

# UMA ABORDAGEM IMUNO-WAVELET APLICADA NA DETECÇÃO E CLASSIFICAÇÃO DE DISTÚRBIOS DE TENSÃO EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

FERNANDO P. A. LIMA<sup>1</sup>, CARLOS R. MINUSSI<sup>1</sup>

<sup>1</sup> *Departamento de Engenharia Elétrica, Faculdade de Engenharia de Ilha Solteira (FEIS), Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), Caixa postal 31, 15385-000, Ilha Solteira, SP, BRASIL*

*E-mails: engfernandoparra@gmail.com, minussi@dee.feis.unesp.br*

**Abstract**— This paper has as its main objective to present a new approach to accomplish the detection and classification of voltage disturbances in electrical distribution systems, using as tool an immune-wavelet algorithm. This proposal is basically to make the addition of a negative selection algorithm immune to the concept of wavelet transform. This way starting from measurements made in a distribution substation by a data acquisition system SCADA module called wavelet decomposition performs signal, transforming the same to the wavelet domain. Following we use a negative selection immune system to accomplish the process of identifying and classifying the diagnostic system abnormalities. The main application of this tool is to assist the operation of the system for failures as well as overseeing the protection system. To evaluate the effectiveness and performance of the proposed method were performed simulations of systems of power distribution in EMTP software for two distribution systems containing 84 and 134 bar, respectively. The result obtained with this new approach shows an excellent performance, highlighting the diagnostic accuracy.

**Keywords**— Immune-wavelet, Detection and Classification, Voltage disturbance, Electrical distribution systems, Smart Grids.

**Resumo**— Este artigo, tem como principal objetivo, apresentar uma nova abordagem para realizar a detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica, usando como ferramenta um algoritmo imuno-wavelet. Esta proposta trata basicamente de realizar a junção de um algoritmo imunológico de seleção negativa com o conceito da transformada wavelet. Desta forma, partindo das medições realizadas em uma subestação de distribuição por um sistema de aquisição de dados SCADA, um módulo, denominado wavelet, realiza a decomposição do sinal, transformando-o para o domínio wavelet. Na sequência, utiliza-se um sistema imunológico de seleção negativa para realizar o processo de diagnóstico identificando e classificando as anormalidades no sistema. A principal aplicação desta ferramenta é auxiliar a operação do sistema durante falhas, bem como supervisionar o sistema de proteção. Para avaliar a eficácia e o desempenho do método proposto foram realizadas simulações de sistemas de distribuição de energia elétrica no software EMTP para dois sistemas de distribuição contendo 84 e 134 barras, respectivamente. Os resultados obtidos com esta nova abordagem demonstram um excelente desempenho, destacando a precisão do diagnóstico.

**Palavras-chave**— Imuno-wavelet, Detecção e Classificação, Distúrbios de tensão, Sistema de distribuição de energia elétrica, Smart Grids.

## 1 Introdução

As companhias elétricas, na sua maioria, passaram a investir em suas instalações, especialmente nos sistemas de distribuição, de forma a modernizar os equipamentos e automatizar o processo de operação, e consequentemente, reduzir os custos operacionais (McDonald, 2003). Os investimentos buscam basicamente satisfazer as normas impostas pelas agências reguladoras, e elevar a confiabilidade, segurança e eficiência do sistema. Duas tecnologias são empregadas neste contexto, sendo a tecnologia digital e a tecnologia da informação. Com estas tecnologias é possível desenvolver sistemas integrados que combinem técnicas de aquisição, análise e processamento de dados, visando oferecer a assistência necessária para realizar a automação, o controle e a tomada de decisão (Northcote-Green e Wilson, 2007).

O diagnóstico de falhas comumente se baseia na inspeção visual das oscilografias. O julgamento é realizado pelos operadores, com base nas suas

experiências em análise e tomada de decisões. Porém, nem todas as falhas podem ser identificadas pelos operadores. desta forma, o processo pode ser ineficiente e inseguro. Portanto, o emprego de técnicas inteligentes se torna uma alternativa para o problema de diagnóstico. Muitas técnicas baseadas neste conceito vêm sendo utilizadas para auxiliar os operadores na execução de rotinas, proporcionando segurança, rapidez e eficiência no planejamento de ações corretivas. Neste contexto, destacam-se alguns trabalhos disponíveis na literatura.

