

## SISTEMA DE DETECÇÃO DE DISTÚRBIOS ELÉTRICOS BASEADO EM REDES NEURAIS

DANTON D. FERREIRA\*, JOSÉ M. DE SEIXAS\*, FÁBIO V. B. DE NAZARÉ†, AUGUSTO S. CERQUEIRA‡  
, LUIZ P. CALÔBA\*, CRISTIANO A. MARQUES\*

\**Universidade Federal do Rio de Janeiro  
Laboratório de Processamento de Sinais  
Rio de Janeiro, RJ, Brasil*

†*Universidade Federal do Rio de Janeiro  
Laboratório de Instrumentação e Fotônica  
Rio de Janeiro, RJ, Brasil*

‡*Universidade Federal de Juiz de Fora  
Laboratório de Processamento de Sinais e Telecomunicações  
Juiz de Fora, MG, Brasil*

Emails: danton@lps.ufrj.br, seixas@lps.ufrj.br, fabio@lif.coppe.ufrj.br,  
augusto.santiago@ufjf.edu.br, caloba@lps.ufrj.br, cristiano@lps.ufrj.br

**Abstract**— This paper presents a methodology based in artificial neural network for electric power quality disturbances detection. The methodology presented is compared with two recently methods and applied to the simulated and world real data. The results show that the detection system proposed can be attractive for the applications in the power quality systems, because it reveals high performance and computational cost reduced in operation stage.

**Keywords**— Artificial Neural Network, Electric Power Quality, Disturbances.

**Resumo**— Este trabalho propõe um sistema para a detecção de distúrbios elétricos em sistemas de potência baseado em redes neurais artificiais. O sistema proposto é aplicado em ambos dados reais e simulados e é comparado com dois outros sistemas referidos na literatura especializada. É observado que o sistema apresenta alto desempenho e reduzido custo computacional na fase de operação e, portanto, pode ser bastante útil em sistemas *online* de monitoramento da qualidade de energia elétrica.

**Keywords**— Redes Neurais Artificiais, Qualidade de Energia Elétrica, Distúrbios.

### 1 Introdução

O crescente uso de equipamentos sensíveis às perturbações do sistema elétrico tem exigido requisitos de qualidade de energia cada vez mais rigorosos, o que, juntamente com a necessidade das concessionárias de energia elétrica de satisfazer os clientes, tem tornado o tema “qualidade de energia” um assunto de extrema importância no mercado atual de energia elétrica.

O aumento do número de cargas de natureza não-linear (sistemas micro-processados, fontes chaveadas, etc) em instalações residenciais, comerciais e industriais provoca o aumento significativo da ocorrência de distúrbios em sistemas de potência, assim como o do número de falhas e, conseqüentemente, a diminuição da vida útil dos equipamentos conectados às redes elétricas.

Este cenário tem acelerado, ao longo dos últimos anos, o desenvolvimento de diversas técnicas de processamento de sinais para o monitoramento e análise da qualidade da energia elétrica (QEE) (Gu et al., 2004; Zhao and Yang, 2007; Duque et al., 2005; Qian et al., 2008; Mishra et al., 2008; Gar-

gom et al., 2008; Biswal et al., 2009). Dentre os principais objetivos destas técnicas destacam-se: i) detecção de distúrbios, ii) classificação de distúrbios, iii) identificação de fontes geradoras de distúrbios, iv) localização de fontes geradoras de distúrbios, v) análise de transitórios de distúrbios, vi) estimação de parâmetros de distúrbios, vii) compressão de distúrbios, etc.

De maneira geral, os distúrbios de qualidade de energia se manifestam como deformidades nas formas de onda da tensão. Estas deformidades, frequentemente referidas como problemas de QEE, afetam significativamente as indústrias em diversos aspectos. Dentre eles, destacam-se a interrupção do processo de produção e baixa velocidade nas redes de computadores, o que é refletido em significativas perdas financeiras para as indústrias.

Dentre os distúrbios refletidos na forma de onda da tensão, podemos destacar os harmônicos, elevações de tensão (*swells*), interrupções, afundamentos de tensão (*sags*), flutuações de tensão (*flickers*), impulsos (*spikes*, *notches*), transitórios de chaveamento, etc. Quando tais distúrbios são monitorados por oscilógrafos, geram arquivos de dados de grande extensão que, além de serem difíceis

de armazenar, trazem muitas vezes informações desnecessárias para a avaliação da QEE. Deve-se ressaltar que a análise desses distúrbios demanda o uso de sofisticadas técnicas de processamento de sinais e inteligência computacional, uma vez que tais eventos são aleatórios e podem ocorrer simultaneamente.

