Programa de Pós-Graduação em Engenharia Elétrica (PPGEL)

Associação Ampla entre UFSJ e CEFET-MG





Naiara Figueiredo Duarte

DETECÇÃO E CLASSIFICAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO UTILIZANDO TRANSFORMADA WAVELET E REDES NEURAIS ARTIFICIAIS

Belo Horizonte

2014

Naiara Figueiredo Duarte

DETECÇÃO E CLASSIFICAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO UTILIZANDO TRANSFORMADA WAVELET E REDES

NEURAIS ARTIFICIAIS

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, associação ampla entre o CEFET-MG e a UFSJ, como parte dos requisitos exigidos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Sistemas Elétricos – SE. Linha de Pesquisa: Planejamento e Operação de Sistemas Elétricos de Potência – POSEP.

Orientador: Eduardo Gonzaga da Silveira

Belo Horizonte

2014

Duarte, Naiara Figueiredo

Detecção e Classificação de Faltas em Linhas de Transmissão Utilizando Transformada Wavelet e Redes Neurais Artificiais

122 páginas

Dissertação (Mestrado) – Centro Federal de Educação Tecnológica de Minas Gerais.

- 1. Proteção do Sistema Elétrico de Potência
- 2. Detecção de Faltas
- 3. Classificação de Faltas
- 4. Transformada Wavelet
- 5. Redes Neurais Artificiais (RNAs)

I. Centro Federal de Educação Tecnológica de Minas Gerais. Departamento de Engenharia Elétrica.

Banca Examinadora:

Prof. Dr. Eduardo Gonzaga da Silveira PPGEL/CEFET-MG

Prof. Dr. Marco Aurélio de Oliveira Schroeder PPGEL/UFSJ-MG

Prof. Dr. Clever Sebastião Pereira Filho DEE/UFMG.

Dedico este trabalho ao meu avô José Sérgio Figueiredo (Zequinha) que, onde quer que esteja, está brilhando mais forte neste momento.

Agradecimentos

A Deus, por nunca ter me abandonado, por ter me dado forças nos momentos mais difíceis e sabedoria para melhor conduzi-los.

Aos meus pais Roberto Duarte e Avelina Duarte, por todo o amor, carinho e dedicação. Por terem aberto mão, inúmeras vezes, de seus sonhos para possibilitarem a mim bons estudos. Por me ensinarem desde cedo que a educação é fundamental para se formar, não somente um bom profissional, mas também um adulto com a possibilidade de contribuir para a sociedade.

Ao meu irmão Fabrício Duarte pelo apoio, carinho e compreensão pelos diversos momentos em que não pude estar presente.

À minha avó Geralda Guerra, por ser uma pessoa presente em todos os momentos na minha vida e ao meu avô José Sérgio Figueiredo, meu grande incentivador nos estudos que, mesmo não estando mais aqui, foi fundamental na construção deste sonho.

Aos meus padrinhos Fernando Viegas e Luzia Viegas, por serem pessoas especiais na minha vida e por serem verdadeiramente meus segundos pais.

Ao meu namorado Kleiser Loregian, que com seu carinho, incentivo e sua tranquilidade fez com que esta caminhada fosse mais amena.

A Neusa Barbosa, por ter me motivado todos os dias e me mostrado que bastava eu acreditar.

Ao meu sempre amigo Fábio Arruda, pela inspiração nos estudos e por ter dividido comigo este sonho, suas experiências e seus conhecimentos. Ao meu amigo Cláudio Santos pela ajuda incondicional durante as matérias do mestrado. Aos amigos Ciby Rosa, Rafael Alípio, Natália Aliani, Lorena Diaz e Joaquim Santiago pela presença carinhosa e fundamental de cada um no meu dia a dia, pelos muitos ensinamentos que vão além da pesquisa e por me ajudarem a ser uma pessoa melhor. Ao meu orientador professor Eduardo Gonzaga que com sua sabedoria, conhecimentos e compreensão possibilitou que eu chegasse até esta etapa. Ele me mostrou que orientar é mais do que apenas ensinar, é antes de tudo, uma relação interpessoal.

Ao meu eterno professor, mestre e orientador Marco Aurélio Schroeder, que despertou em mim a vontade de pesquisar. Seus ensinamentos são, sem dúvida alguma, a base de todo este meu trabalho.

Aos professores do Programa de Pós-graduação em Engenharia Elétrica do CEFET: Úrsula Resende, Sidelmo Silva, Patrícia Jota e Eduardo Nunes aos ensinamentos aprendidos nas matérias cursadas ao longo do mestrado. À funcionária Rosimeire pela atenção e compreensão ao longo de todo o curso.

Aos antigos colegas de trabalho da Minerconsult, em especial à engenheira Helen Silva. Aos colegas da Themag, principalmente aos engenheiros Afonso Silva e Cícero Teixeira. E aos atuais colegas da GE Power Conversion, por me proporcionarem a vivência da engenharia.

Ao Centro Federal de Educação Tecnológica de Minas Gerais, por toda a minha formação técnica e por ter vivido, ali, muitos momentos de grande crescimento pessoal e científico.

A todos os meus familiares e amigos que estiveram comigo nesta caminhada e que, de alguma força, contribuíram para que eu chegasse até aqui.

"Quando uma criatura humana desperta para um grande sonho e sobre ele lança toda a força de sua alma, todo o universo conspira a seu favor." (Johann Goethe)

"Jamais considere seus estudos como uma obrigação, mas como uma oportunidade invejável para aprender a conhecer a influência libertadora da beleza do reino do espírito, para seu próprio prazer pessoal e para proveito da comunidade à qual seu futuro trabalho pertencer." (Albert Einstein)

Resumo

Ao longo dos últimos anos, vários consumidores ficaram sem o fornecimento de energia elétrica no Brasil, o que resultou em um efeito econômico não desprezível, causando prejuízos tanto às concessionárias quanto aos consumidores, fato que se deve principalmente às faltas, que atingem inúmeros estados. Devido à elevada exposição que é submetida em toda a sua extensão, a linha de transmissão aérea é o elemento do sistema elétrico mais vulnerável a curtos-circuitos causados por árvores, isoladores danificados, descargas atmosféricas, dentre outros. Para reduzir os impactos causados pelas faltas em um sistema elétrico de potência (SEP) são adotados mecanismos de diagnóstico para detecção, classificação e localização, que se realizados com rapidez e precisão, tornam possível o restabelecimento do sistema em um menor tempo. O estudo proposto neste trabalho visa detectar e classificar faltas em linhas de transmissão, de forma que os danos causados pelas falhas no sistema sejam minimizados. Portanto, é desenvolvida uma metodologia de detecção e classificação de faltas do tipo curto-circuito, baseada em uma análise de sinais de tensão e corrente e em uma técnica de inteligência computacional. A detecção da falta é realizada por meio da extração de sinais pela Transformada Wavelet, enquanto que a classificação da falta é realizada por Rede Neural Artificial (RNA). Os resultados dos algoritmos aplicados a casos simulados e reais do sistema elétrico brasileiro indicam que as investigações realizadas neste trabalho podem ser de grande valia no auxílio às análises de informações importantes para a operação e manutenção de sistemas elétricos de potência, minimizando o tempo de reparo e, consequentemente, obtendo menores perdas financeiras devido ao rápido diagnóstico de falhas e restabelecimento das condições normais de operação.

Palavras-chave: Transformada Wavelet, Redes Neurais Artificiais, Proteção do Sistemas Elétricos de Potência, Detecção e Classificação de Faltas.

Abstract

Over the past years, several customers ran out of energy supply in Brazil, which resulted in an important economic effect, causing damage to both, electric utilities and consumers. The fact is due to the faults that affect several states. Due to the high exposure that is submitted in all its physical dimension, the overhead transmission line is the element of the electrical system more vulnerable to short circuits caused by trees, damaged insulators, lightning and others. To reduce the impacts caused by faults in an electric system some mechanisms for the signals diagnosis are adopted, which, if quickly and accurately detected, located and classified are able to restore the system in the shortest time possible. The proposed study aims to detect and classify faults in transmission lines, so that the damages caused by system failures are minimized. Therefore, a methodology for faults detection and classification of short circuit sort, based on current and voltage signals analysis and computational intelligence techniques is developed. The faults detection is performed by extracting signals through Wavelet Transform, while the faults classification is performed through Artificial Neural Network (ANN). The results of the algorithms applied to real Brazilian electric system and simulated cases indicate that the investigations made in this work can be of great value in helping the analyzes of important information for the operation and maintenance of electric power systems, minimizing the repair times and consequently getting less financial losses due to quick diagnosis of failures and reestablishment of normal operating conditions.

Keywords: Wavelet Transform, Artificial Neural Networks (ANN), electric power system (EPS) protection, faults detection and classification.

Sumário

Agrade	cimentos	V
Resumo	D	viii
Abstrac	t	ix
Lista de	e Figuras	xii
Lista de	e Tabelas	xvi
Lista de	e Abreviaturas e Símbolos	xvii
1.1	RELEVÂNCIA	1
1.2	MOTIVAÇÃO	2
1.3	OBJETIVO	4
1.4	ESTRUTURA DO TRABALHO	4
3.1	TRANSFORMADA WAVELET e TRANSFORMADA DE FOURIER	11
3.2	ANÁLISE WAVELET	
3.3	APROXIMAÇÕES E DETALHES	14
3.4	ANÁLISE MULTIRESOLUÇÃO	15
3.4	.1 FAMÍLIAS WAVELETS	15
3.5	TEOREMA DE PARSEVAL	17
3.6	TRANSFORMADA WAVELET	
3.6	.1 TRANSFORMADA WAVELET CONTÍNUA	
3.6	.2 TRASNFORMADA WAVELET DISCRETA	21
4.1	NEURÔNIO BIOLÓGICO	23
4.2	NEURÔNIO ARTIFICIAL	24
4.2	.1 PRIMEIRO MODELO MATEMÁTICO	24
4.2	.2 MODELO BASE PARA PROJETO DE REDES NEURAIS	25
4.3	TOPOLOGIA DAS REDES NEURAIS ARTIFICIAIS	
4.4	APRENDIZAGEM DE UMA REDE NEURAL	
4.5	ALGORITMO BACKPROPAGATION	
5.1	VISÃO GERAL	
5.2	Introdução	
5.3	Entrada dos Dados de Tensão e Corrente	
5.4	Detecção de Faltas	
5.4	.1 Detecção de Faltas Para Casos Reais	

