

MONITORAMENTO DA QUALIDADE DE ENERGIA ELÉTRICA BASEADO EM ALGORITMOS GENÉTICOS E MÁQUINA DE VETOR DE SUPORTE

THAIS MARTINS MENDES*, DANTON DIEGO FERREIRA*, BRUNO HENRIQUE GROENNER BARBOSA*

**Departamento de Engenharia
Universidade Federal de Lavras
Lavras, Minas Gerais, Brasil*

Emails: martins_tha@outlook.com, danton@deg.ufla.br, brunohb@deg.ufla.br

Abstract— Power Quality (PQ) has emerged as an important research field in recent years. The development and increasing use of high power converters and the increase of nonlinear loads with high power cause unwanted changes in the electrical signal (current and voltage). This work proposes a method for detecting PQ disturbances. The method makes innovative use of the so called one class support vector machine, which is an unsupervised classification method. Higher-order statistics (HOS)-based features are used to construct a compact and representative vector signatures of the PQ events. Genetic Algorithms are used to select the best features and simplify the algorithm detection. The detection system was simulated considering eight classes of disturbances, achieving a global efficiency of 100%.

Keywords— Power Quality, Disturbance Detection, Support Vector Machine.

Resumo— Qualidade de Energia Elétrica (QEE) tem emergido como um campo importante de pesquisa nos últimos anos. O desenvolvimento e uso crescente de conversores de alta potência, e o aumento de cargas não lineares com potência cada vez mais elevada causam alterações não desejadas no sinal elétrico (corrente e tensão). Este trabalho apresenta um sistema de detecção de distúrbios de qualidade da energia elétrica (QEE). O método faz uso inovador da chamada Máquina de Vetor de Suporte *one class*, que é um método de classificação não-supervisionada. Utiliza Estatística de Ordem Superior (EOS) para construir um compacto e representativo vetor de assinaturas dos eventos de QEE. Algoritmos Genéticos são utilizados para selecionar os melhores parâmetros e simplificar o algoritmo de detecção. O sistema foi testado em simulações para oito classes de distúrbios, apresentando uma eficiência global de 100%.

Palavras-chave— Qualidade de Energia, Distúrbios Elétricos, Máquina de Vetor de Suporte.

1 Introdução

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 (Ribeiro et al., 2013; Bollen et al., 2009). Este termo tem recebido bastante atenção de pesquisadores.

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, interharmônicos, flutuações de tensão, afundamentos, transitórios, entre outros. Algumas modificações e complementações na classificação do IEC foram realizadas pela norma IEEE (*IEEE Recommended Practice for Monitoring Electric Power Quality*, 2009), com a inclusão da categoria de ruído, de elevação de tensão e a definição da categoria de distorção de forma de onda da corrente alternada, que inclui as distorções harmônicas, interharmônicas e de componente contínua. Estes distúrbios estão relacionados com diferentes eventos nos sistemas de potência. Alguns são gerados pela operação normal dos sistemas, tais como chaveamento de banco de capacitores e entrada e saída de grandes cargas lineares ou não, enquanto outros estão relacionados com eventos não operacionais do sis-

tema, como as descargas atmosféricas e as faltas na rede elétrica.

Uma das principais atribuições do monitoramento da qualidade de energia elétrica é a análise dos distúrbios elétricos. Para tal, os sinais de tensão e/ ou corrente do sistema monitorados devem ser armazenados para posterior análise ou analisados em tempo real (Ferreira, 2010).

No entanto, o armazenamento destes gera arquivos de dados de grande extensão. Portanto, torna-se importante utilizar sistemas de detecção para que possam armazenar (ou processar no caso de monitoramento em tempo real) apenas os sinais elétricos com distúrbios e, posteriormente, analisá-los realizando a classificação, identificação e localização das fontes geradoras dos mesmos. A detecção deve ser realizada por sistemas com reduzida complexidade computacional e, consequentemente, rápido processamento de sinais (Ferreira, 2010).

