

Método de Classificação de Afundamentos de Tensão em Rede com Geração Distribuída

Erick A. Nagata, Bruno H. G. Barbosa, Danton D. Ferreira

Universidade Federal de Lavras, Lavras, MG
eanagata@gmail.com, brunohb@deg.ufla.br,
danton@deg.ufla.br

Carlos A. Duque

Universidade Federal de Juiz de Fora, Juiz de Fora, MG
carlos.duque@ufjf.edu.br

Resumo — Este artigo apresenta um método de classificação de afundamentos de tensão (*sags*) de acordo com suas causas (falta, partida de motor de indução e saturação de transformador). São utilizadas Estatísticas de Ordem Superior para extrair as características de um ciclo do sinal de tensão trifásico. Para selecionar as características mais relevantes é utilizado o algoritmo de otimização *Teaching-Learning-based Optimization* (TLBO). Foram alcançados bons resultados utilizando tanto árvore de decisão quanto máquinas de vetores suporte (SVM), sendo que com SVM o desempenho foi melhor (98,33% de acertos com 15 características). O método pode ser utilizado como ferramenta auxiliar de sistemas de proteção da rede, que não devem indicar falta em casos de *sag* por partida de motor ou saturação de transformador.

Palavras-chaves — Qualidade de Energia Elétrica. Classificação de afundamentos de tensão. Geração Distribuída.

I. INTRODUÇÃO

O crescimento da demanda por uma energia elétrica de qualidade tem motivado o aumento das pesquisas na área de qualidade de energia elétrica (QEE) [1]-[3]. Muitos trabalhos de QEE abordam a classificação de distúrbios elétricos, como por exemplo classificar *sags*, harmônicos, transitórios e *flicker*. Outros trabalhos investigam a identificação das causas de determinado distúrbio, permitindo entender melhor o problema e mitigá-lo.

Os afundamentos de tensão (*voltage sag*), juntamente com as interrupções de tensão, são os distúrbios responsáveis por cerca de 85% dos casos de mal funcionamento de equipamentos devido à má QEE, sendo os principais inimigos dos processos industriais [4]. Sendo assim, a identificação das causas dos afundamentos de tensão tem sido de grande importância dentro da QEE [5].

As três principais causas de afundamentos de tensão são: *sag* causado por faltas (curtos-circuitos), *sag* causado por partida de motores de indução e *sag* causado por saturação de transformadores [6]. Os *sags* causados por faltas são os mais severos. Sua magnitude depende da impedância da falta, distância até o ponto de falta e configuração do sistema [7].

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

No caso de partida de motores de indução, a corrente solicitada durante sua partida pode chegar de 6 a 10 vezes maior do que a nominal, o que leva a afundamentos de tensão de menor intensidade. A magnitude do *sag* irá depender das características do motor e de como é feita a sua partida [7]-[8]. As características dos *sags* causados por saturação de transformadores são: desbalanceamento nas três fases, *sag* de baixa intensidade, não há mudanças no ângulo de fase e presença de harmônicos pares [9]. A Fig. 1 ilustra os três tipos de *sag* (gerados via MATLAB/Simulink).




Fig. 1. Exemplos (trechos do sinal trifásico e respectivos valores rms) dos três tipos de afundamentos de tensão causados por: (a) falta trifásica; (b) partida de motor de indução; (c) energização de transformador. Cada cor representa uma das fases do sinal de tensão.

Tendo em vista esse contexto, vários trabalhos já foram desenvolvidos para classificar afundamentos de tensão no sistema elétrico de potência (SEP). No trabalho de [9] foi desenvolvido um método de detecção e classificação das causas de *sags* utilizando a transformada Hilbert e Redes Neurais Probabilísticas. No trabalho de [10] foi desenvolvido um método de classificação de eventos com significantes variações de tensão utilizando filtros de Kalman e um sistema especialista. No trabalho de [11], um sistema Fuzzy foi utilizado como classificador de *sags* causados por faltas, partida de motores de indução e re-aceleração de motores.

Após a classificação, os autores fizeram a caracterização dos eventos. Em [5] os autores propuseram um método baseado em Análise de Multi-Resolução (MRA) e SVM para classificar *sags* causados por faltas e partida de motores de indução.

