

Método de Classificação de Falhas em Linhas de Transmissão baseado em Estatísticas de Ordem Superior

Pedro H.G. Bouzon

Departamento de Automática
Universidade Federal de Lavras

Lavras, Minas Gerais, Brasil, 37200-000
Email: peubouzon@gmail.com

Danton Diego Ferreira

Departamento de Automática
Universidade Federal de Lavras

Lavras, Minas Gerais, Brasil, 37200-000
Email: danton@ufla.br

José Manuel de Seixas

Departamento de Engenharia
Universidade Federal do Rio de Janeiro

Rio de Janeiro, Rio de Janeiro,
Brasil, 21941-901
Email: seixas@lps.ufrj.br

Flávio Bezerra Costa

Escola de Ciência e Tecnologia

Universidade Federal do Rio Grande do Norte
Natal, Rio Grande do Norte, Brasil, 59064-741

Email: flaviocosta@ect.ufrn.br

Mônica Maria Leal

Escola de Ciência e Tecnologia

Universidade Federal do Rio Grande do Norte
Natal, Rio Grande do Norte, Brasil, 59064-741

Email: monicamleal@gmail.com

Resumo—It is known that the study of power transmission lines has been the subject of several researches aiming to provide relevant information to users of electrical systems. This study provides an approach for fault classification using higher order statistics and a neural network based classifier. A detector based on euclidean distance was implemented to reduce the complexity of the classifier. This implementation enables real-time execution because only $\frac{1}{32}$ cycles of post-fault data are used in feature extraction. It was able to classify 10 classes of faults with global efficiency upper to 97%.

Keywords—Estatística de Ordem Superior; Classificação de Falhas; Linhas de Transmissão

I. INTRODUÇÃO

As linhas de transmissão de energia são elementos expostos a eventos de causa natural e humana que podem levar ao seu mal funcionamento. Uma falta é definida como qualquer falha que interfira com o fluxo normal de corrente [1]. Falhas acontecem principalmente quando descargas elétricas danificam os isoladores de uma linha. Neste contexto, é importante detectar e classificar o tipo de falta, para que relés ultrarrápidos possam ser acionados e as cargas ligadas ao sistema não sejam afetadas.

Várias metodologias de detecção e classificação de faltas são encontradas na literatura. Em geral, elas diferem na técnica de extração de características e classificador adotado. Métodos baseados no domínio da frequência são os mais difundidos. Em [2] a Transformada Wavelet (WT) foi utilizada juntamente com uma Rede Neural Artificial (RNA). A Transformada de Fourier Discreta de Meio Ciclo (TFDMC) é adotada nos trabalhos de [3] e [4] em conjunto com uma árvore de decisão para classificar as faltas. O conceito da Transformada Stockwell (TS) foi utilizado em [5], [6] e [7]. Ainda são

encontrados métodos ligados ao domínio do tempo, como em [8], onde a Análise de Componentes Principais (PCA) foi aplicada diretamente aos sinais de corrente e tensão e em [9], onde foi proposto um método de extração de características baseado em Projeções Aleatórias.

Neste estudo, sinais de tensão são continuamente monitorados por um detector baseado na distância euclidiana [10]. Caso uma falta seja detectada, a Estatística de Ordem Superior (EOS) é utilizada para extrair características dos sinais de corrente e tensão, na forma de cumulantes. A classificação da falta é feita por meio de uma Rede Neural Multicamadas. As novidades do método são o uso dos cumulantes na forma proposta por [11] para classificação de faltas em linhas de transmissão. A vantagem desta abordagem está no fato da EOS ser imune a ruídos gaussianos e possuírem uma boa capacidade de representação de processos não lineares.

A Estatística de Ordem Superior é explicada na próxima seção. A seção III descreve o método proposto. Na seção IV detalha-se a base de dados utilizada. Na seção V os resultados são apresentados e discutidos. Finalmente, são apresentadas as conclusões na seção VI.

II. ESTATÍSTICA DE ORDEM SUPERIOR

As Estatísticas de Ordem Superior podem ser descritas por meio de cumulantes ou momentos. O primeiro caso se aplica a sinais aleatórios, enquanto o segundo a sinais determinísticos. Esta técnica é melhor explorada quando utilizada em processos de distribuição não gaussiana e sistemas não lineares [11], [12].

