

IMPLEMENTAÇÃO DE SISTEMA PARA DETECÇÃO E CLASSIFICAÇÃO AUTOMÁTICA DE SAGS EM SISTEMAS TRIFÁSICOS

EDUARDO G. RIBEIRO¹, ERICK A. NAGATA², BRUNO H. G. BARBOSA², DANTON D. FERREIRA²

¹*Laboratório de Sistemas Inteligentes, Departamento de Engenharia Elétrica e de Computação, Escola de Engenharia de São Carlos, Universidade de São Paulo
Campus Universitário, CEP 13566-590, São Carlos, SP, Brasil*

²*Departamento de Engenharia, Universidade Federal de Lavras
Campus Universitário, CEP 37200-000, Lavras, MG, Brasil*

E-mails: eduardogr@usp.br, eanagata@gmail.com, brunohb@deg.ufla.br, danton@deg.ufla.br

Abstract — The growing number of pollutant loads linked to the grid leads to research in the area of electric power quality. Such pollution is visible as deformities in the voltage waveform, among which the voltage sags stand out. This work aims to detect the moment of occurrence of the disturbance through Independent Component Analysis. With such information, the system segments the electrical signal so that it can be processed through higher order statistics. The information obtained by such a process is used for automatic classification of causes of the three-phase sag - faults, induction motors starting and transformer energizing - by means of a multiclass Support Vector Machine. The system was developed in LabVIEW and its performance was evaluated off-line and through an integrated data acquisition system, with a global accuracy of 96,7%.

Keywords — Sags, Detection, Classification, Independent Component Analysis, Support Vector Machines

Resumo — O crescente número de cargas poluidoras ligadas à rede elétrica impulsiona pesquisas na área de qualidade de energia elétrica. Tal poluição se mostra visível como deformidades na forma de onda de tensão, dentre as quais se destacam os sags. Este trabalho visa a detecção do momento da ocorrência do distúrbio por meio de Análise de Componentes Independentes. De posse de tal informação, o sistema segmenta o sinal elétrico para que possa ser processado por meio de estatísticas de ordem superior. As informações obtidas por tal processo são usadas para classificação automática de causas do sag trifásico – faltas, partida de motores de indução e energização de transformadores – por meio de uma Máquina de Vetores Suporte multiclasses. O sistema foi desenvolvido em LabVIEW e seu desempenho foi avaliado de forma *off-line* e por meio de um sistema integrado de aquisição de dados, alcançando uma eficiência global de 96,7%.

Palavras-chave — Sags, Detecção, Classificação, Análise de Componentes Independentes, Máquinas de Vetores Suporte

1 Introdução

A primeira menção ao termo Qualidade de Energia Elétrica (QEE) ocorreu em 1968 em um estudo da Marinha Americana (Bollen, 1999). Desde então, a crescente complexidade do sistema elétrico e o uso contínuo de cargas poluidoras (cargas dos tipos não lineares, flutuantes, não balanceadas e variáveis no tempo) (Ming; Kaicheng; Yisheng, 2010), reafirmam o interesse em QEE. O termo se refere à adequação da forma de onda de tensão e corrente a padrões pré-estabelecidos (Ferreira et al., 2009). Ou seja, a existência, ou não, de distúrbios elétricos determinam o nível de qualidade da onda.

As consequências de uma energia de baixa qualidade envolvem o mal funcionamento de equipamentos eletrônicos ou mesmo sua perda total de funcionalidade. Como exemplo, os custos relativos à falta de QEE na indústria e comércio na União Europeia, de acordo com Targosz e Chapman (2012), são estimados em mais de 150 bilhões de euros ao ano. Portanto a QEE é um fator determinante no setor elétrico.

Os sags, afundamentos de tensão, são um dos principais e mais frequentes problemas relativos à QEE no mundo (Bollen, 1999). Segundo o IEEE Std. 1159 (IEEE, 2009), estes são os principais inimigos de processos industriais e, juntamente com as interrupções de tensão, respondem por 85% dos casos de mal funcionamento de equipamentos.

Este distúrbio é definido, de acordo com o referido documento, como um decréscimo momentâneo no valor RMS do sinal de tensão em uma escala de 10% a 90% de seu valor nominal. E sua duração é, por definição, superior a meio ciclo e inferior a um minuto.

Sags são fenômenos majoritariamente trifásicos. Embora muitas publicações o introduzam em sua versão monofásica e estendam a definição para sistemas trifásicos, grande parte do sistema elétrico é trifásico e as cargas que mais sofrem com as consequências do distúrbio também o são (Bollen, 2001).

Sua principal causa é um aumento momentâneo no valor da corrente, cujas fontes podem ser partida de motores de indução, energização de transformadores e faltas (Bollen, 2001). A Figura 1 ilustra estes fatores.