A maioria dos trabalhos encontrados na literatura não utilizam *sags* provenientes de rede com geração distribuída (*Distributed Generation* - DG), sendo que o foco principal da maioria das pesquisas envolvendo DG é a detecção de ilhamento [12]. No caso dos afundamentos de tensão, alguns trabalhos mostram que a inserção de DG pode atenuar a queda de tensão [13]-[14]. Tal fato depende de fatores como o tipo de conexão da fonte DG na rede (direta ou através de inversores de frequência), da capacidade de geração e proximidade do afundamento à fonte de geração distribuída [13]. No entanto, não é objetivo deste trabalho analisar as diferentes dinâmicas dos diferentes tipos de DG e seus efeitos nos *sags*, podendo ser feito em pesquisas futuras.

Neste trabalho é proposto um novo método de classificação de *sags* de acordo com suas causas. São testados dois classificadores diferentes: árvore de decisão [15] e SVM (*Support Vector Machine*) [16]. A extração de características foi feita com Estatísticas de Ordem Superior (EOS) [17] e a seleção de características foi realizada com o algoritmo TLBO (*Teaching-learning-based optimization*) [18]. Os *sags* são provenientes de uma rede com DG.

Este artigo está dividido da seguinte forma: na seção II são apresentados os conceitos básicos das técnicas de extração e seleção de características; na seção III é mostrado como foram gerados os *sags* e como foi desenvolvido o método; na seção IV são apresentados os resultados alcançados e, finalmente na seção V são apontadas as conclusões.

II. EXTRAÇÃO E SELEÇÃO DE CARACTERÍSTICAS

As Estatísticas de Ordem Superior (EOS) são definidas em termos de momentos e cumulantes, sendo momentos mais indicados para sinais determinísticos e cumulantes para sinais aleatórios [17]. O uso de cumulantes para extrair características de sinais elétricos é motivado pela sua imunidade a ruídos gaussianos e boa capacidade de extrair informações do sinal elétrico. Além disso, nos trabalhos de [19], [20] e [21] as EOS foram aplicadas com sucesso em QEE. É importante deixar claro que os cumulantes são utilizados como entrada para o classificador.

Neste trabalho são utilizados os cumulantes de segunda, terceira e quarta ordens de cada fase $v_j[n]$, $j = A, B$ e C , do sinal de tensão trifásico. Quando $E\{v_j[n]\} = 0$, os três cumulantes são calculados respectivamente por [17]:

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

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

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

em que i é o i -ésimo atraso, e $v_j[n]$ é o n -ésimo elemento do vetor v_j .

Os sinais de tensão analisados possuem um ciclo (128 amostras). Como foi calculado um cumulante por amostra, é necessário reduzir o espaço de parâmetros para projetar classificadores mais eficientes e simples. Pode-se realizar tal tarefa selecionando os cumulantes (dentre todos os cumulantes calculados) que, ao serem processados pelo classificador, gerem o menor erro de classificação possível. Para isso, foi utilizado o algoritmo TLBO [18], que é um algoritmo de otimização inspirado na natureza. Ele utiliza uma população para procurar pela solução global. A população consiste em um grupo de alunos e um professor, sendo o método uma analogia ao sistema de aprendizado dentro de uma sala de aula. Sua execução é dividida em duas fases: a fase do professor, em que o professor passa seus conhecimentos para os alunos, e a fase dos alunos, em que eles aumentam seus conhecimentos através das suas próprias interações. O professor, no caso, representa a melhor solução encontrada naquela iteração, sendo que a evolução da solução leva à troca do professor pelo indivíduo de melhor avaliação [18]. A função de avaliação utilizada é o erro de classificação obtido com o classificador, permitindo que a escolha dos melhores cumulantes seja baseada nos melhores resultados de classificação alcançados com os dados de treino.

As vantagens de se usar o TLBO em relação a outros algoritmos de otimização, tais como Algoritmo Genético e PSO (*Particle Swarm Optimization*) são a menor quantidade de avaliações da função custo para convergir e os poucos parâmetros necessários de inicialização (somente o número de iterações e o tamanho da população) [18].

III. GERAÇÃO DE SINAIS SIMULADOS E METODOLOGIA

Para treinar e testar o método, foram utilizados sinais simulados no *software* MatLab. Os afundamentos de tensão foram gerados no Simulink utilizando-se uma rede de distribuição radial do IEEE com 15 barramentos e com uma fonte de geração distribuída (DG) com capacidade de 300kW, tal como mostra a Fig. 2.