A detecção de distúrbios elétricos, em geral, compreende basicamente a extração de parâmetros e a aplicação de um algoritmo que realize a detecção baseada nos parâmetros extraídos. A extração de parâmetros consiste em uma transformação dos dados para um novo espaço onde as características dos distúrbios são destacadas em relação aos sinais sem distúrbios. Estas características são então selecionadas e apresentadas à técnica de detecção. Assim, o compromisso em

projetar um detector com alto desempenho e rápido processamento está na escolha das técnicas de extração de parâmetros e de detecção.

Neste trabalho, um sistema de detecção de distúrbios de QEE é proposto. Este sistema é baseado na ideia da utilização de estatísticas 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 (Nikias and Petropulu, 1993) e foi, inicialmente, aplicada ao problema de detecção e classificação de distúrbios elétricos em Ribeiro et al. (2007) e Ferreira et al. (2006), 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 Algoritmos genéticos (AGs) (Holland, 1975). Estes parâmetros são apresentados ao algoritmo de detecção, baseado em Máquina de Vetor de Suporte (SVM), algoritmo não supervisionado conhecido como SVM *one class* (Theodoridis et al., 2010). 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 artigo está organizado da seguinte maneira. Na próxima seção é apresentada a formulação do problema de detecção de distúrbios elétricos. Na Seção 3 é apresentado o método proposto. Os resultados são apresentados na Seção 4 e as conclusões finais na Seção 5.

2 Formulação do Problema de Detecção de Distúrbios de QEE

O problema de detecção de distúrbios elétricos pode ser formulado pelas hipóteses (Ferreira et al., 2014):

$$H_0 : \mathbf{v} = \mathbf{f} + \mathbf{r}, \quad (1)$$

$$H_1 : v = \mathbf{f}_c + \mathbf{i} + \mathbf{t} + \mathbf{h} + \mathbf{r}, \quad (2)$$

em que $\mathbf{f} = [f[n] \cdots f[n - N - 1]]^T$, $\mathbf{f}_c = [f_c[n] \cdots f_c[n - N - 1]]^T$, $\mathbf{i} = [i[n] \cdots i[n - N - 1]]^T$, $\mathbf{t} = [t[n] \cdots t[n - N - 1]]^T$, $\mathbf{h} = [h[n] \cdots h[n - N - 1]]^T$, $\mathbf{r} = [r[n] \cdots r[n - N - 1]]^T$ correspondem a N amostras, respectivamente, do sinal fundamental nominal (frequência e amplitude fixa), do sinal fundamental corrompido por alguma variação na frequência ou amplitude, inter-harmônicos, transitórios, harmônicos e ruído. A hipótese H_0 está associada à operação nominal do sistema elétrico e a hipótese H_1 está associada às condições anormais do sistema elétrico, isto é, à presença de distúrbios elétricos.

3 Método Proposto

O sistema proposto neste trabalho pode ser representado pelo diagrama em blocos da Figura 1, em que cada um dos blocos são explicados nos itens listados a seguir.




Figura 1: Método Proposto

3.1 Dados de Entrada

Sinais de tensão sintéticos foram gerados com uma frequência de amostragem igual a 15.360 Hz. Seis classes de distúrbios foram consideradas: harmônicos, afundamentos de tensão, elevação de tensão, interrupções, transitórios oscilatórios, transitórios impulsivos e *notches*. 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. De acordo com (Tomic et al., 2007) o sistema de energia elétrica tem SNR variando entre 50 e 70 dB. A Entrada representa um sinal de tensão contendo 256 amostras. Para avaliação de desempenho, metade dos dados foi usada para o projeto do método e a outra metade para a avaliação de desempenho.

3.2 Extração de Parâmetros

O bloco Extração de Parâmetros extrai os parâmetros de EOS do sinal 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 2^a, 3^a e 4^a ordens foram utilizados, resultando em uma dimensão total de 640 amostras por sinal, sendo equivalente a 128 amostras segunda ordem, 256 amostras de terceira ordem e 256 amostras de quarta ordem. As expressões dos cumulantes de 2^a, 3^a e 4^a ordens de um sinal aleatório $x[n]$, quando $E\{x[n]\} = 0$, são respectivamente (Mendel, 1991):