Neste contexto, a aplicação de técnicas de reconhecimento de padrões e de extração de parâmetros para o monitoramento da qualidade de energia, com destaque para a detecção de distúrbios é fortemente justificada.

Este trabalho propõe um sistema simples de detecção automática de distúrbios elétricos baseado em redes neurais artificiais (RNA) (Haykin, 1999), em que as RNA serão utilizadas como ferramenta de detecção. O desempenho do método proposto será analisado com bancos de dados sintéticos e reais, e comparado com o desempenho de duas outras técnicas de detecção encontradas na literatura (Gu et al., 2004; Ribeiro et al., 2006), que estão descritos na seção 3.

De forma a discutir a presente proposta, este artigo é organizado da seguinte maneira. Na próxima seção o sistema proposto será apresentado em detalhes. Na seção 3 os resultados obtidos serão apresentados e discutidos. Finalmente, na seção 4, as conclusões serão apresentadas.

## 2 Sistema de Detecção Proposto

O sistema de detecção proposto é ilustrado pelo diagrama em blocos da Figura 1, em que o sinal de tensão monitorado passa por um filtro notch sintonizado na frequência do componente fundamental do mesmo ( $f_0 = 60 \text{ Hz}$ ) e ajustado conforme proposto em Ribeiro et al. (2006). A detecção é então realizada no sinal resultante  $\{e(n)\}$ .

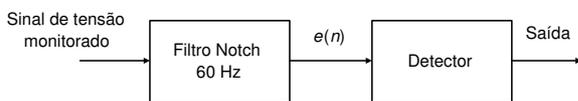


Figura 1: Sistema de detecção proposto.

A estrutura em detalhes do detector é ilustrada pelo diagrama em blocos da Fig. 2.

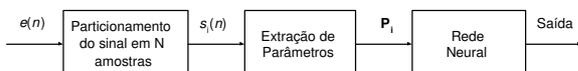


Figura 2: Diagrama em blocos do detector.

No primeiro bloco da Figura 2, o sinal  $e(n)$  é particionado em  $N$  amostras resultando em um novo sinal  $s_i(n)$ , onde  $n = 1, 2, \dots, N$ , e  $i$  representa

cada parcela do sinal  $e(n)$ . O bloco Extração de Parâmetros implementa o cálculo do valor RMS (*Roots Mean Square*) do sinal  $s_i(n)$ , que é computado conforme a Equação (1), e extrai as duas amostras de maior valor absoluto positivo e negativo de  $s_i(n)$ .

$$s_{iRMS} = \sqrt{\frac{1}{N} \sum_{j=1}^N s_{ij}^2}, \quad (1)$$

onde  $N$  é o número de amostras de  $s_i(n)$ .

Deste modo, o vetor de parâmetros extraído será  $P_i = [s_{iRMS} \ p_{i1} \ p_{i2}]$ , onde  $p_{i1}$  e  $p_{i2}$  são as duas amostras de maior valor absoluto positiva e negativa respectivamente de  $s_i(n)$ .

Neste método, tanto na fase de projeto quanto na fase de operação, apenas um vetor ( $P_i$ ) contendo três parâmetros é extraído, o que é bastante relevante, uma vez que a extração destes exige reduzida complexidade computacional, o que é desejável em aplicações *online*.

A Figura 3 ilustra o espaço de parâmetros referentes aos distúrbios de interrupções de tensão e de eventos sem distúrbios para  $N = 256$  amostras. Observe que existe uma boa separabilidade entre as classes. Por outro lado, considerando-se um caso mais extremo, em que os parâmetros são extraídos de sinais  $s_i(n)$  com  $N = 16$  amostras, a separabilidade entre classes já não é tão trivial, conforme mostra a Figura 4. Portanto, a utilização de um separador não-linear, tal como uma RNA, conforme é proposto neste trabalho, torna-se atraente.

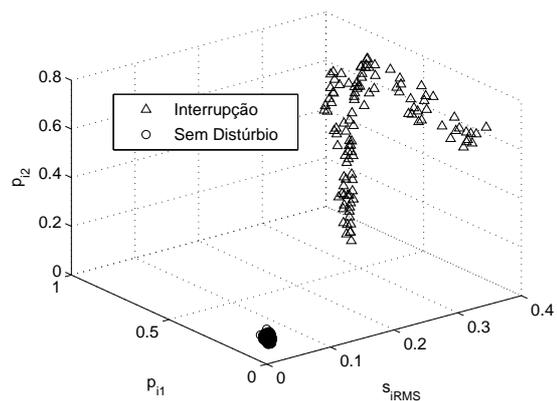


Figura 3: Parâmetros de projeto para a classe de interrupções de tensão para  $N = 256$  amostras.