Fig. 2. Diagrama unifilar da rede de 15 barramentos com DG

Foram gerados 500 sinais para cada tipo de *sag* (causado por faltas, partida de motores de indução e saturação de transformadores). Os locais de ocorrência de cada um desses três eventos foram variados aleatoriamente dentro da rede, tendo como consequência uma variação na amplitude do *sag*, mas não alterando sua forma geral ou “assinatura”. Também

foram gerados 500 sinais de tensão normais (sem distúrbios). Dos 2.000 sinais, 70% (1400) foram usados para treinamento e 30% (600) para teste. Os sinais foram gerados com uma frequência de amostragem de 7.680 Hz (128 pontos por ciclo). Quanto ao modelo de carga utilizado, as simulações foram feitas com o modelo de impedância constante, que tem mais sentido para a análise das tensões e correntes no estado transitório, tal como é feito neste trabalho.

Os *sags* causados por faltas foram gerados de acordo com a Tabela I. Dos 500 sinais com *sags* causados por faltas, 20% são de *sags* com múltiplos estágios. As resistências de curto-circuito das faltas foram variadas aleatoriamente, assim como o instante inicial, a duração do evento e o nível de carga da rede.

TABELA I. TIPOS DE FALTAS PARA GERAR SAGS E AS RESPECTIVAS PORCENTAGENS DE EVENTOS PARA CADA TIPO DE FALTA

Tipo de falta	Porcentagem de eventos gerados
Monofásica	74%
Bifásicas não incluindo o terra	4%
Bifásicas incluindo o terra	4%
Trifásicas	8%
Direto no gerador	10%

Para gerar os *sags* causados por partida de motor de indução e saturação de transformadores, também foram variados aleatoriamente os parâmetros de tempo inicial, duração, nível de carga e potência dos motores e transformadores.

O processo de desenvolvimento do método pode ser analisado na Fig. 3.




Fig. 3. Diagrama de blocos do desenvolvimento do método

Pressupõe-se que a etapa de segmentação dos sinais trifásicos de tensão seja realizada com outros métodos de segmentação existentes na literatura, tal como o apresentado em [22]. Na fase de operação do método, realiza-se apenas a

segmentação, cálculo de N cumulantes selecionados na fase de projeto e aplicação dos N cumulantes no classificador já projetado. O TLBO foi utilizado apenas na fase de projeto (treinamento).

A. Extração de características

Os sinais de tensão trifásicos analisados possuem um ciclo (128 amostras) da componente fundamental (60 Hz). Foi calculado um cumulante de 2ª, 3ª e 4ª ordens para cada amostra de cada fase do sinal e feita a média entre as três fases. Como os cumulantes de 2ª ordem são simétricos, então foi utilizada somente a primeira metade deles (64 cumulantes), totalizando 320 cumulantes para cada sinal de tensão trifásico.

B. Seleção das características

Para selecionar os cumulantes que geram melhor classificação dos *sags*, foi utilizada uma população de 40 indivíduos e 50 iterações no algoritmo TLBO. Foram otimizados os cumulantes selecionados para cada quantidade N de características, variando entre 2 e 15 características. Por exemplo, para $N = 3$, são selecionados os 3 melhores cumulantes (entre os 320) para classificar os *sags*.

Para realizar a seleção, foram utilizados os dados de treinamento normalizados entre -1 e 1. A função custo foi representada pelo erro médio quadrático da validação cruzada em dados de treinamento utilizando 5 *folds*, o que permite medir a capacidade de generalização do classificador. Portanto, o TLBO busca pelos cumulantes que minimizam o erro médio quadrático de classificação em dados de treinamento.

O processo de extração e seleção de características pode ser resumido na Fig. 4.




Fig. 4. Diagrama de blocos do processo de extração e seleção de características

C. Projeto dos classificadores

Foram utilizados dois classificadores diferentes: árvore de decisão e SVM. Para projetar a árvore de decisão com os

conjuntos de cumulantes escolhidos pelo TLBO, foi utilizado o algoritmo CART (*Classification and Regression Trees*) [15] para selecionar os melhores preditores de cada nó.

Para projetar os classificadores baseados em SVM foi utilizado o *kernel* polinomial de quarta ordem. O classificador utiliza a abordagem um-contra-um para classificar os *sags*.

IV. RESULTADOS

A. Classificação com Árvore de decisão

1) *Projeto do classificador com dados de treinamento*: Antes de projetar o classificador, é preciso determinar o número N de cumulantes utilizados como entrada para o classificador. Tal tarefa é feita na fase de seleção de características. O menor valor de erro de classificação para cada quantidade N de cumulantes é mostrado na Fig. 5. Observa-se que com 12 cumulantes obtém-se o menor erro de classificação (5,64%) para o classificador árvore de decisão. A linha em vermelho na Fig. 5 representa o diagrama de Pareto com o menor erro de classificação para a menor quantidade de cumulantes.