R	eferênc	ias Bibliográficas
	7.2	Propostas de Continuidade106
	7.1	Conclusões102
	6.5.2	Casos Reais
	6.5.1	Casos Simulados
	6.5	Resultados da Etapa de Classificação de Faltas85
		82
	6.4.1	2 Curtos-circuitos nas fases A, B e C; impedância de falta: 10 Ω; wavelet mãe: symlet8
	6.4.1	1 Curtos-circuitos nas fases A e B; impedância de falta: 10 Ω; wavelet mãe: symlet8.80
	6.4.1	0 Curto-circuito na fase A; impedância de falta: 0 Ω; wavelet mãe: symlet8
	6.4.9	Curtos-circuitos nas fases A, B e C; impedância de falta: 10 Ω ; wavelet mãe: coiflet576
	6.4.8	Curtos-circuitos nas fases A e B; impedância de falta: 10 Ω ; wavelet mãe: coiflet574
	6.4.7	Curto-circuito na fase A; impedância de falta: 0 Ω; wavelet mãe: coiflet573
	6.4.6	Curtos-circuitos nas fases A, B e C; impedância de falta: 10 Ω ; wavelet mãe: db870
	6.4.5	Curtos-circuitos nas fases A e B; impedância de falta: 10 Ω; wavelet mãe: db868
	6.4.4	Curto-circuito na fase A; impedância de falta: 0 Ω; wavelet mãe: db867
	6.4.3	Curtos-circuitos nas fases A, B e C; impedância de falta: 10 Ω ; wavelet mãe: db464
	6.4.2	Curtos-circuitos nas fases A e B; impedância de falta: 10 Ω ; wavelet mãe: db462
	6.4.1	Curto-circuito na fase A; impedância de falta: 0 Ω; wavelet mãe: db461
	6.4	Resultados da Etapa de Detecção de Faltas60
	6.3	Implementações no MATLAB59
	6.2	Simulações no ATP52
	6.1	Modelo utilizado
	5.8	Classificação de Faltas
	5.7	Estimação dos Fasores Fundamentais44
	5.6	Interpolação dos Dados Filtrados
	5.5	Filtragem Passa-baixa

Lista de Figuras

Figura 3.1: Diferenças entre uma onda senoidal e uma wavelet.	12
Figura 3.2: Aplicação da Transformada Wavelet	13
Figura 3.3: Árvore de decomposição wavelet (S- sinal; Ai- coeficientes de aproximação do i	nível i; Di-
coeficientes de detalhes do nível i)	14
Figura 3.4: Wavelet Haar	16
Figura 3.5: Wavelet Daubechies	16
Figura 3.6: Wavelet Coiflets	17
Figura 3.7: Wavelet Symlets	17
Figura 3.8: Representação de um sinal em diferentes escalas e posições	19
Figura 3.9: Exemplo do fator de escala em uma função seno	20
Figura 3.10: Exemplo do fator de escala em uma função wavelet	20
Figura 3.11: Translação aplicada a uma wavelet	21
Figura 4.1: Neurônio biológico	23
Figura 4.2: Representação da sinapse neural	24
Figura 4.3: Neurônio de McCulloch & Pitts	24
Figura 4.4: Modelo não linear de um neurônio	25
Figura 4.5: Transformação produzida pelo efeito do bias	26
Figura 4.6: Modelo não linear de um neurônio, considerando uma entrada fixa igual a 1 e	um peso
igual ao bias b_k	27
Figura 4.7: Função de limiar	28
Figura 4.8: Função de linear	28
Figura 4.9: Função linear por partes	29
Figura 4.10: Função sigmóide	29
Figura 4.11: Função tangente hiperbólica	30
Figura 4.12: Rede neural direta.	31
Figura 4.13: Rede neural recorrente	31
Figura 5.1: Etapas desenvolvidas no algoritmo de detecção e classificação de faltas	36
Figura 5.2: Decomposição do sinal de tensão em primeiro nível	40
Figura 5.3: Energia dos coeficientes do sinal de tensão	41
Figura 5.4: Resposta em frequência para um filtro de Butterworth de ordem 2	

Figura 5.5: Ondas de tensão de entrada e filtradas para um curto-circuito AT	42
Figura 5.6: Ondas de corrente original e a obtida por interpolação	43
Figura 5.7: Resposta em frequência do filtro dos erros mínimos quadrados	47
Figura 5.8: Ondas de tensão e corrente de uma falta real, após aplicação do filtro passa-baixa	47
Figura 5.9: Amplitude e fase dos fasores estimados a partir das ondas de tensão da Figura 5.7	48
Figura 5.10: Amplitude e fase dos fasores estimados a partir das ondas de corrente da Figura 5.7.	48
Figura 6.1: Modelo de SEP utilizado para simulações de faltas	52
Figura 6.2: Geometria da linha de 345 kV	52
Figura 6.3: Circuito simulado no ATP	53
Figura 6.4: Simulação de falta tipo curto-circuito fase AT	55
Figura 6.5: Simulação de falta tipo curto-circuito fase BT	55
Figura 6.6: Simulação de falta tipo curto-circuito fase CT	56
Figura 6.7: Simulação de falta tipo curto-circuito fases ABT	56
Figura 6.8: Simulação de falta tipo curto-circuito fases BCT	57
Figura 6.9: Simulação de falta tipo curto-circuito fases CAT	57
Figura 6.10: Simulação de falta tipo curto-circuito fases AB	58
Figura 6.11: Simulação de falta tipo curto-circuito fases BC	58
Figura 6.12: Simulação de falta tipo curto-circuito fases CA	59
Figura 6.13: Simulação de falta tipo curto-circuito fases ABC	59
Figura 6.14: Estrutura implementada do sistema para detecção e classificação de faltas	60
Figura 6.15: Tensão na Fase A	61
Figura 6.16: Corrente na Fase A	61
Figura 6.17: Tensão na Fase A	62
Figura 6.18: Tensão na Fase B	62
Figura 6.19: Corrente na Fase A	63
Figura 6.20: Corrente na Fase B	63
Figura 6.21: Tensão na Fase A	64
Figura 6.22: Tensão na Fase B	64
Figura 6.23: Tensão na Fase B	65
Figura 6.24: Corrente na Fase A	65
Figura 6.25: Corrente na Fase B	66
Figura 6.26: Corrente na Fase C	66
Figura 6.27: Tensão na Fase A	67
Figura 6.28: Corrente na Fase A	67

Figura 6.29: Tensão na Fase A	68
Figura 6.30: Tensão na Fase B	68
Figura 6.31: Corrente na Fase A	69
Figura 6.32: Corrente na Fase B.	69
Figura 6.33: Tensão na Fase A	70
Figura 6.34: Tensão na Fase B	70
Figura 6.35: Tensão na Fase C	71
Figura 6.36: Corrente na Fase A	71
Figura 6.37: Corrente na Fase B	72
Figura 6.38: Corrente na Fase C	72
Figura 6.39: Tensão na Fase A	73
Figura 6.40: Corrente na Fase A	73
Figura 6.41: Tensão na Fase A	74
Figura 6.42: Tensão na Fase B	74
Figura 6.43: Corrente na Fase A	75
Figura 6.44: Corrente na Fase B	75
Figura 6.45: Tensão na Fase A	76
Figura 6.46: Tensão na Fase B	76
Figura 6.47: Tensão na Fase C	77
Figura 6.48: Corrente na Fase A	77
Figura 6.49: Corrente na Fase B.	78
Figura 6.50: Corrente na Fase C	78
Figura 6.51: Tensão na Fase A	79
Figura 6.52: Corrente na Fase A	79
Figura 6.53: Tensão na Fase A	80
Figura 6.54: Tensão na Fase B	80
Figura 6.55: Corrente na Fase A	81
Figura 6.56: Corrente na Fase B	81
Figura 6.57: Tensão na Fase A	82
Figura 6.58: Tensão na Fase B	82
Figura 6.59: Tensão na Fase C	83
Figura 6.60: Corrente na Fase A	83
Figura 6.61: Corrente na Fase B	84
Figura 6.62: Corrente na Fase C.	84

Figura 6.63: Corrente – Caso 1	89
Figura 6.64: Tensão – Caso 1	89
Figura 6.65: Corrente no trecho de análise – Caso 1	90
Figura 6.66: Tensão no trecho de análise – Caso 1	91
Figura 6.67: Corrente – Caso 2	92
Figura 6.68: Tensão – Caso 2	92
Figura 6.69: Corrente no trecho de análise – Caso 2	93
Figura 6.70: Tensão no trecho de análise – Caso 2	94
Figura 6.71: Corrente – Caso 3	95
Figura 6.72: Tensão – Caso 3	95
Figura 6.73: Corrente no trecho de análise – Caso 3	96
Figura 6.74: Tensão no trecho de análise – Caso 3	96
Figura 6.75: Corrente – Caso 4	97
Figura 6.76: Tensão – Caso 4	98
Figura 6.77: Corrente no trecho 1 de análise – Caso 4	99
Figura 6.78: Tensão no trecho 1 de análise – Caso 4	99
Figura 6.79: Corrente no trecho 2 de análise – Caso 4	
Figura 6.80: Tensão no trecho 2 de análise – Caso 4	100
	 Figura 6.63: Corrente – Caso 1. Figura 6.64: Tensão – Caso 1. Figura 6.65: Corrente no trecho de análise – Caso 1. Figura 6.66: Tensão no trecho de análise – Caso 1. Figura 6.67: Corrente – Caso 2. Figura 6.68: Tensão – Caso 2. Figura 6.69: Corrente no trecho de análise – Caso 2. Figura 6.69: Corrente no trecho de análise – Caso 2. Figura 6.70: Tensão no trecho de análise – Caso 2. Figura 6.71: Corrente – Caso 3. Figura 6.72: Tensão – Caso 3. Figura 6.73: Corrente no trecho de análise – Caso 3. Figura 6.74: Tensão no trecho de análise – Caso 3. Figura 6.75: Corrente – Caso 4. Figura 6.76: Tensão – Caso 4. Figura 6.78: Tensão no trecho 1 de análise – Caso 4. Figura 6.79: Corrente no trecho 2 de análise – Caso 4. Figura 6.80: Tensão no trecho 2 de análise – Caso 4.