As expressões que descrevem os cumulantes de segunda, terceira e quarta ordens de um sinal aleatório $x[n]$ com

$E\{x[n]\} = 0$ são representadas pelas Equações (1), (2) e (3) [13].

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

$$c_{3,x}[i] = E\{x[n]x^2[n+1]\} \quad (2)$$

$$c_{4,x}[i] = E\{x[n]x^3[n+1]\} - 3c_{2,x}[i]c_{2,x}[0] \quad (3)$$

Para um vetor finito de tamanho N , aproximações estocásticas [14] resultam nas expressões

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

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

e

$$\begin{aligned} \hat{c}_{4,x}[i] = & \frac{2}{N} \sum_{n=0}^{N/2-1} x[n]x^3[n+i] - \\ & \frac{2}{N^2} \sum_{n=0}^{N/2-1} x[n]x[n+i] \sum_{n=0}^{N/2-1} x^2[n], \end{aligned} \quad (6)$$

onde $i = 0, 1, \dots, \frac{N}{2} - 1$. Infelizmente, as Equações (4), (5) e (6) não podem ser usadas para $i > \frac{N}{2} - 1$ porque o índice $n+i$ ultrapassa o tamanho do vetor. Devido a esta limitação, aproximações alternativas foram introduzidas por [12]. Nesta nova abordagem, os cumulantes são estimados pelas seguintes equações

$$\hat{c}_{2,x}[i] = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x[\text{mod}(n+i, N)], \quad (7)$$

$$\hat{c}_{3,x}[i] = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^2[\text{mod}(n+i, N)] \quad (8)$$

e

$$\begin{aligned} \hat{c}_{4,x}[i] = & \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^3[\text{mod}(n+i, N)] - \\ & \frac{3}{N^2} \sum_{n=0}^{N-1} x[n]x[\text{mod}(n+i, N)] \sum_{n=0}^{N-1} x^2[n], \end{aligned} \quad (9)$$

onde $\text{mod}(n+1, N)$ é o resto inteiro da divisão de $n+i$ por N . O uso do operador mod implica na assunção de que o vetor $x[n]$ é periódico.

III. MÉTODO PROPOSTO

O método proposto é organizado como se segue. Sinais de tensão são monitorados em tempo real por um detector baseado na distância euclidiana [10]. Se uma condição anormal for encontrada, os sinais de tensão e corrente são segmentados e características são extraídas destes na forma de cumulantes, com base nas Equações (7), (8) e (9). Finalmente, um Rede Neural Multicamadas realiza a classificação em uma das seguintes faltas: AT, BT, CT, AB, AC, BC, ABT, ACT, BCT e ABT.

A. Detecção

O detector utilizado neste trabalho foi proposto por [10] onde o monitoramento se dá por meio de janelas deslizantes (amostra a amostra) com tamanho igual a um ciclo do sinal fundamental. Neste método, considera-se o sinal de tensão como um ponto d -dimensional, onde d é o tamanho da janela monitorada. Calcula-se então a distância euclidiana deste ponto ao centro do espaço, definido como $\mathbf{c} = [0 \ 0 \ 0 \ \dots \ 0_d]$. A Equação (10) descreve a operação de extração de características, onde \mathbf{v} representa a janela monitorada e \mathbf{c} o centro do espaço. A partir desta análise, é possível obter uma região hipersférica no espaço d -dimensional que modela sinais sem distúrbios [10].

$$r = \|\mathbf{v} - \mathbf{c}\|^2 \quad (10)$$

Com objetivo de definir a região onde não há presença de falta, sinais nominais contendo fases de -180° a 180° e SNR (*signal-to-noise ratio*) de 60dB, são utilizados para determinar os valores de r para esta situação. A partir destes valores, os limites inferior e superior são adotados como

$$r_{max} = \bar{r} + 3 * \sigma \quad (11)$$

e

$$r_{min} = \bar{r} - 3 * \sigma \quad (12)$$

onde \bar{r} é o valor médio e σ o desvio padrão de r .

Os limites encontrados durante a fase de projeto definem uma região que modela os sinais nominais e a qualquer evento fora desta é associado uma perturbação.

