

SISTEMA DE CLASSIFICAÇÃO AUTOMÁTICA DE DISTÚRBIOS ELÉTRICOS EM TEMPO REAL PARA QUALIDADE DE ENERGIA ELÉTRICA

EDUARDO G. RIBEIRO, GUILHERME L. DIAS, EULER R. S. FARIA, BRUNO H. G. BARBOSA, DANTON D. FERREIRA

Departamento de Engenharia, Universidade Federal de Lavras
Campus Universitário, Caixa Postal 3037, CEP 37200-000, Lavras, MG, Brasil

E-mails: eduzero10@gmail.com, guilermelopedias@gmail.com, eulerfaria@gmail.com
brunohb@deg.ufla.br, danton@deg.ufla.br

Abstract— This work implements in LabVIEW and real-time, the automatic system for classification of electrical disturbances proposed by Barbosa and Ferreira in 2013. Its basic structure can be listed in three stages: acquisition, extraction and classification. The first refers to the signal sampling by means of a monitoring embedded system and to filtering through a notch filter in order to divide the data into a fundamental component and an error signal. Such components are used in the extraction step, respectively, to calculate the RMS value and for obtaining second order cumulants. The extracted parameters are then sent to the classification process, which is based on a decision tree constructed with perceptrons and Bayesian classifiers. It was possible to classify twenty classes of multiple and isolated disturbances. The results were satisfactory since there was classification agreement with simulated samples of disturbances and real-time signal monitoring was also coherent.

Keywords— LabVIEW, High-Order Statistics, Real-Time Classification, Decision Tree, Smart Grids.

Resumo— Este trabalho implementa em LabVIEW e em tempo real, o sistema automático para classificação de distúrbios elétricos proposto por Barbosa e Ferreira em 2013. Sua estrutura básica pode ser listada em três etapas: aquisição, extração e classificação. A primeira delas se refere à amostragem do sinal, através de um sistema embarcado de monitoramento, e à filtragem, através de um filtro *Notch*, de forma a dividir os dados em uma componente fundamental e um sinal de erro. Tais componentes são utilizadas na etapa de extração, respectivamente, para cálculo do valor RMS e para obtenção de cumulantes de segunda ordem. Os parâmetros extraídos são, então, enviados ao processo de classificação, que se baseia em uma árvore de decisão construída com perceptrons e classificadores Bayesianos. Foi possível classificar vinte classes de distúrbios múltiplos e isolados. Os resultados obtidos foram satisfatórios uma vez que houve concordância de classificação com amostras simuladas de distúrbios e a monitoração de sinais em tempo real também se mostrou coerente.

Palavras-chave— LabVIEW, Estatística de ordem superior, Classificação em tempo real, Árvore de decisão, *Smart Grids*.

1 Introdução

A crescente complexidade do sistema elétrico mundial e o contínuo uso de cargas elétricas poluidoras (cargas não lineares, flutuantes, não balanceadas, variáveis no tempo) (Ming et al., 2010) produzem distúrbios indesejáveis na transmissão da energia que podem ocasionar mal funcionamento de equipamentos. Por essa razão, a Qualidade de Energia Elétrica (QEE) se tornou uma essencial área de estudo.

A potencialização do processo de medição, regulação e disponibilização de informações aos consumidores, por meio das *Smart Grids* (IEA, 2011) reafirmam a importância e relevância da área de QEE.

A definição e as características dos distúrbios de QEE podem ser encontradas no documento divulgado pelo IEEE para Qualidade de Energia (IEEE Std. 1159, 1995). Cumpre ressaltar que existe esforço por parte das agências reguladoras dos países para manter certos padrões de qualidade da energia distribuída.

No Brasil, o PRODIST (Procedimentos de Distribuição), através de seu Módulo 8, que trata da Qualidade da Energia Elétrica (ANEEL, 2016), procura estabelecer estes padrões.