Uma outra opção para selecionar as características (cumulantes), é o uso do discriminante linear de Fisher, tal como foi feito nos trabalhos de [20] e [21]. No entanto, essa ferramenta explora a estatística dos dados (média e variância), ao contrário do TLBO, que otimiza diretamente o erro do classificador e leva a um melhor desempenho. Tal fato pode ser comprovado pela Fig. 6, em que se utiliza o discriminante de Fisher para selecionar as características (em analogia à Fig. 5), mas o erro mínimo (22,71%) é maior do que quando se utiliza o TLBO (5,64%).




Fig. 5. Valores otimizados dos erros médios quadráticos obtidos por **árvore de decisão** na validação cruzada em dados de treinamento para cada quantidade de cumulantes e diagrama de Pareto para esses erros.

2) *Validação do classificador com dados de teste*: Para avaliar o desempenho do classificador, foram utilizados os cumulantes selecionados durante a fase de seleção de características e a árvore de decisão já treinada com esses cumulantes para classificar os 30% de dados de teste (600 sinais de tensão trifásicos). A porcentagem de erro para cada quantidade de cumulantes é mostrada na Fig. 7.

O número de cumulantes ideal tanto na fase de treino como na de teste foi de 12 cumulantes, alcançando erros de 5,64% e 6,67%, respectivamente. Em dados de teste, o mesmo

desempenho foi encontrado quando apenas 4 cumulantes foram utilizados, tal como mostra a Fig. 7.




Fig. 6. Erros médios quadráticos obtidos na validação cruzada em dados de treinamento para cada quantidade de cumulantes, utilizando discriminante linear de Fisher para selecionar as características e **árvore de decisão** para classificar.




Fig. 7. Erro de classificação com **árvore de decisão** para os dados de teste.

Como existem 4 classes, é importante analisar o erro de classificação para cada classe individualmente. Tais erros são representados na matriz de confusão da Tabela II, que corresponde ao caso de 12 cumulantes. As classes são representadas por:

- C1: *Sag* causado por faltas
- C2: *Sag* causado por partida de motor de indução
- C3: *Sag* causado por saturação de transformadores
- C4: Sinal de tensão normal (sem distúrbios).

TABELA II. MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO COM DADOS DE TESTE (ÁRVORE DE DECISÃO COM 12 CUMULANTES)

Dados em porcentagem		Classe estimada				Falsos negativos
		C1	C2	C3	C4	
Classe real	C1	92,03	2,17	5,8	0	7,97
	C2	3,6	94,61	1,8	0	5,39
	C3	13,33	0	86,67	0	13,30
	C4	0	0	0	100	0
	Falsos positivos	17,0	1,9	7,8	0	93,33

Pela matriz de confusão da Tabela II é possível notar que o classificador erra mais a classe C3 e acerta mais a C4. De fato, o classificador obteve 100% de desempenho para a classe C4, não havendo nem falsos negativos e nem falsos positivos. A maior taxa de falsos negativos foi para C3 e de falsos positivos para C1.

B. Classificação com SVM

1) *Projeto do classificador com dados de treinamento:* A Fig. 8 mostra o menor erro de classificação em dados de treinamento para cada valor N de cumulantes utilizando o classificador SVM. A linha em vermelho representa o diagrama de Pareto para esses dados. Observa-se que com 15 cumulantes tem-se o menor erro de 2,21%.

A Fig. 9 mostra essa mesma tarefa realizada com discriminante de Fisher, com erro mínimo de 19,43%. Novamente verifica-se o melhor desempenho do TLBO para selecionar as características que levam ao menor erro de treinamento. Portanto, para projetar o classificador baseado em SVM também se utilizou os cumulantes selecionados pelo TLBO.




Fig. 8. Valores otimizados dos erros médios quadráticos obtidos por SVM na validação cruzada em dados de treinamento para cada quantidade de cumulantes e diagrama de Pareto para esses erros.




Fig. 9. Erros médios quadráticos obtidos na validação cruzada em dados de treinamento para cada quantidade de cumulantes utilizando discriminante linear de Fisher para selecionar as características e SVM para classificar.

2) *Validação do classificador com dados de teste:* Utilizando também os cumulantes selecionados na fase de seleção com TLBO e os classificadores SVM já treinados, foi feita a classificação dos dados de teste. A porcentagem de erro para

cada quantidade de cumulantes é mostrada na Fig. 10. O menor erro (1,67%) foi alcançado com 15 cumulantes.




