

SISTEMA DE DETECÇÃO DE DISTÚBIOS ELÉTRICOS DE BAIXA COMPLEXIDADE

ROBSON R. DE LIMA¹, DANTON D. FERREIRA¹, JOSÉ M. DE SEIXAS², LEONARDO S. PAIVA¹

¹*Departamento de Engenharia, Universidade Federal de Lavras*

Caixa postal 3037, 37200-000, Lavras, MG, Brasil

*E-mails: rosserrani@engautomacao.ufla.br, danton@deg.ufla.br,
leonardopaiva@deg.ufla.br*

²*Universidade Federal do Rio de Janeiro*

Av. Pedro Calmon. nº 550 - Prédio da Reitoria, 2º andar - Cidade Universitária, 21941-901, Rio de Janeiro, RJ, Brasil

E-mail: seixas@lps.ufrj.br

Abstract— This paper proposes a low-complexity system for power quality disturbance detection. The method makes innovative use of simple features extracted from reduced segments of the monitored voltage waveform. The features (the mean value, variance, energy, and the maximum and minimum values of the filtered voltage signals) require low computational effort and allow a considerable dimensional reduction of the signals, leading to simple classification algorithms. The proposed method achieves high detection rates on both simulated and real signals.

Keywords— Power quality, disturbance detection, pattern recognition.

Resumo— Este trabalho propõe um sistema de baixa complexidade para a detecção de distúrbios elétricos. O método faz uso inovador de parâmetros simples extraídos de segmentos reduzidos da forma de onda de tensão monitorada. Os parâmetros (o valor médio, variância, energia, e os máximo e mínimos valores dos sinais de tensão filtrados) exigem baixo esforço computacional e permitem uma redução dimensional considerável dos sinais, levando a algoritmos de classificação simples. O método proposto atinge altas taxas de detecção de ambos os sinais simulados e reais.

Palavras-chave— Qualidade de energia elétrica, detecção de distúrbios, reconhecimento de padrões.

1 Introdução

A Qualidade de Energia Elétrica (QEE) tem emergido como um campo de pesquisa importante nos últimos anos e as principais razões são: (i) a necessidade de definir índices e indicadores para quantificar a qualidade da energia entregue; (ii) a ampla utilização de dispositivos eletrônicos de potência, que são a causa mais importante de baixa QEE; (iii) a necessidade de localizar as fontes de distúrbios e (iv) a grande quantidade de dados de QEE gravados que exige a detecção automática (RIBEIRO et al., 2013). Neste contexto, a monitoração da QEE é necessária e uma das principais razões é a de assegurar a disponibilidade de energia para os clientes.

Em termos gerais, os sistemas de monitoramento de QEE compreendem as fases de aquisição de dados, pré-processamento de dados e visualização de dados. O primeiro passo é medir tensões para detectar distúrbios de tensão em tempo real no Ponto de Acoplamento Comum.

Vários métodos têm sido propostos na literatura para a detecção de distúrbios e as técnicas mais utilizadas são baseadas na transformada wavelet (WT) (YANG and LIAO, 2001; CAUJOLLE et al., 2010). No entanto, os resultados obtidos com WT podem ser seriamente afetados pelo ruído do sistema, e geralmente têm alta complexidade computacional (YANG and LIAO, 2001). Outros métodos que devem ser mencionados incluem a transformada S (BERTHET, BHENDE and PANIGRAHI, 2008), a

transformada de Hilbert (CHUN-LING et al., 2009), morfologia matemática (LI et al., 2005), máquinas de vetores de suporte (MORAVEJA, ABDOOSA and PAZOKIA, 2010) e curvas principais (FERREIRA et al., 2013, 2014). Cada uma destas técnicas apresenta vantagens e desvantagens.

Para projetar os sistemas de detecção automática de distúrbios em sistemas de energia, devem ser considerados alguns aspectos importante: (i) a sensibilidade ao ruído; (ii) a sensibilidade a variações na frequência fundamental; (iii) o custo computacional. Para aplicações em tempo real, técnicas de baixo custo computacional são preferidas. Para estes fins, técnicas sofisticadas têm sido recentemente propostas (FERREIRA et al., 2013, 2014; MARQUES et al., 2011). O objetivo destas técnicas de detecção é o de proporcionar uma fonte em tempo real e confiável de detecção para uma variedade de distúrbios, de modo que a classificação do distúrbio e a identificação da fonte geradora do mesmo possam ser ambas realizadas.

