

Sistema de Classificação de Distúrbios baseado no conceito de Detecção de Novidade

Thais Martins Mendes
Universidade Federal de Juiz de Fora
martins_tha@outlook.com

Danton Diego Ferreira e Bruno Henrique Groenner
Barbosa

Universidade Federal de Lavras
danton@deg.ufla.br, brunohd@deg.ufla.br

Resumo — A preocupação com a qualidade de energia elétrica (QEE) se faz presente no cotidiano de engenheiros, concessionárias, consumidores e pesquisadores. Este trabalho apresenta um sistema de classificação especialista (SCE) em distúrbios de QEE que aplica o conceito de detecção de novidade (DN). O método faz uso inovador da chamada Máquina de Vetor de Suporte *one class*, que é um método de classificação não supervisionado e utiliza Estatísticas de Ordem Superior (EOS) para construir um compacto e representativo vetor de assinaturas dos eventos de QEE. O Discriminante Linear de Fisher (FDR) é utilizado para selecionar os melhores parâmetros e simplificar o algoritmo de detecção. O sistema foi testado em simulações para cinco classes de distúrbios, apresentando uma eficiência global de 99.9%.

Palavras-chaves — Qualidade de energia elétrica, distúrbios elétricos, classificação de distúrbios, detecção de novidade.

I. INTRODUÇÃO

A qualidade da energia elétrica disponibilizada na rede elétrica tem recebido bastante atenção de pesquisadores nos últimos anos. O termo “Qualidade de Energia Elétrica” (QEE), em geral, compreende a qualidade das formas de onda da tensão e corrente elétricas em um sistema elétrico [1].

O aparecimento de deformidades nas formas de onda da tensão e corrente caracteriza a falta de QEE. Estas deformidades são definidas pelo IEC (Commission, 1991) como fenômenos eletromagnéticos ou simplesmente distúrbios, dentre os quais se destacam os harmônicos, flutuações de tensão, afundamentos, transitórios, entre outros.

O sistema de energia elétrica está constantemente sujeito a transformações. Mudanças na produção, no consumo ou na própria rede de distribuição de energia, comprovam tal afirmação [3]. Este cenário de mudanças gera consequências ao desempenho dos equipamentos ligados à rede e, portanto, afetam a QEE. A finalidade do sistema de energia elétrica é fornecer alimentação para estes equipamentos, por conseguinte, essas consequências imprevistas exigem atenção.

Independente da causa das distorções presentes nos sinais elétricos, elas podem gerar perdas consideráveis aos consumidores de energia, uma vez que tais distúrbios podem causar o funcionamento incorreto ou até mesmo a queima dos

equipamentos conectados à rede elétrica e, consequentemente, interromper um processo de produção[4].

Diante das inevitáveis mudanças que ocorrem no sistema elétrico, o aparecimento de deformidades no sinal elétrico pode não ser necessariamente decorrente de perturbações já conhecidas de QEE, mas de algum fenômeno novo, ainda desconhecido. Neste caso, os detectores convencionais, focados em detectar apenas os distúrbios de QEE já bem conhecidos (variações de tensão, harmônicos, transientes) podem não funcionar. Desta forma, algoritmos de detecção que se baseiam no conceito de detecção de novidade (DN) [5]-[6] se encaixam muito bem neste novo panorama dos sistemas de energia elétrica.

A etapa de classificação de distúrbios é de grande relevância em um processo de monitoramento da QEE, uma vez que contribui diretamente para identificar e localizar a fonte causadora dos distúrbios. Sabe-se que o problema de classificação de distúrbios é bastante complexo, principalmente quando classes de múltiplos distúrbios são consideradas.

Existem na literatura vários trabalhos de classificação de distúrbios. A maioria deles emprega técnicas bem conhecidas de processamento de sinais para extrair informações relevantes e/ou filtrar informações irrelevantes. Dentre elas se destacam a Transformada Wavelet [7]-[9], Transformada S [10], Transformada de Hilbert [11] e Transformada de Fourier [12]-[13]. Como classificadores, os algoritmos mais empregados são Redes Neurais [14]-[16], Máquina de Vetor e Suporte [17] e Sistemas Neuro-Fuzzy [18].