Figura 1. Sinais trifásicos simulados contendo sags

À esquerda tem-se os sinais de tensão, e à direita os valores RMS equivalentes, calculados em uma janela de um ciclo e deslocada no eixo temporal.

As figuras 1(a) representam sags causados por faltas monofásicas, cuja carga está conectada em estrela. O valor RMS é caracterizado pela queda, permanência neste valor inferior durante o intervalo do distúrbio e posterior retorno ao valor nominal (Bollen, 2001). Deve-se mencionar que as faltas podem ser ainda bifásicas com terra, bifásicas sem terra ou trifásicas (Anderson, 1995).

As figuras 1(b) indicam os sags provenientes de acionamento de motores. Nota-se a forma padrão da queda de tensão devida à corrente de partida elevada do motor. Além do fato de a queda ocorrer de forma semelhante nas três fases (Bollen, 2001).

Por fim, as figuras 1(c) demonstram o cenário de sags causados por energização de transformadores. As quedas são diferentes em cada fase e associadas a deformações de harmônicos (Bollen, 2001), (Styvaktakis; Bollen, 2003).

Tendo em vista a detecção e a classificação destes distúrbios, alguns trabalhos fazem uso de técnicas de processamento de sinais e inteligência computacional. Embora QEE lide especialmente com métodos de medição e mitigação de distúrbios (Rojin, 2013), por meio de um sistema de classificação, os distúrbios elétricos recorrentes em uma medição podem ser automaticamente reconhecidos para que técnicas específicas de mitigação sejam empregadas.

Em Meléndez et al. (2008) o objetivo da classificação quanto à origem de sags se desdobra em discriminar se o distúrbio ocorreu na rede de distribuição ou na rede de transmissão. Para tal, os autores lançam mão da técnica de Análise de Componentes Principais para projetar as características em um novo espaço e, então, classificar novos sags com base em critérios de similaridade de forma de onda.

Já em Ismail, Zakaria e Hamzah (2016), os grupos considerados para classificação são mais evidentes, a saber, faltas e acionamento de motores. Os autores conseguem bons resultados de classificação com o uso de Análise Multi-Resolução e Máquinas de Vetores Suporte.

Em Kezunovic e Liao (2001), os autores implementaram um sistema Fuzzy para classificar sags causados por faltas, partida de motores de indução e reaceleração de motores. No trabalho de Manjula, Sarma e Mishra (2011) os autores se dispõem a detectar o sag e classificá-lo de acordo com suas três principais causas. O método utilizado para detecção é a Transformada Hilbert e o modelo de classificador proposto é a Rede Neural Probabilística. Uma revisão das diversas técnicas utilizadas exclusivamente para detecção de sags pode ser encontrada em Mansor e Rahim (2009).

Neste trabalho é implementado um sistema de detecção de sags por meio da técnica de Análise de Componentes Independentes (ICA), no seu formato *Single-Channel*. A proposta é feita em Nagata et al. (2016) e aqui o método é estendido para detecção trifásica. Em adição à detecção, é implementado também um sistema de classificação de causas dos sags (entre faltas, partida de motores de indução e energização de transformadores) por meio de uma Máquina de Vetores Suporte (SVM). O trabalho foi desenvolvido em LabVIEW e avaliado de maneira *off-line*, bem como de forma integrada à um equipamento de aquisição de sinais.

Este artigo está estruturado da seguinte forma: Na seção 2 as técnicas utilizadas e o método implementado são explicados. Na seção 3, os resultados obtidos são apresentados e discutidos. Por fim, na seção 4, as conclusões e considerações finais são feitas.




Figura 2. Resumo esquemático do método proposto

2 Método Implementado

Resumidamente, no sistema proposto, tem-se a execução do *Single-Channel ICA* (SCICA) (Davies e James, 2007), capaz de retirar as componentes independentes do sinal de entrada. Estas serão usadas para obtenção de um índice de segmentação (após filtragem para minimizar a influência de ruído). Os sinais segmentados a partir do índice obtido anteriormente são submetidos à extração de características, normalizados e selecionados. Todas estas etapas são executadas nas três fases do sinal trifásico. Os cumulantes (Mendel, 1991) selecionados de cada fase são somados e suas médias são obtidas. O vetor de médias resultante é entregue à três SVMs binárias e os resultados são submetidos a uma operação lógica para, por fim, prever a classe de *sag*. Estes passos estão representados de maneira esquemática na Figura 2.