Tais distúrbios se manifestam, de maneira geral, como deformidades da forma de onda de tensão e

corrente de um sistema elétrico de potência (Ferreira et al. 2009).

Algumas formas conhecidas de deformidades isoladas são expostas na Figura 1. Suas definições podem ser encontradas na norma IEEE Std. 1159, (1995).

Por suas implicações econômicas e relativas ao bem-estar social, estes distúrbios, representados visualmente na onda de tensão, são o centro da questão de QEE.




Figura 1. Tipos de distúrbios elétricos. De cima para baixo: *Sag*, *Swell*, *Notch*, Harmônico, Transiente Impulsivo e Transiente Oscilatório

Para obtenção desta energia elétrica de qualidade é necessário, primeiramente, conhecer e classificar os distúrbios elétricos. No campo da classificação, em que se encontra o foco deste trabalho, muitas estratégias têm sido desenvolvidas. Uma breve revisão do cenário é feita a seguir.

A representação em Tempo-Frequência (RTF) é um método recorrente de extração de características dos sinais. No trabalho de Wang et al. (2001), a RTF é implementada de forma a maximizar a extração retendo apenas as melhores características do sinal. Para tal, o conceito de *Ambiguity Plane* e de Discriminante de Fisher e Kernel modificado foram implantados. Como classificador uma rede neural artificial (RNA) foi construída e o sistema foi capaz de classificar 6 classes de distúrbios isolados, porém a classificação não ocorreu em tempo real.

Em Wang et al. (2003), o mesmo sistema de extração foi construído somando à RNA a função linear de Heaviside. A extração em tempo real foi possível com o uso de um Processador Digital de Sinais (PDS) para aquisição. Porém, apenas 5 classes foram abordadas.

Ainda em RTF, Abidullah et al. (2014) extraíram alguns parâmetros da representação, tais como RMS, Valor Fundamental, Distorção Harmônica Total (DHT), Distorção Não-Harmônica Total (DnHT) e Distorção Total da Onda (DTO). Estes parâmetros constroem um Classificador Baseado em Regras que é capaz de classificar 6 distúrbios isolados em tempo real. Para aquisição dos dados (DAQ) utilizaram-se o NI USB 6009 com interface em Visual Basic.

Em Ferreira et al. (2009) o sinal monitorado é decomposto em uma porção fundamental e uma parcela de erro utilizando um filtro *Notch*. A extração dos parâmetros é feita com Estatísticas de Ordem Superior (EOS). Uma RNA é utilizada para a classificação. Vale dizer que o trabalho é otimizado pela presença de um detector baseado na teoria de Bayes, sendo capaz de classificar 6 classes.

Outros sistemas consideram a Transformada Wavelet como forma de extração de características. Dentre os quais, He e Starzyk (2006) obtiveram bons resultados de classificação de distúrbios, incluindo dois múltiplos, ao utilizar a técnica em conjunto com o SOLAR (*Self Organizing Learning Array*), método alternativo à RNA.

Bollen et al. (2009) publicaram uma revisão na qual as diversas metodologias aplicáveis à extração e classificação de distúrbios elétricos são explanadas.

O objetivo do presente trabalho foi implementar em LabVIEW o método de classificação proposto por Barbosa e Ferreira (2013) e possibilitar sua execução em tempo real para monitoração da rede elétrica.

Dessa forma, foi utilizado o protocolo FPGA (NI Compact-RIO) para aquisição dos dados. Tais dados são previamente filtrados por um filtro *Notch* e divididos em um sinal fundamental e um sinal de erro. A extração de cumulantes de segunda ordem (Nikias e

Mendel 1999) é aplicada ao sinal de erro e um vetor de cumulantes é obtido.

Aqueles que representam melhor as características do distúrbio são selecionados e servem de entrada para uma árvore de decisão baseada em perceptrons. Como última folha da árvore tem-se um classificador Bayesiano baseado no valor RMS extraído da componente fundamental do sinal.

