

ALGORITMO PARA DETECTAR, CLASSIFICAR, LOCALIZAR FALTAS E DETERMINAR RESISTÊNCIAS DE FALTAS EM LINHAS DE TRANSMISSÃO, UTILIZANDO DADOS DE UM TERMINAL

HENRIQUE R. PAULA¹, EDUARDO G. SILVEIRA¹, GIOVANI G. RODRIGUES²

1. *Coordenação de Área de Eletrotécnica, Centro Federal de Educação Tecnológica de Minas Gerais*
Av. Amazonas 5253, Nova Suíça, Belo Horizonte, MG, Brasil CEP: 30.421-169
E-mails: henriquerp_2006@yahoo.com.br, eduardo@deii.cefetmg.br
2. *Departamento de Engenharia Elétrica, Centro Federal de Educação Tecnológica de Minas Gerais*
Av. Amazonas, 7675, Nova Gameleira, Belo Horizonte, MG, CEP: 30510-000
E-mails: giovani@des.cefetmg.br

Resumo— This article proposes an algorithm to detect, classify, locate faults and determine resistance faults in transmission lines. In order to execute such functions, the algorithm use data obtained from measurements carried out in a one line terminal. Initially, the data of a fault event is pre-processed. This is the stage in which the fault detection occurs, and it is based on the Stationary Wavelet Transform (SWT) and the Theorem of Parseval. Furthermore, from the signals pre-fault, the phasor estimate of the equivalent sources is executed and, finally, 504 fault scenarios are generated in Alternative Transient Program (ATP) software, which are required for the Artificial Neural Network (ANN) training. For the classification, fault Location and determination of the fault resistance, the algorithm use modular ANN, implemented through the Neural Network Toolbox of Matlab. For the ANN tests and training, the proposed algorithm presents a new methodology, which selects the energy data of the detail coefficient extracted from the current and voltage signals registered in a single terminal in the line, during the first 1/8 of the fault period cycle of the fault period cycle. From the tests, the method for classification obtained 100% accuracy, while, the relative errors for location and determination of fault resistance was less than 3% and 4% respectively.

Keywords— Wavelet Transform, Theorem of Parseval, method of least errors and Artificial Neural Network, transmission line

Resumo— Esse artigo propõe um algoritmo capaz de detectar, classificar, localizar faltas e determinar resistências de faltas em linhas de transmissão. Para realizar tais funções, o algoritmo utiliza dados obtidos a partir das medições realizadas em um único terminal da linha. Inicialmente os dados de um evento de falta são pré-processados. Nessa etapa ocorre detecção da falta, que é baseada na Transformada Wavelet Estacionária (TWE) e teorema de Parseval. Além disso, a partir dos sinais pré-falta, é realizada a estimação fasorial das fontes equivalentes e, por fim, são gerados 504 cenários de falta, no software Alternative Transient Program (ATP), para treinamento das Redes Neurais Artificiais (RNAs). Para classificação, localização de faltas e determinação da resistência de falta, o algoritmo utiliza RNAs modulares, implementadas através do Toolbox Neural Network do Matlab. Para treinamento e testes das RNAs, o algoritmo proposto apresenta nova metodologia, que seleciona os dados de energia dos coeficientes detalhados extraídos dos sinais de corrente e tensão, durante os primeiros 1/8 de ciclo do período de falta. Diante dos testes realizados, o método para classificação obteve 100% de acerto, enquanto que, os erros relativos para localização e determinação da resistência de falta foram inferiores a 3% e 4 % respectivamente.

Palavras-chave— Transformada Wavelet, Teorema de Parseval, Redes Neurais Artificiais Modulares, Linhas de Transmissão

1 Introdução

As linhas de transmissão compõem a maior parte dos Sistemas Elétricos de Potência e são responsáveis pelo transporte de grandes blocos de energia desde as unidades geradoras até o consumidor final. Devido as grandes extensões, elas são consideradas um dos componentes mais vulneráveis, estando sujeitas a eventos indesejáveis como, descargas atmosféricas, queimadas, quedas de árvores, ações de vandalismo, entre outros, que podem causar faltas e levar à interrupção do fornecimento de energia elétrica.