Este artigo propõe um método de baixa complexidade computacional para detecção de distúrbios de QEE. O método faz uso inovador de parâmetros simples, que possuem uma boa capacidade de distinguir entre as condições de distúrbio e não-distúrbio. Esses parâmetros são extraídos de pequenos segmentos da forma de onda de tensão filtrada e compreendem o valor médio, variância, energia e os valores máximos e mínimos. Para a detecção o Classificador Bayesiano e o Perceptron Multicamadas

(MLP) são avaliados em ambos os sinais simulados e reais.

O trabalho está organizado da seguinte forma. A próxima seção apresenta a formulação de detecção de distúrbios de QEE. O método proposto é descrito na Seção 3. A Seção 4 apresenta os resultados e discussões e as conclusões são apresentadas na Seção 5.

2 Detecção de Distúrbios Elétricos

A versão discreta do sinal de tensão monitorado pode ser segmentada em janelas não sobrepostas de N amostras que são expressas como a contribuição aditiva de vários tipos de fenômenos (RIBEIRO and PEREIRA, 2007), como:

$$v[n] = v(t)|_{t=n/f_s} := f[n] + h[n] + i[n] + t[n] + r[n] \quad (1)$$

em que $n = 0, \dots, N-1$, f_s é a frequência de amostragem, as sequências $f[n]$, $h[n]$, $i[n]$, $t[n]$ e $r[n]$ são a componente fundamental, harmônicos, interharmônicos, transitórios e ruído, respectivamente.

Considerando o vetor $\mathbf{v} = [v[n] \dots v[n - N - 1]]^T$ construído pelas amostras do sinal $v[n]$, o problema de detecção pode ser formulado como um problema de teste de hipóteses:

$$\begin{aligned} \mathcal{H}_0: \mathbf{v} &= \mathbf{f} + \mathbf{r} \\ \mathcal{H}_1: \mathbf{v} &= \mathbf{f} + \Delta\mathbf{f} + \mathbf{i} + \mathbf{t} + \mathbf{h} + \mathbf{r} \end{aligned} \quad (2)$$

onde $\mathbf{i} = [i[n] \dots i[n - N - 1]]^T$, $\mathbf{t} = [t[n] \dots t[n - N - 1]]^T$, $\mathbf{h} = [h[n] \dots h[n - N - 1]]^T$, $\mathbf{r} = [r[n] \dots r[n - N - 1]]^T$. O vetor $\Delta\mathbf{f}$ representa súbitas variações no componente fundamental.

A hipótese $\mathcal{H}_0$ está relacionada à operação nominal e a hipótese $\mathcal{H}_1$ está associada a condições anormais do sinal de tensão.

3 Descrição da Metodologia

3.1 Banco de Dados

O método proposto foi projetado usando sinais simulados e testado utilizando ambos sinais simulados e reais.

Os eventos simulados foram gerados seguindo as normas da IEEE (IEEE, 1995), com uma frequência de amostragem igual a 256 amostras por ciclo da componente fundamental ($f_s = 15.360$ Hz) e SNR (*signal-to-noise ratio*) igual a 30 dB.

Para fins de detecção, há dois pontos de vista bastante diferentes. O primeiro é determinar se existe ou não distúrbio dentro da janela processada, e a ação necessária não é de controle ou proteção, mas apenas de aquisição da janela e processamento (classificação e análise do distúrbio). Neste caso, o tamanho da janela não é tão importante porque não há a ação

imediate ou em tempo real. No entanto, assumindo-se uma aplicação de proteção, em que um distúrbio é detectado e identificado, a ação imediata necessária é isolar o sistema, ou parte dele, o mais rapidamente possível. Em tal caso, a utilização de janelas reduzidas é o método mais adequado.

A fim de avaliar o desempenho do método proposto para segmentos reduzidos do sinal de tensão monitorado, segmentos do sinal de tensão são usados na série de 16-256 amostras, a última correspondente a um ciclo do componente fundamental.