No projeto do detector, as classes de distúrbios são agrupadas em uma única classe e uma RNA do tipo *perceptron* multi-camadas foi treinada para separar as classes de distúrbios e não distúrbios. A RNA utilizada possui três entradas, referentes aos três parâmetros do vetor  $P_i$ , uma camada escondida e uma camada de saída contendo apenas um

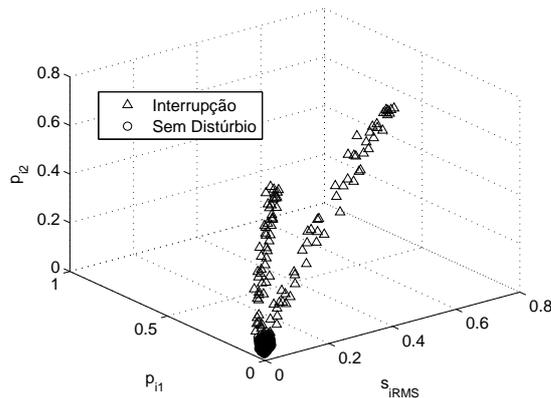


Figura 4: Parâmetros de projeto para a classe de interrupções de tensão para  $N = 16$  amostras.

neurônio. Os pesos e bias foram inicializados de acordo com o algoritmo de Nguyen and Widrow (1990). A função de ativação utilizada foi a tangente hiperbólica e o algoritmo de treinamento foi baseado na otimização de Levenberg-Marquardt (Haykin, 1999).

Objetivando um estudo de complexidade computacional e desempenho do método, foram realizados testes considerando diferentes números de amostras ( $N$ ) na etapa de particionamento de sinal (vide Fig. 2): 256, 128, 64, 32 e 16 amostras. Nos três primeiros casos foram utilizados 5 neurônios na camada intermediária da RNA. Para  $N = 32$  amostras foram utilizados 8 neurônios e para  $N = 16$  amostras, 10 neurônios.

A utilização de uma RNA simples para a detecção se deve ao fato de a classe de eventos sem distúrbios ser tão homogênea, conforme mostram as Figuras 3 e 4.

### 3 Resultados Obtidos

O sistema proposto foi testado utilizando dados simulados e dados reais, conforme mostrado a seguir.

Os resultados são comparados às técnicas de detecção propostas em Gu et al. (2004) e Ribeiro et al. (2006). A técnica proposta em Gu et al. (2004), basicamente, utiliza como parâmetro o valor eficaz (RMS) do sinal de tensão e o critério de Neyman-Pearson para detecção. Já a técnica proposta em Ribeiro et al. (2006) utiliza como parâmetros estatísticas de ordem superior (EOS), e o detector de Bayes, baseado no critério da máxima verossimilhança, para a detecção. Esta comparação é bastante relevante, uma vez que, para a obtenção dos resultados de desempenho destes métodos, utilizou-se o mesmo banco de da-

dos em que se baseou o projeto do sistema proposto.

#### 3.1 Dados Simulados

Para os resultados obtidos com dados simulados foram consideradas sete classes de distúrbios: afundamentos de tensão (*sags*), elevações de tensão (*swells*), transitórios oscilatórios, *notches*, *spikes*, interrupções e harmônicos. Os distúrbios foram gerados seguindo os padrões e definições consideradas pela norma do IEEE (on Power Quality, 1995) considerando uma relação sinal-ruído de 30 dB e frequência de amostragem  $fs = 15.360 Hz$ .

Foram gerados 110 eventos de cada distúrbio acumulando um total de 770 distúrbios e 770 eventos sem distúrbio. Deste total, 2/3 foi utilizado para o projeto do sistema e 1/3 para a validação. Com o objetivo de atingir um elevado índice de generalização no processo de classificação, as características de cada evento foram escolhidas de forma aleatória em intervalos pré-definidos. Dentro dos intervalos foi considerado que as características deveriam apresentar uma distribuição estatística uniforme.

A Tabela 1 mostra os resultados de desempenhos obtidos para os dados de validação, considerando-se o número de amostras ( $N$ ). O desempenho mostrado é referente à eficiência global do método, obtida pela média entre os desempenhos das classes de distúrbios e sem distúrbios.

Tabela 1: Eficiência global de detecção em % para dados simulados.