Lista de Tabelas

Tabela 1.1: Ocorrências de faltas no SEP em um sistema de 500 kV, em um período de 10 anos	2
Tabela 5.1: Tempos de falta detectados a partir da simulação de ondas de tensão	39
Tabela 5.2: Tempos de falta detectados a partir da simulação de ondas de corrente	39
Tabela 5.3: Lógica de diagnóstico das faltas	50
Tabela 6.1: Parâmetros da linha utilizada nas faltas simuladas.	53
Tabela 6.2: Dados das fontes utilizadas nas faltas simuladas	53
Tabela 6.3: Resultados dos testes com o grupo 1	86
Tabela 6.4: Resultados dos testes com o grupo 2	86
Tabela 6.5: Resultados dos testes com o grupo 3	87
Tabela 6.6: Resultados dos testes com o grupo 4	87
Tabela 6.7: Resultados dos testes com o grupo 5	87

Lista de Abreviaturas e Símbolos

Fator de Escala Para a Transformada Wavelet
Análise Multiresolução
Artificial Neural Network
Alternative Transient Program
Fator de Translação Para a Transformada Wavelet
Bias Correspondente ao Neurônio k
Coeficientes de Aproximação
Coeficientes de Detalhe
Companhia Energética de Minas Gerais
Companhia Hidrelétrica do São Francisco
Família Wavelet Coiflet
Continuous Wavelet Transform
Família Wavelet Daubechies
Digital Fault Recorder
Discrete Wavelet Transform
Frequência Fundamental
Inverse Discrete Wavelet Transform
Neurônio Artificial
Multi-layer Perceptron
Learning Vector Quantization
Ordem da Família Wavelet
Taxa de Amostragem
Qualidade de Energia Elétrica
Registradores Digitais de Perturbação
Rede Neural Artificial
Resilient Propagation
Sistemas Elétricos de Potência
Source Impedance Ratio
Short Time Fourier Transform
Família Wavelet Symlet
Transformada Wavelet
Transformada Wavelet Contínua
Peso Sináptico
Frequência Angular Fundamental
Função escalar
Função Wavelet

1 Introdução

1.1 RELEVÂNCIA

As linhas de transmissão constituem uma parte do sistema elétrico de potência de grande importância, visto que estas são as responsáveis pela interligação do sistema de geração de energia elétrica ao sistema de distribuição. Portanto, é imprescindível que as linhas de transmissão operem adequadamente para que o fornecimento de energia elétrica não seja cessado.

É desejável que o SEP funcione de maneira correta e ininterrupta, fornecendo energia com determinado padrão de qualidade aos consumidores, sejam eles residenciais, comerciais ou industriais. Com os curtos-circuitos na operação, porém, nem sempre esse objetivo é atingido. Por falta em um SEP, entende-se como a falha total ou parcial no fornecimento de energia elétrica. A causa de uma falta pode ser devido a um fenômeno interno (sobrecarga ou defeito em equipamentos) ou externo ao sistema (sobretensões devido às descargas atmosféricas, por exemplo). As faltas podem causar problemas tais como danos aos equipamentos, desligamento de áreas não faltosas, explosões, dentre outros. Além disso, podem ser classificadas como permanentes ou transitórias. As faltas permanentes, após a abertura do dispositivo de proteção, exigirão investigação do local da falta para remoção das mesmas. Apenas após eliminadas estas causas, a energia poderá ser reestabelecida. As faltas transitórias são aquelas que afetam o circuito temporariamente, ou seja, após a operação de um dos equipamentos de proteção, ocorre o religamento do circuito e a falha é eliminada [1].

Devido à elevada exposição que é submetida em toda a sua extensão, a linha de transmissão aérea é o elemento mais vulnerável de um sistema elétrico e sofre ação de vários fatores como curto-circuito causado por árvores, isoladores danificados, descargas atmosféricas, queimadas dentre outros. As linhas de transmissão do SEP contam com um sistema de proteção, cuja função é proteger o sistema de faltas que podem ocorrer devido a causas internas e externas a esse. A Tabela 1.1 a seguir ilustra o número de faltas para cada

setor do sistema elétrico. A partir desta tabela é possível observar que pouco mais de 80 % das faltas envolvem as linhas de transmissão, [2].

Setor do sistema elétrico	Número de Faltas
Linhas de Transmissão	82
Circuitos disjuntores	4
Autotransformadores	6
Barramentos	1
Geradores	1
Falha humana	5

Tabela 1.1: Ocorrências de faltas no SEP em um sistema de 500 kV, em um período de 10 anos.

Para proteger as linhas de transmissão de energia elétrica, suas extremidades geralmente são equipadas com dispositivos de proteção (relés), os quais detectam as faltas através da identificação de condições anormais de operação. As grandezas mais comuns que indicam anormalidade são os sinais de tensão e corrente, os quais são medidos usualmente nos pontos de instalação de equipamentos de proteção ou nos limites apropriados das zonas de proteção. A partir da detecção de uma falta, os relés devem enviar um sinal de abertura aos correspondentes disjuntores para isolar a linha afetada do sistema restante [3], [4].

1.2 MOTIVAÇÃO

O diagnóstico de faltas em linhas de transmissão é uma importante tarefa da proteção do sistema elétrico de potência. A operação segura do SEP demanda um sistema de proteção capaz de detectar, classificar e localizar faltas com elevada precisão e rapidez, de forma a minimizar os danos causados pelas mesmas.

O desenvolvimento de sistemas de proteção do SEP teve início há mais de cem anos, quando se utilizou os primeiros relés eletromecânicos de sobrecorrente, com base nos princípios de proteção que foram desenvolvidos nas três primeiras décadas do século. Com o avanço da tecnologia eletroeletrônica, os relés de proteção evoluíram dos dispositivos eletromecânicos para dispositivos de estado sólido, construídos com componentes semicondutores, inicialmente transistores, em seguida circuitos integrados e, mais recentemente, microprocessadores. Apesar da grande evolução alcançada pela tecnologia dos relés de proteção, muitos dos princípios básicos de proteção não mudaram e permanecem em uso nos dias atuais [5].

Os relés digitais tiveram sua origem no final dos anos 60 e início dos anos 70, com trabalhos pioneiros sobre a aplicação desses dispositivos na área de proteção de SEP [6]. Os relés digitais executam um algoritmo que processa os dados de entrada (amostras de tensão e corrente) para produzir uma saída digital. O algoritmo é o elemento central do relé digital e um grande número de algoritmos tem sido desenvolvidos e publicados na literatura [3].

No estágio inicial do seu desenvolvimento, os relés digitais empregavam algoritmos desenvolvidos a partir dos mesmos métodos de diagnósticos de faltas dos relés convencionais, que se baseiam em parâmetros da linha (tensão, corrente, impedância e outros). Nos últimos anos, as pesquisas sobre algoritmos utilizados em relés digitais para diagnóstico de faltas em linhas de transmissão se concentraram no uso de ferramentas matemáticas de análises de sinais, tais como Transformada de Fourier e Transformada Wavelet, e em sistemas inteligentes, tais como RNA.

O diagnóstico de faltas empregando a Transformada de Fourier ou a Transformada Wavelet é um sistema de proteção baseado em transitórios que utiliza as componentes de alta frequência do sinal de falta para análise, ao invés da frequência fundamental. Trabalhos na área de proteção de SEP têm demonstrado que a análise de transitórios baseada na Transformada de Fourier, em algumas situações, não é suficientemente precisa para alguns tipos de falta, enquanto que a Transformada Wavelet permite a investigação de transitórios

O diagnóstico de faltas empregando RNA é uma tentativa de superar os problemas encontrados nos sistemas de proteção baseados em cálculos determinísticos a partir do modelo do sistema a ser protegido. Em tais situações, as dificuldades estão relacionadas a diversos fatores, tais como: complexidade do sistema, falta de conhecimento exato dos seus parâmetros, grande quantidade de informações a ser processada, além de sinais que contêm incertezas. Muitos trabalhos têm demonstrado que sistemas de proteção baseados nos sistemas inteligentes são capazes de superar grande parte dos problemas citados anteriormente.

Mesmo com todo o desenvolvimento alcançado, o diagnóstico de faltas em linhas de transmissão não é tarefa trivial, dados os inúmeros fatores que afetam a eficácia dos métodos existentes, como por exemplo, a resistência de falta, o ângulo de incidência da falta, o momento e o local da falta, os ruídos dos sinais, dentre outros.

As técnicas baseadas em inteligência computacional para diagnóstico de faltas em linhas de transmissão têm se mostrado mais eficientes, devido à sua capacidade de aprendizado, robustez e generalização, o que contribui para superar as deficiências dos demais métodos de proteção de linhas de transmissão. A adição de métodos de análises de sinais mais precisos, como a Transformada Wavelet, com sistemas inteligentes como as RNAs torna possível a implementação de algoritmos de diagnósticos de faltas em linhas de transmissão mais eficientes. Esses algoritmos servem de auxílio às análises de informações importantes para a operação e manutenção de sistemas elétricos de potência, minimizando os tempos de reparos e, consequentemente, obtendo menos perdas financeiras devido ao rápido diagnóstico de falhas e restabelecimentos das condições normais de operação.

1.3 OBJETIVO

O objetivo do trabalho desenvolvido é detectar e classificar faltas em linhas de transmissão, de forma que os danos causados pelas falhas em um sistema sejam minimizados. Portanto, foi desenvolvida uma metodologia de detecção e classificação de faltas do tipo curtocircuito, baseada em análise de sinais e em inteligência computacional. A detecção da falta é realizada por meio da extração de sinais da mesma pela Transformada Wavelet [7] [8], enquanto que a classificação da falta é realizada pela RNA. Essa metodologia consiste em algoritmos que podem ser implementados computacionalmente.

1.4 ESTRUTURA DO TRABALHO

Este trabalho está estruturado em 6 capítulos, tal como descrito na sequência.

O primeiro capítulo se dedica a apresentar a relevância dos métodos computacionais que utilizam a Transformada Wavelet e as Redes Neurais Artificiais para detectar e classificar,

respectivamente, faltas em linhas de transmissão. No segundo capítulo é feito o levantamento do estado da arte referente a esses métodos. Em seguida, nos capítulos, três e quatro, respectivamente, são apresentadas a Transformada Wavelet e as Redes Neurais Artificiais. No capítulo cinco é exposta, em detalhes, a metodologia proposta no trabalho para detecção e classificação de faltas. No capítulo seis são apresentados os resultados obtidos e, finalmente, o capítulo sete é dedicado às conclusões e às futuras propostas de trabalho.

2 Estado da Arte: Técnicas de Detecção e Classificação de Faltas

Com o propósito de conhecer os estudos referentes à aplicação da Transformada Wavelet (TW) e das Redes Neurais Artificiais para análises de faltas em linhas de transmissão foram levantados alguns dos importantes trabalhos sobre a temática desenvolvida nesta dissertação. A abordagem inclui as principais técnicas e metodologias utilizadas pelos pesquisadores em todo o mundo, com destaque para os trabalhos que utilizam ferramentas para análise no domínio do tempo-frequência e para treinamento de redes artificiais, o que permitirá observar o conjunto: técnica e desempenho obtidos.