Como podem ter diversas origens, as faltas em linhas de transmissão são definidas como fenômenos aleatórios e com características próprias, como: instante que se iniciou, resistência de falta, tipo de falta (fase-terra, bifásico, bifásico-terra e trifásico) e local onde ocorreu. Dentre essas características, determinar, principalmente, o local onde ocorreu a falta é de fundamental importância, pois evita a inspeção completa da linha na procura do defeito, possibilitando um rápido restabelecimento do fornecimento de

energia.

Na literatura são amplamente encontradas metodologias que utilizam sinais de baixas frequências, para realizar a localização de falta. A extração dos fasores fundamentais é realizada via transformada de fourier ou método dos erros dos mínimos quadrados, a partir dos sinais de tensão e corrente registrados em um terminal da linha (Silva e Lima, 2007; Lout e Aggarwal, 2012; Paula e Silveira, 2015).

Nesse artigo, o objetivo é apresentar um algoritmo que além da localização da falta, seja capaz de detectá-la, classificá-la, e determinar a resistência associada à falta.

Para realizar tais funções, é proposta nova metodologia, que utiliza técnicas matemáticas para processamentos de sinais (interpolação, transformada wavelet e energia de Parseval). Essa metodologia possibilita a seleção de sinais de altas frequências, extraídos dos sinais de corrente de tensão, registrados em único terminal da linha durante o período de falta. Os dados selecionados são enviados para treinamento e testes das Redes Neurais Artificiais (RNAs) modulares. O algoritmo foi implementado no software Matlab e os diversos cenários de falta para treinamentos

e testes das RNAs foram gerados no software Alternative Transient Program (ATP).

Essa metodologia se demonstrou eficiente diante do problema proposto, que adota modelos simplificados de linhas de transmissão, onde não são contemplados variáveis que influenciam na localização da falta, como: resistências de falta variável durante o curto-circuito, erros percentuais de transformadores de corrente e de potencial e resistividade do solo.

2 Topologia do Sistema Elétrico

O algoritmo proposto é aplicável a sistemas elétricos modelados por uma linha de transmissão e fontes equivalentes no terminal emissor **S** e terminal receptor **R**, com medições de tensões e correntes trifásicas registrados em um único terminal, conforme apresentado na figura 1.




Figura 1. Topologia do sistema elétrico

É nesse cenário que o algoritmo desenvolvido é capaz de detectar faltas, classificá-las quanto ao tipo (fase-terra, trifásica, bifásica, bifásica-terra), localizá-las, informando em quilômetros onde a falta ocorreu e ainda determinar a resistência, em ohms, associada à falta.

3 Metodologia: Algoritmo Proposto

Para realizar tais funções, os sinais de tensão e corrente, registrados em um único terminal da linha, são submetidos a três etapas, denominadas, pré-processamento de dados, processamento de dados e RNAs para classificar, localizar falta e determinar resistências de falta.

3.1 Etapa 1: Pré-processamento de Dados

A Figura 2 apresenta a estrutura do algoritmo para pré-processamento de dados. Esse algoritmo é responsável, por detectar o instante de início da falta, estimar os módulos e ângulos das fontes equivalentes nos dois terminais e gerar o banco de dados necessários para treinamentos das RNAs (Paula e Silveira, 2015).

3.1.1 Detector de Falta

O detector de falta entra em operação quando são obtidos os sinais trifásicos de corrente e tensão (sinais de entrada) registrados no terminal emissor,




Figura 2. Estrutura do algoritmo para pré-processamento de dados

durante um evento de falta.