Neste trabalho, um sistema de classificação especialista em distúrbios de QEE é proposto. Este sistema é baseado na ideia da utilização de estatística de ordem superior (EOS) para extrair parâmetros dos distúrbios aqui abordados. Este tipo de abordagem é motivada pelo fato de as EOS serem imunes à presença de ruído gaussiano [19] e foi, inicialmente, aplicada ao problema de detecção e classificação de distúrbios elétricos em [20]-[21], resultando em um elevado desempenho aliado a uma reduzida complexidade computacional. Após a etapa de extração de características os parâmetros mais representativos de cada classe são selecionados utilizando o Discriminante Linear de Fisher (FDR) [22]. A escolha do uso desta ferramenta de seleção de parâmetros deve-se à sua simplicidade e por já ter sido provado sua efetividade em vários trabalhos de classificação de distúrbios [23]. Estes

parâmetros são apresentados ao algoritmo de classificação baseado em Máquina de Vetor de Suporte (SVM). Utiliza-se uma abordagem inovadora do classificador conhecida com SVM *one class* [24], que constrói um envelope multidimensional que circunda as amostras de cada classe de distúrbios, realizando a classificação de distúrbios através do conceito de detecção de novidade. Este tipo de classificador é interessante para a aplicação proposta, uma vez que requer dados apenas de uma das classes de um problema de classificação de duas classes.

O trabalho está organizado da seguinte maneira. A próxima seção apresenta o método proposto. Os resultados são apresentados na seção III e as conclusões finais na seção IV.

II. Método Proposto

O diagrama da Fig. 1 representa a forma geral adotada para o sistema de classificação especialista proposto para cada uma das classes de distúrbios abordadas. Nos itens listados a seguir cada um dos blocos são explicados.




Fig. 1. Método Proposto.

A. Dados de Entrada

Sinais de tensão sintéticos foram gerados com uma frequência de amostragem igual a 15.360 Hz. Sete classes de distúrbios foram consideradas: harmônicos, afundamentos de tensão, elevação de tensão, transitórios oscilatórios e transitórios impulsivos. Um total de 500 eventos foi gerado para cada classe de distúrbios, e 500 sinais foram gerados sem distúrbios (classe de sinais nominais). Os sinais foram gerados com um ruído branco Gaussiano aditivo a SNR (*Signal-to-noise ratio*) de 60 dB.

A Entrada do método proposto, conforme Fig. 1, representa um sinal de tensão contendo 256 amostras (apenas um ciclo do sinal).

Para avaliação de desempenho, metade dos dados foi usada para o projeto do método e a outra metade para a avaliação de desempenho.

B. Extração de Parâmetros

O bloco Extração de Parâmetros extrai os parâmetros de EOS pelo cálculo dos cumulantes de segunda, terceira e quarta ordens do sinal de entrada. Os parâmetros de EOS e o número destes podem ser escolhidos de forma a haver um melhor compromisso entre baixo custo computacional e desempenho. Neste trabalho, devido ao alcance de resultados melhores e satisfatórios, os cumulantes de 2ª, 3ª e 4ª ordens foram utilizados, resultando em uma dimensão total de 640 parâmetros por sinal, sendo equivalente a 128 amostras de

segunda ordem, 256 amostras de terceira ordem e 256 amostras de quarta ordem.

As expressões dos cumulantes de 2ª, 3ª e 4ª ordens de um sinal aleatório $x[n]$, quando $E\{x[n]\} = 0$, são respectivamente [25]:

$$C_{2,x}[i] = E\{x[n]x[n+i]\} \quad (1)$$

$$C_{3,x}[i] = E\{x[n]x^2[n+i]\} \quad (2)$$

$$C_{4,x}[i] = E\{x[n]x^3[n+i]\} - 3C_{2,x}[i]C_{2,x}[0] \quad (3)$$

Para um vetor com comprimento finito (N), as aproximações estocásticas oferecem as seguintes expressões [26]:

$$\hat{C}_{2,x}[i] := \frac{2}{N} \sum_{n=0}^{\frac{N}{2}-1} x[n]x[n+i], \quad (4)$$

$$\hat{C}_{3,x}[i] := \frac{2}{N} \sum_{n=0}^{\frac{N}{2}-1} x[n]x^2[n+i], \quad (5)$$

$$\hat{C}_{4,x}[i] := \frac{2}{N} \sum_{n=0}^{\frac{N}{2}-1} x[n]x^3[n+i] \quad (6)$$

$$- \frac{2}{N^2} \sum_{n=0}^{\frac{N}{2}-1} x[n]x[n+i] \sum_{n=0}^{\frac{N}{2}-1} x^2[n],$$

em que $i = 0, 1, \dots, N/2 - 1$.