Atualmente, a Transformada Wavelet é a ferramenta mais utilizada para obtenção de características no domínio do tempo e da frequência [9]. Na análise de eventos de qualidade de energia elétrica (QEE), foi introduzida por Ribeiro [10] na análise de sinais não estacionários em sistemas de potência e, dois anos depois, como método de análise de transitórios por Robertson [11] e Santoso [12], explorando a capacidade de decompor um sinal, mediante o uso da análise de multiresolução (AMR), em coeficientes de aproximação (referentes às componentes de baixa frequência) e em coeficientes de detalhe (referentes às componentes de alta frequência). Além disso, destaca-se a necessidade de projetar um sistema capaz de classificar automaticamente os distúrbios presentes no sistema elétrico.

Vários trabalhos abordam a análise de sinais com distúrbios utilizando a Transformada Wavelet, devido à sua capacidade de fornecer informações das componentes no domínio do tempo e da frequência de forma simultânea.

Uma vez estabelecida a ferramenta para extração das características próprias de um sinal, neste caso a Transformada Wavelet, precede-se a tarefa de um sistema capaz de receber estas características e decifrar, dentre as suas composições, semelhanças que possam ser agrupadas em classes. Estes sistemas são conhecidos como classificadores. Um dos classificadores mais utilizados em QEE são as RNAs. Alguns artigos que apresentam as técnicas de análise e classificação citadas acima e que são de interesse para o desenvolvimento deste trabalho são expostos a seguir. Em 1994, Santoso, Powers e Grady [13] propõem uma abordagem baseada na utilização da Transformada Wavelet para detecção e localização de distúrbios. Os distúrbios tratados são flutuações rápidas de tensão, variações de tensão de curta e longa duração e distorções harmônicas. Os sinais dos distúrbios são decompostos em até dois níveis de resolução, sob a justificativa de que, em níveis maiores, a localização no tempo não é importante. As wavelets usadas são do tipo Daubechies 4 e 6 (para transitórios rápidos) e 8 e 10 (para transitórios lentos).

Liang, Elangovan e Devotta, em 1998, [14] propõem um algoritmo para detecção e classificação de faltas usando a AMR por wavelets em tempo real. O primeiro estágio de detalhes do sinal AMR extraído do sinal original é usado como critério de análise para esse trabalho. As faltas no sistema de potência podem ser detectadas medindo-se a variação brusca dos valores do detalhe do sinal AMR. O tipo de falta é identificado por meio da comparação da variação brusca da AMR das três fases. Os efeitos da distância da falta, o ângulo de incidência e a impedância da falta são analisados e uma rotina de classificação é desenvolvida para seus efeitos.

Uma abordagem modular e integrada para o problema de detecção e classificação rápida de faltas é proposta por Chowdhury e Aravena, em 1998, [15]. Embora o exemplo estudado seja específico de um sistema de potência, o método pode ser aplicado para um sistema dinâmico arbitrário. A abordagem é flexível, uma vez que essa pode ser baseada ou não no modelo existente. Quando não baseada no modelo, é importante o uso de conceitos da teoria de processamento de sinais e wavelets para criar indicadores de faltas que sejam rápidos e sensíveis. Se o modelo estiver disponível, os resíduos gerados de forma convencional (diferença entre a saída do modelo e os dados reais) podem servir como indicadores de falta. Os indicadores podem ser analisados por meio de hipóteses padrões de estatísticas ou por redes neurais artificiais, com o objetivo de se criar regras de decisões inteligentes. Após a detecção, o indicador de falta é processado por uma rede de *Kohonen* para classificá-la.

Coury e Gionaninia (1999) [16] apresentam o desenvolvimento de um *software* baseado em redes neurais do tipo *Perceptron* de Múltiplas Camadas, cujo treinamento envolve o algoritmo da retropropagação do erro (*backpropagation*) para a classificação de faltas em

linhas de transmissão. Diversos tipos de faltas tais como: fase-fase, fase-terra e fase-faseterra foram simulados sob diferentes condições de ângulos de incidência, distâncias e resistências de falta. O objetivo do trabalho é a melhoria do bloco classificador do sistema de proteção de linhas de transmissão, sobretudo do ponto de vista do tempo de processamento para a estimação da falta.

Zhenf et all [17] utilizam a técnica de AMR do domínio Wavelet para obtenção de modelos transitório e de estado permanente, de acordo com as diferentes propostas de análises. O modelo transitório é, geralmente, adaptado para a análise de distúrbios transitórios no sistema. O de estado permanente pode ser aplicado para análise de harmônicos e respostas no domínio do tempo-frequência.

Zhao, Songb e Minb [18] apresentam um novo método para detecção e classificação de faltas transitórias em sistemas de cabos subterrâneos, baseado no uso da transformada wavelet discreta. Um sistema subterrâneo de 400 kV é simulado usando o ATP (*Alternative Transient Program*) sob várias condições de falta e de carregamento. A wavelet mãe Daubechies 8 é empregada para analisar os transitórios de falta e alimenta os dados de entrada para a detecção e classificação dos sinais. Os resultados simulados mostram um esquema eficiente e robusto. O procedimento de análise do método empregado é baseado na adoção de uma wavelet protótipo (wavelet mãe). A análise temporal é feita utilizando-se uma versão contraída e de alta frequência da wavelet protótipo. Em seguida, é investigada a aplicação das wavelets na análise transitória das faltas em cabos subterrâneos e, assim, estabelecer resultados preliminares para um novo conceito de detecção e classificação de faltas.

Em 2002, Fernández e Rojas [19] publicam um trabalho que tem como objetivo avaliar a bibliografia disponível em um período significativo, cerca de dez anos, para apresentar uma visão geral sobre a aplicação da Transformada Wavelet em sistemas de potência, onde 116 publicações coletadas são analisadas segundo critérios de relevância da contribuição ou fortalecimento de linhas de pesquisa que utilizam Transformadas Wavelets em sistemas de potência são em proteção de SEP, qualidade de energia, transitórios em SEP, descargas parciais, balanceamento de cargas, medições em SEP, dentre outras. Os autores observam que as

técnicas de Transformadas Wavelets são utilizadas com mais ênfase na implementação de métodos de identificação e classificação dos sinais. Os dados para esse tipo de análise são obtidos, em geral, a partir de simulações utilizando programas de análise de transitórios como o ATP. As análises realizadas utilizam programas específicos como a *toolbox* wavelet disponível para o software Matlab[®]. Além disso, identificam que o uso dessas transformadas para a implementação de métodos rápidos de detecção e localização de faltas é uma linha de pesquisa bastante promissora.

Um sistema Neuro-Fuzzy classificador de distúrbios relacionados com a QEE é apresentado por Huang et al [20]. O sistema classificador utiliza uma rede neural com treinamento competitivo e um refinamento com o algoritmo LVQ (*Learning Vector Quantization*), que compreende um modelo supervisionado da rede de mapeamento auto-organizável. O algoritmo, que emprega a técnica *Fuzzy*, é utilizado para otimizar o sistema contendo a rede neural. O sistema classificador utiliza, como entrada de dados, características do sinal original extraídas através da AMR usando Daubechies de quarta ordem como wavelet mãe. Treze tipos de distúrbios são utilizados como padrões de entrada para o sistema A93 %.

Uma metodologia baseada em redes neurais para detecção, localização e classificação de faltas em sistemas elétricos é apresentada em Arruda [21]. O trabalho busca identificar faltas nos sistemas utilizando os conhecimentos adquiridos pelas redes neurais. Para o treinamento das redes são realizadas simulações de curto-circuito por meio do ATP e os resultados previstos são empregados em um sistema automatizado para análise de faltas, baseado em amostras de tensões e correntes trifásicas obtidas através de registradores digitais de perturbação (RDP).

Entre as publicações nacionais, o trabalho de Souza et all (2004) [22] apresenta resultados obtidos pela implementação de algoritmos de inteligência artificial, usados para identificar e classificar faltas em linhas de transmissão. A metodologia proposta usa dados amostrados de sinais de tensão e corrente obtidos por registradores digitais de falta (DFRs). O desempenho dos algoritmos do tipo *resilient propagation* (RPROP) e *backpropagation* são avaliados para faltas monofásicas, bifásicas e trifásicas. Os resultados obtidos atestam a eficiência e a eficácia do uso das redes neurais, principalmente as redes LMP (*multi-layer*)

perceptron) em classificação de faltas em linhas de transmissão. Pela investigação dos resultados verifica-se que o algoritmo RPROP obteve melhor desempenho. A sua prioridade, quando comparado ao *backpropagation*, é atestada pela análise das curvas do erro médio quadrático dos conjuntos de treinamento e validação.

Silva et all (2005) [23] apresentam um método de detecção e classificação de faltas em linhas de transmissão. A detecção da falta e de seu intervalo de duração são realizados por um conjunto de regras estabelecidas a partir da análise dos sinais de corrente no domínio do tempo e dos coeficientes wavelet. Na etapa de classificação emprega-se uma RNA, cujos sinais de entrada são as tensões e correntes nas linhas de transmissão. O método é avaliado para faltas reais e simuladas em linhas de transmissão de 230 kV do sistema elétrico da CHESF (Companhia Hidrelétrica do São Francisco). A principal contribuição do método está relacionada à pré-análise e triagem dos registros capturados pelos equipamentos registradores de perturbação. Além da situação normal de operação em regime permanente do sistema, as faltas foram diferenciadas de distúrbios associados à qualidade de energia elétrica e de operações de manobra para manutenção do sistema. Apesar dos resultados evidenciarem uma possível generalização das regras de detecção, elas ainda não podem ser tidas como gerais. Outras regras devem ser incorporadas ao método, contemplando outros tipos de distúrbios em linhas de transmissão.

Conforme exposto acima, vários são os trabalhos realizados para detecção e classificação de sinais. Neste trabalho será utilizada a Transformada Wavelet para detecção e as redes neurais artificiais para classificação dos sinais de tensão e corrente de uma linha de transmissão.

3 Transformada Wavelet

Nas duas últimas décadas, as wavelets têm despertado grande interesse de pesquisadores de diversas áreas de atuação, tais como matemática física, engenharia e computação. Esta característica interdisciplinar, aliada à simplicidade e versatilidade da abordagem dos conceitos da teoria, proporcionou um rápido avanço das wavelets.

As Transformadas de Wavelet podem ser vistas como mecanismos para decompor ou quebrar sinais nas suas partes constituintes, o que permite analisar os dados em diferentes domínios de frequências com a resolução de cada componente amarrada à sua escala. Elas utilizam a ideia de aproximação usando a superposição de funções. Esta ideia tem sua origem no século XIX com o trabalho de *Joseph Fourier*, o qual descobriu que poderia utilizar da combinação de senos e cossenos para representar outras funções. O princípio mais geral na construção das wavelets é o uso de dilatações e translações. As wavelets formam um sistema ortonormal de funções com suportes compactos. Esta é a razão pela qual elas podem distinguir as características locais de um sinal em diferentes escalas e, por translações, elas cobrem toda a região na qual o sistema é estudado. Na análise de sinais não estacionários, a propriedade de localidade das wavelets conduz a vantagens sobre a Transformada de Fourier [24].