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

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

e

$$C_{4,x}[i] = E\{x[n]x^3[n+i]\} - 3C_{2,x}[i]C_{2,x}[0]. \quad (5)$$

Para um vetor com comprimento finito (N), as aproximações estocásticas oferecem as seguintes expressões (Mendel, 1991):

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

$$\hat{C}_{3,x}[i] = 2/N \sum_{n=0}^{N/2-1} x[n]x^2[n+i] \quad (7)$$

e

$$\begin{aligned} \hat{C}_{4,x}[i] = & 2/N \sum_{n=0}^{N/2-1} x[n]x^3[n+i] \\ & - 2/N^2 \sum_{n=0}^{N/2-1} x[n]x[n+i] \sum_{n=0}^{N/2-1} x^2[n], \end{aligned} \quad (8)$$

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

3.3 Seleção dos Parâmetros

Para reduzir a dimensão dos parâmetros extraídos e, consequentemente, a complexidade computacional e o tempo de processamento, Algoritmos Genéticos são utilizados para selecionar um conjunto reduzido de dados composto pelos parâmetros mais representativos dentre os obtidos usando EOS, esta etapa está representada pelo bloco Seleção de Parâmetros. Os Algoritmos Genéticos podem ser definidos como uma técnica de busca baseada numa metáfora do processo biológico de evolução natural. Os AGs são robustos e eficientes em espaços de procura irregulares, multidimensionais e complexos.

Os AGs simples representam os indivíduos por uma cadeia de bits, aplicam operadores de recombinação e mutação e selecionam os indivíduos proporcionalmente à sua aptidão (Barbosa, 2009). Usualmente os AGs são implementados conforme o algoritmo abaixo (Linden, 2006):

1. $t := 0$
2. Inicializa_População $P(0)$
3. Enquanto não terminar faça
4. Avalie_População $P(t)$
5. $P' := \text{Selecione_Pais } P(t)$
6. $P' := \text{Recombinação_e_Mutação } P$
7. Avalie_População P'
8. $P(t+1) := \text{Selecione_sobreviventes } P(t), P'$
9. $t := t + 1$
10. Fim Enquanto

A Seleção de Parâmetros do problema proposto realizada através dos Algoritmos Genéticos consiste em minimizar o erro de detecção descrito por uma função de aptidão considerando o menor número de cumulantes utilizados. A função de avaliação de cada indivíduo pode ser descrita por:

$$\text{Avaliação} = \text{Erro_Detecção} + 0,01 * \text{Número_Cumulantes} \quad (9)$$

sendo fator o $0,01 * \text{Número_Cumulantes}$ utilizado para reduzir o número de cumulantes selecionados para o detector, de forma que quando o detector obtiver o mesmo erro de detecção, será utilizado o que possuir menor número de cumulantes selecionados. O valor 0,01 mesmo sendo multiplicado pelo número de parâmetros selecionados, não altera a escolha do melhor classificador, pois esse termo só é levado em consideração quando os classificadores possuem os mesmos acertos.

Os indivíduos são representados por sequências binárias com 640 posições, resultantes dos cumulantes extraídos de segunda, terceira e quarta ordem, sendo que cada posição indica o uso ou não do cumulante, representados pelo valor 1 ou 0 respectivamente. Posteriormente os cumulantes selecionados são apresentados ao detector baseado em SVM e por último é feito o cálculo da aptidão pela Equação (9). A Figura 2 ilustra o método de avaliação do indivíduo.

Devido ao fato de serem extremamente dependentes de fatores estocásticos (probabilísticos), tanto na fase de inicialização da população quanto na fase de evolução, para seleção dos melhores parâmetros que representam a classe dos sinais nominais em relação a classe dos sinais que contém distúrbios, neste trabalho foram realizadas 10 simulações do AG, cada uma contendo 100 gerações.




Figura 2: Avaliação do indivíduo

3.4 Algoritmo de Detecção

Neste bloco, é utilizada uma técnica para detectar de forma eficiente a ocorrência de distúrbio através do processamento dos parâmetros extraídos 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 (Ferreira et al., 2009). 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 (Ferreira et al., 2009).