2.1 Single Channel ICA

Análise de Componentes Independentes é uma técnica de processamento estatístico de sinais que busca obter componentes não-gaussianas e estatisticamente independentes de uma mistura de sinais (Hyvärinen; Karhunen; Oja, 2001). O problema, dissociado de seus pressupostos conceituais, pode ser matematicamente definido como:

$$\mathbf{x}[k] = \mathbf{A}\mathbf{s}[k], \quad (1)$$

em que $\mathbf{x}[k]$ representa um vetor com m observações da mistura e $\mathbf{s}[k]$ é um vetor que contém as n fontes independentes desconhecidas. A matriz $m \times n$ $\mathbf{A}$ é chamada matriz de mistura.

A estimação das fontes originais é feita cegamente, pois nenhuma outra informação além do sinal observado é considerada (Nagata et al., 2016). Dessa forma, as fontes estimadas pelo ICA são:

$$\mathbf{y}[k] = \mathbf{W}\mathbf{x}[k]. \quad (2)$$

Assim, o objetivo do algoritmo é achar a matriz de separação $\mathbf{W}$ (uma estimativa de $\mathbf{A}^{-1}$), para que as componentes independentes $\mathbf{y}[k]$ possam ser estimadas. No contexto de QEE, as fontes independentes no sinal de tensão monitorado são a componente fundamental, o distúrbio e o ruído (Nagata et al., 2016).

No entanto, para o caso em que apenas uma observação da mistura está disponível (i. e. um sensor),

alguns artifícios devem ser empregados para que o ICA possa ser usado.

Para se obter uma matriz de observação $\mathbf{x}[k]$ mediante apenas um sinal observado (o sinal de tensão), versões atrasadas deste sinal são utilizadas como forma de obter uma representação multicanal, conforme mostra a Equação 3. Esta técnica é uma adaptação da proposta de Davies e James (2007), conhecida como *Single Channel ICA* (SCICA).

$$\mathbf{x}[k] = \begin{bmatrix} x[k] \\ x[k-1] \\ \vdots \\ x[k-D] \end{bmatrix} \quad (3)$$

Segundo os autores acima, para que a aplicação da técnica SCICA funcione bem, os sinais devem ter espectro disjunto. Desta forma, as colunas a_i da matriz de misturas $\mathbf{A}$ tendem a ser filtros individuais atrasados. Assim, a estimativa das componentes independentes pode ser dada por uma das versões filtradas da mistura $\mathbf{x}[k]$ ou pelo agrupamento de sinais de mesmo conteúdo espectral, em que os coeficientes de cada filtro são dados pelas linhas da matriz de separação $\mathbf{W}$ (Nagata et al., 2016).

Após a construção de uma representação multicanal, um dos muitos algoritmos disponíveis para a técnica ICA pode ser utilizado. A ferramenta *Second-Order Blind Identification* (SOBI) foi utilizada neste trabalho devido à sua robustez ao ruído e por lidar com fontes correlatas temporalmente (Belouchrani et al., 1993). A subseção seguinte trata deste algoritmo.

- *Second Order Blind Identification* (SOBI)

Proposto nos trabalhos de Belouchrani et al. (1993) e Belouchrani et al. (1997) o algoritmo SOBI possibilita a identificação cega de fontes por meio de estatísticas de segunda ordem. Em comparação com os métodos que utilizam estatística de ordem superior (Hyvärinen; Karhunen; Oja, 2001), os métodos de segunda ordem não precisam estimar a função densidade de probabilidade das fontes (Leite, 2004).

Manipulando a Equação 2 a partir da aplicação do SOBI, têm-se as fontes independentes estimadas como

$$\mathbf{y}[k] = \mathbf{U}^T \mathbf{z}[k], \quad (4)$$

em que U é uma matriz unitária encontrada por meio da diagonalização da matriz de correlação $R[t]$. Esta matriz é construída a partir dos dados $z[k]$, uma versão branqueada de $x[k]$. Para detalhes a respeito do método recomenda-se a leitura dos trabalhos citados.

Conforme mencionado anteriormente estas fontes independentes são versões filtradas do sinal de tensão contendo *sag*. É por meio desta característica que a ICA pode funcionar como um detector. A amostra que contém um pico no sinal filtrado coincide com o momento da ocorrência do *sag*, uma vez que o instante de ocorrência é caracterizado por alta frequência e as componentes independentes são versões filtradas do sinal de tensão, cujas componentes de baixa frequência são atenuadas.

Na Figura 3, tem-se um exemplo de detecção para o caso de *sag* causado por falta. O sinal usado como detector é obtido pela soma das fontes 3 e 7 estimadas pela ICA.




Figura 3. Sinal de tensão contendo *sag* ocasionado por falta (acima) e correspondente sinal de detecção (abaixo).