3.1 TRANSFORMADA WAVELET e TRANSFORMADA DE FOURIER

Uma wavelet é uma forma de onda com duração limitada e que tem valor médio zero. Comparando com as ondas senoidais, que são a base da Transformada de Fourier, enquanto as senóides não têm duração limitada (vão de menos infinito a mais infinito) são suaves e previsíveis, as wavelets tendem a ser irregulares e assimétricas [25]. A Figura 3.1 ilustra estas diferenças.



Figura 3.1: Diferenças entre uma onda senoidal e uma wavelet.

A Transformada de Fourier consiste em dividir um sinal em componentes de ondas senoidais de diferentes frequências. Da mesma forma, a Transformada Wavelet é a divisão de um sinal em versões deslocadas e escalonadas da wavelet original, chamada de wavelet mãe.

Para muitos sinais, a Transformada de Fourier é muito útil porque o conteúdo de frequência do sinal é de grande importância, mas que pode ter um inconveniente para algumas aplicações. Na transformação para o domínio da frequência, a informação de tempo é perdida. Ao observar a Transformada de Fourier de um sinal, é impossível dizer quando um evento aconteceu. Para corrigir esta deficiência, a Transformada de Fourier foi adaptada para analisar somente uma pequena parcela do sinal de cada vez, uma técnica chamada de "janelamento" do sinal. Essa adaptação, denominada Transformada de Fourier de Janela ou *Short Time Fourier Transform* – STFT, mapeia um sinal em uma função de duas dimensões: tempo e frequência. Entretanto, essa informação somente poderá ser obtida com precisão limitada, sendo que a precisão é determinada pelo tamanho da janela. A desvantagem é que quando se escolhe um determinado tamanho para a janela de tempo, essa janela é a mesma para todas as frequências [25].

A Transformada Wavelet representa o próximo passo em métodos de análise de sinais: uma técnica de "janelamento" com janelas de tamanhos variáveis. A análise de wavelet permite o uso de intervalos de tempos longos, onde se deseja informação mais precisa de baixas frequências e intervalos de tempos curtos, onde se deseja informação mais de altas frequências. A Figura 3.2 ilustra a aplicação da Transformada Wavelet em um sinal.



Figura 3.2: Aplicação da Transformada Wavelet.

3.2 ANÁLISE WAVELET

O termo wavelet está associado a ondas localizadas, ou seja, ondas que crescem e decaem em um período limitado de tempo. Para que uma função seja denominada de wavelet, usualmente denotada pela letra ψ , deve satisfazer às propriedades a seguir:

a) A integral desta função (wavelet) deve ser zero, isto é:

$$\int_{-\infty}^{+\infty} \Psi(t) dt = 0$$
(3.1)

Isso garante que a função wavelet tenha uma forma do tipo onda. Essa condição é conhecida como condição de admissibilidade.

b) A função wavelet deve ter energia unitária, ou seja,

$$\int_{-\infty}^{+\infty} \left|\Psi(t)\right|^2 dt = 1$$
(3.2)

Isso garante que a função wavelet possua suporte compacto, ou com um decaimento rápido de amplitude, garantindo a localização temporal.

De modo geral, as funções wavelets possuem a propriedade de dupla localização: em frequência e em tempo. A localização temporal ocorre por ser a função wavelet localizada em um intervalo finito. Dessa forma, à medida que a escala aumenta, as funções wavelet ficam localizadas em intervalos de comprimento cada vez menores. Em cada nível de escala, todas as funções wavelet possuem a mesma forma, só mudando seus pontos de localização,

isto é, há uma translação da função wavelet. Devido à propriedade de dupla localização das funções wavelet, a transformada wavelet é dita do tipo local em tempo-frequência, com resolução temporal e em frequência inversamente proporcionais [26].

A análise de wavelet é ainda uma ferramenta para decomposição em nível hierárquico em um conjunto de aproximações e detalhes que permite a descrição de uma função em termos globais, mais termos que variam de detalhes globais até detalhes finos, aumentando o nível de resolução. As wavelets apresentam uma técnica elegante para representar os níveis de detalhes presentes.

3.3 APROXIMAÇÕES E DETALHES

Um sinal pode ser analisado através de uma escala grande, quando se notam as características globais do mesmo, ou através de uma escala menor, quando os detalhes finos se tornam prioridades.

Na Transformada Wavelet um sinal S é decomposto em coeficientes de aproximação A1 e coeficientes de detalhe D1 do nível 1. A aproximação do nível 1 (A1) é, também, decomposta em coeficientes de aproximação A2 e coeficientes de detalhes D2 do nível 2. Este processo ocorre até o n-ésimo nível de decomposição. A Figura 3.3 a seguir mostra a árvore de decomposição wavelet até o terceiro nível.



Figura 3.3: Árvore de decomposição wavelet (S- sinal; Ai- coeficientes de aproximação do nível i; Dicoeficientes de detalhes do nível i)

A decomposição wavelet consiste em aproximações e detalhes. As aproximações representam o conteúdo de baixa frequência do sinal original e os detalhes representam o conteúdo de alta frequência do mesmo sinal.

3.4 ANÁLISE MULTIRESOLUÇÃO

A análise multiresolução tem como objetivo representar uma dada função em diferentes níveis de resolução e obter a informação necessária para poder passar de um nível de resolução para outro de forma eficaz. Com a análise multiresolução é possível obter uma boa resolução no domínio do tempo e em frequência, o que é bastante interessante pelo fato de que os sinais encontrados em aplicações práticas geralmente apresentam componentes de alta frequência por curtas durações de tempo e componentes de baixa frequência por longas durações de tempo [27]. De forma simplificada, com a AMR é possível dividir o espectro de frequências de um sinal em sub-bandas e, desta forma, tratar individualmente cada uma dessas partes por meio de bancos de filtros passa-alta e passabaixa.

O número máximo de níveis de decomposição wavelet é determinado pelo comprimento do sinal original, pela wavelet mãe selecionada e pelo nível de detalhe exigido. Os filtros passaalta e passa-baixa são determinados, respectivamente, pela função wavelet e pela função escala [28].

3.4.1 FAMÍLIAS WAVELETS

Existem diferentes tipos de famílias wavelets. Dentre elas as mais amplamente utilizadas são: Haar, Daubechies, Coiflets e Symlets.

3.4.1.1 HAAR

A base de *Haa*r é a primeira e mais simples das bases. Ela é descontínua, se parece com a função degrau e equivale a wavelet de Daubechies db1 (Figura 3.4).



Figura 3.4: Wavelet Haar

3.4.1.2 DAUBECHIES

A família de bases wavelets de Daubechies leva o sobrenome de *Ingrid Daubechies*, uma das mais importantes pesquisadoras no campo das wavelets. Ela descobriu as wavelets ortonormais com suporte compacto, o que tornou possível a análise discreta das wavelets.

O nome da família wavelet Daubechies é geralmente escrito por três caracteres como *dbN*, onde *db* é uma indicação de seu sobrenome (*Daubechies*) e *N* é o número de sua ordem (Figura 3.5).



Figura 3.5: Wavelet Daubechies

3.4.1.3 COIFLETS

A wavelet de Coiflets é denominada pelo nome CoifN, onde Coif descreve seu nome e N é o número de sua ordem (Figura 3.6).



Figura 3.6: Wavelet Coiflets

3.4.1.4 SYMLETS

SymN denomina a família wavelet Symlets, onde Sym é o nome e N é a ordem. As Symlets são próximas das wavelets simétricas propostas por Daubechies, como uma modificação da família db. Ela apresenta as mesmas propriedades da família db (Figura 3.7).



Figura 3.7: Wavelet Symlets

3.5 TEOREMA DE PARSEVAL

Uma vez que as wavelets mãe caracterizam-se por apresentarem bases ortogonais e suporte compacto, essas funções admitem o Teorema de Parseval. A energia de um sinal será igual ao somatório das energias presentes em cada um dos seus coeficientes de aproximação e detalhe da Transformada Wavelet. Para um caso geral, a energia no domínio de expansão é dividida em função dos fatores escala e translação:

$$\sum_{k=-\infty}^{\infty} |x(t)|^2 = \sum_{k=-\infty}^{\infty} |C_{j0}(k)|^2 + \sum_{k=-\infty}^{\infty} \sum_{j=j0}^{J} |d(j,k)|^2$$
(3.3)

Onde $j, k \in \mathbb{Z}$.

As variáveis utilizadas na Equação (3.3) são:

x(*t*) sinal com distúrbio, amostrado no domínio do tempo;

k amostras do sinal;

 $\sum_{k=-\infty}^{\infty} |x(t)|^2$ energia do sinal analisado;

 $\sum_{k=-\infty}^{\infty} |C_{j0}(k)|^2$ energia concentrada na versão aproximada de nível j₀ do sinal analisado;

 $\sum_{k=-\infty}^{\infty} \sum_{j=j0}^{J} |d(j,k)|$ energias concentradas nas versões detalhadas de nível j₀ a J do sinal analisado.

3.6 TRANSFORMADA WAVELET

As variantes da Transformada Wavelet são duas: Transformada Wavelet Contínua (CWT – *Continuous Wavelet Transform*), definida no tempo contínuo e a Transformada Wavelet Discreta (*DWT - Discrete Wavelet Transform*), definida no tempo discreto. Os sinais analisados neste trabalho foram sinais discretos.

3.6.1 TRANSFORMADA WAVELET CONTÍNUA

A Transformada Wavelet Contínua (TWC) de um sinal f(x) dado, considerando a wavelet mãe $\psi(x)$ é definido como [29]:

$$(TWC)(a,b) = \left|a\right|^{\frac{-1}{2}} \int_{-\infty}^{\infty} f(x)\Psi(\frac{x-b}{a}).dx$$
(3.4)

Onde a é o fator de dilatação ou escala e b é o fator de translação. A Equação (3.4) mostra que na TW o sinal unidimensional original f(x) é mapeado em uma nova função em um espaço bidimensional composto pela escala a e pela translação b. O coeficiente TWC (a,b)

representa o quão bem corresponde o sinal original f(x) está com a wavelet mãe [30]. Desse modo, o grupo de coeficientes TWC(a,b) associado com um sinal particular é a representação wavelet do sinal original f(x) em relação à wavelet mãe $\psi(x)$, conforme Figura 3.8.



Figura 3.8: Representação de um sinal em diferentes escalas e posições.