Uma abordagem alternativa é proposta em [13], onde que cada cumulante é calculado utilizando todas as N amostras de sinal disponível.

$$\hat{C}_{2,x}[i] := \frac{1}{N} \sum_{n=0}^{N-1} x[n]x[\text{mod}[n+i, N]], \quad (4)$$

$$\hat{C}_{3,x}[i] := \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^2[\text{mod}[n+i, N]], \quad (5)$$

$$\hat{C}_{4,x}[i] := \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^3[\text{mod}[n+i, N]] - \frac{1}{N^2} \sum_{n=0}^{N-1} x[n]x[\text{mod}[n+i, N]] \sum_{n=0}^{N-1} x^2[n], \quad (6)$$

em que $\text{mod}[n+i, N]$ é o resto inteiro da divisão de $n+i$ por N .

C. Seleção de Parâmetros

Conforme discutido anteriormente, o cálculo dos cumulantes pode envolver um número expressivo de parâmetros, devido aos *lags* considerados. A fim de reduzir a quantidade de parâmetros foi utilizado o FDR para selecionar os *lags* mais significativos para o problema de classificação.

A função custo do critério FDR como ferramenta de seleção de parâmetros é:

$$J_c = (m_1 - m_2)^T \odot \frac{1}{(D_1)^2 + (D_2)^2} \quad (7)$$

onde $\mathbf{J}_c = [J_1 \cdot \dots \cdot J_{L_I}]^T$, L_I é o número total de parâmetros, $\mathbf{m}_1$ e $\mathbf{m}_2$, e $\mathbf{D}_1^2$ e $\mathbf{D}_2^2$ são, respectivamente, os vetores de média e variância dos dados da classe 1 e da classe 2. O símbolo $\odot$ refere-se ao produto de Hadamard tal que $r \odot s = [r_0 s_0 \dots r_{L_I-1} s_{L_I-1}]^T$.

Pode-se entender que os i -ésimos elementos do vetor de parâmetros, referentes aos maiores valores de $\mathbf{J}_c$, representam os parâmetros que apresentam melhor capacidade de separação entre classes. Esta técnica é bastante útil em processos de classificação mais complexos, uma vez que torna possível selecionar os melhores parâmetros (que mais discriminam as classes envolvidas) e, conseqüentemente, reduzir o número de parâmetros utilizado na classificação. Esta redução de parâmetros é atraente em sistemas que necessitam de menor complexidade computacional, tais como sistemas que operam em tempo real. Ademais, o uso de um número reduzido de parâmetros pode levar ao projeto de classificadores mais simples e com melhor desempenho, já que os parâmetros responsáveis pela interseção entre classes são, teoricamente, descartados.

D. Sistema de Classificação

Neste bloco, é utilizada uma técnica para classificar de forma eficiente os distúrbios através do processamento dos parâmetros selecionados do sinal. Para isso foi empregado o detector baseado em Máquina de Vetor de Suporte. O método SVM apresenta uma elevada eficiência na classificação com um esforço computacional relativamente alto comparado a outros métodos [23]. Nas pesquisas desenvolvidas

recentemente na área de QEE nota-se uma preocupação muito grande com dois aspectos: eficiência elevada aliada a um baixo esforço computacional.

Para o sistema de classificação proposto neste trabalho foi utilizada uma abordagem conhecida como SVM *one class*, conforme Fig. 2, onde o círculo sólido representa o cluster resultante para a classe conhecida no espaço de características, enquanto os valores alvo negativos são obtidos mediante o agrupamento de todos os eventos de outras classes não conhecidas durante o treinamento.




Fig. 2. Modelo do classificador proposto baseado em SVM *one class*.

O sistema de classificação proposto é representado pela Fig. 3, onde projeta-se um sistema de classificação especialista (SCE) para cada distúrbio. Dessa forma, o número de SCE é determinado pela quantidade de distúrbios possíveis de estarem presentes do sinal monitorado. A vantagem deste método é a facilidade de incluir novas classes no sistema e a capacidade de detectar a presença de classes desconhecidas.




Fig. 3. Sistema de Classificação Especialista baseado em SVM *one class*.