2.2 Extração de Características

O principal objetivo da etapa de extração de características em um sistema de classificação é representar os dados em um novo espaço de características, no qual a probabilidade de distinguir classes é maior que no espaço original (Ferreira et al., 2011). A escolha do método de extração a ser usado deve levar em conta alguns detalhes, tais como sua sensibilidade ao ruído e seu custo computacional. Deste modo, conforme exposto por Mendel (1991), o uso de estatísticas de ordem superior (EOS) pode ser mais imune ao ruído gaussiano que medidas de segunda ordem.

As EOS são definidas em termos de momentos e cumulantes, sendo os primeiros indicados para sinais determinísticos e os cumulantes para sinais estocásticos (Nagata et al., 2017), (Mendel, 1991). O uso de cumulantes em QEE tem se mostrado eficiente e pode ser encontrado em trabalhos como o de Barbosa e Ferreira (2013).

As expressões para os cumulantes de segunda, terceira e quarta ordens de um sinal $x(t)$ com $E\{x(t)\}=0$ podem ser aproximadas (Ribeiro; Pereira, 2007) pelas equações 5-7 respectivamente.

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

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

$$\begin{aligned} \hat{C}_{4,x}(\tau) = & \frac{1}{N} \sum_{n=0}^{N-1} x(n)x^3(\text{mod}(n+\tau, N)) - \\ & - \frac{1}{N^2} \sum_{n=0}^{N-1} x(n)x(\text{mod}(n+\tau, N)) \sum_{n=0}^{N-1} x(n)^2, \end{aligned} \quad (7)$$

em que $x \in \mathcal{R}^N$, $\tau = 0, 1, \dots, N-1$ e N é igual ao número de amostras no sinal.

O uso de algoritmos de otimização é necessário para seleção de características providas da etapa de extração. Desta forma, é possível que a etapa posterior, de classificação, se torne mais eficiente e simples. Considerando este fato, os índices dos cumulantes que demonstram as maiores diferenças entre classes foram obtidos por meio do algoritmo *Teaching-Learning-Based Optimization* (TLBO) (Rao, Savsani e Vakharia, 2011). Como semente para a execução do TLBO, os cumulantes mais representativos foram pré-selecionados por meio do Discriminante Linear de Fisher.

2.3 Máquina de Vetores Suporte

O uso de máquina de vetores suporte (SVM) tem sido considerado em problemas de classificação como uma alternativa a métodos convencionais, como as redes neurais artificiais.

Sua teoria foi desenvolvida por Vapnik (1995), a partir da sua Teoria do Aprendizado Estatístico, e se trata de uma técnica supervisionada de aprendizado de máquina. Seu treinamento baseia-se na busca de um hiperplano ótimo de separação entre classes (i. e. aquele que se encontra mais distante de ambas as classes) em um espaço multidimensional.

Muitas vezes, a aplicação de um método puramente linear pode sofrer com *outliers* ou levar a classificação equivocada. Para superar esta deficiência pode-se delimitar uma certa folga na classificação com o parâmetro *soft-margin*. Porém, mesmo com este parâmetro, em alguns problemas, o algoritmo pode não conseguir separar as classes. A solução para tal situação consiste em mapear os dados em análise para uma dimensão maior, na qual estes dados se mostrem linearmente separáveis. Este artifício é implementado por meio das funções *kernel*, sendo as funções polinomial, gaussiana e sigmoideal, as mais conhecidas.

A formulação matemática do caso de uma SVM com margens suaves e com mapeamento *kernel* pode ser resumida como se segue (Lorena e Carvalho, 2007).

A minimização da distância entre dois hiperplanos leva a um problema dual de otimização quadrática que visa maximizar a seguinte equação:

$$\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i y_j \alpha_i \alpha_j (\Phi(\mathbf{x}_i)) \cdot (\Phi(\mathbf{x}_j)), \quad (8)$$

sujeita às restrições:

$$\sum_{i=1}^n y_i \alpha_i = 0, \quad (9)$$

$$0 \leq \alpha_i \leq C, i = 1, \dots, n; \quad (10)$$

em que α_i representam os multiplicadores de Lagrange que determinarão os vetores suporte, C é o critério de suavização das margens, Φ é a função *kernel*, $\mathbf{x}_i$ e y_i representam o conjunto de n dados de treinamento. O seguinte par $(\mathbf{w}^*; b^*)$ define o hiperplano ótimo:

$$\mathbf{w}^* = \sum_{i=1}^n \alpha_i^* y_i \Phi(\mathbf{x}_i), \quad (11)$$

$$b^* = \frac{1}{2} [\max\{i \mid y_i = -1\} (\mathbf{w}^* \cdot \Phi(\mathbf{x}_i)) + \min\{i \mid y_i = +1\} (\mathbf{w}^* \cdot \Phi(\mathbf{x}_i))]. \quad (12)$$

Após a definição dos parâmetros na etapa de treinamento, a fase de teste se baseia na classificação de amostras mediante a lei indicada na Equação 13:

$$g(x) = \text{sgn}(*) = \text{sgn}(\mathbf{w}^* \cdot \Phi(\mathbf{x}) + b^*) \quad (13)$$

em que o resultado de $g(x)$ pode assumir os valores +1 ou -1 se o valor de $*$ for > 0 ou < 0 respectivamente, determinando, desta forma, as classes.