	RMS	EOS	Método Proposto
N=256	75,8	100	100
N=128	82,6	100	100
N=64	78,7	99,8	99,8
N=32	77,1	99,3	99,2
N=16	75,1	98,6	98,4

Conforme mostra a Tabela 1, o método proposto, baseado em RNA, apresenta resultados compatíveis aos do método baseado em EOS (Ribeiro et al., 2006) e superiores ao método baseado em RMS (Gu et al., 2004). É importante ressaltar que mesmo com um número bem reduzido de amostras ( $N = 16$ ), o que corresponde a 1/16 ciclos do componente fundamental do sinal de tensão monitorado, o método proposto alcançou bons resultados de detecção. É importante ressaltar também que, para o método proposto, o percentual de falso alarme é de 0%. Isto se deve ao fato de os parâmetros extraídos constituírem uma classe de eventos

sem distúrbios bastante homogênea, o que facilita sua classificação.

### 3.2 Dados Reais

Para testar o desempenho do sistema proposto para distúrbios reais, os sinais amostrados com  $f_s = 15.360 \text{ Hz}$  foram obtidos no site de um grupo de trabalho IEEE (*IEEE working group P1159.3*) dos quais foram retirados 110 sinais reais com diversos tipos de distúrbios de longa e curta duração, sendo os quais com valores de SNR estimados de  $40 \text{ dB}$ . A Figura 5 ilustra dois destes distúrbios. Na Figura 5 (a) podemos visualizar um afundamento de tensão de curta duração e um curto transitório seguido de harmônicos. Na Figura 5 (b), o sinal é composto basicamente de harmônicos e transitórios que decaem a oscilação.

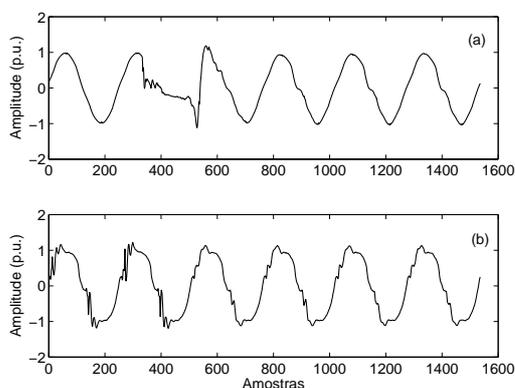


Figura 5: Distúrbios reais extraídos do grupo de trabalho IEEE (*IEEE working group P1159.3*).

A Tabela 2 mostra os resultados referentes a estes dados. Observa-se que o método proposto obteve uma taxa de acertos de  $100,0\%$  para os casos de 64 e 16 amostras. A técnica baseada em EOS detecta perfeitamente em todos os casos, enquanto que as taxas de detecção para o método baseado no valor RMS não são tão elevadas.

Tabela 2: Eficiência global de detecção em % para dados reais.

	RMS	EOS	Método Proposto
N=256	66,4	100	98,2
N=128	88,2	100	99,1
N=64	82,7	100	100
N=32	72,7	100	98,2
N=16	67,3	100	100

A aplicação de dados reais no sistema proposto é bastante importante para testar a capacidade de generalização do método, uma vez que o banco

de dados reais é bastante heterogêneo, composto por diversos distúrbios que acontecem em sequência e/ou simultaneamente, e o sistema foi projetado utilizando apenas dados simulados. Além disso, os dados reais são compostos por distúrbios muitas vezes não tão caracterizados como aqueles simulados, ou seja, difíceis de serem identificados mesmo na presença de um especialista. Assim, o alto desempenho obtido pelo método proposto quando aplicado a dados reais pode comprovar a boa capacidade de generalização do método.

### 3.3 Estudo da Complexidade Computacional

Os sistemas de monitoramento de QEE podem trabalhar de forma *online* ou de forma *offline* com bancos de dados gravados por oscilógrafos. Contudo, em sistemas de monitoramento *online*, uma reduzida complexidade computacional é requerida e, portanto, uma análise da mesma para o método proposto torna-se necessária.

Uma forma de averiguar a complexidade computacional de um método é calcular o número total de operações matemáticas que seu algoritmo realiza no processamento do sinal desde sua entrada até sua saída. Assim, é mostrada na Tabela 3, a complexidade computacional de cada um dos métodos. Para os valores apresentados nesta tabela é observado que o método proposto possui a menor complexidade computacional entre os métodos considerados para o caso mais crítico com  $N = 16$  amostras. O método EOS possui uma complexidade computacional superior para o caso de 256 amostras e o método RMS possui a maior complexidade computacional para o caso de 16 amostras. Os casos para 128, 64 e 32 amostras foram omitidos por questões de simplificação.