Caso o valor de r para um sinal seja maior que r_{max} ou menor que r_{min} , janelas com sessenta e quatro pontos pré-falta (um quarto de ciclo) e oito pontos pós-falta (um trinta e dois avos de ciclo) dos sinais de corrente e tensão são enviadas para a etapa de extração de características.

B. Extração de Características

O uso da Estatística de Ordem Superior para obter informações relevantes sobre sinais elétricos em sistemas de potência tem se mostrado uma boa alternativa para extração de características [15], [16]. Para um vetor de características finito, tais estatísticas podem ser aproximadas pelas Equações (7), (8) e (9).

Como o conjunto de características gerado por esta abordagem é muito grande, o Discriminante Linear de Fisher (DLF) foi utilizado para selecionar os cumulantes que melhor discriminam entre as classes. O DLF vem sendo aplicado

em problemas de classificação para selecionar e reduzir os dados de entrada [17], [18], [19]. A Equação (13) apresenta a função de custo do Discriminante Linear de Fisher para um problema com N classes [20], onde μ_i, σ_i, μ_j e σ_j são a média e variância das classes i e j respectivamente.

$$\mathbf{J} = \sum_i^N \sum_{j \neq i}^N \frac{(\mu_i - \mu_j)^2}{(\sigma_i^2 + \sigma_j^2)} \quad (13)$$

Uma vez que o Discriminante Linear de Fisher não remove redundância, outra técnica deve ser utilizada para este fim. Neste trabalho, um filtro baseado no Coeficiente de Pearson foi implementado para limitar a correlação entre as características selecionadas. A Equação (14) apresenta o coeficiente de Pearson calculado para as características c_i e c_j com matrizes de autocorrelação e correlação cruzada iguais a σ_{ii}, σ_{jj} e σ_{ij} . Quanto mais próximo da unidade for o valor absoluto de R_{ij} , maior é a correlação as características.

$$\mathbf{R}_{ij} = \frac{\sigma_{ij}}{\sigma_{ii} * \sigma_{jj}} \quad (14)$$

C. Classificação

Nesta etapa, os cumulantes selecionados servem de base para o treinamento de uma Rede Neural Multicamadas. A arquitetura do classificador é apresentada na Tabela I. Foi adotada uma arquitetura simples para melhorar a capacidade de generalização do classificador [21]. O classificador conta com duas camadas. A camada escondida possui oito neurônios com função de ativação Tangente Hiperbólica Sigmoidal, descrita pela Equação (15). A camada de saída possui dez neurônios, representando as possíveis faltas, com função de ativação Softmax, descrita pela Equação (16).

Tabela I
ARQUITETURA DO CLASSIFICADOR.

Camada	Neurônios	Função de Ativação
Camada escondida	8	Tangente Hiperbólica
Camada de saída	10	Softmax

$$g_1(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (15)$$

$$g_2(x_i) = \frac{e^{-x_i}}{\sum_{j=1}^{10} e^{-x_j}} \quad (16)$$

Para treinamento da rede, aplicou-se o otimizador Adam, proposto por [22]. Os hiper parâmetros deste algoritmo foram mantidos nos valores sugeridos pelos autores do método. A taxa de aprendizado utilizada foi de 0.01.

IV. BASE DE DADOS

O sistema de transmissão utilizado para simular os dados conta com 2 linhas de 300km cada, tensão de 500 kV e SNR (signal-noise-ratio) de 60dB. A frequência fundamental adotada foi de 60Hz e frequência de amostragem de 15360Hz, resultando em 256 pontos por ciclo. Foram simulados dez tipos

de falta: AT, BT, CT, AB, AC, BC, ABT, ACT, BCT e ABT. A simulação foi feita por meio do software Simulink.

Ao todo, 950 sinais contendo falta foram gerados. A Tabela II descreve as 5 bases utilizadas na simulação. Em cada base foram gerados 19 sinais de cada tipo de falta com ângulos de incidência de 0 à 180° em passos de 10°.

Tabela II
PARÂMETROS UTILIZADOS PARA SIMULAR AS FALTAS.

Resistência (Ohms)	Distância à Barra Local(Km)
1	20
1	150
1	280
50	150
100	150

V. RESULTADOS E DISCUSSÃO

A. Detecção

Nesta etapa, os limiares inferior e superior encontrados para definir a região que modela os sinais nominais foram $r_{max} = 2.642 * 10^{13}$ e $r_{min} = 2.637 * 10^{13}$.