Para cada tamanho de segmento, 110 eventos foram gerados para cada distúrbio isolado. As classes de distúrbios aqui consideradas foram afundamentos, elevações de tensão, interrupções de tensão de curto e longo prazo, transitórios oscilatórios, harmônicos, transitório impulsivo e *notches*, acumulando um total de 880 eventos. Um total de 880 sinais sem distúrbios (sinais de tensão nominal) também foram gerados.

A fim de avaliar o desempenho do método para sinais reais, 110 formas de onda de tensão reais com distúrbios fornecidas pelo grupo de trabalho do IEEE (P1159.3) (IEEE, 2012) foram utilizados.

3.2 Pré-processamento

Os sinais de tensão monitorados são pré-processados por um filtro *notch* (HIRANO, NISHIMURA and MITRA, 1974), sintonizado na frequência fundamental ($f_0 = 60$ Hz). O filtro *notch* tem sido amplamente utilizado na literatura (FERREIRA et al., 2013; FERREIRA, SEIXAS and CERQUEIRA, 2015) para a detecção e classificação de distúrbios de QEE. Este é um importante passo de pré-processamento, uma vez que elimina a componente fundamental do sinal de tensão monitorado, que é a informação redundante presente em todos os tipos de distúrbios e não-distúrbios. Assim, o sinal resultante após a filtragem, aqui denominado como $e[n]$, carrega a informação presente em $v[n]$ dos harmônicos, interharmônicos, transitórios e ruído.

Principalmente devido ao baixo custo computacional e maior seletividade na frequência de interesse, foi utilizada uma estrutura de segunda ordem do filtro IIR (MITRA, 2005), cuja transformada z é dada pela equação:

$$H_0(z) = \frac{1 + a_0 z^{-1} + z^{-2}}{1 + \rho_0 a_0 z^{-1} + \rho_0^2 z^{-2}} \quad (3)$$

onde $a_0 = -2 \cos \omega_0$ e ρ_0 é o fator *notch* (aqui, $\rho_0 = 0,97$).

A Figura 1 mostra sinais simulados pré-processados com e sem distúrbios. Note que quando não há perturbação no sinal, o sinal resultante é composto apenas por ruído ($\mathbf{r}$) como formulado na Equação 2.




Figura 1. Sinais pré-processados ($e[n]$): (a) sinal sem distúrbios, (b) transitório oscilatório, (c) elevação de tensão, (d) notch e (e) harmônicos.

3.3 Extração de parâmetros

Para representar os sinais em um espaço dimensional reduzido e maximizar a fronteira de separação entre as classes, cinco parâmetros foram extraídos de $e[n]$, a dizer: ambos máximo ($\max_{e[n]}$) e mínimo ($\min_{e[n]}$) valores, o valor médio ($\mu_{e[n]}$), variância ($\sigma_{e[n]}^2$) e energia ($E_{e[n]}$). Este último foi calculado de acordo com a Equação 4. Isto resulta numa redução de dimensão considerável, considerando-se um ciclo do componente fundamental. Estes parâmetros foram escolhidos por serem fáceis de ser calculados e representar bem as assinaturas dos eventos (PANUGRAHI and PANDI, 2009; ERISTI and DEMIR, 2012).

$$E_{e[n]} = \sum_{n=1}^N |e[n]|^2 \quad (4)$$

onde N é o tamanho do segmento do sinal monitorado.

3.4 Seleção de parâmetros

O Discriminante Linear de Fisher (FDR) é uma técnica muito simples para revelar as características mais relevantes de dados multidimensionais. Bem discutido em (THEODORIDIS and KOUTROUMBAS, 2009), o FDR tem duas aplicações principais e diferentes: ele pode ser usado como classificador e como ferramenta de seleção de parâmetros. Neste trabalho, foi empregado como seletor de parâmetros com o objetivo de revelar quais são os parâmetros mais relevantes dentre os cinco extraídos, como descrito na subseção anterior.

Como ferramenta de seleção de parâmetros, a função custo a ser minimizada no critério FDR é:

$$\mathbf{J}_c = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^2 \odot \frac{1}{\sigma_1^2 + \sigma_2^2} \quad (5)$$

onde $\mathbf{J}_c = [J_1 \dots J_{L_l}]^T$, L_l é o número total de parâmetros, $\boldsymbol{\mu}_1$ e $\boldsymbol{\mu}_2$, e σ_1^2 e σ_2^2 são os vetores de médio e variância das classe 1 e classe 2, respectivamente. O símbolo $\odot$ refere-se ao produto de Hadamard $\mathbf{r} \odot \mathbf{s} = [r_0 s_0 \dots r_{L-1} s_{L-1}]^T$.