Inicialmente os sinais de entrada são submetidos ao processo de interpolação linear, que visa padronizar em 32 o número de pontos por ciclo (NPC) dos dados de entrada. Em seguida, os sinais são normalizados considerando o máximo valor de pico, registrado durante os dois primeiros ciclos em que o sistema elétrico está operando no período pré-falta. Esse processo estabelece que as amostras dos sinais de entrada estejam entre os valores de 1 à -1 durante o período pré-falta, padronizando assim as amostras utilizadas para treinamento e testes das RNAs. Depois, é aplicado aos sinais normalizados a Transformada Wavelet Estacionária (TWE), em seu primeiro nível de decomposição. Para construção do filtro passa-alta, foi utilizada Wavelet mãe Daubechies de quarta ordem (db4), pois apresentam bom desempenho para extração de coeficientes detalhes **cd1** na análise de sistemas elétricos (Silva, Sousa e Brito, 2006; Kalam, Jamil; Ansari, 2010). A implementação computacional é realizada com o recurso do Toolbox Wavelet no Matlab (Misiti, Misiti, et al., 2015).

A partir dos coeficientes detalhes **cd1** obtidos via TWE, calcula-se a energia do coeficiente detalhe **E**, baseando-se no teorema de Parseval de acordo com a equação 1 (Costa, 2014; Salim, Oliveira, et al., 2008; Silva, Sousa e Brito, 2006).

$$E = \sum_{n=1}^{NPC} cD1^2(n) \quad (1)$$

O cálculo é realizado movendo uma janela, de comprimento igual a NPC, através de **cd1**, com passo de deslocamento de uma amostra. A Figura 3 apresenta a evolução de um sinal original de corrente ao passar pelos processos descritos anteriormente.




Figura 3. Evolução do sinal de corrente ao passar pelos processos de interpolação, normalização, TWE e Energia de Parserval

Para detecção da falta são selecionados os dados de energia do coeficiente detalhe **E** referente aos sinais de correntes trifásicas, e então a ocorrência da falta é identificada em qualquer uma das três fases, de acordo com a equação 2 (Costa, 2014; Salim, Oliveira, et al., 2008; Silva, Sousa e Brito, 2006),

$$E(n+1) - E(n) > E_{\max} \quad (2)$$

sendo que, **n** corresponde à **n**ésima amostra da Energia do Coeficiente Detalhe **E** e **E_{max}** corresponde ao valor limite de energia que deve ser estabelecido pelo engenheiro de proteção, dado pela diferença entre a primeira amostra do período de falta e a última amostra do período pré-falta, conforme indicado na Figura 3.

O detector de falta, além de possibilitar a separação dos sinais em conjuntos de dados pré-falta e de falta é também relevante para definir o instante da ocorrência da falta (ângulo de incidência de falta). Essa informação contribuirá para reduzir o tempo de treinamento das RNAs.

3.1.2 Estimação Fasorial das Fontes Equivalentes

Ângulo de incidência de falta, fluxo de potência, os tipos de falta (AT, BT, CT, ABT, ...), valores de resistência de falta e locais possíveis de falta, são variáveis que geram vários cenários de falta e que devem ser contemplados no processo de treinamento das RNAs. Diante disso, a estimação fasorial é proposta para estimar o fluxo de potência, definido pelos módulos e ângulos das fontes equivalentes do sistema elétrico. Assim, não será necessário criar cenários de falta considerando diferentes fluxos de potência, o que favorecerá para reduzir o tempo de treinamento das RNAs.

Assim, o processo para a estimação fasorial das

fontes equivalentes do terminal emissor **S** e receptor **R**, inicia-se com o cálculo dos fasores fundamentais dos sinais de corrente e tensão registrados no terminal emissor **S**, por meio de uma variação do método dos erros dos mínimos quadrados de Sachdev & Baribeau (Pereira e Cruz, 1999). Os valores foram obtidos considerando uma janela de dados com 32 pontos por ciclo.