A Figura 1 mostra um exemplo dos sinais de tensão e corrente segmentados pelo detector na ocorrência de uma falta. A linha preta tracejada indica o ponto em que foi detectado a falta. A partir deste ponto, um quarto de ciclo pré-falta e um trinta e dois avos de ciclo pós-falta formam a janela a ser enviada para a etapa de extração de características. Todos os 950 segmentos contendo falta foram detectados.

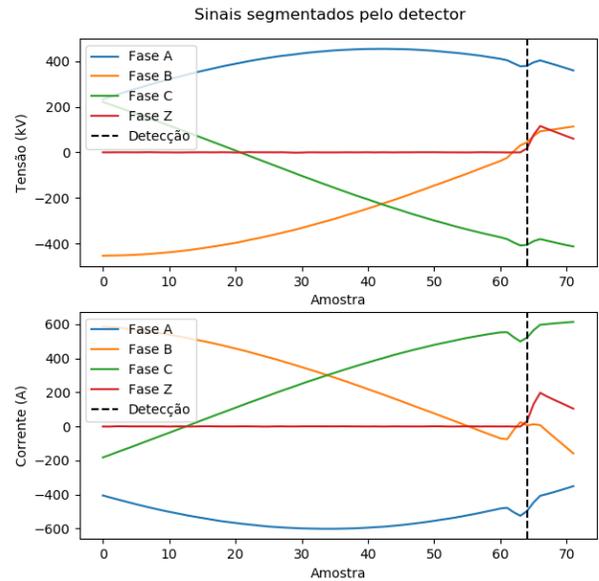


Figura 1. Sinais de tensão e corrente segmentados pelo detector.

O detector apresentou um atraso de detecção igual ao tempo necessário para que a deformação no sinal de tensão gere uma distância maior que os limiares estabelecidos. Ao ser aplicado no banco de dados, o atraso do instante de detecção em relação

ao valor real foi de 4.13 ± 0.95 amostras. Em termos de fração de ciclo, este valor representa um erro médio de sessenta e quatro avos com desvio padrão de um duzentos e cinquenta e seis avos de ciclo.

B. Extração de Características

Os cumulantes de segunda, terceira e quarta ordem foram extraídos das fases A, B, C e Z dos sinais de tensão e corrente. Para cada cumulante foi gerado um conjunto de N características, onde N é o tamanho da janela enviada pelo detector. Devido à simetria dos cumulantes de segunda ordem, a primeira metade destes foi descartada. Foi ainda extraído o valor médio quadrático e o valor máximo absoluto dos sinais. Desta forma, foram obtidas 1456 características.

Para reduzir o número de características e assim a complexidade computacional do método, o Discriminante Linear de Fisher foi aplicado ao conjunto total de características. A Figura 2 mostra o resultado deste método. Cada ponto nesta figura representa o valor de importância dada pelo critério de Fisher a uma característica.

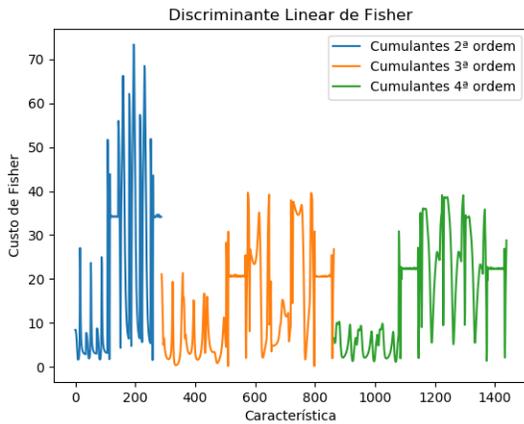


Figura 2. Função custo do Discriminante Linear de Fisher

A partir do DLF e do coeficiente de correlação de Pearson, foram selecionadas vinte e cinco características com correlação máxima de cinquenta por cento entre elas. A Figura 3 mostra a quantidade de características selecionadas de cada tipo.