Considerando um conjunto de pontos que possum duas classes como mostrado na Figura 3, a estratégia geral do SVM trata-se de estabelecer um hiperplano que coloca a maioria dos pontos da mesma classe no mesmo lado, enquanto maximiza a distância (m) entre duas classes do presente hiperplano. A distância entre uma classe e um hiperplano é a menor distância entre o hiperplano e os outros pontos da mesma classe, e é chamado de hiperplano de separação ótima. O hiperplano de separação criado pelo SVM é traçado ao meio da margem de separação (m). Os subconjuntos de pontos que determinam os planos de separação que originam a margem (m), denominam-se vetores de suporte (Baccarani et al., 2011). É importante destacar que no presente trabalho foi utilizado o *kernel* RBF (*Radial Basis Function*) para classificação.

Para o sistema de detecção proposto neste trabalho foi utilizada uma abordagem conhecida como SVM *one class*, conforme Figura 4, onde o círculo sólido representa o cluster resultante para a classe conhecida no espaço de características, valores de saída positivos são os padrões da classe representada pelos sinais nominais enquanto os va-




Figura 3: Hiperplano ótimo de separação das classes

lores alvo negativos são obtidos mediante o agrupamento de todos os padrões de outras classes não conhecidas durante o treinamento, representadas pelos respectivos distúrbios elétricos: harmônicos, afundamentos de tensão, elevação de tensão, interrupções, transitórios oscilatórios, transitórios impulsivos e *notches*.




Figura 4: Modelo do detector proposto baseado em SVM *one class*

Para treinamento da Máquina de Vetores de Suporte é suficiente apenas o conhecimento dos parâmetros selecionados dos sinais nominais, isto mostra a boa capacidade de generalização das SVMs assim como a não necessidade do conhecimento de todas as classes do problema. Ademais, espera-se detectar distúrbios não abordados neste trabalho como subharmônicos e interharmônicos sem que haja a necessidade de reprojeter o método.

4 Resultados

O desempenho do método proposto para os sinais simulados foi analisado em função das taxas de probabilidade de detecção (P_d) e probabilidade de falso alarme (P_f). Vale ressaltar que P_f está relacionado à probabilidade de detecção de distúrbio em um sinal de tensão nominal, isto é, desprovido de qualquer poluição relacionada a algum distúrbio.

Utilizando os parâmetros selecionados pelo AG em cada uma das dez simulações e apresentando estes valores ao detector baseado em SVM, o P_d global do método proposto foi de 100%, de

forma que todas formas de onda de distúrbios na tensão foram detectadas e obteve 0.04% de Pf, conforme a Tabela 1 pode-se ver os resultados de cada um dos testes realizados. A Tabela 1 apresenta o número de parâmetros selecionados pelo AG e o desempenho do detector baseado em SVM é analisado em função de Pd e Pf.

Tabela 1: Desempenho do detector para dados de validação em função dos parâmetros selecionados

Testes	Número de Parâmetros Selecionados	Pd(%)	Pf(%)
1	9	100	0.0
2	5	100	0.0
3	8	100	0.2
4	5	100	0.0
5	3	100	0.0
6	8	100	0.2
7	6	100	0.0
8	4	100	0.0
9	7	100	0.0
10	9	100	0.0

No melhor caso de seleção de parâmetros, onde utiliza-se um menor número de parâmetros e alcança um resultado ótimo de detecção, foi necessário o uso de apenas três parâmetros, um de segunda ordem e dois de terceira ordem, os resultados de valor médio de *fitness* e melhor indivíduo da população (indivíduo que atinge o melhor resultado) pode ser observado na Figura 5.




Figura 5: Resultado da melhor combinação de parâmetros obtida pelo AG

5 Conclusão

O presente trabalho teve como principal objetivo o desenvolvimento de um método não supervisionado de detecção de distúrbios elétricos em sistemas de potência. Para a extração de parâmetros o uso de EOS foi proposto, através do cálculo

dos cumulantes de segunda, terceira e quarta ordens, seguidos da utilização de AGs para seleção de parâmetros. Como resultado, um pequeno número de parâmetros a serem usados pelo algoritmo de detecção foi selecionado, o que reduz a complexidade do método proposto.