Os parâmetros extraídos através de EOS e selecionados pelo discriminante de Fisher são apresentados a Máquina de Vetor de Suporte *one class*. Este classificador é responsável pela identificação das seguintes classes: afundamentos/ elevações de tensão, harmônicos, transitórios impulsivos e transitórios oscilatórios.

III. Resultados e Discussões

Foram apresentados quinze *lags* dentre os mais representativos da classe ao seu respectivo classificador especialista baseado em SVM *one class*, apenas para o treinamento do classificador especialista em interharmônicos foram necessários cinquenta *lags* para alcançar melhores

resultados de classificação. Os resultados finais do classificador, para os eventos de teste, são mostrados na Tabela I em relação ao percentual de detecção (Pd) e percentual de falso alarme (Pf), onde pode-se observar que o desempenho na classificação é satisfatório, com a eficiência se situando acima de 99.9% considerando-se a média aritmética dos desempenhos obtidos para cada classe de distúrbio.

Tabela I. Desempenho dos Sistemas de Classificação Especialista em %.

Sistema de Classificação Especialista	Pd	Pf
Afundamento de Tensão x Todos	98.66	3.0
Elevação de Tensão x Todos	100.00	4.2
Harmônicos x Todos	99.74	2.4
Transitório Impulsivo x Todos	100.00	4.6
Transitório Oscilatório x Todos	100.00	10.8
Normais x Todos	100.00	4.2

IV. Conclusões

O sistema utilizou um método não supervisionado, SVM *one class*, para classificar distúrbios. EOS foi utilizada como ferramenta extratora de parâmetros, através do cálculo dos cumulantes de segunda, terceira e quarta ordens. Os parâmetros extraídos foram selecionados pelo FDR. A escolha foi motivada pelo fato de o FDR possuir tempo de processamento e complexidade computacional. Para o uso do classificador (SVM *one class*) é suficiente apenas o conhecimento dos parâmetros de uma das classes em um problema de classificação de duas classes. Baseado nesta característica foi desenvolvido um classificador especialista para cada uma das classes de distúrbios aqui abordadas. Este sistema de classificação apresenta a vantagem de ser possível inserir facilmente uma nova classe de distúrbio a ser classificada, não precisando reformular o classificador. Portanto este tipo de sistema torna-se útil visando as constantes mudanças observadas no cenário dos sistemas de energia elétrica.

Agradecimentos

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação e Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelo suporte financeiro.