Para verificar se os cumulantes trazem informação útil quanto à presença de falta, a distribuição amostral de um cumulante foi aproximada por uma gaussiana. A Figura 4 mostra o resultado. Este cumulante foi extraído da fase C do sinal de corrente. Nota-se que as distribuições das classes que contém a fase C estão situadas mais à esquerda, enquanto as demais à direita. Estas diferenças são interessantes no problema de classificação.

A Figura 5 mostra o espaço gerado pelas três melhores características selecionadas (C1, C2 e C3) para diferentes quantidades de dados pós falta. Com 1 ciclo pós falta, há uma separação linear entre as classes. Utilizando pelo menos $\frac{1}{8}$

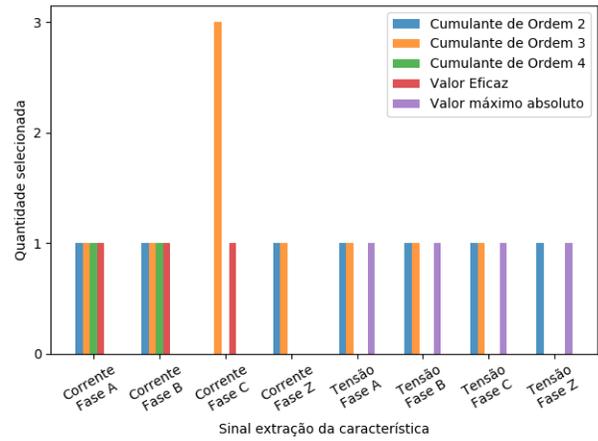


Figura 3. Sinal de origem, ordem e quantidade dos cumulantes selecionados.

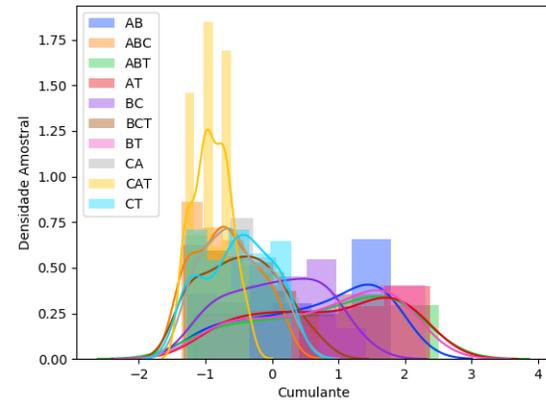


Figura 4. Densidade amostral de um cumulante extraído da fase C do sinal de corrente.

ciclo há uma boa separação. Nos demais casos, as sobreposições se tornam mais evidentes. Apesar disso, quando todas as 25 características foram utilizadas, o classificador apresentou bons resultados em todos os casos.

C. Classificação

Para validação do classificador foi utilizado a metodologia K-Fold com 10 divisões. A Figura 6 mostra a porcentagem de acerto para diferentes quantidades de pontos pós falta na janela segmentada pelo detector. Como não se sabia inicialmente quantos ciclos seriam necessários, este número foi diminuído gradativamente de 1 até $\frac{1}{32}$ ciclos. Foi obtido 100% (0,00%) de acerto para $\frac{1}{2}$ e $\frac{1}{8}$ ciclo pós falta, 99,78% (0,43%) para 1, $\frac{1}{4}$ e $\frac{1}{16}$ ciclo pós falta e 97,66% (1,15%) para $\frac{1}{32}$ ciclo pós falta.

A partir destes resultados, foi escolhido utilizar $\frac{1}{32}$ ciclos de dados após a detecção. Para este caso, a validação também foi feita por matriz de confusão. O conjunto de teste foi formado por 30% dos dados. O resultado é apresentado na Figura 7. Para as faltas monofásicas e as faltas CA e ABT o resultado