É possível visualizar a wavelet mãe como uma função janelada. O fator de escala *a* e o tamanho da janela são interdependentes, onde menores escalas implicam em menores janelas. Consequentemente, componentes de bandas estreitas de frequência de um sinal com um pequeno fator de escala e componentes de bandas largas de frequência com fatores de escala maiores permitem captar todas as características de um sinal particular.

3.6.1.1 ESCALAMENTO

Escalar uma wavelet significa dilatá-la ou contraí-la. O fator de escala é usualmente denotado pela letra *a*. O efeito do fator de escala pode ser observado, por exemplo, nas senóides, conforme Figura 3.9.


Figura 3.9: Exemplo do fator de escala em uma função seno.

O fator de escala atua da mesma forma nas wavelets. Quanto menor o fator de escala, mais contraída será a wavelet, o que pode ser confirmado na Figura 3.10.

$$f(t) = \Psi(t); a = 1$$
(3.8)
$$f(t) = \Psi(2t); a = 1/2$$
(3.9)
$$f(t) = \Psi(4t); a = 1/4$$
(3.10)

Figura 3.10: Exemplo do fator de escala em uma função wavelet.

Através da Figura 3.9 é possível observar que, para o segmento da senóide *sen(wt)*, o fator de escala a é relacionado inversamente com a frequência em radianos *w*. Desta forma,

conforme mostrado na Figura 3.10, na Transformada Wavelet, a escala está inversamente relacionada com a frequência do sinal, o que corresponde a:

- Baixa escala *a* wavelet contraída detalhes que mudam rapidamente alta frequência *w*.
- Alta escala *a* wavelet dilatada detalhes que mudam vagarosamente baixa frequência *w*.

3.6.1.2 TRANSLAÇÃO

Transladar uma wavelet significa atrasá-la ou adiantá-la em relação ao eixo das abcissas, o que é feito, similarmente, com um atraso na função f de um fator k, f(x-k), como pode ser visto na Figura 3.11.



Figura 3.11: Translação aplicada a uma wavelet.

3.6.2 TRASNFORMADA WAVELET DISCRETA

Na Transformada Wavelet Contínua, foi considerada a função:

$$\Psi_{a,b}(x) = |a|^{-p} \Psi(\frac{x-b}{a})$$
(3.11).

Onde $b \in \Re$, $a \in \Re_{+}$ com $a \neq 0 e \Psi$ sendo a wavelet mãe.

Para se obter a Transformada Wavelet Discreta, *a* e *b* serão restritos somente a valores discretos, ou seja, valores que não variam continuamente.

A discretização dos parâmetros de dilatação e translação se mostra necessária em algumas aplicações, como por exemplo, na análise de sinais. Desta forma, $a = a_0^m$, onde $m \in \Re$, e o

passo de dilatação $a_0 \neq 1$ é fixado e $b = nb_0$, onde $n \in \Re$, e o passo de translação $b_0 > 0$ é fixado. É assumido um passo de dilatação $a_0 > 1$ e um passo de translação $b_0 \neq 0$

A função das wavelets discretas para $m, n \in \mathbb{Z}$ torna-se então:

$$\Psi_{ab}(t) = \frac{1}{\sqrt{a_0^m}} \Psi(\frac{t - nb_0 a_0^m}{a_0^m})$$
(3.12)

ou

$$\Psi_{mn}(t) = a_0^{-\frac{m}{2}} \Psi(a_0^{-m} t - nb_0)$$
(3.13)

Sendo

$$a = a_0^m$$
 (3.14)

$$b = nb_0 a_0^m \tag{3.15}$$

Segundo Equação (3.15) é possível observar que o parâmetro de translação *b* depende da taxa de dilatação a_0^m . Para um valor de m grande e positivo, a função da Transformada Wavelet Discreta é bastante dilatada e os passos de translação grandes são adaptados a esta grande largura. O contrário ocorre para m grande e negativo. A função da transformada é bastante contraída e os passos da translação pequenos são necessários para cobrir toda a extensão.

4 **REDES NEURAIS ARTIFICIAIS**

As Redes Neurais Artificiais, ou simplesmente Redes Neurais, são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes, que estão presentes em muitas áreas, tais como neurociências, matemática, estatística, física, ciência da computação e engenharia. As RNAs são aplicadas em vários campos, como por exemplo, modelagens de sistemas, análises de séries temporais, reconhecimento de padrões, processamento de sinais e controle de processos. Isso se deve a uma importante propriedade das RNAs: a capacidade de aprender a partir de dados de entrada com ou sem professor [1].

4.1 NEURÔNIO BIOLÓGICO

A rede neural biológica é formada por milhões de unidades fundamentais chamadas neurônios. Um neurônio típico é composto por um corpo celular ou soma, um axônio tubular e várias ramificações arbóreas conhecidas como dendritos. Os dendritos formam uma malha de filamentos finíssima ao redor do neurônio. O axônio consta de um tubo longo e fino que ao final se divide em ramos que terminam em pequenos bulbos que quase tocam os dendritos dos outros neurônios. O pequeno espaço entre o fim do bulbo e o dendrito é conhecido como sinapse, através da qual as informações se propagam. Na Figura 4.1 e Figura 4.2 são mostradas ilustrações de um neurônio biológico e de uma sinapse, respectivamente.



Figura 4.1: Neurônio biológico.



Figura 4.2: Representação da sinapse neural.

4.2 NEURÔNIO ARTIFICIAL

4.2.1 PRIMEIRO MODELO MATEMÁTICO

Com inspiração nos neurônios biológicos, foram desenvolvidos modelos para o neurônio artificial, buscando reproduzir as características do neurônio biológico por meio da análise do seu funcionamento. Um dos trabalhos pioneiros foi o de *Warren S. McCulloch* e *Walter Pitts*. Esses pesquisadores propuseram, em 1943, o primeiro modelo matemático para o neurônio [31]. O neurônio que tinha um número finito de entradas e uma saída, foi denominado Neurônio de *McCulloch & Pitts* e pode ser visto na Figura 4.3.



Figura 4.3: Neurônio de McCulloch & Pitts.

Sua operação pode ser resumida da seguinte forma:

- 1) Os sinais são apresentados às entradas x_m ;
- 2) Cada sinal é multiplicado por um peso W_{km} que indica a sua influência na saída do neurônio (efeito de excitação ou inibição da sinapse);
- 3) É feita a soma ponderada dos sinais (v_k), produzindo um nível de atividade;
- 4) Se este nível de atividade exceder um certo limiar, a unidade ativa sua saída y_k .

4.2.2 MODELO BASE PARA PROJETO DE REDES NEURAIS

Para a operação de uma rede neural, o conhecimento da unidade de processamento da informação fundamental torna-se indispensável. Portanto, o modelo de um neurônio artificial é a base para um projeto de redes neurais. O diagrama da Figura 4.4 mostra o modelo de um neurônio artificial.



Figura 4.4: Modelo não linear de um neurônio.

Conforme Figura 4.4 é possível identificar três elementos básicos [31]:

- Um conjunto de sinapses, em que cada uma é caracterizada por um peso ou força própria. Especificamente, um sinal x_m na entrada m conectada ao neurônio k é multiplicado pelo peso sináptico w_{km}. O primeiro índice do peso sináptico se refere ao neurônio em questão e o segundo se refere ao terminal de entrada da sinapse à qual o peso se refere.
- 2) Um somador para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio, o que constitui uma combinação linear.
- 3) Uma função de ativação para restringir a amplitude da saída de um neurônio.

O modelo da Figura 4.4 inclui também um bias aplicado externamente, representado por b_k . O bias b_k tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele for positivo ou negativo, respectivamente.

É possível descrever matematicamente um neurônio k a partir das seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \tag{4.1}$$

е

$$y_k = \varphi(u_k + b_k) \tag{4.2}$$

Onde $x_1, x_2, ..., x_m$ são os sinais de entrada; $w_{k1}, w_{k2}, ..., w_{km}$ são os pesos sinápticos do neurônio k; u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o bias; $\varphi(.)$ é a função de ativação e y_k é o sinal de saída do neurônio. Portanto, o uso do bias b_k tem o efeito de aplicar uma transformação à saída u_k do combinador linear no modelo da Figura 4.4 anteriormente apresentada. Esse efeito pode ser representado da seguinte forma:

$$v_k = u_k + b_k. \tag{4.3}$$

O bias b_k , se positivo ou negativo, modifica diretamente a relação entre o potencial de ativação v_k do neurônio k e a saída do combinador linear da seguinte forma:



Figura 4.5: Transformação produzida pelo efeito do bias.

Conforme Figura 4.5, o gráfico de v_k em função de u_k , após transformação produzida pelo efeito do bias, não passa mais pela origem. O bias b_k é um parâmetro externo do neurônio artificial k. Pode-se considerar a sua presença na Equação (4.2). Desta forma, é possível formular a combinação das Equações (4.1) a (4.3) da seguinte forma:

$$v_k = \sum_{j=0}^m w_{kj} x_j \tag{4.4}$$

$$y_k = \varphi(v_k) \tag{4.5}$$

Na Equação (4.4) é adicionada uma nova sinapse, com entrada

$$x_0 = +1$$
 (4.6)

e peso

$$w_{k0} = b_k \tag{4.7}.$$

O modelo do neurônio k pode ser reformulado conforme figura a seguir:



Figura 4.6: Modelo não linear de um neurônio, considerando uma entrada fixa igual a 1 e um peso igual ao bias b_k .

Por meio da Figura 4.6 nota-se que o efeito do bias é levado em consideração de duas maneiras:

- 1) Adicionando-se um novo sinal de entrada fixo;
- 2) Adicionando-se um novo peso sináptico igual ao bias b_k .

4.2.2.1 TIPOS DE FUNÇÃO DE ATIVAÇÃO

Segundo [31], existem alguns tipos básicos de função de ativação utilizados em RNAs, conforme podem ser vistos da Figura 4.7 à Figura 4.11 descritas a seguir:

a) Função de limiar, utilizada no neurônio de *McCulloch & Pitts*, com a seguinte definição:

$$\varphi(v) = \begin{cases} 1, sev \ge 0\\ 0, sev < 0 \end{cases}$$
(4.8)



Figura 4.7: Função de limiar.

b) Função linear, com a seguinte definição:

 $\varphi(v) = v$



Figura 4.8: Função de linear.

c) Função linear por partes, com a seguinte definição:

(4.9)





Figura 4.9: Função linear por partes.

d) Função sigmóide, função mais amplamente utilizada, é definida por:

$$\varphi(v) = \frac{1}{1 + e^{-axv}} \tag{4.11}$$

Onde *a* é o parâmetro de inclinação da função, como pode ser observado na Figura 4.10 seguinte.





e) Função Tangente Hiperbólica, de forma similar à função sigmóide. Assume valores entre 1 e -1, sendo representada por:

 $\varphi(v) = \tanh(a\,x\,v)$

Onde *a* é o parâmetro de inclinação da curva, como pode ser observado na Figura 4.11; *v* é o valor de ativação da unidade.