O sistema é capaz de classificar 20 classes de distúrbios múltiplos e isolados em tempo real. Seu funcionamento será explicado na próxima seção.

2 Método Implementado

A Figura 2 mostra o esquema do sistema proposto na forma de um diagrama em blocos. Cada bloco de processamento é explanado em seguida.




Figura 2. Diagrama em blocos para aquisição e classificação de distúrbios elétricos

2.1 Aquisição

A aquisição dos dados é realizada pelo sistema integrado NI cRIO-9076, que combina um processador de tempo real e um FPGA (*Field-Programmable Gate Array*) reconfigurável em um único chassi para aplicações embarcadas de controle e monitoramento de máquinas (*National Instruments Corporation*, 2014).

Apresentando alto desempenho e grande robustez, sua aplicação é de especial importância para o projeto, uma vez que possibilita a aquisição e processamento dos dados em tempo real. Sua interface é feita em LabVIEW® e a conexão acontece via rede-LAN.

Os sinais amostrados são provenientes de duas fontes. A primeira delas se trata do gerador de funções aleatórias AFG3022B da Tektronix. O gerador permite a leitura de arquivos de forma de onda, em formato específico, e o gera com as características desejadas. Dessa forma, amostras previamente classificadas como distúrbios elétricos puderam ser entregues ao sistema de aquisição.

A segunda fonte é a energia distribuída pela concessionária. Através da ponta de prova P5 100A da Tektronix, a energia fornecida para o campus universitário pôde ser entregue ao sistema de classificação, fechando o objetivo de monitoração da rede.

A taxa de amostragem escolhida para o projeto é de 15,36kHz e o protocolo executado é o de FIFO (*First In, First Out*). Assim são obtidos 256 pontos por período da forma de onda analisada de 60 Hz. Portanto, um vetor com 4 ciclos, que somados fornecem 1.024 pontos são encaminhados ao filtro Notch (Hirano et al. 1974).

Conforme exposto na Figura 2, ao subtrair o sinal original do filtrado são obtidos outros 1.024 pontos, $f[n]$. Estes são associados ao vetor resultante do filtro Notch, $u[n]$, formando 2.048 pontos. Dessa forma, uma fila de 2.048 elementos é entregue 15 vezes por segundo ao sistema de classificação.

No sistema de classificação os sinais $f[n]$ e $u[n]$ são novamente separados para serem entregues à etapa de extração de características.

2.1.1 Filtro Notch

Conforme dito, a presença do Filtro *Notch* (Hirano et al. 1974) é necessária para decomposição do sinal monitorado. Sua implementação em LabVIEW® é possível a partir da definição de seus parâmetros em um algoritmo padrão da interface FPGA.

O modelo seguido é o de um filtro IIR de segunda ordem (Mitra 2006) cuja transformada z é

$$H_0(z) = \frac{1 + (-2\cos\omega_0)z^{-1} + z^{-2}}{1 + \rho_0(-2\cos\omega_0)z^{-1} + \rho_0^2 z^{-2}}, \quad (1)$$

Os parâmetros definidos foram a frequência *Notch* de 60 Hz e o fator *Notch* ρ_0 de 0,97. A resposta em frequência da magnitude é exposta na Figura 3.

O sinal resultante deste filtro, $u[n]$, contém as informações de harmônicos, transientes e ruídos encontrados em $v[n]$, e será a entrada do algoritmo que extrai cumulantes de segunda ordem.




Figura 3. Resposta em frequência do filtro projetado

É importante notar que todo o processo de amostragem e filtragem acontece no processador da placa NI cRIO, de forma a aproveitar o alto desempenho

do sistema integrado. Após a execução do processo, estes dados são enviados por *Network Stream* (Habets, 2014) para o computador que contém a interface e, então, a extração das características e a classificação ocorrerá no processador do computador. A Figura 4 ilustra parte do processo de aquisição.