2.4 Banco de dados

Os dados utilizados para treinamento e teste do sistema foram gerados no *Simulink*, utilizando-se uma rede de distribuição radial do IEEE com 15 barramentos e uma fonte de geração distribuída com capacidade de 300kW.

Foram gerados 1500 sinais, 500 para cada tipo de *sag* considerado. A estes sinais foi adicionado ruído gaussiano de forma a se obter uma relação sinal-ruído (SNR) de 40dB. O local da ocorrência do evento foi variado dentro da rede, fazendo com que *sags* de diferentes amplitudes fossem obtidos. A frequência de amostragem utilizada é de 7680Hz, ou seja, 128 pontos por ciclo.

Os *sags* causados por acionamento de motor e energização de transformadores foram gerados variando-se, aleatoriamente, suas potências, o tempo inicial do distúrbio, bem como sua duração e o nível de carga da rede. Já para os *sags* causados por faltas, os parâmetros de tempo inicial, duração do distúrbio e nível de carga também foram variados, além das resistências de curto-circuito. Do total de eventos de falta, 20% contêm múltiplos estágios.

A proporção entre sinais de treinamento e teste para a etapa de classificação foi de 69,2% e 30,8% respectivamente. A discriminação mais detalhada desta divisão está na Tabela 1. Estes valores foram obtidos a partir de uma escolha automática do algoritmo, de modo a introduzir certa aleatoriedade ao treinamento.

Tabela 1. Divisão dos sinais trifásicos entre treinamento e teste.

Causa	Treina- mento	Teste	Total
Falta	355	145	500
Acionamento de Motor	350	150	500
Energização de Transformador	333	167	500
Total	1038	462	1500

2.5 Operação do sistema

LabVIEW é um software desenvolvido pela *National Instruments* com o intuito de servir como ferramenta poderosa de controle de sistemas, simulações, operações matemáticas de alta complexidade, aquisição e processamento de sinais. Por tais características e, notadamente, por servir bem ao propósito de visualização e monitoramento, foi escolhido para implementação dos algoritmos.

O algoritmo tem como entrada 11520 pontos de sinal. Ele é formado alternadamente por amostras das três fases do sinal trifásico que, na sequência, é dividido para obtenção dos três sinais individuais de 3840 pontos. Cada um destes será operado pelos algoritmos ICA.

Após a execução do algoritmo ICA, um índice de segmentação é obtido. Tal índice representa a amostra na qual o *sag* é detectado pelo sistema. A limiarização é feita considerando o primeiro pico que possua amplitude maior que cinco vezes a média da amplitude dos picos, em módulo. Uma discussão a respeito desta estratégia é feita na Seção 3.

Após a obtenção de um índice de segmentação em cada fase, escolhe-se o maior deles como índice geral. As três fases serão segmentadas a partir deste índice e cada uma passa a conter apenas 128 pontos (1 ciclo). Este ciclo é o mais representativo dos sinais e dos distúrbios, portanto, será entregue à extração de características.

Na etapa de extração de características calculam-se 64 cumulantes de segunda ordem, 128 cumulantes de terceira ordem e 128 cumulantes de quarta ordem, totalizando 320. Os 320 cumulantes extraídos de cada fase são normalizados e selecionados.

Utilizando uma população de 40 indivíduos e 50 iterações do TLBO, os índices dos melhores cumulantes foram obtidos. A função custo foi representada pelo erro médio quadrático da validação cruzada em dados de treinamento utilizando 5 *folds*. Por meio da execução do algoritmo, percebeu-se que a seleção dos 15 melhores cumulantes leva aos melhores resultados de classificação.

Assim, na fase operacional, dos 320 cumulantes extraídos, os 15 relativos aos índices encontrados pelo TLBO são selecionados. Por fim, o resultado da fase de extração de características é o seguinte:

$$cum_i = (cum_{ia} + cum_{ib} + cum_{ic}) / 3, \quad (14)$$

em que $i = 1, 2, \dots, 15$ e a, b e c representam as fases.

A etapa final do sistema é a classificação por meio de uma SVM.

Como as SVMs são classificadores binários, estratégias para lidar com mais de duas classes devem ser empregadas. Neste sentido, a abordagem *one x one* foi utilizada para evitar a assimetria da abordagem *one x all*. A ideia é fazer com que cada SVM classifique duas classes separadamente e o resultado seja aquele obtido pelo maior número de SVMs. A Tabela 2 mostra como cada SVM lida com as classes.