Em seguida foram selecionados somente os fasores pré-falta e calculou-se a média de cada conjunto (módulos e ângulos). Por meio do Teorema de Fortescue, obteve-se um fasor de corrente **IS** e um fasor de tensão **VS** de sequência positiva no terminal emissor **S**. Conhecendo-se as impedâncias das fontes equivalentes **ZS1** e **ZR1**, da linha **ZL1** e os fasores de sequência positiva de corrente e tensão no terminal emissor **S**, é necessário apenas resolver as equações 3, 4 e 5, para estimar módulo e ângulo das tensões das fontes equivalentes nos dois terminais, conforme Figura 4.

$$ES = VS + ZS1.IS \quad (3)$$

$$VR = VS - ZL1.IS \quad (4)$$

$$ER = VR - ZR1.IS \quad (5)$$




Figura 4. Modelo linha de transmissão: circuito pré-falta

Para melhor ilustrar o processo descrito, na tabela 1 estão apresentados os parâmetros de um sistema elétrico real, localizado no interior de Minas Gerais, Brasil, pertencente a uma concessionária de energia.

Tabela 1. Parâmetros sistema elétrico real

Tabela 1: Parâmetros sistema elétrico real			
DADOS DAS FONTES EQUIVALENTES			
IMPEDÂNCIA DA FONTE (Ω/km)			
TERMINAL EMISSOR		TERMINAL RECEPTOR	
ZS0	ZS1	ZR0	ZR1
4,0692+ j33,6032	4,00077+ j34,1103	2,73069+ j39,3637	6,33183+ j53,845
DADOS LINHA DE TRANSMISSÃO			
COMPRIMENTO (km)		74,4	
TENSÃO (kV)		345	
IMPEDÂNCIA DA LINHA (Ω/km)			
ZL0		ZL1	
0,362191+ j1,432507		0,036102+j 0.375919	

Estão apresentados na Figura 5 os sinais registrados no terminal emissor **S** durante uma falta.




Figura 5. Sinais registrados no terminal S

Já na Tabela 2 estão os resultados estimados das fontes equivalentes, obtidos a partir das equações 3, 4 e 5, das informações da Tabela 1 e dos dados registrados terminal S, representado na Figura 5.

Tabela 2. Fontes equivalentes: Valores estimados para terminais emissor S e receptor R considerando dados de um terminal

TERMINAL EMISSOR (S)		TERMINAL RECEPTOR (R)	
Módulo	Ângulo (°)	Módulo (kV)	Ângulo (°)
292,059	24	290,158	13,9

3.1.3 Simulação: Geração do Banco de Dados

Para o bom desempenho das RNAs é necessário um conjunto de cenários, que contemplem diversas possibilidades de falta no sistema elétrico. As variáveis consideradas para estabelecimento dos padrões necessários para treinamento das RNAs estão apresentadas na Tabela 3.

Tabela 3. Conjunto de variáveis para gerar padrões de treinamento

VARIÁVEIS	TREINAMENTO
Locais de falta (km)	Locais de falta estão entre 10% e 90% do comprimento da linha, com incremento de 10%.
Resistência de Falta Fase-terra (Ω)	0 – 7 – 14 – 21 – 28 – 35 – 42 – 49
Resistência de Falta Fase-Fase (Ω)	0 – 5
Tipos de Falta	AT – BT – CT – AB – AC – BC – ABT – ACT – BCT – ABC
Fluxo de Potência	*Determinado na etapa de Estimação Fasorial: Fontes Equivalentes
Ângulo de Incidência de Falta	*Determinado pelo Detector de Falta

*O ângulo de incidência de falta, assim como o fluxo de potência, já são informações conhecidas, ambos determinados nas etapas de detecção de falta e estimação fasorial das fontes equivalentes, respectivamente.

As combinações das variáveis citadas na Tabela 3 geram 504 cenários de faltas diferentes. Como não existem registros reais de todas essas situações, tais condições são simuladas nessa etapa. O método consiste no uso de arquivos com extensão .bat, que permite gerar esses diferentes cenários de falta de forma automática através do software ATP (Su, X. Duan e Zeng., 2008 e Júnio, 2009).

Após gerado o conjunto de cenários para treinamento das RNAs, esses dados devem ser tratados

conforme etapa de processamento de dados.