Figura 4. Diagrama simplificado da aquisição do sinal

2.2 Extração de Características

2.2.1 Cumulantes de 2ª Ordem

A análise de distúrbios da rede elétrica com estatísticas de ordem superior tem se mostrado uma abordagem promissora (Ferreira et al. 2009; de la Rosa et al. 2009). Para encontrar um algoritmo com baixo custo computacional apenas cumulantes de segunda ordem foram extraídos de $u[n]$ (Barbosa e Ferreira, 2013).

Os cumulantes de segunda ordem de $x(t)$, um processo estacionário de média zero, podem ser expressos por:

$$C_{2,x}(\tau) = E\{x(t)x(t+\tau)\} \quad (2)$$

em que $E\{\cdot\}$ representa o operador de esperança matemática.

Uma vez que a informação é perdida quando um valor τ maior que zero é usado, a equação a seguir pode ser aplicada (Ribeiro e Pereira, 2007):

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

em que $x \in \mathbb{R}^N$ e $\tau = 0, 1, \dots, N-1$.

Assim, N cumulantes de segunda ordem são obtidos e considerando o alto custo computacional, apenas aqueles que demonstram as maiores diferenças entre classes foram selecionados utilizando o Discriminante Linear de Fisher (Barbosa e Ferreira, 2013). O cálculo e seleção dos melhores cumulantes é representado na Figura 5.




Figura 5. Extração dos cumulantes de segunda ordem

2.2.2 RMS

Uma vez que existe dificuldade de classificação de algumas classes baseando-se somente nos cumulantes, outro parâmetro do sinal também é extraído. A componente fundamental $f[n]$ tem seu valor RMS calculado e este será, então, entregue aos classificadores bayesianos.

O valor de RMS da componente fundamental é calculado por:

$$RMS(f) = \sqrt{\frac{\sum_{n=1}^N (f[n] - \bar{f})^2}{N-1}}, \quad (4)$$

sendo N o número de amostras (1.024) por ciclo de classificação e $\bar{f}$ sua média.

2.3 Classificador

2.3.1 Classificador Bayesiano

O classificador Bayesiano aprende distribuições de probabilidade através dos dados e classifica o teste ocorrido escolhendo a classe com maior probabilidade posterior (MAP) (Barbosa e Ferreira, 2013). A classe é escolhida de forma a satisfazer a seguinte equação:

$$H_{MAP} = \arg_{H_i \in H} \max p(x|H_i)p(H_i) \quad (5)$$

em que x é o atributo (RMS) e $i = 1, 2, 3$ correspondem às classes de *sag*, *nem sag* e *nem swell* e *swell*, respectivamente. Maiores detalhes são encontrados em Barbosa e Ferreira (2013) e Mitchell (1997).

A Figura 6 mostra a distribuição de probabilidade obtida.




Figura 6. Probabilidade *a posteriori* do classificador Bayesiano (RMS). Classes *sags* (linha pontilhada), *swells* (linha tracejada) e classes sem *sags* ou *swells* (linha contínua)

2.3.2 Árvore de perceptrons

Após a extração e escolha dos cumulantes e cálculo do valor RMS, estes parâmetros servirão de entrada para a estrutura em forma de árvore ilustrada na Figura 9.

Para distinguir entre as classes de harmônicos, transientes oscilatórios, transientes impulsivos e *notches* (Barbosa e Ferreira, 2013), perceptrons foram utilizados (Duda et al. 2000).

A ideia básica do perceptron é gerar uma saída binária a partir de um vetor de dados. Neste caso, o vetor é composto por 5 cumulantes selecionados e sua função de ativação é dada por:

$$g(x) = \frac{2}{(1 + e^{-2x}) - 1}, \quad (6)$$

em que x é o produto escalar entre o vetor de cumulantes e um vetor de pesos. A Figura 7 mostra a implementação de um perceptron.