V. REFERÊNCIAS

- [1] M. H. Bollen; S. Santoso; M. F. McGranaghan; P. A. Crossle; M. V. Ribeiro, et al., "Bridging the gap between signal and power," *IEEE Signal Processing Magazine*, 26.4, 2009.
- [2] P. F. Ribeiro; C. A. Duque; P. M. Ribeiro; A. S. Cerqueira, "Power systems signal processing for smart grids," *John Wiley & Sons*, 2013.
- [3] S. Rönnerberg; M. H. Bollen, "Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications," *The Electricity Journal*, vol. 29, pp. 49 – 61, 2016.
- [4] P. Kanirajan; V. S. Kumar, "Power quality disturbance detection and classification using wavelet and RBFNN," *Applied Soft Computing*, vol. 35: pp. 470-481, 2015.
- [5] L. R. M. Silva; E. B. Kapish; C. A. Duque; L. M. de Andrade Filho; L. A. S. Cerqueira, et al., "The concept of novelty detection applied to Power Quality," *Power and Energy Society General Meeting (PESGM)*. IEEE, 2016.
- [6] M. A. Pimentel; D. A. Clifton; L. Clifton; L. Tarassenko, "A review of novelty detection," *Signal Processing*, vol. 99, pp. 215-249, 2014.
- [7] He, H. and Starzyk; J.A. "A Self-Organizing Learning Array System for Power Quality Classification Based on Wavelet Transform". *IEEE Transactions on Power Delivery*, pp 286-295. 2006.
- [8] H.-T. Yang; C.-C. Liao, "A de-noising scheme for enhancing wavelet based power quality monitoring system," *IEEE Transaction on Power Delivery*, vol. Vol. 16, no. No. 3, pp. 353–360, 2001.
- [9] W.-M. Lin; C.-H. Wu; C.-H. Lin; F.-S. Cheng, "Detection and classification of multiple power-quality disturbances with wavelet multiclass svm," *IEEE Transaction on Power Delivery*, vol. Vol. 23, no. No. 4, pp. 2575–2582, 2008.
- [10] S. Mishra; C. N. Bhende; B. K. Panigrahi, "Detection and Classification of Power Quality Disturbances Using S-Transform and Probabilistic Neural Network," *IEEE Transactions on Power Delivery*, vol. 23, no. 1, pp. 280–287, 2008.
- [11] C. Chun-Ling; Y. Yong; X. Tongyu; C. Yingli; W. Xiaofeng, "Power quality disturbances detection based on Hilbert phase-shifting," in *AsiaPacific Power and Energy Engineering Conference, APPEEC 2009*. Wuhan, China: 10.1109/APPEEC.2009.4918613, pp. 1–4, 2009.
- [12] Q. Hao; R Zhao; C. Tong. Interharmonics analysis based on interpolating windowed FFT algorithm. *IEEE Trans Power Deliv*; vol. 22, pp. 1064–9, 2007.
- [13] F. Zhang; Z. Geng; W. Yuan. The algorithm of interpolating windowed FFT for harmonic analysis of electric power system. *IEEE Trans Power Deliv*; vol. 16, pp.160–4, 2001.
- [14] M. Valtierra-Rodriguez, R. de Jesus Romero-Troncoso, R. A. OsornioRios, and A. Garcia-Perez, "Detection and classification of single and combined power quality disturbances using neural networks," *IEEE Transactions on Industrial Electronics*, vol. 61, no. 5, pp. 2473–2482, 2014.
- [15] I. Monedero; C. Leon; J. Ropero; A. Garcia; JM. Elena; JC. Montano. Classification of electrical disturbances in real time using neural networks. *IEEE Trans Power Deliv*, vol. 22: pp. 1288–96, 2007.
- [16] He Z, Zhang H, Zhao J, Qian Q. Classification of power quality disturbances using quantum neural network and DS evidence fusion. *European Trans Electr Power*, vol. 22, pp. 533–47, 2012.

- [17] Z. Moraveja; A. A. Abdoosa; M. Pazokia, "Detection and classification of power quality disturbances using wavelet transform and support vector machines," *Electric Power Components and Systems*, vol. Vol. 38, no. No. 2, pp. 182–196, 2010.
- [18] Liao C-C, Yang H-T. Recognizing noise-influenced power quality events with integrated feature extraction and neuro-fuzzy network. *IEEE Trans Power Deliv*, vol. 24, pp. 2132–41, 2009.
- [19] C. L. Nikias; J. M. Mendel. "Signal processing with higher-order spectra," *IEEE Signal processing magazine*, vol. 10.3, pp. 10-37, 1993.
- [20] M. V. Ribeiro; C. A. Marques; C. A. Duque; A. S. Cerqueira; J. L. R. Pereira, "Detection of disturbances in voltage signals for power quality analysis using HOS," *EURASIP Journal on Applied Signal Processing*, vol. 1, pp. 177-177, 2007.
- [21] D. D. Ferreira; A. S. Cerqueira; M. V. Ribeiro; C. A. Duque, "HOS-based method for power quality event classification," *Signal Processing Conference, 2006 14th European. IEEE*, 2006.
- [22] R. O. Duda; E. H. Peter; G. S. David, "Pattern classification," *John Wiley & Sons*, 2012.
- [23] D. D. Ferreira; C. A. G. Marques; A. S. Cerqueira; C. A. Duque; M. V. Ribeiro, "Sistema automático de detecção e classificação de distúrbios elétricos em qualidade da energia elétrica," *Sba: Controle & Automação Sociedade Brasileira de Automatica*, vol. 20.1, pp. 53-62, 2009.
- [24] D. M. Tax; R. P. Duin, "Support vector data description," *Machine learning*, vol. 54(1), pp. 45-66, 2004.
- [25] J. M. Mendel, "Tutorial on higher-order statistics (spectra) in signal processing and system theory: Theoretical results and some applications." *Proceedings of the IEEE*, vol. 79.3, pp. 278-305, 1991.
- [26] M. V. Ribeiro; C. A. G. Marques; C. A., Duque; A. S. Cerqueira; J. L. R. Pereira, "Power quality disturbances detection using HOS," *Power Engineering Society General Meeting, 2006. IEEE. IEEE*, 2006.