A partir disso, pode-se entender que os i -ésimos elementos do vetor de parâmetros, relacionados a valores mais elevados de $\mathbf{J}_c$, representam as características que apresentam melhor separabilidade entre as classes. Esta técnica é muito útil para os problemas de classificação de altas dimensões, uma vez que torna possível selecionar os melhores parâmetros (mais discriminantes entre as classes) e, assim, reduzir o número de parâmetros a serem utilizados para a classificação. Esta redução de dimensão é atraente em sistemas que requerem baixa complexidade computacional, tais como os sistemas que operam em tempo real. Além disso, a utilização de um número reduzido de parâmetros pode levar a classificadores mais simples, com melhor desempenho, uma vez que os parâmetros responsáveis pela intersecção entre as classes (ou parte deles) podem ser descartados.

3.5 Classificadores

Os parâmetros extraídos alimentam os classificadores. A partir dos parâmetros mais relevantes, novos parâmetros são adicionados gradualmente ao classificador até incluir os cinco parâmetros. Dois diferentes classificadores são propostos, um oferece solução linear (*Naive-Bayes*) e outro não-linear (*Perceptron Multicamadas – MLP*). Os classificadores são apresentados em detalhe em (THEODORIDIS and KOUTROUMBAS, 2009). Note que, neste estágio, o problema de detecção de distúrbios da QEE é visto como um problema de classificação de duas classes, com distúrbios e sem distúrbios.

Para o projeto do classificador *Naive-Bayes* foram consideradas classes equiprováveis e foi assumida distribuição Gaussiana.

A rede MLP implementada neste trabalho tem uma camada escondida e um neurônio de saída. O número de neurônios presentes na camada escondida foi variado desde um até um máximo de dois neurônios a mais do que o número de parâmetros de entrada utilizado. Foi utilizado o algoritmo de *Levenberg-Marquardt backpropagation* (LEVENBERG, 1944; MARQUARDT, 1963) para o treinamento, a função tangente hiperbólica como função de ativação em todos os neurônios.


4 Resultados

4.1 Sinais Simulados


A Figura 2 mostra a relevância de cada parâmetro selecionado (de 1 a 5), de acordo com o critério FDR, para $N = 16$ -256 amostras e usando o conjunto de dados de treinamento $[\mu_{e[n]} \sigma_{e[n]}^2 E_{e[n]} \min_{e[n]} \max_{e[n]}]$.

Exceto para o caso de 16 amostras, foi observado o mesmo comportamento: valores máximo e mínimo apresentaram maior capacidade de discriminação no que diz respeito a outras características. Para o caso de $N = 16$ amostras, a variância provou ser tão relevante quanto estes dois. Em todos os casos, o valor médio foi a característica que contribuiu menos para a separação entre as classes.


Do conjunto total de dados, 60% foram utilizados para treinamento e 40% para validação. Usando este conjunto de dados, 100 diferentes subconjuntos de treinamento e validação foram criados aleatoriamente (procedimento de validação cruzada). Eles foram gerados para avaliar e comparar o desempenho dos classificadores. Foi usado o *software* MatLab® para executar os testes. Os resultados são a média $\pm$ desvio padrão.




(a)




(b)



(c)



(d)



(e)

Figura 2. FDR para segmentos de sinais com N amostras: (a) $N = 16$; (b) $N = 32$; (c) $N = 64$; (d) $N = 128$; (e) $N = 256$.

As tabelas 1-5 mostram o desempenho dos detectores propostos a partir do conjunto de validação para cada comprimento de janela. A Classe 1 aplica-se aos sinais com distúrbios e a Classe 2 aplica-se aos sinais sem distúrbios de QEE. Os resultados estão apresentados considerando vetores de parâmetros contendo de um a cinco dos parâmetros propostos escolhidos de acordo com o FDR para cada janela de aquisição.