Em (Santoso et al., 2000) foi apresentado um sistema de classificação de distúrbio de tensão com utilização de wavelet e redes neurais. Já em (Reaz et al., 2007) os autores baseiam-se em redes neurais, lógica fuzzy e wavelet para realizar o diagnóstico de distúrbios de tensão. Em (Uyar et al., 2008) foi apresentado uma metodologia baseada em wavelet e a norma entropia com o uso de redes neurais multi-layer perceptron, com o algoritmo de treinamento retropropagação (Werbos, 1974) para classificação de distúrbios de tensão. Um sistema híbrido de redes neurais artificiais e transformada wavelet discreta foi

utilizado para realizar a detecção, localização e classificação de distúrbios de qualidade de energia em (Oleskovicz et al., 2009). Em (Decanini et al., 2011) foram empregados as técnicas de wavelets e norma entropia para agregar informações uma rede neural ARTMAP-*Fuzzy* para realizar a classificação dos distúrbios. Em (Lima e Minussi, 2012) foi proposta uma nova abordagem para o problema de diagnóstico de distúrbios de tensão, utilizando sistemas imunológicos artificiais de seleção negativa. Neste trabalho, usou-se a discriminação próprio/não-próprio para diferenciar os sinais.

Como destacado em (Lima e Minussi, 2012) os Sistemas Imunológicos Artificiais (SIA's) se mostram ferramentas adequadas para ser aplicadas no diagnóstico de falhas em sistemas elétricos, por causa das suas características naturais.

Desta forma, neste artigo, apresenta-se uma nova abordagem para realizar o diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica, usando um algoritmo imuno-wavelet. Esta proposta imuno-wavelet visa maior robustez e eficiência (maior precisão) no processo de diagnóstico. Para avaliar o desempenho do método foram realizados testes com dois sistemas de distribuição de energia elétrica, sendo um sistema teste 84 barras e um sistema real de 134 barras.

## 2 Algoritmo de Seleção Negativa (ANS)

O ASN foi proposto por Forrest et al. (1994), para detecção de mudanças em sistemas de segurança computacional. Este algoritmo é baseado na seleção negativa de linfócitos T dentro do timo. Este processo representa a discriminação que o organismo realiza com as células, entre próprias e não-próprias.

Na fase de censuriamento do ASN, são definidos, inicialmente, os detectores próprios, que representam uma condição normal do problema, sendo conhecidos como cadeias próprias (S). Na sequência gera-se o conjunto de detectores (R), que possuem a capacidade de reconhecer padrões não-próprios. Assim, a partir da leitura dos dados, escolhem-se cadeias aleatoriamente e verifica-se a afinidade comparando estas cadeias ao conjunto de cadeias próprias (S). Se a afinidade é superior a um limiar preestabelecido, rejeita-se a cadeia. Caso contrário, esta cadeia é aceita no conjunto de detectores (R), e será utilizada para fazer as classificações durante o monitoramento dos dados (Lima, 2013).

Na fase de monitoramento, faz-se um monitoramento nos dados visando identificar mudanças no comportamento das amostras e, então, classificar estas mudanças utilizando o conjunto de detectores criados na fase de censuriamento. Assim, analisando as cadeias protegidas (S) e comparando-as

com o conjunto de detectores (R), avalia-se a afinidade entre cada uma das cadeias. Caso a afinidade entre as cadeias seja superior a um determinado limiar, então, um elemento não-próprio é detectado e classificado (de Castro e Timmis, 2002).

Nas figuras 1 e 2 apresentam-se os fluxogramas das fases do ASN.




Figura 1. Fluxograma do Censuriamento do ASN.




Figura 2. Fluxograma do Monitoramento do ASN.

### 2.1 Critério de Afinidade

Para avaliar a afinidade entre as cadeias e aceitar que são semelhantes, utiliza-se um critério denominado, casamento. O casamento pode ser perfeito ou parcial.

A diferença entre o casamento perfeito e o casamento parcial é que no perfeito todos os pontos dos padrões em análise devem possuir os mesmos valores, já no casamento parcial é necessário que apenas uma quantidade de pontos seja igual, sendo esta quantidade definida previamente. Esta quantidade é denominada, taxa de afinidade (de Castro e Timmis, 2002). A taxa de afinidade indica o mínimo grau de semelhança que deve existir entre dois padrões para que sejam dados como casados ou iguais (Lima, 2013). A taxa de afinidade é definida em (1) como apresentado em Bradley e Tyrrell (2002):

$$TAf = \left( \frac{An}{At} \right) * 100 \quad (1)$$

sendo:

$TAf$  : taxa de afinidade;

$An$  : número de cadeias próprias no problema;

$At$  : número total de cadeias no problema.