O uso do SVM *one class* oferece ao método a vantagem de não requerer o conhecimento dos tipos de distúrbios que ocorrem no sistema elétrico, o que torna seu projeto mais simples. Ademais, o método está apto a detectar novas classes de distúrbios, que são esperadas com o progresso e implantação das redes inteligentes, sem a necessidade de reprojetar ou algum conhecimento técnico sobre os distúrbios.

Os resultados, em geral, mostram que o sistema proposto é apropriado para aplicações de QEE, apresentando elevado índice de detecção. Como propostas futuras, pretende-se incorporar a classificação de distúrbios utilizando o método não supervisionado proposto.

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.

Referências

- Baccarani, L. M. R., Silva, V. V. R., Menezes, B. R. and Caminhas, W. M. (2011). SVM practical industrial application for mechanical faults diagnostic, *Expert Systems with Applications* **38**: 6980–6984.
- Barbosa, B. H. G. (2009). *Computação Evolucionária e Máquinas de Comitê na Identificação de Sistemas Não-Lineares*, PhD thesis, Universidade Federal de Minas Gerais, Mestrado em Engenharia Elétrica.
- Bollen, M. H. J., F., R. P., Gu, I. Y. H. and Duque, C. A. (2009). Trends, challenges and opportunities in power quality research, *EUROPEAN, Transactions on Electrical Power* **20**: 3–18.
- Commission, I. I. E. (1991). IEC-91- Draft Classification of Electromagnetic Environments, *Technical report*, IEC: TC77WG6 (Secretary) 110-R5.
- Ferreira, D. D. (2010). *Análise de Distúrbios Elétricos em Sistemas de Potência*, PhD thesis, Universidade Federal do Rio de Janeiro, Doutorado em Engenharia Elétrica.

- Ferreira, D. D., Cerqueira, A. S., Marques, C. A. G. and Duque, C. A. (2009). Sistema automático de detecção e classificação de distúrbios elétricos em qualidade de energia elétrica, *Sociedade Brasileira de Automática* **20**: 53–62.
- Ferreira, D. D., Cerqueira, A. S., Ribeiro, M. V. and Duque, C. A. (2006). Hos-based method for power quality event classification, in IEEE (ed.), *Signal Processing Conference, 2006 14th European*, Signal Processing Conference, 2006 14th European, pp. 1–5.
- Ferreira, D. D., Seixas, J. M., Duque, C. A., Cerqueira, A. S. and Ribeiro, P. F. (2014). A direct approach for disturbance detection based on principal curves, in IEEE (ed.), *Harmonics and Quality of Power (ICHQP), 2014 IEEE 16th International Conference on*, Bucharest, pp. 747 – 751.
- Holland, J. H. (1975). *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence.*, U Michigan Press.
- IEEE Recommended Practice for Monitoring Electric Power Quality (2009). *IEEE Std 1159-2009 (Revision of IEEE Std 1159-1995)* pp. c1–81.
- Linden, R. (2006). *Algoritmos genéticos: uma importante ferramenta da inteligência computacional*, Brasport.
- Mendel, J. M. (1991). Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications, *Proceedings of the IEEE*. **79**(3): 278 – 305.
- Nikias, C. L. and Petropulu, A. (1993). *Higher-Order Spectra Analysis - A Nonlinear Signal Processing Framework*, Englewood Cliffs, Prentice-Hall.
- Ribeiro, M. V., Marques, C. A. G., Duque, C. A., Cerqueira, A. S. and Pereira, J. L. . R. (2007). Detection of disturbances in voltage signals for power quality analysis using hos, *EURASIP Journal on Advances in Signal Processing* pp. 13–25.
- Ribeiro, P. F., Duque, C. A., Ribeiro, P. M. and Cerqueira, A. S. (2013). *Power systems signal processing for smart grids*, John Wiley & Sons.
- Theodoridis, S., Pikrakis, A., Koutroumbas, K. and Cavouras, D. (2010). *Introduction to Pattern Recognition: A Matlab Approach: A Matlab Approach*, Academic Press.
- Tomic, J. J., Kusljevic, M. D. and Vujicic, V. V. (2007). A new power system digital harmonic analyzer, *IEEE Transactions on Power Delivery* **22**(2): 772–780.