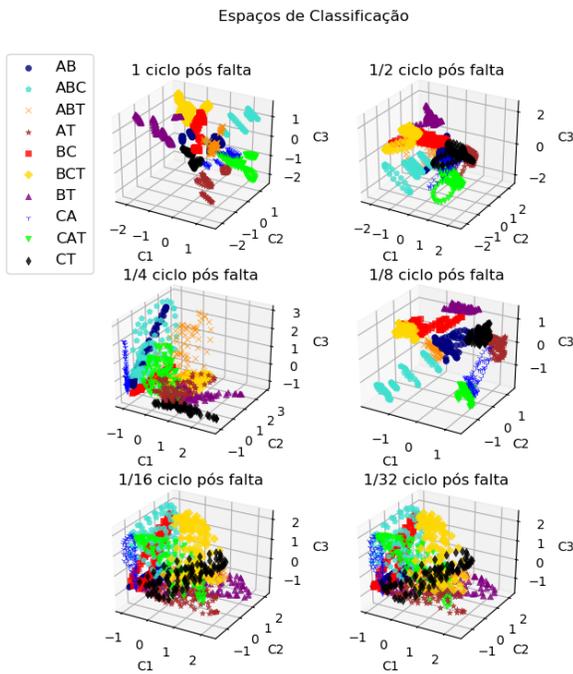


Figura 5. Espaços de classificação para diferentes quantidades de ciclos pós falta.

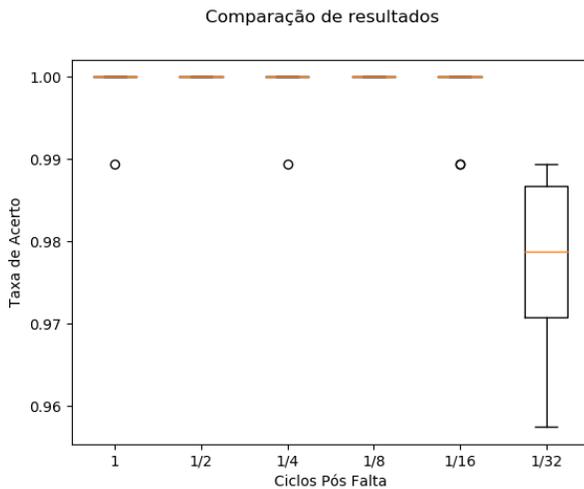


Figura 6. Variação da porcentagem de acerto com o número de ciclos pós falta utilizado.

da classificação foi de 100%. As demais faltas apresentaram porcentagens de acerto entre 96% e 97%.

VI. CONCLUSÃO

Este trabalho propôs um método de classificação baseado em Estatística de Ordem Superior que utiliza apenas $\frac{1}{32}$ ciclos pós falta. Neste sentido, foi possível classificar 10 tipos de falta, incluindo as monofásicas, bifásicas e trifásicas. Para reduzir a complexidade do classificador, um detector baseado na distancia euclidiana foi implementado.

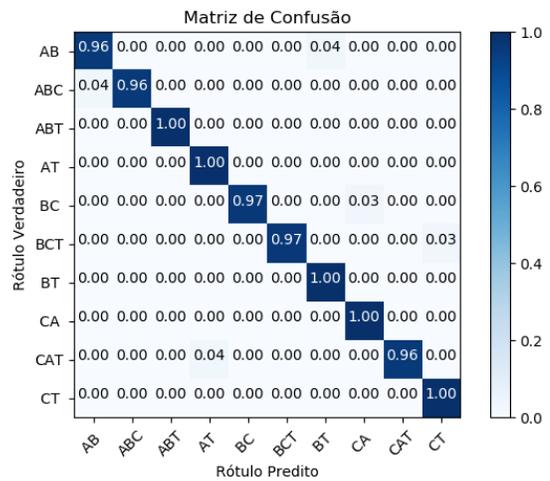


Figura 7. Matriz de confusão.

Deve ser mencionado que os cumulantes de ordem três e quatro, utilizados como entrada para o classificador, são imunes a ruídos gaussianos, o que confere robustez ao método.

Em trabalhos futuros, pretende-se analisar a complexidade computacional do método e implementar um classificador que dê mais prioridade para as faltas monofásicas.

AGRADECIMENTOS

Os autores gostariam de agradecer à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelo suporte.