Em geral, os classificadores Naive-Bayes e MLP alcançaram bons resultados de detecção, com altas taxas de precisão para ambas as classes.

Quanto ao número de amostras (N) processadas, ela aumenta a taxa de sucesso dos classificadores a medida que N aumenta. No entanto, é importante notar que, mesmo para N igual a 16 amostras (equivalente a 1/16 de um ciclo da componente fundamental), desempenhos superiores a 99% foram obtidos pelo classificador MLP para ambas as classes.

Tabela 1. Desempenho de Detecção para $N = 16$ em % - dados simulados.

Nº de Parâmetros	Naive-Bayes		MLP	
	Classe 1	Classe 2	Classe 1	Classe 2
1	86,36 $\pm$ 0,00	99,71 $\pm$ 0,00	87,71 $\pm$ 0,25	98,86 $\pm$ 0,00
2	94,03 $\pm$ 0,00	100,00 $\pm$ 0,00	93,83 $\pm$ 2,68	99,47 $\pm$ 0,46
3	96,02 $\pm$ 0,00	100,00 $\pm$ 0,00	96,32 $\pm$ 0,47	98,93 $\pm$ 0,45
4	96,59 $\pm$ 0,00	100,00 $\pm$ 0,00	97,09 $\pm$ 1,11	99,80 $\pm$ 0,25
5	96,31 $\pm$ 0,00	100,00 $\pm$ 0,00	99,14 $\pm$ 0,98	99,82 $\pm$ 0,43

Tabela 2. Desempenho de Detecção para $N = 32$ em % - dados simulados.

Nº de Parâmetros	Naive-Bayes		MLP	
	Classe 1	Classe 2	Classe 1	Classe 2
1	84,37 ± 0,00	98,01 ± 0,00	85,22 ± 0,68	97,64 ± 0,34
2	99,43 ± 0,00	100,00 ± 0,00	98,22 ± 0,39	99,95 ± 0,22
3	98,01 ± 0,00	100,00 ± 0,00	97,84 ± 0,65	99,70 ± 0,47
4	98,01 ± 0,00	100,00 ± 0,00	98,00 ± 0,76	99,77 ± 0,39
5	98,30 ± 0,00	100,00 ± 0,00	99,43 ± 0,54	99,61 ± 0,59

Quanto ao número de parâmetros usados, taxas de acerto superiores a 96% foram obtidas por ambos os classificadores com apenas três parâmetros e $N = 16$ amostras. Para $N \geq 32$ amostras e apenas dois parâmetros, o classificador Naive-Bayes atingiu taxas acima de 99,4%.

Tabela 3. Desempenho de Detecção para $N = 64$ em % - dados simulados.

Nº de Parâmetros	Naive-Bayes		MLP	
	Classe 1	Classe 2	Classe 1	Classe 2
1	90,91 ± 0,00	99,72 ± 0,00	91,80 ± 0,58	99,13 ± 0,33
2	99,43 ± 0,00	99,72 ± 0,00	99,20 ± 0,69	99,98 ± 0,07
3	99,72 ± 0,00	100,00 ± 0,00	99,39 ± 0,38	99,99 ± 0,03
4	99,72 ± 0,00	99,72 ± 0,00	98,91 ± 0,22	100,00 ± 0,00
5	99,72 ± 0,00	99,72 ± 0,00	99,77 ± 0,30	100,00 ± 0,00

Tabela 4. Desempenho de Detecção para $N = 128$ em % - dados simulados.

Nº de Parâmetros	Naive-Bayes		MLP	
	Classe 1	Classe 2	Classe 1	Classe 2
1	90,90 ± 0,00	98,86 ± 0,00	90,94 ± 0,48	90,86 ± 0,11
2	100,00 ± 0,00	99,43 ± 0,00	99,91 ± 0,29	99,95 ± 0,09
3	100,00 ± 0,00	100,00 ± 0,00	99,43 ± 0,66	100,00 ± 0,00
4	100,00 ± 0,00	100,00 ± 0,00	99,94 ± 0,13	100,00 ± 0,00
5	100,00 ± 0,00	100,00 ± 0,00	99,96 ± 0,13	100,00 ± 0,00

Tabela 5. Desempenho de Detecção para $N = 256$ em % - dados simulados.

