema, uma vez que pelo algoritmo 2 a obtenção do sinal de referência estava sendo realizada a partir da extrapolação do primeiro ciclo do sinal (considerado sem distúrbio). Assim, mais uma vez alterou-se o algoritmo de obtenção do sinal de referência. O melhor índice de acerto após o uso do algoritmo 3 foi 96,22%.

3.3 Localização do Distúrbio no Tempo

Durante o desenvolvimento deste trabalho, o pré-processamento dos sinais se deu de duas formas:

- Os sinais analisados com distúrbio eram pré-processados exatamente como se apresentavam, sem modificações (Figura 3).
- Trata apenas da parte do sinal que continha o distúrbio, sendo a parte sem distúrbio descartada (Figura 4) [de Melo (2007)].

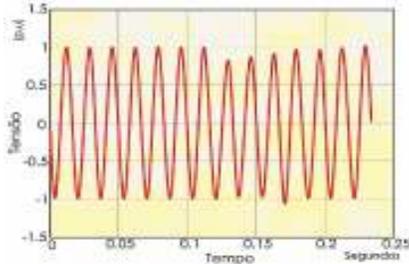


Figura 3. Sinal de entrada sem passar por nenhum pré-processamento.

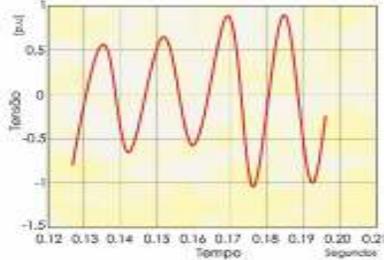


Figura 4. Sinal de entrada contendo apenas o distúrbio.

É importante ressaltar que a seleção do distúrbio reduz a quantidade de amostras totais do sinal. Dessa forma, os sinais analisados podem possuir números de amostras diferentes, o que não representa um problema. A única dificuldade seria se estas quantidades fossem inferiores a uma quantidade mínima. Se isso ocorresse, o algoritmo elaborado se adapta para que os sinais não devam possuir o número de amostras menores que o mínimo preestabelecido.

A tabela 4 mostra que o melhor resultado obtido foi de 98,26%.

Tabela 4. Porcentagem de acerto obtido pela RNA para o algoritmo 3 de obtenção do sinal de referência e o sinal contendo apenas a parte com distúrbio.

Arquitetura	Índice de acertos
10:20:4	90,69%
10:40:4	98,26%
10:60:4	84,59%
10:80:4	89,53%
10:100:4	82,55%

3.4 Normalização

As alterações realizadas na etapa de pré-processamento dos sinais provocaram um aumento considerável no índice de acerto, que de 89,25% passou a ser de 98,26%. Para obtenção do índice de a-

certo igual a 100% apenas foi feita a normalização dos padrões de entrada utilizados pela rede neural.

4 Resultados de Aplicações e a Importância da Taxa de Amostragem

É importante destacar que os sinais registrados analisados possuem diferentes taxas de amostragem:

- 128 amostras/ciclo → taxa que a rede de oscilografia estava ajustada. A duração de cada registro possui 14 ciclos.
- 32 amostras/ciclo → taxa que a rede de qualimetria estava ajustada. A duração de cada registro possui 54 ciclos.
- 64 amostras/ciclo → taxa obtida a partir da redução da taxa dos sinais registrados pela oscilografia. Esta redução foi realizada com a intenção de analisar o impacto da diminuição da taxa na classificação dos distúrbios.

4.1 Resultados Obtidos Para Sinais Com 128 Amostras/Ciclo

Para estes sinais foram analisados quatro tipos de distúrbios presentes na rede elétrica: afundamento e elevação de tensão, harmônicos e transitórios.

Foi utilizada para a classificação uma rede neural do tipo Perceptron de Múltiplas Camadas (PMC), com treinamento segundo o algoritmo Resilient Backpropagation (Rprop). Deve-se ressaltar que também foi testado o algoritmo Backpropagation.

A tabela 5 mostra os resultados obtidos, assim como, o tempo de treinamento gasto, utilizando os dois algoritmos e 1000 épocas para o treinamento. A análise desta tabela comprova que os melhores resultados foram obtidos utilizando-se o algoritmo Rprop, chegando-se a obter 100% de acerto.

Tabela 5. Porcentagem de acerto e tempo de treinamento obtido pela RNA utilizando o algoritmo RPROP e o Backpropagation.

Arquitetura	Índice de acerto		Tempo de treinamento	
	RPROP	BACK	RPROP	BACK
10:20:4	96,51%	96,22%	45,4s	48,5s
10:40:4	99,70%	96,80%	76,8s	82,1s
10:60:4	100,0%	96,80%	97,8s	103,2s
10:80:4	98,26%	96,51%	131,6s	133,9s
10:100:4	95,64%	96,51%	175,8s	203,2s

4.2 Resultados Obtidos Para Sinais Com 32 Amostras/Ciclo

Com esta baixa taxa de amostragem, não foi possível registrar sinais com transitórios, sendo por este motivo analisado sinal com afundamento e elevação de

tensão, harmônicos e sinais considerados normais de acordo com as normas técnicas.