(4.12)



Figura 4.11: Função tangente hiperbólica.

4.3 TOPOLOGIA DAS REDES NEURAIS ARTIFICIAIS

Para a vasta maioria dos problemas práticos, um único neurônio não é suficiente. Portanto, são utilizados neurônios interconectados, sendo que a decisão de como interconectar os neurônios é uma das mais importantes decisões a se tomar em um projeto de uma rede neural artificial.

Quanto à interligação dos neurônios, é conveniente ressaltar a utilização de camadas intermediárias (ou ocultas) que possibilitam às RNAs implementarem superfícies de decisão mais complexas. Essas camadas permitem que seus elementos se organizem de tal forma que cada elemento aprenda a reconhecer características diferentes do espaço de entrada. Logo, o algoritmo de treinamento deve decidir quais características devem ser extraídas do conjunto de treinamento. A desvantagem em utilizar camada oculta é que o aprendizado se torna muito mais difícil [32].

As redes neurais artificiais podem ser diretas ou recorrentes, sendo que a principal diferença entre elas é que, na primeira, os neurônios não recebem realimentação em suas entradas.

Atualmente, as redes neurais diretas são as mais utilizadas, principalmente pelo advento da popularização do algoritmo de treinamento *backpropagation*. Esse tipo de rede pode ser considerado um aproximador universal de funções, sendo que seu nível de precisão dependerá principalmente do número de neurônios, bem como da escolha eficiente do conjunto de exemplos.

Nas redes neurais recorrentes existe pelo menos um ciclo de retroalimentação, onde algum neurônio fornece o seu sinal de saída para a entrada de outro neurônio. Esse tipo de rede se comporta melhor com problemas dinâmicos e que, portanto, necessitam de dinâmica da rede neural.

A Figura 4.12 e Figura 4.13 ilustram redes neurais diretas e recorrentes, respectivamente.



Figura 4.12: Rede neural direta.





É importante salientar que as conexões entre neurônios podem ser feitas de outras maneiras, tais como, ligações entre neurônios da mesma camada, ligações entre todos os neurônios de uma camada com apenas alguns de outra camada e outras. A disposição das ligações dependerá de que tipo de rede neural se deseja utilizar. Além dessas, novas arquiteturas ainda são objeto de pesquisa e o campo ainda está aberto para inovações nesse sentido. No trabalho desenvolvido, foram tratadas apenas redes neurais diretas.

4.4 APRENDIZAGEM DE UMA REDE NEURAL

A utilização de uma RNA na solução de uma tarefa passa inicialmente por uma fase de aprendizagem, quando a rede extrai informações relevantes de padrões de informação que lhe foram apresentados. A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, dos pesos das conexões entre as unidades de processamento que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando.

Quanto à forma de aprendizado, as RNAs podem ser classificadas em dois tipos:

- Aprendizado supervisionado: tem em sua estrutura uma espécie de instrutor que confere o quanto a rede está próxima de uma solução aceitável, adaptando na concepção do treinamento os pesos entre os neurônios, de modo a prover uma menor diferença entre as saídas desejadas e a obtida.
- Aprendizado não supervisionado: não possui conhecimento a priori das saídas da rede e funciona de modo a distinguir classes de padrões diferentes dos dados apresentados à rede, por meio de algoritmos de aprendizado baseados, geralmente, em conceitos de vizinhanças e agrupamento.

Para esse trabalho foi utilizado o aprendizado supervisionado, cujo algoritmo de treinamento é o *Backpropagation*, o qual é a alternativa mais utilizada para treinamento de redes neurais diretas.

4.5 ALGORITMO BACKPROPAGATION

O algoritmo *backpropagation* provê um aprendizado supervisionado, isto é, ele procura achar iterativamente a diferença entre as saídas desejadas e as saídas obtidas pela rede neural, segundo um erro mínimo. Para tanto, ele ajusta os pesos entre as camadas através da retropropagação do erro encontrado em cada iteração.

Uma solução para superar o problema do aprendizado da classificação de padrões não linearmente separáveis é a utilização de uma camada intermediária de neurônios ou

camada oculta, o que possibilita implementar superfícies de decisão mais complexas. A característica principal da camada escondida é que seus elementos se organizam de tal forma que cada elemento aprenda a reconhecer características diferentes do espaço de entrada. Assim, o algoritmo de treinamento deve decidir que características devem ser extraídas do conjunto de treinamento.

Como até o início dos anos 70 nenhum algoritmo de aprendizado para estas redes multicamadas havia sido desenvolvido, as pesquisas na área de redes neurais acabaram caindo em descrédito, até que nos anos 80, um algoritmo chamado Retropropagação ou *Backpropagation*, veio fazer renascer o interesse geral pelas redes neurais. O algoritmo *Backpropagation* é, hoje em dia, a técnica de aprendizado supervisionado mais utilizada para redes neurais unidirecionais multicamadas.

A rede aprende um conjunto pré-definido de pares de exemplos de entrada/saída em ciclos de propagação/adaptação. Depois que um padrão de entrada foi aplicado como um estímulo aos elementos da primeira camada da rede, ele é propagado por cada uma das outras camadas até que a saída seja gerada. Esse padrão de saída é então comparado com a saída desejada e um sinal de erro é calculado para cada elemento de saída.

O sinal de erro é então retropropagado da camada de saída para cada elemento da camada intermediária anterior que contribui diretamente para a formação da saída. Entretanto, cada elemento da camada intermediária recebe apenas uma porção do sinal de erro total, proporcional apenas à contribuição relativa de cada elemento na formação da saída original. Esse processo se repete, camada por camada, até que cada elemento da rede receba um sinal de erro que descreva sua contribuição relativa para o erro total. Baseado no sinal de erro recebido, os pesos das conexões são então atualizados para cada elemento com o objetivo de fazer a rede convergir para um estado que permita a codificação de todos os padrões do conjunto de treinamento.

O *Backpropagation* tem, na sua base, a minimização de uma função custo, no caso, a soma dos erros médios quadráticos sobre um conjunto de treinamento, utilizando a técnica de busca do gradiente descendente.

5 METODOLOGIA DESENVOLVIDA

Neste capítulo, é apresentada a metodologia proposta neste trabalho, a qual está dividida em duas etapas, sendo uma de detecção e a outra de classificação de faltas em linhas de transmissão. A primeira etapa utiliza como base a detecção de mudanças abruptas dos coeficientes da Transformada Wavelet e a segunda etapa baseia-se no aprendizado e reconhecimento de padrões através de Redes Neurais Artificiais.

5.1 VISÃO GERAL

Conforme mencionado anteriormente, o diagnóstico de faltas em linhas de transmissão é realizado em etapas distintas.

Para a primeira etapa, o método proposto consiste em detectar faltas a partir de amostras digitalizadas de sinais de tensão e corrente, extraídos de uma linha de transmissão. O algoritmo recebe, como entrada, vetores contendo dados registrados em um determinado intervalo de amostragem. Em seguida, ele extrai as características dos sinais e, conforme tais características, é admitida ou não a ocorrência da falta. Caso seja detectada uma falta, o algoritmo fornece um vetor de saída contendo amostras de tensão e corrente no intervalo de ocorrência da mesma, para que essas amostras sejam utilizadas na classificação do sinal. Na extração das características de falta é empregada a Transformada Wavelet, a qual é responsável pela obtenção dos coeficientes de detalhe dos sinais de tensão e corrente. Para a detecção de faltas é adotada uma técnica capaz de identificar mudanças abruptas por meio da comparação dos coeficientes obtidos pela Transformada Wavelet com um valor prefixado (*pickup*), para obter o instante da falta.

Para a segunda etapa, o método de classificação proposto consiste em especificar a falta utilizando como entrada os vetores com amostras de tensão e corrente, além do instante da falta, fornecido pela etapa de detecção. Esses dados são tratados e, conforme suas características, o algoritmo o classifica como uma operação normal da linha ou como algum tipo de falta conhecida. Neste caso, as faltas conhecidas são obtidas através de um processo de treinamento realizado nas redes, inicialmente. Na classificação das faltas é empregada

uma rede lógica, que determina o tipo de falta presente nos sinais analisados, a partir do conhecimento adquirido durante o processo de treinamento.

Os métodos propostos podem ser implementados computacionalmente como um sistema de detecção e classificação de faltas em linhas de transmissão. Para sua aplicação é necessário apenas dispor de dados de treinamento, o que pode ser obtido através de medições de uma linha de transmissão real ou através de simulações do modelo teórico da mesma.

5.2 Introdução

Algoritmos para detecção e classificação de faltas em linhas de transmissão contêm rotinas que lidam com os dados de entrada, desde sua obtenção junto aos registradores instalados nas subestações até o momento de aplicação dos mesmos. As rotinas anteriores ao processo de detecção e classificação de uma falta são de fundamental importância. Quando é feita a gravação pelos registradores, os dados não estão representados de uma forma adequada e, também, não estão com todas as informações necessárias diretamente disponíveis para sua utilização imediata. Neste capítulo, serão descritas as técnicas aplicadas aos dados, desde sua entrada até o momento da aplicação do algoritmo de detecção e classificação de faltas.

A detecção e a classificação de faltas em linhas de transmissão são procedimentos auxiliares à proteção das linhas. Cabe à proteção, a responsabilidade de tomar a decisão de *trip* com rapidez, sendo o fator tempo, de fundamental importância nesse processo. Essas duas funções compartilham de aspectos comuns em seus algoritmos e se complementam na busca do objetivo final. Os algoritmos de detecção e classificação de faltas em linhas de transmissão servem de subsídios aos operadores do sistema elétrico, para que esses sejam capazes de conhecer melhor as contingências do mesmo e propiciarem a atuação de uma proteção mais confiável e com mais rapidez.

Os programas de detecção e classificação de faltas podem operar de forma automática, ou seja, a partir da leitura dos arquivos de entrada fornecer o momento de ocorrência da falta e o tipo da mesma. A experiência, porém, tem mostrado que cem por cento de acerto ainda

é um objetivo a ser alcançado. Sendo a detecção e a classificação procedimentos *off-line*, é possível ao operador ter uma confirmação visual, através das ondas plotadas, bem como intervir, se necessário, caracterizando um procedimento semiautomático.

Os estágios de um algoritmo de detecção e classificação de faltas podem variar conforme as informações requeridas pelo mesmo. Desta forma, pode não haver necessidade de treinar a rede novamente, uma vez que já forem utilizados casos para o treinamento inicial. A seguir, são descritas as rotinas de pré-processamento para o algoritmo utilizado, conforme Figura 5.1.