Nº de Parâmetros	Naive-Bayes		MLP	
	Classe 1	Classe 2	Classe 1	Classe 2
1	94,31 ± 0,00	99,43 ± 0,00	94,36 ± 0,58	99,33 ± 0,27
2	100,00 ± 0,00	100,00 ± 0,00	99,61 ± 0,27	100,00 ± 0,00
3	100,00 ± 0,00	100,00 ± 0,00	99,74 ± 0,39	99,99 ± 0,05
4	100,00 ± 0,00	100,00 ± 0,00	99,54 ± 0,25	100,00 ± 0,00
5	100,00 ± 0,00	100,00 ± 0,00	99,57 ± 0,50	100,00 ± 0,00

4.2 Sinais Reais

As Tabelas 6-10 mostram os desempenhos dos detectores propostos para os sinais reais. Esses resultados foram obtidos utilizando os melhores detectores encontrados para ambos métodos, dentre os 100 obtidos nos testes com sinais simulados. Como os sinais reais do banco de dados consistem em apenas distúrbios, são mostrados os resultados apenas para a Classe 1.

Em geral, ambos os classificadores mostraram boa capacidade de generalização, alcançando altas taxas de acerto. O classificador *Naive-Bayes* obteve os melhores índices de acerto. Com $N \geq 32$ e utilizando apenas dois parâmetros, ambos os classificadores alcançaram taxas de sucesso acima de 99%. Para $N = 16$, que é o caso das menores taxas de acerto, taxas superiores a 90% foram alcançadas usando apenas dois parâmetros.

Tabela 6. Desempenho de Detecção para $N = 16$ em % - dados reais.

Nº de Parâmetros	Naive-Bayes	MLP
	Classe 1	Classe 1
1	85,45	85,45
2	97,27	90,91
3	100	90
4	99,09	100
5	100	96,36

Tabela 7. Desempenho de Detecção para $N = 32$ em % - dados reais.

Nº de Parâmetros	Naive-Bayes	MLP
	Classe 1	Classe 1
1	86,36	86,36
2	100	99,09
3	100	100
4	100	100
5	100	98,18

Tabela 8. Desempenho de Detecção para $N = 64$ em % - dados reais.

	Naive-Bayes	MLP
Nº de Parâmetros	Classe 1	Classe 1
1	87,27	87,27
2	100	99,09
3	100	100
4	100	99,09
5	100	100

Tabela 9. Desempenho de Detecção para $N = 128$ em % - dados reais.

	Naive-Bayes	MLP
Nº de Parâmetros	Classe 1	Classe 1
1	89,09	90,91
2	99,09	100
3	100	98,18
4	100	100
5	100	100

Tabela 10. Desempenho de Detecção para $N = 256$ em % - dados reais.

	Naive-Bayes	MLP
Nº de Parâmetros	Classe 1	Classe 1
1	95,45	95,45
2	99,09	99,09
3	100	99,09
4	100	99,09
5	100	100

5 Conclusão

O trabalho apresenta um método de detecção de distúrbios simples. Mostra-se que, utilizando apenas dois parâmetros (os valores máximo e mínimo), facilmente extraídos do sinal de tensão filtrada, e um classificador simples, altas taxas de detecção foram obtidas para ambos os sinais simulados e reais. Além disso, o método funciona bem mesmo quando reduzidas janelas de sinal (até 1/16 de um ciclo da componente fundamental) são processadas.

O método proposto pode ser útil em sistemas de monitoramento *on-line* e para efeitos de proteção devido à sua baixa complexidade computacional e bons resultados.

No contexto de *Smart Grids*, onde a quantidade de informações e os níveis de QEE necessários são muito elevados, o método proposto pode dar uma boa contribuição como parte de um sistema *on-line* de monitoramento da QEE.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) por apoiar este trabalho e fornecer suporte financeiro.