Através da equação (1), é possível calcular, de forma estatística, o valor da taxa de afinidade para o problema proposto.

A expressão (2) representa a forma de quantificar a afinidade total entre os padrões em análise (Bradley e Tyrrell, 2002):

$$Af_T = \frac{\sum_{i=1}^L P_c}{L} * 100 \quad (2)$$

sendo:

$Af_T$  : % de afinidade entre os padrões;

$L$  : quantidade total de posições do padrão;

$Pc$  : posição casada;

$\sum_{i=1}^L Pc$  : quantidade de posições casadas.

Desta forma, se  $Af_T$  for maior ou igual a  $TAf$  ocorre o casamento entre os padrões, ou seja, eles são considerados semelhantes. Caso contrário, não ocorre o casamento entre os sinais.

### 3 Transformada Wavelet

As funções wavelets constituem-se em transformadas matemáticas capazes de decompor funções, permitindo reescrever estas funções com os mais finos detalhes, ou seja, permite uma visão “global”. Desta forma, podem-se diferenciar características locais de um sinal em diferentes escalas (resoluções) e, ainda, analisar toda a extensão do sinal por meio de translações. Como a maioria das wavelets possuem suporte compacto, são muito úteis na análise de sinais não-estacionários. Neste sentido, a análise wavelet leva vantagem em relação à análise de Fourier (Mallat, 1999).

Existem diversas famílias de funções wavelet. Neste trabalho, consideram-se as funções wavelets ortonormais da família discretas de Daubechies (Daubechies, 1992) por possuírem transformadas com algoritmos computacionalmente rápidos (Mallat, 1999).

#### 3.1 Transformada Wavelet Discreta (TWD)

Dado um sinal  $y[t] = (y_0, \dots, y_{n-1})$  representando por um vetor discreto, pode ser representado por uma série wavelet como em (3), (Mallat, 1999):

$$y[t] = \sum_{k=0}^{N_j} c_{j,k} \phi_{j,k}(t) + \sum_{j=1}^J \sum_{l=0}^{N_j} d_{j,k} \psi_{j,k}(t), \forall t \in [0, N_0] \quad (3)$$

em que:  $J$  representa o nível de resolução,  $N_j = (N/2^j) - 1$  representa o número de pontos de cada novo vetor obtido pela transformação,  $\phi_{j,k}(t)$  e  $\psi_{j,k}(t)$  são as funções escala e wavelet, responsáveis pela transformação;  $j$  indica escala (dilatação) e  $k$  a posição (translação).

A Transformada Wavelet Discreta (TWD) aplicada diretamente a sinal para a geração do conjunto de coeficientes é computada por sucessivas passagens pelo filtro  $G$  (passa baixa) e pelo filtro  $H$  (passa alta), ou como também conhecido níveis de resolução. Os filtros  $G$  e  $H$  são vetores de constantes já calculados que proporcionam uma base ortogonal relacionada às funções escala e wavelet,

respectivamente. Esse processo é conhecido como algoritmo Piramidal de Mallat (Mallat, 1999) é ilustrado na figura 3.




Figura 3. Representação do algoritmo piramidal para TWD.

Na figura 3,  $C_0$  corresponde ao sinal original discreto ( $C_0 = y[t]$ ),  $H$  e  $G$  representam os filtros passa-alta e passa-baixa, respectivamente. Os parâmetros  $d_1$ ,  $d_2$  e  $d_3$  são os coeficientes wavelets ou detalhe em cada nível de resolução e  $C_3$  são os coeficientes escala ou aproximação no último nível de transformada. Estes coeficientes são obtidos através da convolução das constantes nos filtros (4) e (5), (Mallat, 1999):

$$C_{j+1,k} = \sum_{l=0}^{D-1} h_l C_{j,2k+l} \quad (4)$$

$$d_{j+1,k} = \sum_{l=0}^{D-1} g_l C_{j,2k+l} \quad (5)$$

sendo:  $k = 0, \dots, (N/2^j) - 1$  e  $D$  o número de constantes do filtro. Desta forma, os coeficientes  $C_{j,k}$  representam a média local ponderada e os coeficientes wavelet  $d_{j,k}$  representam a informação complementar ou simplesmente os detalhes que escapam da média ponderada. Assim, os coeficientes da transformada ordenados por escala ( $j$ ) e posição ( $k$ ) e são representados como a seguir (Mallat, 1999):