Figura 7. Perceptron

A saída deste perceptron determina qual será o próximo perceptron a ser ativado e ao final do processo as classes serão parcialmente classificadas. Para concluí-la, ou seja, separar entre as três classes que resultam da penúltima folha da árvore, o classificador bayesiano é executado. A Figura 8 contém um fragmento do fluxo de dados e do processo de classificação.




Figura 8. Fragmento do programa principal de classificação

O fluxo da classificação pode ser compreendido pela Figura 9, onde os números correspondem às classes conforme enumerado na Tabela 1.

3 Resultados e Discussão

Uma vez que o sistema implementado em LabVIEW® é o mesmo desenvolvido por Barbosa e Ferreira (2013) em MatLab, tem-se que as estatísticas de classificação daquele algoritmo, expostas na Tabela 1, se aplicam ao método atual. Vê-se que a porcentagem

de acerto é muito próxima de 100% inclusive para classes de distúrbios múltiplos.

O diferencial deste trabalho se concentra na execução em tempo real do algoritmo, possibilitando a monitoração extensiva da rede elétrica e sua interpretação detalhada mediante a possibilidade de classificação de 20 classes. Esta implementação foi possível devido ao esforço de redução da complexidade com-

putacional e à divisão de processamento entre a placa cRIO e o computador.

Outro ponto relevante e de interesse se trata da interface gráfica disponível em LabVIEW®. O resultado final do programa desenvolvido pode ser visto na Figura 10.




Figura 9. Árvore de decisão




Figura 10. Interface final do projeto em LabVIEW

4 Conclusão

Classificação de distúrbios elétricos é uma área de possibilidades. Este trabalho procurou suprir a ausência de um sistema capaz de classificar um grande

número de classes de distúrbios múltiplos e isolados, em tempo real.

Reitera-se também sua possibilidade de aplicação nas promissoras *Smart Grids*.

Notam-se, entretanto, limitações quanto à dependência de acesso via LAN e à ausência de um detector. Este último configura ponto de interesse para trabalhos futuros.

Tabela 1. Estatísticas do método proposto

	Classe	Porcentagem de acerto
1	<i>Sag</i>	99,61 ± 0,58
2	<i>Swell</i>	99,66 ± 0,54
3	<i>Notch</i>	99,90 ± 0,28
4	Transiente impulsivo	99,90 ± 0,28
5	Transiente oscilatório	99,83 ± 0,29
6	Harmônicos	97,99 ± 1,24
7	Transiente oscilatório + <i>Sag</i>	99,63 ± 0,42
8	Transiente oscilatório + <i>Swell</i>	99,50 ± 0,47
9	Harmônicos + Transiente oscilatório	94,18 ± 1,86
10	Harmônicos + <i>Notch</i>	99,60 ± 0,37
11	Harmônicos + <i>Sag</i>	99,99 ± 0,09
12	Harmônicos + <i>Swell</i>	99,95 ± 0,30
13	<i>Notch</i> + <i>Sag</i>	99,96 ± 0,15
14	<i>Notch</i> + <i>Swell</i>	99,57 ± 0,39
15	Transiente Impulsivo + <i>Sag</i>	94,21 ± 2,02
16	Transiente Impulsivo + <i>Swell</i>	97,51 ± 0,99
17	Harmônicos + Transiente oscilatório + <i>Sag</i>	96,70 ± 1,31
18	Harmônicos + Transiente oscilatório + <i>Swell</i>	95,71 ± 1,25
19	Harmônicos + <i>Notch</i> + <i>Sag</i>	97,67 ± 1,24
20	Harmônicos + <i>Notch</i> + <i>Swell</i>	98,30 ± 1,28

Agradecimentos

Os autores gostariam de agradecer ao CNPq e à Fapemig pelo suporte financeiro.