3.2 Etapa 2: Processamento de Dados

Encerrada o Pré-processamento de Dados, inicia-se a etapa denominada Processamento de Dados. De forma geral, essa etapa é responsável pela extração de características dos sinais de tensão e corrente de fase e neutro (A, B, C e N), e seleção dos dados de falta para testes e treinamentos das RNAs.

Na Figura 6 está apresentada a estrutura do algoritmo de Processamento de Dados. Para extração das características, os dados de entrada são submetidos aos processos de interpolação, normalização, cálculo da TWE e energia de Parseval. Em seguida ocorre a seleção dos dados para treinamento e teste das RNAs.




Figura 6. Estrutura do algoritmo para processamento de dados

A seleção dos dados é realizada de acordo com o instante de falta informado pelo detector de falta. Nessa etapa são escolhidos os dados correspondentes a energia do coeficiente detalhe dos sinais de corrente **EI** e tensão **EV** registrados nos primeiros 1/8 de ciclo do período de falta. É considerada uma janela fixa com 4 amostras, totalizando 32 amostras para cada cenário de falta. Para melhor visualização, na Figura 7 está ilustrado a seleção dos dados de energia do coeficiente detalhe do sinal de corrente da fase A **EIAx**, mas essa análise deve ser estendida aos demais dados de energias de coeficientes detalhe, **EIBx**, **EICx**, **EINx**, **EVax**, **EVbx**, **EVCx**, **EVNx**, sendo $x=1, \dots, 4$.




figura 7. Seleção de dados para testes e treinamentos das RNAs. Energia do coeficiente detalhe da corrente e tensão


3.3 Etapa 3: RNAs para Classificar, Localizar Falta e Determinar Resistências De Falta

As RNAs foram implementadas utilizando o Toolbox Neural Network do Matlab (Demuth e Beale, 2015). Possuem método de aprendizagem supervisionado backpropagation com algoritmo de treinamento Levenberg Marquardt.

É proposto neste artigo a utilização de RNAs modulares. Nesse processo, existem várias RNAs independentes dentro de um único módulo, em que cada RNA realiza uma sub tarefa e a solução geral é dada pela combinação de resultados de cada RNA que estruturam o módulo. Essa metodologia ajuda na precisão dos resultados (Pradhan, Mohanty e Routray, 2006; Sahoo, Ray e Panigrahi, 2010 e Lout e Aggarwal, 2012).

3.3.1 RNAs Modulares Para Classificar Faltas


Conforme Figura 8, o módulo para classificar falta é composto por 4 RNAs. Cada RNA recebe os dados de energia do coeficiente detalhe de corrente **EI** e tensão **EV** de uma única fase ou neutro, sendo 4 amostras por tipo de sinal. Todas RNAs possuem arquiteturas iguais e foram determinadas de forma experimental, sendo 8 dados de entrada, 26 neurônios na primeira camada oculta, 22 neurônios na segunda camada oculta e um neurônio na camada de saída. Os alvos de saída são 1 para condições de falta e 0 para não falta. As RNAs trabalham em paralelo e foi utilizada a função de ativação log-sigmóide para todos os neurônios.



3.3.2 RNAs modulares para localizar falta e RNAs modulares para determinar resistências de falta

Os módulos para localização de falta e determinação das resistências de falta também são compostos por 4 RNAs cada, conforme pode ser verificado na Figura 9. Cada RNA recebe os dados de energia do coeficiente detalhe dos sinais de corrente **EI** e tensão **EV** de fase e neutro, de acordo com o tipo de falta (monofásica, bifásica, trifásica, bifásica-terra).

Os módulos possuem RNAs com estruturas iguais que também foram definidas de forma experimental, sendo 32 dados de entrada, 16 neurônios na camada oculta, e um neurônio na camada de saída. Foi utilizado função de ativação log-sigmóide para os neurônios pertencentes à camada oculta e função de ativação linear para o neurônio da camada de saída. As RNAs de cada módulo devem ser ativadas de acordo com o tipo de falta definido pelo módulo de classificação de falta. As RNAs, para o módulo de localização de falta, retornam a distância de falta **Df**, em quilômetros, a partir do ponto de medição. Já as RNAs, para o módulo de determinação de resistência, informam a resistência de falta **Rf**, em ohms, associada ao local da falta.