$$\psi = \left( (C_{j,k})_{k=0}^{N_j}, (d_{j,k})_{k=0}^{N_j} \right)_{j=J}^1 \quad (6)$$

de forma que  $\psi$  é a representação finita apenas em termos dos coeficientes da decomposição do sinal na equação (3). A figura 4 ilustra graficamente o processo de decomposição de um sinal com dois níveis de resolução. Observa-se que a cada nível de transformação, o tamanho dos vetores resultantes é reduzido pela metade ( $N/2^j$ ).




Figura 4. Representação do algoritmo piramidal para TWD.

Na sequência, na figura 5 é mostrado um trecho de um sinal qualquer e sua transformada wavelet. O segmento foi decomposto usando a função wavelet de Daubechies de ordem 10, e uma janela de Hanning com 40 pontos.




Figura 5. Sinal e sua respectiva transformada wavelet.

Na figura nota-se que a energia do sinal original é mantida nos primeiros pontos do sinal, isto se deve a decomposição em vários níveis de resolução.

#### 4 Modelagem e Simulações

Por causa da falta de uma base de dados de sistemas de distribuição de energia elétrica sob o efeito de perturbações, é necessário modelar sistemas testes, nos quais se podem fazer simulações destes eventos (distúrbios de tensão, curtos-circuitos, entre outros), fornecendo dados a serem utilizados na avaliação da metodologia.

Neste sentido, com o auxílio da rotina *models* (Dubé, 1996) no software EMTP (EMTP-RV, 2011) foram modelados dois sistemas de distribuição de energia elétrica, sendo um sistema-teste de 84 barras e um sistema real de 134 barras. Como parâmetros, foram usados uma frequência de amostragem de 15,36 kHz equivalente a 256 amostras por ciclo. O tempo de simulação foi de 200 ms.

Para as simulações de distúrbios de tensão foi utilizado o modelo teórico proposto por Abdel-Galil et al. (2004), no qual cada distúrbio é gerado através de variações de parâmetros em equações que representam a forma de onda dos distúrbios.

Foram realizadas 1248 simulações, sendo 624 simulações para cada sistema elétrico. As simulações foram realizadas considerando a fase na qual o distúrbio ocorria, os carregamentos do sistema de 50% até 120% e os parâmetros do modelo teórico. Na tabela 1 apresenta-se o número de simulações que foram realizadas para cada classe de distúrbio.

Tabela 2. Quantidade de simulações realizadas.

Distúrbio de Tensão	Sistema	
	84 Barras	134 Barras
<i>Outage</i>	48	48
Harmônico	144	144
<i>Swell</i>	72	72
<i>Sag</i>	72	72
<i>Swell</i> com Harmônico	96	96
<i>Sag</i> com Harmônico	96	96
Transitório Oscilatório	96	96
Total	624	624

## 5 Metodologia Proposta

O algoritmo imuno-wavelet proposto neste trabalho, para a detecção e classificação de distúrbios de tensão, baseia-se no princípio de seleção negativa e suas fases são apresentadas nos tópicos a seguir.

### 5.1 Fase de Censoriamento

Nesta fase são gerados os detectores próprios e o conjunto de detectores de distúrbios. Os conjuntos de detectores são utilizados pelo sistema de diagnóstico durante o processo de monitoramento. Os detectores são gerados para cada fase do sistema elétrico.

Os detectores próprios representam as características de operação normal do sistema elétrico. Desta forma, são armazenadas janelas (256 pontos) de oscilografias que representem o sistema em operação normal. Uma vez gerado o conjunto de detectores próprios pode-se gerar o conjunto de detectores de distúrbios. Este processo é ilustrado no fluxograma apresentado na figura 6.