REFERÊNCIAS

- [1] J. Grainger and W. Stevenson, *Power System Analysis*, ser. Electrical engineering series. McGraw-Hill, 1994.
- [2] K. Silva, B. A. Souza, and N. S. Brito, "Fault detection and classification in transmission lines based on wavelet transform and ann," *IEEE Transactions on Power Delivery*, vol. 21, no. 4, pp. 2058–2063, 2006.
- [3] A. Jamehbozorg and S. M. Shahrtash, "A decision-tree-based method for fault classification in single-circuit transmission lines," *IEEE Transactions on Power Delivery*, vol. 25, no. 4, pp. 2190–2196, 2010.
- [4] A. Jamehbozorg and S. Shahrtash, "A decision tree-based method for fault classification in double-circuit transmission lines," *IEEE Transactions on Power Delivery*, vol. 25, no. 4, pp. 2184–2189, 2010.
- [5] S. Samantaray, P. Dash, and G. Panda, "Fault classification and location using hs-transform and radial basis function neural network," *Electric Power Systems Research*, vol. 76, no. 9-10, pp. 897–905, 2006.
- [6] S. Samantaray and P. Dash, "Pattern recognition based digital relaying for advanced series compensated line," *International Journal of Electrical Power & Energy Systems*, vol. 30, no. 2, pp. 102–112, 2008.
- [7] S. Samantaray, "A systematic fuzzy rule based approach for fault classification in transmission lines," *Applied soft computing*, vol. 13, no. 2, pp. 928–938, 2013.
- [8] D. Thukaram, H. Khincha, and H. Vijaynarasimha, "Artificial neural network and support vector machine approach for locating faults in radial distribution systems," *IEEE Transactions on Power Delivery*, vol. 20, no. 2, pp. 710–721, 2005.
- [9] L. Cheng, L. Wang, and F. Gao, "Power system fault classification method based on sparse representation and random dimensionality reduction projection," in *2015 IEEE Power & Energy Society General Meeting*. IEEE, 2015, pp. 1–5.
- [10] E. G. Ribeiro, T. M. Mendes, G. L. Dias, E. R. Faria, F. M. Viana, B. H. Barbosa, and D. D. Ferreira, "Real-time system for automatic detection and classification of single and multiple power quality disturbances," *Measurement*, vol. 128, pp. 276–283, 2018.

- [11] D. D. Ferreira, C. A. Marques, J. M. de Seixas, A. S. Cerqueira, M. V. Ribeiro, and C. A. Duque, "Exploiting higher-order statistics information for power quality monitoring," *Power Quality: Intech Open Access Publisher*, pp. 345–362, 2011.
- [12] M. V. Ribeiro, C. A. G. Marques, C. A. Duque, A. S. Cerqueira, and J. L. R. Pereira, "Detection of disturbances in voltage signals for power quality analysis using hos," *EURASIP Journal on Applied Signal Processing*, vol. 2007, no. 1, pp. 177–177, 2007.
- [13] 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.
- [14] H. Kushner and G. G. Yin, *Stochastic approximation and recursive algorithms and applications*. Springer Science & Business Media, 2003, vol. 35.
- [15] J. J. G. de la Rosa and A. Moreno-Munoz, "Higher-order characterization of power quality transients and their classification using competitive layers," in *2009 Compatibility and Power Electronics*. IEEE, 2009, pp. 390–395.
- [16] C. L. Nikias and J. M. Mendel, "Signal processing with higher-order spectra," *IEEE Signal processing magazine*, vol. 10, no. 3, pp. 10–37, 1993.
- [17] T. S. Barbosa, D. D. Ferreira, D. A. Pereira, R. R. Magalhães, and B. H. Barbosa, "Fault detection and classification in cantilever beams through vibration signal analysis and higher-order statistics," *Journal of Control, Automation and Electrical Systems*, vol. 27, no. 5, pp. 535–541, 2016.
- [18] R. Naves, B. H. Barbosa, and D. D. Ferreira, "Classification of lung sounds using higher-order statistics: A divide-and-conquer approach," *Computer methods and programs in biomedicine*, vol. 129, pp. 12–20, 2016.
- [19] J. D. S. Guedes, D. D. Ferreira, B. H. G. Barbosa, C. A. Duque, and A. S. Cerqueira, "Non-intrusive appliance load identification based on higher-order statistics," *IEEE Latin America Transactions*, vol. 13, no. 10, pp. 3343–3349, 2015.
- [20] S. Theodoridis, A. Pikrakis, K. Koutroumbas, and D. Cavouras, *Introduction to pattern recognition: a matlab approach*. Academic Press, 2010.
- [21] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern classification*. John Wiley & Sons, 2012.
- [22] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.