Tabela 3: Complexidade Computacional dos Métodos.

	Adições N=256	Mult. N=256	Adições N=16	Mult. N=16
RMS	266	267	266	267
EOS	2.312	2.321	152	161
Método Proposto	1.285	1.043	105	98

Além das operações de adição e multiplicação, é importante considerar também as operações de tangente hiperbólica, raiz quadrada e exponencial de cada método. Neste caso, o método baseado em RMS utiliza duas operações de exponencial e seis operações de raiz quadrada. O método baseado em EOS utiliza apenas duas operações de exponencial. O método proposto utiliza apenas uma operação de raiz quadrada para todos os casos ( $N$

= 256, 128, 64, 32 e 16) e seis tangentes hiperbólicas nos três primeiros casos, nove quando  $N = 32$  e onze quando  $N = 16$  amostras.

#### 4 Conclusões

Este trabalho propôs um sistema simples de detecção de distúrbios elétricos em sistemas elétricos de potência utilizando RNA, em que a extração de parâmetros é baseada no valor RMS e valores de pico. Os resultados de desempenho e complexidade computacional podem ser considerados bastante atraentes, quando comparados com os métodos baseados em EOS e RMS.

O método proposto apresentou uma reduzida complexidade computacional para  $N = 16$  amostras acompanhado de uma eficiência de 100 % para o conjunto de dados considerado. Deste modo, o método proposto apresenta-se mais adequado para aplicações de monitoramento *online*, onde uma reduzida complexidade computacional é requerida.

Como trabalhos futuros, pretende-se obter melhoria na eficiência, seguindo a mesma metodologia deste trabalho, porém para diferentes frequências de amostragens e diferentes níveis de ruído nos sinais de tensão monitorados. Dada a boa capacidade de generalização das RNA e reduzido custo computacional na fase de operação, espera-se alcançar melhores resultados utilizando uma extração de parâmetros mais elaborada.

#### Agradecimentos

Os autores gostariam de agradecer ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação e Aperfeiçoamento de Pessoal de Nível Superior (CAPES), à Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) por apoiarem este trabalho.

#### Referências

- Biswal, B., Dash, P. K. and Panigrahi, B. K. (2009). Power Quality Disturbance Classification Using Fuzzy C-Means Algorithm and Adaptive Particle Swarm Optimization, *IEEE Transactions on Industrial Electronics* **56**(1): 212 – 220.
- Duque, C. A., Ribeiro, M. V., Ramos, F. R. and Szczupak, J. (2005). Power Quality Event

- Detection Based on the Divide and Conquer Principle and Innovation Concept, *IEEE Transactions on Power Delivery* **20**(4): 2361 – 2369.
- Gargoom, A. M., Ertugrul, N. and Soong, W. L. (2008). Automatic Classification and Characterization of Power Quality Events, *IEEE Transactions on Power Delivery* **23**(4): 2417–2425.
- Gu, I. Y. H., Ernberg, N., Styvaktakis, E. and Bollen, M. H. J. (2004). A statistical-based sequential method for fast online detection of fault-induced voltage dips, *IEEE Transaction on Power Delivery* **19**(2): 497–504.
- Haykin, S. (1999). *Neural networks. A comprehensive foundation*, 2 ed. edn, NJ: Englewood Cliffs, Prentice Hall.
- Mishra, S., Bhende, C. N. and Panigrahi, B. K. (2008). Detection and Classification of Power Quality Disturbances Using S-Transform and Probabilistic Neural Network, *IEEE Transactions on Power Delivery* **23**(1): 280–287.
- Nguyen, D. and Widrow, B. (1990). Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights, *IJCNN International Joint Conference on Neural Networks* **3**: 21 – 26.
- on Power Quality, I. S. C. C. . (1995). IEEE recommended practice for monitoring electric power quality, *Technical report*, IEEE.
- Qian, L., Cartes, D. A. and Li, H. (2008). An Improved Adaptive Detection Method for Power Quality Improvement, *IEEE Transactions on Industry Applications* **44**(2): 525–533.
- Ribeiro, M. V., Marques, C. A. G., Duque, C. A., Cerqueira, A. S. and Pereira, J. L. R. (2006). Power Quality Disturbances Detection Using HOS, *IEEE Power Engineering Society General Meeting*.
- Zhao, F. and Yang, R. (2007). Power-quality disturbance recognition using s-transform, *IEEE Transaction on Power Delivery* **22**(2): 944–950.