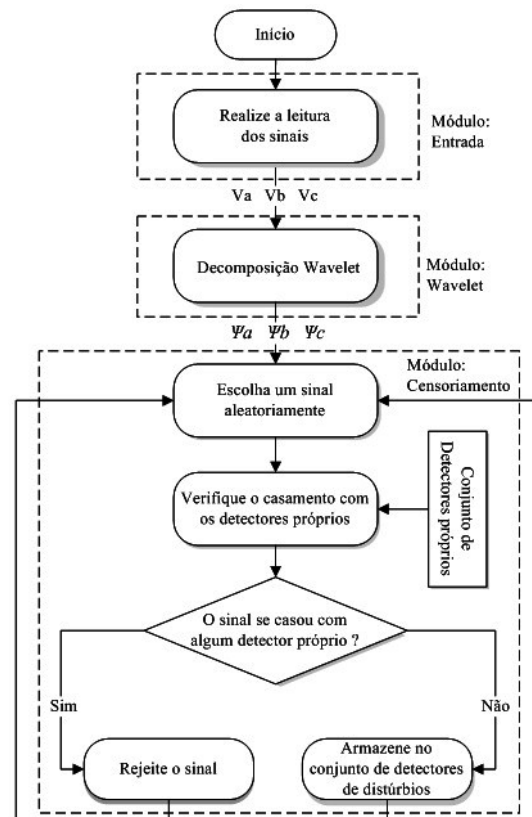


Figura 6. Fluxograma fase censoriamento.

Em resumo, este procedimento é dividido em três módulos, sendo a leitura dos sinais, que se deseja criar os detectores, o módulo wavelet que realiza a decomposição dos sinais utilizando uma transformada discreta com quatro níveis de resolução e, por fim, o módulo de censoriamento, onde se escolhem sinais aleatoriamente e verifica-se o casamento em relação ao conjunto de detectores próprios. Caso o critério de afinidade seja satisfeito,

rejeitam-se os sinais, pois possuem características próprias. Caso contrário, estes sinais são armazenados no conjunto de detectores de distúrbios.

Vale ressaltar que a quantidade de detectores utilizados é determinada pelo operador. No entanto, recomenda-se utilizar 30% dos dados disponíveis. O critério de casamento utilizado é o casamento parcial proposto por (Bradley e Tyrrell, 2002), no qual se utiliza um desvio de 3%.

## 5.2 Fase de Monitoramento

A fase de monitoramento é dividida em cinco módulos, sendo o módulo de entrada ou leitura dos sinais (via sistema de aquisição de dados SCADA), o módulo wavelet, que realiza uma decomposição nos sinais em quatro níveis de resolução, o módulo de detecção, responsável por realizar a discriminação próprio/não-próprio, o módulo de extração que extrai os sinais não-próprios detectados e, finalmente, o módulo de classificação, responsável por classificar os distúrbios. Na figura 7 ilustra-se o fluxograma da fase de monitoramento dos dados.

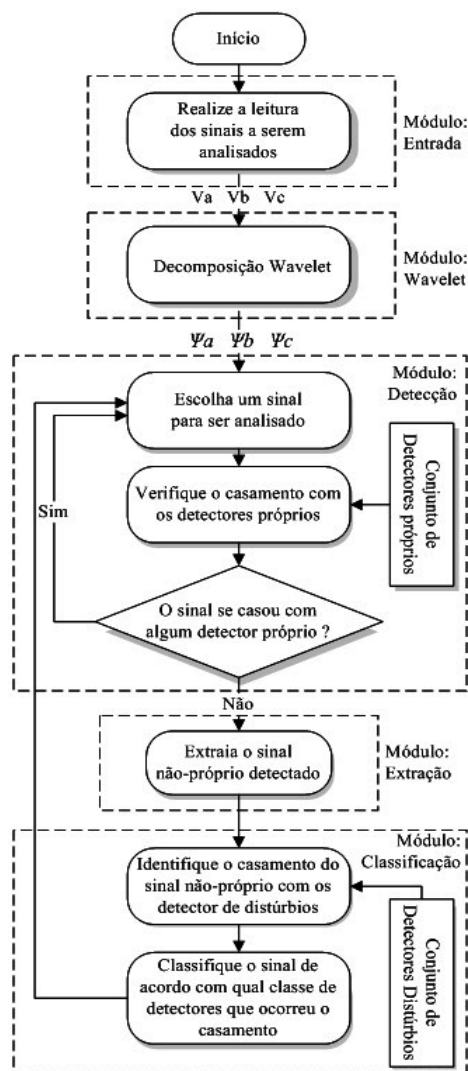


Figura 7. Fluxograma fase monitoramento.