Tabela 2. Configuração da SVM Multiclasses.

	Classes envolvidas
SVM 1	Partida de Motor (0) x Energ. de Transformador (1)
SVM 2	Falta (0) x Energ. de Transformador (1)
SVM 3	Falta (0) x Partida de Motor (1)

A Máquina de Vetores Suporte multiclasses foi construída com as ferramentas disponíveis no *Machine Learning Toolkit* do LabVIEW. Suas SVMs binárias foram treinadas com *kernel* polinomial de grau quatro e *soft-margin parameter* igual a dois.

De posse dos parâmetros encontrados durante o treinamento, foi possível montar a SVM Multiclasses estática que recebe novos valores de entrada e os classifica sem mais necessitar de treinamento.

Ao fim do desenvolvimento do sistema avaliou-se a inclusão da aquisição dos sinais simulados como etapa primária. A subseção seguinte trata do assunto.

2.5.1 Geração e aquisição dos sinais simulados

Para analisar a viabilidade do sistema proposto funcionar como ferramenta de monitoramento, a placa *CompactRIO 9076* da *National Instruments* e o módulo de entradas analógicas simultâneas NI9215 foram utilizados. A implementação do sistema integrado às placas é ilustrada na Figura 4.

Para gerar os sinais simulados, a placa *CompactDAQ 9178*, também da *National Instruments*, e o módulo de saídas analógicas simultâneas NI9263 foram utilizados. A montagem experimental pode ser assim resumida: As três fases dos sinais simulados são geradas por meio do NI9263 e adquiridos pelo NI9215, ambos à uma taxa de 7680Hz. A amplitude máxima de operação dos módulos é 10V, fazendo-se necessária a redução na geração e posterior reajuste após a aquisição. Ambos possuem 16 bits de resolução e possibilitam geração/aquisição simultânea, uma característica essencial para sistemas trifásicos.




Figura 4. Implementação do sistema

O sistema de aquisição foi desenvolvido com base nas práticas recomendadas pela *National Instruments*. Estas práticas incluem a divisão do sistema em três *targets*: *FPGA*, *Real-Time* e *Remote Machine*. O primeiro *target* é uma interface para a programação do *Field Programmable Gate Array*. Ele implementa um buffer (FIFO - *first-in, first-out*) para adquirir os sinais e controlar a frequência de amostragem.

Ainda dentro da *CompactRIO*, os dados provenientes do *FPGA* são transferidos para o processador em tempo real por meio de um barramento *PCI*. Este é o segundo *target*, programado para ajustar os parâmetros de aquisição no *FPGA* e para reiniciar o processo, caso ocorram erros na fila de aquisição.

Os dados do segundo *target* são enviados via *Network Stream* (NI, 2013) para o computador, onde o sistema desenvolvido de detecção e classificação será executado. Ou seja, o *FPGA* e processador da *cRIO* são responsáveis apenas pelo controle de aquisição.

3 Resultados e Discussão

Os resultados obtidos pelo sistema de detecção proposto são apresentados na Tabela 3. Estes resultados percentuais foram calculados ao levar em consideração algumas observações. A primeira delas diz respeito à estratégia de detecção adotada.

Tabela 3. Índice de detecção.

Causa	Eficiência na Detecção
Falta	92,4%
Acionamento de Motor	97,6%
Energização de Transformador	94,2%

Fez-se necessário utilizar uma estratégia de detecção que incluísse as três causas de *sags* e fosse menos susceptível aos efeitos do ruído. Portanto, como etapa anterior à determinação do índice de segmentação, foi utilizado um filtro *Butterworth* passa-baixas de 2ª ordem e frequência de corte igual 60Hz. Visto que o ruído branco possui, por definição, igual intensidade em todas as frequências, tentou-se diminuir sua influência por meio de tal filtro. Após a filtragem, embora o pico de detecção também tenha sido consideravelmente atenuado, ficou mais evidente em relação ao ruído.

A segunda observação diz respeito ao intervalo considerado como satisfatório na detecção dos *sags*. A duração mínima de um *sag* é meio ciclo, ou seja, 64 amostras do sinal considerado. Desta forma, foi considerada como uma detecção eficiente aquela que ocorre com diferença máxima de 32 amostras (um quarto de ciclo).

Estas considerações são prudentes visto que certa folga quanto ao instante exato da segmentação do sinal deve ser admitida, para que o classificador tenha maior capacidade de generalização. Outro ponto relevante é o fato de a segmentação ser um norte para a etapa de classificação, principal objetivo do sistema.