4 Resultados

Foram criados vários cenários de falta que buscam simular condições de falta ainda não treinadas pelas RNAs. Diante dos testes realizados, o módulo para classificação de falta apresentou exatidão, acertando 100% dos tipos de falta. Na Tabela 4 estão apresentados os resultados, sendo que, são consideradas condições de falta caso a RNA retorne valor maior ou igual a 0,7. Se a RNA retornar valor menor ou igual a 0,3 não se indica falta.

Tabela 4. Resultados para classificação de falta

Cenários de Falta			Saídas Estimadas			
Falta	Df (km)	Rf (Ω)	A	B	C	T
AT	6,00	3	0,999	9E-13	0,025	0,999
	6,00	45	0,999	6E-13	0,023	0,999
	68,4	3	0,999	3,4E-4	0,088	0,999
	68,4	45	0,999	8,6E-6	0,058	0,999
AB	6,00	3	0,999	0,9999	0,020	0,002
	68,4	3	0,999	1	0,020	0,002
ABC	6,00	3	0,999	1	0,999	0,002
	68,4	3	0,999	1	0,999	0,002
ABT	6,00	3	0,999	1	0,022	0,999
	6,00	45	0,999	1	0,021	0,999
	68,4	3	0,999	1	0,039	0,999
	68,4	45	0,999	1	0,029	0,999

Os módulos para localizar falta e determinar resistência de falta também foram testados, considerando os mesmos cenários de faltas aplicados ao módulo de classificação. Os resultados estão na Tabela 5, sendo que, apresentam erros relativos **ER** inferiores a 3% para o módulo de localização de falta e inferiores a 4 % para o módulo de determinação de resistência de falta. Para o erro relativo considerou a seguinte formulação:

$$ER = \frac{|\text{valoresperado} - \text{valorestimado}|}{\text{valoresperado}} \quad (6)$$

Tabela 5. Resultados para localização de falta e determinação da resistência de falta

Falta	Df (km)	Df Estimado(km)	ER (%)	Rf (Ω)	Rf Estimada (Ω)	ER (%)
AT	6	6,17	2,83	3	3,05	1,67
	6	6,16	2,67	45	44,98	0,04
	68,4	68,30	0,15	3	2,99	0,33
	68,4	68,35	0,07	45	44,98	0,04
AB	6	6,02	0,33	3	3,03	1,00
	68,4	68,36	0,06	3	3,01	0,33
ABC	6	6,02	0,33	3	2,92	2,67
	68,4	68,35	0,07	3	3,04	1,33
ABT	6	6,01	0,17	3	2,89	3,67
	6	6,01	0,17	45	45,07	0,16
	68,4	68,40	0,00	3	2,98	0,67
	68,4	68,40	0,00	45	45,00	0,00

5 Conclusão

Neste artigo destaca-se a utilização da transformada wavelet estacionária, em conjunto com a energia de Parseval para realizar detecção de falta em linhas de transmissão, enquanto que, redes neurais artificiais são utilizadas nos processos de classificação e localização de faltas, e determinação de resistências de falta. Diante dos testes realizados, o método foi preciso para diferentes cenários de falta, sendo que, para a classificação obteve 100% de acerto, enquanto que, os erros relativos para localização e determinação da resistência de falta foram inferiores a 3% e 4 % respectivamente.

No que refere à metodologia, destaca-se a etapa denominada pré-processamento, que determina as condições pré-falta do sistema, detectando o início da falta e o fluxo de potência na linha, variáveis que uma vez conhecidas, contribuem para reduzir o número de cenários de falta, possibilitando menor tempo de treinamento das RNAs. Além disso, na etapa processamento de dados, são selecionadas as energias dos coeficientes detalhes de tensão e corrente, sendo este um novo método de seleção para treinamento e testes de RNAs. Por fim, a utilização de RNAs modulares, permitiu utilizar RNAs de forma direcionada, o que contribui para o aumento da precisão dos resultados.