Após realizar a aquisição do sinal é executado o módulo wavelet que faz a decomposição dos sinais, transformando os sinais para o domínio wavelet. Na sequência, o módulo de detecção compara os sinais em análise com os detectores próprios visando identificar o casamento entre os sinais. Este módulo retorna um diagnóstico dos sinais analisados em próprios e não-próprios.

Quando uma anormalidade é detectada, é executada a extração do sinal anormal, e aciona-se o módulo de classificação. No módulo de classificação compara-se o sinal anormal com o conjunto de detectores de distúrbios, e verifica-se o casamento. Desta forma, classifica-se o sinal anormal com qual classe de detectores o sinal se casar.

Nesta fase, utiliza-se o critério de casamento parcial proposto por (Bradley e Tyrrell, 2002), adotando-se um desvio de 3% nos detectores.

## 6 Resultados

Nesta seção, apresentam-se os resultados obtidos com a aplicação do método proposto nos sistemas testes simulados. Todas as simulações foram realizadas utilizando um PC Intel Core 2 Duo 1.9 GHz, 2 GB de Memória RAM, e sistema operacional Windows 7 Ultimate 32 bits. O algoritmo foi desenvolvido em MATLAB (Matlab, 2011).

O algoritmo proposto foi aplicado aos sistemas de distribuição de energia elétrica de 84 e 134 barras (Chiou et al., 2005; LaPSEE, 2011). Na tabela 2 apresentam-se os resultados obtidos pelo algoritmo imuno-wavelet para os sistemas testados.

Tabela 2. Resultados obtidos pelo ASN-Wavelet.

Diagnóstico	Sistema 84 barras		Sistema 134 barras	
	Padrões testados	Acerto (%)	Padrões testados	Acerto (%)
<i>Swell</i>	72	100,00	72	100,00
<i>Sag</i>	72	100,00	72	100,00
<i>Outage</i>	48	100,00	48	100,00
Harmônico	144	100,00	144	100,00
<i>Swell</i> com Harmônico	96	100,00	96	100,00
<i>Sag</i> com Harmônico	96	100,00	96	100,00
Transitório Oscilatório	96	100,00	96	100,00
Total	624	100,00	624	100,00

Os resultados ilustram o percentual de acertos na identificação dos distúrbios de tensão, com relação à quantidade de padrões utilizados nos testes.

Ressalta-se que o algoritmo imuno-wavelet é executado com tempo inferior a 100 milésimos de segundos. Com a introdução do módulo wavelet, é possível identificar as anormalidades facilmente, pois, no domínio wavelet, os coeficientes de detalhe dos sinais se manifestam de maneira desordenada, indicando a presença de anormalidades.

## 7 Conclusão

Neste artigo foi apresentada uma nova abordagem para realizar a detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica utilizando um algoritmo imuno-wavelet. Foi utilizado o software EMTP (EMTP-RV, 2011), para realizar simulações, gerando o conjunto de dados. O algoritmo proposto apresentou excelentes resultados, obtendo um acerto de 100% na detecção e classificação das anormalidades testadas. A fase de geração de detectores é executada de forma off-line não acarretando prejuízo ao algoritmo. A fase de monitoramento do sistema é realizada rapidamente, com um tempo inferior a 100 milésimos de segundo, credenciando esta nova abordagem a ser utilizada em tempo real, visando auxiliar a tomada de decisões. A combinação da transformada wavelet com o ASN proporcionou maior precisão ao diagnóstico, pois, ao decompor sinais em níveis de resolução, o sistema imunológico consegue identificar as anormalidades facilmente, por causa do nível de detalhe exibido no processo de decomposição. Desta forma, conclui-se que o algoritmo imuno-wavelet proposto neste artigo possui bastante precisão, robustez, eficiência e permite importantes aplicações, inclusive no contexto Smart Grid.

## Agradecimentos

Os autores agradecem a FAPESP pelo apoio financeiro de pesquisa (Proc. Nº 2011/06394-5).