Referências Bibliográficas

- Abidullah, N.A.; Abdullah, A.R.; Zuri Sha'ameri, A.; Shamsudin, N.H.; Ahmad N.H.H. and Jopri, M.H. (2014). Real-Time Power Quality Disturbances Detection and Classification System. *World Applied Sciences Journal* 32, pp. 1637-1651, 2014.
- ANEEL (2016). PRODIST: Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional, Manual Técnico, www.aneel.gov.br.
- Barbosa, B.H.G. and Ferreira, D.D. (2013). Classification of Multiple and Single Power Quality Disturbances Using a Decision Tree Approach. *J Control Autom Electr Syst* (2013) 24, pp. 638- 648.
- Bollen, M.; Gu, I.; Santoso, S.; Mcgranaghan, M.; Crossley, P.; Ribeiro, M.; et al. (2009). Bridging the gap between signal and power. *Signal Processing Magazine, IEEE*, 26(4), 12–31.
- de la Rosa, J. J. G., Muñoz, A. M., Gallego, A., Piotrkowski, R., & Castro, E. (2009). Higher-order characterization of power quality transients and their classification using competitive layers. *Measurement*, 42(3), 478–484.
- Duda, R. O., Hart, P. E., & Stork, D. G. (2000). *Pattern classification* (2nd ed.). London: Wiley-Interscience.
- Ferreira, D.D.; Cerqueira, A.S.; Marques, C.A.G. e Duque, C.A. (2009). Sistema Automático de Detecção e Classificação de Distúrbios Elétricos em Qualidade da Energia Elétrica. *Revista Controle & Automação/Vol.20 no.1/Janeiro, Fevereiro e Março* 2009.
- Habets, J. (2014). Everything You Ever Wanted to Know About Network Streams. ALUGM Copenhagen 21 March 2014, www.vi-tech.nl/en.
- He, H. and Starzyk, J.A. (2006). A Self-Organizing Learning Array System for Power Quality Classification Based on Wavelet Transform. *IEEE Transactions on Power Delivery*, February 2006, pp 286-295.
- Hirano, K., Nishimura, S., & Mitra, S. K. (1974). Design of digital notch filters. *IEEE Transactions on Communications*, 22(7), 964–970.
- IEEE (1995). Recommended Practice for Monitoring Electric Power Quality, IEEE Std. 1159-1995.
- International Energy Agency (2011). Technology Roadmap Smart Grids, www.iea.org.
- Ming, Z.; Kaicheng, L. and Yisheng, H. (2010). DSP-FPGA Based Real-Time Power Quality Disturbances Classifier. *Metrol. Meas. Syst.*, Vol. XVII (2010), No. 2, pp. 205-216.
- Mitchell, T. (1997). *Machine Learning* (1st ed.) New York: McGrawHill Education.
- Mitra, S. K. (2006). *Digital signal processing: computer-based approach* (3rd ed.). New Delhi: Tata McGraw-Hill Publishing.
- National Instruments (2014). CompactRIO Integrated Systems with Real-Time Controller and Reconfigurable Chassis NI cRIO-907x, Manual Técnico, www.ni.com.
- Nikias, C. and Mendel, J. (1999). Signal processing with higher order statistics. *IEEE Transactions on Signal Processing*, 41(1), 10–38.
- Ribeiro, M. V., & Pereira, J. L. R. (2007). Classification of single and multiple disturbances in electric signals. *EURASIP Journal on Advances in Signal Processing*, 2, 15–15.
- Wang, M.; Ochenkowski, P. and Mamishev, A. (2001). Classification of power quality disturbances using time-frequency ambiguity plane and neural networks. *Power Engineering Society Summer Meeting*, 2001, Vol 2, IEEE.
- Wang, M.; Rowe, G.I. e Mamishev, A.V. (2003). Real-Time Power Quality Waveform Recognition with a Programmable Digital Signal Processor. *Power Engineering Society General Meeting*, 2003, Vol 2, IEEE.