Fig. 10. Erro de classificação com SVM para dados de teste

A Tabela III mostra a matriz de confusão alcançada com SVM para 12 cumulantes. Pela Tabela III, observa-se que apesar do erro de classificação da classe C1 ter ficado ligeiramente maior, no geral a porcentagem de acertos subiu para 97,17%, melhorando bastante os acertos das classes C2 e C3 em comparação com a abordagem com árvore de decisão.

TABELA III. MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO COM DADOS DE TESTE (SVM COM 12 CUMULANTES)

Dados em porcentagem		Classe estimada				Falsos negativos
		C1	C2	C3	C4	
Classe real	C1	91,3	4,34	4,34	0	8,69
	C2	0	100	0	0	0
	C3	2,0	1,33	96,67	0	3,33
	C4	0	0	0	100	0
	Falsos positivos	2,0	5,67	4,34	0	97,17

Com 15 cumulantes alcança-se os melhores resultados. No entanto, quanto maior for o número de entradas para o SVM, maior o custo computacional. A Tabela IV mostra a matriz de confusão para o caso de 15 cumulantes. Nota-se que a maior diferença foi na porcentagem de acertos para a classe C1.

TABELA IV. MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO COM DADOS DE TESTE (SVM COM 15 CUMULANTES)

Dados em porcentagem		Classe estimada				Falsos negativos
		C1	C2	C3	C4	
Classe real	C1	94,93	2,17	2,9	0	5,07
	C2	0	100	0	0	0
	C3	1,33	0,7	98	0	2,03
	C4	0	0	0	100	0
	Falsos positivos	1,33	2,87	2,9	0	98,33

A complexidade de cada classificador pode ser analisada pelo tempo de processamento gasto no treino do classificador e no teste com dados desconhecidos. Tal análise é feita na

Tabela V. O tempo de treinamento foi computado com os 70% dos dados (1400 eventos). O tempo médio de teste foi computado com 30% de dados de teste (600 eventos), sendo feita sua média para obter o tempo de classificação por evento.

TABELA V. COMPARAÇÃO DE TEMPOS DE PROCESSAMENTO ENTRE ÁRVORE DE DECISÃO E SVM

	Tempo de treino	Tempo médio de teste por evento
Árvore de decisão com 12 cumulantes	1,215 s	0,0011 s
SVM com 12 cumulantes	4,261 s	0,0011 s
SVM com 15 cumulantes	6,573 s	0,0012 s

Apesar do tempo de treinamento do SVM ser maior do que da árvore de decisão, o tempo de teste dos dois classificadores são muito semelhantes. Portanto, na prática, o tempo de execução dos dois algoritmos são também semelhantes, e se os recursos de memória e processamento permitirem, pode-se escolher aquele de maior acurácia, que no caso é o SVM com 15 cumulantes de entrada.

O sistema de classificação de *sags* que foi projetado pode ser implementado para o monitoramento *on-line*, uma vez que é utilizado somente um ciclo do sinal de tensão (128 amostras no caso deste trabalho) e o método apresentou rápida resposta na fase de operação. O método também pode ser utilizado como ferramenta auxiliar de sistemas de proteção da rede, que não devem indicar falta em casos de *sag* por partida de motor ou saturação de transformador.

V. CONCLUSÃO

Neste trabalho foi desenvolvido um novo método de classificação de afundamentos de tensão em uma rede com geração distribuída.

Através das EOS e do algoritmo TLBO, foi possível extrair e selecionar as características do sinal trifásico de tensão de forma eficiente e garantindo bom desempenho dos classificadores. Foram treinados dois classificadores diferentes: um baseado em árvore de decisão e outro baseado em SVM, sendo que o classificador SVM obteve melhor desempenho. Como o tempo de processamento dos dois classificadores são semelhantes na fase de operação do método, então o SVM acaba se tornando uma boa escolha. Cumpre ressaltar que o uso do algoritmo TLBO é realizado apenas na fase de projeto, por isso a fase operacional dos métodos propostos apresenta reduzida complexidade computacional.

O uso de apenas um ciclo da componente fundamental e a rápida resposta do método na fase de operação sugerem sua aplicação em monitoramento *on-line*. Além disso o método pode ser usado para avaliar o desempenho dos sistemas de proteção.