## Referências Bibliográficas

- Abdel-Galil, T. K.; Kamel, M.; Youssef, A. M.; El-Saadany, E. F.; Salama, M. M. A (2004). Power quality disturbance classification using inductive inference approach. *IEEE Transactions on Power Delivery*, Piscataway, v. 19, n. 4, p. 1812–1818.
- Alag, S. et al. A methodology for intelligent sensor measurement, validation, fusion, and fault detection for equipment monitoring and diagnosis. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing*, Cambridge, v. 15, n. 4, p. 307–320, 2001.
- Bradley, D.W.; Tyrrell, A.M. (2002). Immunotronics - Novel Finite-State-Machine Architectures with Built-In Self-Test Using Self-Nonsel Self-Differentiation. *IEEE Transactions on Evolutionary Computation*. Vol. 6, pp. 227–238.
- Chiou, J. P.; Chang, C. F.; Su, C. T. Variable scaling hybrid differential evolution for solving network reconfiguration of distribution systems. *IEEE Transactions on Power Systems*, New York, v. 20, n. 2, p. 668-674, 2005.
- Daubechies, I. *Ten Lectures on Wavelets*. Philadelphia: Society for Industrial and Applied Mathematics, n. 61, 1992.
- de Castro, L. N. and Timmis, J. (2002). “Artificial Immune Systems: A New Computational Intelligence Approach”, Springer. 1st edition.
- Decanini, J. G. M. S.; Tonelli-Neto, M. S.; Malange, F. C. V. ; Minussi, C. R. Detection and classification of voltage disturbances using a fuzzy-ARTMAP-wavelet network. *Electric Power Systems Research*, v. 81, n. 12, p. 2057-2065, 2011.
- Dubé, L. (1996). How to use MODELS-based user-defined network components in ATP. In: *EUROPEAN EMTP USERS GROUP MEETING*, 1996, Budapest. Proceedings... Siegen: EEUG, p. 10–12.
- Emtp-Rv (2011). *Eletromagnetic Transient Program*, Powersys-Solutions, Le Puy-Sainte-Réparate, France.
- Forrest, S., A. Perelson, Allen, L. & Cherukuri, R. (1994), “Self-Nonsel Discrimination in a computer”, *Proc. do IEEE Symposium on Research in Security and Privacy*, pp. 202-212.
- LaPSEE, (2011). Practical 134 bus feeder data. *Lines*, Transactions of the AIEE, part III - Power Apparatus and Systems, v. 76 (Aug.), p. 518-539. Disponível em: <http://www.dee.feis.unesp.br/lapsee/>
- Lima, F. P. A. “Análise de distúrbios de tensão em sistemas de distribuição de energia elétrica baseada em sistemas imunológicos artificiais”. Dissertação de Mestrado, Faculdade de Engenharia de Ilha Solteira, UNESP, Ilha Solteira, Brasil, 2013.
- Lima, F. P. A.; Minussi, C. R. Análise de distúrbios de tensão em sistemas de distribuição de energia elétrica usando o algoritmo de seleção negativa. In: *BRACIS-2012, ENIA-2012*. p. 1-12, 2012.
- Mcdonald, J. D. *Electric power substations engineering*. New York: CRC Press, 2003.
- Mallat, S. “A Wavelet tour of signal processing”. 2. ed. New York. Academic Press, 1999. 637 p.
- Matlab (2011). 7.8 Version, Mathworks Company.
- Northcote-Green, J.; WILSON, R. *Control and automation of electrical power distribution systems*. Boca Raton: CRC/Taylor & Francis, 2007.
- Oleskovicz, M.; Coury, D. V.; Felho, O. D., Usida, W. F.; Carneiro, A. F. M.; Pires, L. R. S. Power quality analysis applying a hybrid methodology with wavelet transform and neural networks. *International Journal of Electrical Power & Energy Systems*, Oxford, v. 31, n. 5, p. 206–212, 2009.
- Reaz, M. B. I.; Choong, F.; Sulaiman, M. S.; Mohd-Yasin, F.; Kamada, M. Expert system for power quality disturbance classifier. *IEEE Transaction on Power Delivery*, Piscataway, v. 22, n.3, p.1979-1988, 2007.
- Santoso, S.; Powers, E. J.; Grady, W. M.; Parsons, A. C. Power quality waveform recognition using wavelet-based neural classifier-Part 1: theoretical foundation. *IEEE Transactions on Power Delivery*, New York, v. 15, n. 1, p. 222-228, 2000.
- Uyar, M.; Yildirim, S. ;Gencoglu, M. T. An effective wavelet-based feature extraction method classification of power quality disturbance signals. *Electric Power System Research*, Lausanne, v. 78, n. 10, p.1747-1755, 2008.
- Werbos, P. J. “Beyond Regression: New Tools For Prediction And Analysis in the Behavioral Sciences”, PhD. Thesis, Harvard University, 1974.