Referências Bibliográficas

- Berthet, 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, Vol.23, N°. 1, pp. 280- 287.
- Caujolle, M.; Petit, M.; Fleury, G. and Berthet, L. (2010). Reliable power disturbance detection using wavelet decomposition or harmonic model based kalman filtering. 14th International Conference on Harmonics and Quality of Power (ICHQP), 2010, Sept. 2010, pp. 1- 6.
- Chun-Ling, C.; Yong, Y.; Tongyu, X.; Yingli, C. and Xiaofeng, W. (2009). Power quality disturbances detection based on Hilbert phase-shifting. Asia-Pacific Power and Energy Engineering Conference, APPEEC 2009. Wuhan, China: 10.1109/APPEEC.2009.4918613, March 2009, pp. 1- 4.
- Eristi, H. and Demir, Y. (2012). The Feature Selection based Power Quality Event Classification using Wavelet Transform and Logistic Model Tree. PRZEGLĄD ELEKTROTECHNICZNY (Electrical Review), pp. 43- 48.
- Ferreira, D. D.; Seixas, J. M.; Cerqueira, A. S. and Duque, C. A. (2013). Exploiting principal curves for power quality monitoring. Electric Power Systems Research, vol. 100, pp. 1- 6.
- Ferreira, D. D.; Seixas, J. M.; Duque, C. A.; Ribeiro, P. F. (2014). A Direct Approach for Disturbance Detection Based on Principal Curves. 16th International Conference on Harmonics and Quality of Power (ICHQP), 2014, Bucharest, p. 1.
- Ferreira, D.D.; Seixas J. M.; Cerqueira, A. S. (2015). A method based on independent component analysis for single and multiple power quality disturbance classification. Electric Power Systems Research (Print), Vol. 119, pp. 425- 431.
- Hirano, K.; Nishimura, S. and Mitra, S. K. (1974). Design of digital notch filters. IEEE Trans. on Communications, Vol. 22, N°.7, pp. 964- 970.
- IEEE (1995). On Power Quality, I. S. C. C. IEEE recommended practice for monitoring electric power quality. Technical reporting, IEEE.
- IEEE (2012). Power Quality Data of the IEEE P1159.3 Task Force. <http://grouper.ieee.org/groups/1159/3/docs.html>, this reference was last accessed at 10/12/2012.
- Levenberg, K. (1944). A method for the solution of certain problems in least squares. Quarterly of Applied Mathematics, 5, pp. 164- 168.

- Li, G.; Zhou, M.; Luo, Y. and Ni, Y. (2005). Power quality disturbance detection based on mathematical morphology and fractal technique. 2005 IEEE/PES Transmission and Distribution Conference and Exhibition: Asia and Pacific. Dalian: 10.1109/TDC.2005.1547030, pp. 1- 6.
- Marquardt, D. (1963). An algorithm for least-squares estimation of nonlinear parameters. SIAM Journal on Applied Mathematics, 11(2), pp. 431-441.
- Marques, C. A. G.; Ferreira, D. D.; Freitas, L. R.; Duque, C. A. and Ribeiro, M. V. (2011). Improved disturbance detection technique for power quality analysis. Power Delivery, IEEE Transactions on, Vol. 26, N°. 2, pp. 1286- 1287.
- Mitra, S. K. (2005). Digital Signal Processing: A computer-based approach. Third ed., McGraw-Hill.
- Moraveja, Z.; Abdoosa, A. A. and Pazokia, M. (2010). Detection and classification of power quality disturbances using wavelet transform and support vector machines. Electric Power Components and Systems, Vol.38, N°.2, pp. 182- 196.
- Panugrahi, B. K.; Pandi, V. R. (2009). Optimal feature selection for classification of power quality disturbances using wavelet packet-based fuzzy k-nearest neighbor algorithm. IET Gener. Transm. Distrib., Vol.3, Iss.3, pp. 296- 306.
- Ribeiro, M. V. and Pereira, J. L. R.. (2007). Classification of single and multiple disturbances in electric signals. EURASIP Journal on Advances in Signal Processing, Vol. 2007, N°. Article ID 56918, pp. 18 pages.
- Ribeiro, P. F.; Duque, C. A.; Ribeiro, P. M. and Cerqueira, A. S. (2013). Power Systems Signal Processing for Smart Grids. John Wiley and Sons.
- Theodoridis, S., Koutroumbas, K. (2009). Pattern Recognition. 4 ed., Elsevier.
- Yang, H.-T. and Liao, C.-C. (2001). A de-noising scheme for enhancing wavelet based power quality monitoring system. IEEE Transaction on Power Delivery, Vol. 16, N°. 3, pp. 353- 360.