VI. REFERÊNCIAS

[1] W. G. Morsi and M. E. El-Hawary. "A New Perspective for the IEEE Standard 1459-2000 via Stationary Wavelet Transform in the Presence

of Nonstationary Power Quality Disturbance". *IEEE Transactions on Power Delivery*, vol. 2, no. 4, pp. 2356 – 2365, 2008.

[2] R. Godoy; J. Pinto and L. Galotto. "Multiple signal processing techniques based power quality disturbance detection, classification, and diagnostic software". *IEEE 9th International Conference on Electrical Power Quality and Utilization, Barcelona*, pp. 1–6, 2007.

[3] P. F. Ribeiro et al. "Power systems signal processing for smart grids". John Wiley & Sons, 2013.

[4] Institute of Electrical and Electronics Engineers. *IEEE Std 1159-2009. IEEE Recommended Practice for Monitoring Electric Power Quality*, 2009.

[5] H. Ismail, Z. Zakaria and N. Hamzah. "Classification of Voltage Sag Using Multi-resolution Analysis and Support Vector Machine". *Journal of Clean Energy Technologies*, vol. 4, no. 3, 2016.

[6] H. Sedighnejad and A. Jalilian. "Effect of protection device coordination on voltage sag characteristics of distribution networks". *ISA Transactions*, vol. 49, no. 4, pp. 407-414, 2010.

[7] E. Styvaktakis and M. H. J. Bollen. "Signatures of voltage dips: transformer saturation and multistage dips". *IEEE Transactions on Power Delivery*, vol. 18, no. 1, pp. 265-270, 2003.

[8] A. Foroughi, E. Mohammadi and S. Esmaili. "Application of Hilbert–Huang transform and support vector machine for detection and classification of voltage sag sources". *Turkish Journal of Electrical Engineering & Computer Sciences*, vol. 22, no. 5, pp. 1116-1129, 2014.

[9] M. Manjula, S. Mishra and A. V. R. S. Sarma. "Empirical mode decomposition with Hilbert transform for classification of voltage sag causes using probabilistic neural network". *International Journal of Electrical Power & Energy Systems*, vol. 44, no. 1, pp. 597-603, 2013.

[10] E. Styvaktakis, M. H. J. Bollen and I. Y. H. Gu. "Expert system for classification and analysis of power system events". *IEEE Transactions on Power Delivery*, vol. 17, no. 2, pp. 423-428, 2002.

[11] M. Kezunovic and Y. Liao. "A new method for classification and characterization of voltage sags". *Electric Power Systems Research*, vol. 58, no. 1, pp. 27-35, 2001.

[12] S. R. Mohanty et al. "Comparative study of advanced signal processing techniques for islanding detection in a hybrid distributed generation system." *IEEE Transactions on Sustainable Energy*, vol. 6, no. 1, pp. 112-131, 2015.

[13] M. H. J. Bollen and F. Hassan. "Integration of Distributed Generation in the Power System". John Wiley & Sons, 2011.

[14] P. P. Barker and R. W. De Mello. "Determining the impact of distributed generation on power systems I - Radial distribution systems". In *Power Engineering Society Summer Meeting, IEEE*, vol. 3, pp. 1645-1656, 2000.

[15] L. Breiman et al. "Classification and regression trees". CRC Press, 1984.

[16] N. Christianini and J. C. Shawe-Taylor. "An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods". Cambridge, UK: Cambridge University Press, 2000.

[17] 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, no. 3, pp. 278-305, 1991.

[18] R. V. Rao, V. J. Savsani and D. P. Vakharia. "Teaching–learning-based optimization: a novel method for constrained mechanical design optimization problems". *Computer-Aided Design*, vol. 43, no. 3, p. 303-315, 2011.

[19] B. H. G. Barbosa e D. D. Ferreira. "Classification of Multiple and Single Power Quality Disturbances Using a Decision Tree-Based Approach". *Journal of Control, Automation and Electrical Systems*, vol. 24, no. 5, pp. 638-648, 2013.

[20] D. D. Ferreira et al. "HOS-based method for classification of power quality disturbances". *Electronics letters*, vol. 45, no. 3, pp. 1, 2009.

[21] D. D. Ferreira, J. M. Seixas e A. S. Cerqueira. "A method based on independent component analysis for single and multiple power quality disturbance classification". *Electric Power Systems Research*, vol. 119, pp. 425-431, 2015.

[22] E. A. Nagata; D. D. Ferreira; C. A. Duque. "ICA-based method for power quality disturbance detection". *17th International Conference on Harmonics and Quality of Power (ICHQP)*, IEEE, pp. 412-417, 2016.