A mudança da taxa de amostragem dos sinais analisados, que era de 128 amostras/ciclo e que passou a ser de 32, mostrou que tal redução teve como consequência resultados não tão bons como os obtidos anteriormente (Tabela 5). O melhor índice de acerto obtido foi de 84,43% (Tabela 6).

Tabela 6. Porcentagem de acerto obtida pela RNA utilizando o algoritmo RPROP para sinais com 32 (qualimetria), 64 e 32 (reduzidos da amostragem dos sinais com 128) amostras/ciclo.

Arquitetura	Índice de acerto		
	32 amost/ciclo (qualimetria)	64 amost/ciclo (reduzida da oscilografia)	32 amost/ciclo (reduzida da oscilografia)
10:20:4	80,19%	92,15%	84,88%
10:40:4	84,43%	92,44%	85,17%
10:60:4	83,02%	92,44%	85,76%
10:80:4	83,02%	91,57%	86,63%
10:100:4	82,55%	90,12%	86,05%

4.3 Resultados Obtidos Para Sinais com 64 Amostras/Ciclo Provenientes da Redução da Taxa de Amostragem dos Sinais com 128 Amostras/Ciclo

Para verificar a relação da taxa de amostragem com o índice de acerto, os sinais analisados com 128 amostras por ciclo, cuja classificação atingiu um índice de 100% de acerto (Tabela 5), tiveram a sua taxa de amostragem reduzida, diminuindo-se de 128 para 64 e 32 amostras/ciclo.

Para obtenção dos resultados utilizando-se os sinais com a taxa de amostragem reduzida, as classes utilizadas pela RNA são as mesmas da Tabela 2.

Pela tabela 6 observa-se que o melhor índice de acerto obtido para esta taxa de amostragem foi de 92,44%. Esse índice representa uma queda de 7,56% em relação ao melhor índice obtido para os sinais com taxa de 128 amostras/ciclo.

4.4 Resultados Obtidos Para Sinais com 32 Amostras/Ciclo Provenientes da Redução da Taxa de Amostragem dos Sinais com 128 Amostras/Ciclo

A tabela 6 mostra que para os sinais com taxa de 32 amostras/ciclo (reduzida da oscilografia), o melhor índice de acerto foi de 86,63%. Este fato confirma a relação entre a taxa de amostragem e a redução no índice de acerto na classificação da RNA. É importante destacar ainda que a redução da taxa de amostragem mostra-se proporcional a redução da taxa de acerto, ou seja, quanto menor a taxa de amostragem, menor o índice de acerto.

5 Conclusão

O objetivo deste artigo é elaborar um método eficiente para classificação automática de distúrbios responsáveis pela qualidade da energia elétrica.

Por este trabalho foi possível observar através de um estudo mais aprofundado a importância da etapa do pré-processamento dos sinais para a classificação dos distúrbios. Conforme mostraram os resultados, as melhorias realizadas nesta etapa aliadas à normalização dos descritores foram significativas para obter uma melhora na qualidade da classificação, atingindo-se o índice de 100% de acerto.

Além disso, foram analisados sinais com diferentes taxas de amostragem, 128, 64 e 32 amostras/ciclo. Pela análise dos resultados foi possível concluir que pela metodologia desenvolvida a redução da taxa de amostragem do sinal também reduz o índice de acerto da classificação dos distúrbios.

Agradecimentos

Os autores agradecem a CHESF pelo apoio técnico e por ter confiado o tema deste artigo, constante do seu programa de P&D, ao grupo de pesquisa do qual fazem parte.

Referências Bibliográficas

- Medeiros Jr, M. F., Santos, C.K.S., de Oliveira, J. T., de Lacerda, E. G. M.e Leitão, J. J. A. L.(2006). Classificação automática de distúrbios através de redes neurais e da transformada wavelet combinando dados de simulações e registros de perturbações .VII INDUSCON. RECIFE – PE.
- Resende, J.W. e Penna, C.(2001). Identificação de distúrbios da qualidade da energia através da transformada wavelet. IV SBQEE. Porto Alegre-RS.
- HSU, H. S. (1973). Análise de Fourier Livros Técnicos e Científicos, Editora – Rio.
- Santos, C. K. S. (2004). Caracterização de Distúrbios em Redes de Energia Elétrica Através da Transformada Wavelet de Segunda Geração - Dissertação (Mestrado) - UFRN, Natal-RN.
- HAYKIN, S.(1999). Redes Neurais: Princípios e Práticas - Segunda Edição: Bookman Companhia Editora - RS, 1999.
- de Melo, J.D., Santos, C.K.S., Medeiros Jr M.F., de Oliveira, J. T., Pires, P.S.M., Dória Neto, A.D. e Leitão, J.J.A.L.(2007). Influence of signal pre-processing in the efficiency of algorithms based on neural networks for disturbance classification IEEE Symposium on Computational Intelligence in Image and Signal Processing. Hawaii – USA.