No entanto, observa-se que o período transitório do *sag* deve sempre estar presente no sinal enviado ao classificador. Dessa forma, o uso de um detector computacionalmente mais simples, como o baseado em RMS, pode interferir negativamente na classificação já que introduz incerteza de meio-ciclo na detecção do início do distúrbio.

Os erros de detecção mais frequentes ocorrem em *sags* causados por faltas, pois o instante final do distúrbio pode ser retornado. Isso acontece quando o pico do sinal de detecção no instante final for muito maior que o inicial.

Em comparação à outra técnica de detecção presente na literatura baseada em transformada Wavelet (Latran e Teke, 2015), o método proposto é menos preciso quanto ao instante de detecção. No entanto, é avaliado na presença de ruído e classes diferentes de *sags*, análises não consideradas pelos autores.

Como último comentário a respeito do sistema de detecção pode-se enaltecer seu funcionamento como filtro adaptativo (Haykin, 2007). Uma vez que a cada iteração do algoritmo uma nova matriz W é obtida, tem-se, então, novos coeficientes do filtro pelo qual as componentes independentes, utilizadas na segmentação, são obtidas. Ou seja, o resultado do sistema é adaptado aos sinais de entrada, o que possibilita uma maior eficiência na detecção.

Para o sistema de classificação, o resultado obtido é apresentado na Tabela 4. Este é o resultado da classificação dos dados de teste da SVM Multiclasses. Todas as SVMs binárias alcançaram resultados individuais superiores ao resultado geral. Esta eficiência é considerada alta e condizente com trabalhos que utilizam máquinas de vetores suporte como classificadores em problemas de qualidade de energia elétrica (Nagata et al., 2017), (Ismail; Zakaria; Hamzah, 2016).

Os erros mais comuns da etapa de classificação estão na predição equivocada da classe “Falta” quando o sinal pertencente à classe “Acionamento de motor” possui retorno muito lento ao valor nominal. Outra observação quanto às classes é a possibilidade de erros se o sinal monitorado estiver corrompido por harmônicos. Este distúrbio pode levar o sistema a classificar os *sags* como provenientes de energização de transformador.

Tabela 4. Índice de classificação.

	Eficiência na Classificação
SVM Multiclasses	98,2%

Por fim, testou-se o sistema completo. Os 1500 sinais simulados foram testados de modo a avaliar a operação conjunta de todos os métodos implementados (detecção, segmentação e classificação). Os resultados obtidos estão na Tabela 5.

Tabela 5. Eficiência global do sistema.

Causa	Percentual Final
Falta	96,2%
Acionamento de Motor	99,2%
Energização de Transformador	94,6%
Total	96,7%

Percebe-se, pela tabela, que eventuais erros na detecção podem ser suprimidos, em alguns casos, na classificação, visto que a eficiência final do sistema é superior à eficiência do detector isolado. Este resultado condiz com aqueles encontrados em outros sistemas de classificação propostos em QEE.

No trabalho de Nagata et al. (2017), por exemplo, os *sags* foram classificados com 98,33% de eficiência. Este resultado considera a segmentação dos sinais feita *a priori* e contabiliza também a classificação correta de sinais nominais, não considerados neste trabalho. Portanto, entende-se que o sistema aqui proposto é completo, no sentido de englobar detector e classificador e, notadamente eficiente.

Todos os resultados apresentados foram obtidos *off-line*, sem a etapa de aquisição dos sinais. Para teste do sistema de forma *on-line*, 25 sinais trifásicos contendo cada causa de *sag* considerada foram gerados e avaliados de acordo com suas classes preditas, totalizando 75 testes. Notou-se que o sistema é capaz de realizar todas as operações necessárias à classificação sem que ocorra *overflow* na aquisição. Os resultados foram corretos para todos os 75 sinais trifásicos testados.

4 Conclusão

Neste trabalho, um dos problemas mais preocupantes da área de QEE, os *sags*, foram abordados de forma conceitual e prática e foram classificados corretamente quanto às suas causas em 96,7% dos testes.

O sistema desenvolvido busca servir como um aparato funcional mediante esforços na implementação dos códigos em LabVIEW. De modo que novos sinais possam ser classificados a qualquer momento, sem nenhuma necessidade de novos treinamentos ou ajustes. Além da criação de uma interface de monitoramento e integração com hardwares de aquisição.