Em trabalhos futuros deve-se buscar um modelo mais robusto de sistema elétrico, que possibilite representar com maior proximidade o comportamento de um sistema real. Para alcançar tal objetivo deve avaliar a possibilidade de contemplar no modelo do sistema elétrico algumas variáveis, como: erros percentuais de transformadores de correntes e tensão, resistência de falta variável durante o curto-circuito e resistividade do solo.

Agradecimentos

Os autores agradecem ao Centro Federal de Educação Tecnológica de Minas Gerais pelo apoio.

Referências Bibliográficas

- Costa, F. B. "Fault-Induced Transient Detection Based on Real-Time Analysis of the Wavelet Coefficient Energy". IEEE Transactions on Power Delivery, v. 29, n. 1, february 2014.
- Demuth, H.; Beale, M. "Neural Network Toolbox User'S Guide, The Math Work". [S.l.]: [s.n.], 2015.
- Júnio, G. R. G. "Detecção e Classificação Automática de Faltas a partir de Registros Oscilográficos". Projeto fim de curso II, Universidade Federal de Minas Gerais. [S.l.]. 2009.
- Kalam, M. A.; Jamil, M.; Ansari, A. Q. "Wavelet based ANN Approach for Fault Location on a Transmission Line". IEEE, New Delhi Conference. [S.l.]: [s.n.]. 2010.
- Lout, K.; Aggarwal, R. K. "A Feedforward Artificial Neural Network Approach to Fault Classification and Location on a 132 kV Transmission Line Using Current Signals Only". IEEE, Universities Power Engineering Conference (UPEC). [S.l.]: [s.n.]. 2012.
- Misiti, M. et al. Wavelet Toolbox User'S Guide, The Math Work. [S.l.]: [s.n.], 2015.
- Paula, H. R e Silveira, E. G." Inteligência Computacional Para Detectar, Classificar, Localizar Faltas e Determinar Resistência de Falta em Linha de Transmissão". In: 8o seminário Nacional de Sistemas Industriais e Automação, 2015, Belo Horizonte. Anais do Evento, 2015.

- Pereira, C.; Cruz, F. D. “Análise do Comportamento Estático e Dinâmico dos Filtros Digitais de Mínimos Quadrados na Proteção de Linhas de Transmissão”. XV SNPTEE, Foz do Iguaçu, 1999.
- Pradhan, A. K.; Mohanty, S. R.; Routray., “A Neural Fault Classifier for Transmission Line Protection. A Modular Approach”. IEEE, Department of Electrical Engineering, Indian: 2006
- Sahoo, S.; Ray, P.; Panigrahi, B. K. “A Computational Intelligence Approach for Fault Location in Transmission Lines”. IEEE, Power Electronics, Drives and Energy Systems (PEDES) & Power India, 2010 Joint International Conference on. [S.l.]: [s.n.]. 2010.
- Salim, R. H. et al. “Hybrid Fault Diagnosis Scheme Implementation for Power Distribution Systems Automation”. IEEE Transactions on Power Delivery, v. 23, n. 4, October 2008.
- Silva, K. M.; Sousa, B. A.; Brito, N. S. D. “Fault Detection and Classification in Transmission Lines Based on Wavelet Transform an ANN”. IEEE, Transactions on Power Delivery, v. 21, October 2006.
- Souza, S. M. D.; Silva, A. P. A. D.; A.C.S. Lima. “Voltage and Current Patterns for Fault Location in Transmission Lines”. IEEE, Proceedings of International Joint Conference on Neural Networks. Orlando, Florida, USA: [s.n.], August, 2007.
- Su, S.; X. Duan; Zeng., X. “Atp-based automated fault simulation”. IEEE Transactions on Power Delivery, v. 23, n. 3, 2008.