Agradecimentos

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

Referências Bibliográficas

- Anderson, P. M. (1995). Analysis of faulted power systems. IEEE Press, v. 445, New York.
- Barbosa, B. H. G.; Ferreira, D. D. (2013). Classification of multiple and single power quality disturbances using a decision tree approach. Journal of Control, Automation and Electrical Systems, v. 24, n. 5, p. 638–648.
- Belouchrani, A. et al. (1993). Second order blind separation of temporally correlated sources. In: CITESEER. Proc. of International Conference on Signal Processing. Cyprus, 1993. p. 346–351.
- Belouchrani, A. et al. (1997). A blind separation techniques using second order statistics. IEEE Trans. on Signal Processing, v. 45, p. 434–444.
- Bollen, M. J. H. (1999). Understanding Power Quality Problems: Voltage Sags and Interruptions. Wiley-IEEE Press, New Jersey.
- Bollen, M. J. H. (2001). Voltage sags in three-phase systems. IEEE Power Engineering Review, p. 8–11.
- Davies, M. E.; James, C. J. (2007). Source separation using single channel ica. Signal Processing, v. 87, n. 8, p. 1819–1832.
- Ferreira, D. D. et al. (2009). Sistema automático de detecção e classificação de distúrbios elétricos em qualidade da energia elétrica. Revista Controle e Automação, v. 20, n. 1, p. 53–62.
- Haykin, S. (2007). Redes neurais: princípios e prática. Bookman Editora.
- Hyvärinen, A.; Karhunen, J.; Oja, E. (2001). Independent Component Analysis. Wiley-Interscience, New York.
- IEEE (2009). IEEE Std. 1159 - Recommended Practice for Monitoring Electric Power Quality. New Jersey.
- Ismail, H.; Zakaria, Z.; Hamzah, N. (2016). Classification of voltage sag using multi-resolution analysis and support vector machine. Journal of Clean Energy Technologies, v. 4, n. 3; pp. 183–186.
- Kezunovic, M.; Liao, Y. (2001). A new method for classification and characterization of voltage sags. Electric Power Systems Research, v. 58, n. 1; pp. 27–35.
- Latran, M. B. and Teke, A. (2015). A novel wavelet transform based voltage sag/swell detection algorithm. International Journal of Electrical Power & Energy Systems, Vol. 71, pp. 131–139.
- Leite, V. C. M. N. (2004). Separação Cega de Sinais: Análise Comparativa entre Algoritmos. Dissertação (Mestrado) - Unifei, Itajubá.
- Lorena, A. C.; Carvalho, A. C. P. L. F. (2007). Uma introdução às support vector machines. Revista de Informática Teórica e aplicada, v. 14, n. 2; pp. 43–67.
- Manjula, M.; Sarma, A.; Mishra, S. (2011). Detection and classification of voltage sag causes based on empirical mode decomposition. In: India Conference (INDICON), Annual IEEE. pp. 1–5.
- Mansor, M.; Rahim, N. A. (2009). Voltage sag detection-a survey. In: IEEE. Technical Postgraduates (TECHPOS), 2009 International Conference for. Kuala Lumpur; pp. 1–6.
- Meléndez, J. et al. (2008). Classification of sags according to their origin based on the waveform similarity. In: IEEE. Transmission and Distribution Conference and Exposition: Latin America, IEEE/PES. Bogota; pp. 1–6.
- 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, v. 79, n. 3; pp. 278–305.
- Ming, Z.; Kaicheng, L.; Yisheng, H. (2010). Dsp-fpga based real-time power quality disturbances classifier. Metrol. Meas. Syst., v. 17, n. 2; pp. 205–216.
- Nagata, E. A. et al. (2016). Método de detecção de sag e swell baseado em análise de componentes independentes. In: SBA. XXI Congresso Brasileiro de Automática - CBA. Vitória; pp. 1355–1360.
- Nagata, E. A. et al. (2017). Método de classificação de afundamentos de tensão em rede com geração distribuída. In: SBQEE. XII Conferência Brasileira sobre Qualidade de Energia Elétrica - CBQEE, Curitiba.
- National Instruments (2013). Lossless Communication with Network Streams: Components, Architecture, and Performance.
- Rao, R. V.; Savsani, V. J.; Vakharia, D. P. (2011). Teaching-learning-based optimization: A novel method for constrained mechanical design optimization problems. Computer-Aided Design, v. 43; pp. 303–315.
- Ribeiro, M. V.; Pereira, J. L. R. (2007). Classification of single and multiple disturbances in electric signals. EURASIP Journal on Advances in Signal Processing, v. 2; pp. 15–15.
- Rojin, R. K. (2013) A review of power quality problems and solutions in the electrical power system. Int. J. of Adv. Research in Electrical, Electronics and Instrumentation Engineering, v. 2, n. 11; pp. 5605–5614.
- Styvaktakis, E.; Bollen, M. H. (2003). Signatures of voltage dips: transformer saturation and multistage dips. IEEE Transactions on power delivery, v. 18, n. 1; pp. 265–270.
- Targosz, R.; Chapman, D. (2012). Application Note - Cost of Poor Power Quality. London.
- Vapnik, V. (1995). The Nature of Statistical Learning Theory. Springer-Verlag, New York.