Figura 5.1: Etapas desenvolvidas no algoritmo de detecção e classificação de faltas.

O ponto inicial é a obtenção dos dados digitalizados de tensão e corrente. Os passos seguintes envolvidos no processo são: determinação do instante da falta, pré condicionamento dos sinais de entrada, estimação dos fasores fundamentais, treinamento da rede e, finalmente, o método de redes neurais artificiais para classificação do tipo de falta ocorrida.

5.3 Entrada dos Dados de Tensão e Corrente

Os dados relativos às tensões e correntes do sistema elétrico monitorado são obtidos de um arquivo. No caso de faltas simuladas, pode ser um arquivo ASCII do tipo ".out" de saída do ATP ou em formato semelhante como, por exemplo, no padrão COMTRADE [33], resultantes de dados reais oscilografados. Desses arquivos, devem ser previamente removidas as linhas referentes aos dados de entrada e quaisquer comentários, mantendo um mesmo intervalo de amostragem, como exposto a seguir, ao ser apresentada parte de um arquivo de dados de entrada.

Ν	t	va	vb	VC	ia	ib	ic
0	0.0	29.022652	-296.04362	269.671622	.265322127	.014869371	27174764
1	.1E-4	30.2402438	-296.57095	268.986569	.26455126	.016172086	27234721
2	.2E-4	31.4573799	-297.0956	268.299272	.263776924	.017471591	27294019
3	.3E-4	32.6740683	-297.61603	267.608164	.262998839	.018770848	2735293
4	.4E-4	33.8902919	-298.13224	266.913253	.262217016	.020069839	27411452
5	.5E-4	35.1060338	-298.64421	266.214549	.261431467	.021368544	27469585
6	.6E-4	36.3212768	-299.15193	265.512063	.260642202	.022666946	27527327

A primeira coluna se refere aos instantes, a segunda, aos tempos (em segundos), da terceira à quinta, tensões de fase (em kV) e da sexta à oitava, correntes (em kA). Do ponto de vista de detecção e classificação de faltas, as tensões e correntes podem estar em qualquer unidade, desde que compatíveis, ou seja, kV - kA, V - A, pu - pu. Neste trabalho foi considerado um $\Delta t = 1x10^{-5} = 100 \mu s$, logo fa = 100000 Hz = 100 kHz. Onde Δt é o período adotado e fa a frequência de amostragem.

5.4 Detecção de Faltas

Na etapa de detecção de faltas, conforme mencionado anteriormente, foi utilizada a Transformada Wavelet. Para a implementação dessa Transformada é de fundamental importância definir a wavelet mãe a ser utilizada e o nível de decomposição a que o sinal será submetido. Foram feitas várias simulações computacionais para sinais de tensão e corrente com diferentes configurações, tais como: tipo, localização, resistência e ponto de falta. Para essas simulações foram utilizadas as wavelets mãe: db4, db8, symlet8 e coiflet5 e níveis de decomposição de 1 a 8. Além da determinação da wavelet mãe e do nível de decomposição escolhidos para aplicação da Transformada Wavelet, essas simulações também tiveram como objetivo a determinação do valor prefixado (*pickup*) para detecção do instante da falta. Ao final dessas simulações foram escolhidos o valor de *pickup* de 0,7 pu, a wavelet mãe db4 e o nível 3 de decomposição alcançaram tempos de falta com mais constância e eficiência, respectivamente, para serem implementados na Transformada Wavelet. O valor prefixado de 0,7 pu foi capaz de detectar todas as faltas simuladas. Essas simulações são apresentadas no capítulo de resultados.

As conclusões a respeito das definições da wavelet mãe e do nível de decomposição utilizados estão exemplificadas de forma resumida nas Tabela 5.1 e Tabela 5.2 a seguir. Nelas é possível observar os tempos de falta obtidos para as wavelets mãe e níveis de decomposição considerados para os sinais de tensão e corrente simulados. Esses sinais são provenientes de uma linha de transmissão de 13,8 kV, com SIR (*source impedance ratio*) 1, curto trifásico, falta ocorrida a 90 % do comprimento da linha, com impedância de falta de 5 ohms.

Tempo Real Esperado: 66,46 ms												
		V	а			V	b			Vc		
	Sym8	Coif5	db4	db8	Sym8	Coif5	db4	db8	Sym8	Coif5	db4	db8
cD1	67,7	67,7	67,8	67,7	67,7	67,7	67,7	67,7	67,7	67,7	67,7	67,7
cD2	67,7	67,7	67,7	67,7	67,7	67,7	67,8	67,7	67,7	67,7	67,8	67,7
cD3	67,8	67,7	67,7	70,2	67,8	67,7	67,7	67 <i>,</i> 8	67,8	67,7	67,7	67,8
cD4	67,8	67,8	67,7	67,8	67,8	67,8	70,1	67,8	67,8	67,8	70,1	67,8
cD5	70,5	68,0	67,9	68,0	68,0	68,0	67,9	68,0	68,0	68,0	67,9	68,0
cD6	68,1	68,7	67,8	68,1	68,1	71,0	70,3	68,7	68,1	71,0	68,5	68,7
cD7	68,2	69,3	67,7	68,2	68,2	69,3	67,7	68,2	68,2	69,3	71,4	68,2
cD8	74,0	74,1	71,5	74,0	71,9	70,7	69,2	71,9	69,9	70,7	69,2	71,9

Tabela 5.1: Tempos de falta detectados a partir da simulação de ondas de tensão.

Tabela 5.2: Tempos de falta detectados a partir da simulação de ondas de corrente.

Tempo Real Esperado: 66,46 ms												
		la	1			lb)			lc		
	Sym8	Coif5	db4	db8	Sym8	Coif5	db4	db8	Sym8	Coif5	db4	db8
cD1	67,7	67,7	67,8	67,7	67,7	67,7	67,7	67,7	67,7	67,7	67,7	67,7
cD2	67,7	67,7	67,7	67,6	67,7	67,7	67,8	67,6	67,7	67,7	67,8	67,6
cD3	67,8	70,2	67,7	67,7	67,8	67,8	67,7	67,7	67,8	67,8	67,7	67,7
cD4	67,8	70,2	67,7	70,2	67,8	68,0	67,7	70,2	67,8	68,0	67,7	70,2
cD5	68,0	68,0	67,9	70,5	68,0	70,5	70,4	70,5	68,0	70,5	70,4	70,5
cD6	70,5	68,7	67,8	68,1	68,1	68,7	67,8	68,1	68,1	68,7	67,8	68,1
cD7	68,2	71,4	71,4	69,3	69,3	69,3	69,0	69,3	68,2	69,3	69,0	69,3
cD8	69,9	70,7	69,2	69,9	69,9	74,1	73,8	74,0	74,0	74,1	71,5	74,0

Nas tabelas acima é possível observar que a db4 apresentou tempos mais próximos do valor real para mais níveis de decomposição, tanto para os sinais de tensão quanto para os de corrente. Além disso, é possível constatar que o nível 3 de decomposição dos sinais mantém os melhores tempos obtidos para todos os sinais da db4.

Uma vez obtidas as características do coeficiente de nível 3 dos sinais de tensão e corrente por meio da wavelet mãe db4, essas foram armazenadas em vetores e, seus valores de *pickup* foram comparados ao valor de 0,7 pu. O resultado dessa comparação possibilita a detecção da falta no momento da sua ocorrência.

5.4.1 Detecção de Faltas Para Casos Reais

Para os casos reais analisados neste trabalho, em sua maior parte, trata-se de sinais com baixa taxa de amostragem, se comparados aos casos simulados. Esse fato dificulta a detecção de faltas, uma vez que esses sinais são decompostos em AMR e adquirem frequências ainda menores que a original.

Para solucionar este problema, após a aplicação da Transformada Wavelet nos sinais amostrados, é calculada a energia contida nos detalhes Wavelet, segundo Teorema de Parseval apresentado no item 3.5 deste trabalho. Dessa forma, o valor de *pickup* anteriormente estabelecido, será comparado com o valor da energia, em pu, do coeficiente de maior contribuição. Tal fato pode ser visto na Figura 5.2 e Figura 5.3 a seguir.



Figura 5.2: Decomposição do sinal de tensão em primeiro nível.



Figura 5.3: Energia dos coeficientes do sinal de tensão.

5.5 Filtragem Passa-baixa

Os valores pós-falta de corrente e tensão podem apresentar transitórios de altas frequências, que conduzem a erros na classificação da falta [4]. Assim, antes de qualquer processamento nos sinais de entrada da etapa de classificação da falta, é essencial um correto pré-processamento desses dados. A tarefa inicial é, então, uma filtragem passabaixa, sendo o filtro utilizado o de Butterworth de 2a ordem, em razão de sua simplicidade, efetividade e por ser um dos mais utilizados na área, com frequência de corte de 100 Hz [34]. Na Figura 5.4, mostra-se a amplitude da resposta em frequência do filtro empregado, para os dados com uma frequência de amostragem de 960 (16 x 60) Hz, valor adotado por diversos fabricantes de relés. Na prática, os dados de entrada são recebidos de diversas linhas e podem ter taxas de amostragem diferentes, dependendo das características do equipamento utilizado ou do valor escolhido para gravação do arquivo em dados simulados. Na Figura 5.5 são mostradas as tensões de fase em uma linha trifásica onde ocorreu uma falta fase-terra do tipo AT (Fase A-Terra) e as mesmas filtradas. Nessa figura, é possível verificar a eliminação das altas frequências das tensões.



Figura 5.4: Resposta em frequência para um filtro de Butterworth de ordem 2.



Figura 5.5: Ondas de tensão de entrada e filtradas para um curto-circuito AT.

5.6 Interpolação dos Dados Filtrados

As rotinas de programa posteriores ao processo da filtragem necessitam de dados amostrados a uma frequência igual a

$$f_a = NPC f_0 \tag{5.1}$$

onde NPC representa o número de pontos amostrados por ciclo da frequência fundamental e f0, a frequência fundamental. Os dados podem, conforme a origem, ter diferentes taxas de amostragem. Assim é feita uma normalização da taxa, padronizando-a em 960 Hz, ou 16 pontos por ciclo, através de uma interpolação linear nos dados filtrados. Na Figura 5.6, apresenta-se uma onda de tensão filtrada, com uma frequência de amostragem de 4000 Hz, e a onda obtida por interpolação com frequência de amostragem de 960 Hz, NPC = 16.



Figura 5.6: Ondas de corrente original e a obtida por interpolação.

5.7 Estimação dos Fasores Fundamentais

Os valores de corrente e tensão das ondas pós-falta podem apresentar componente contínua e, mesmo após a filtragem passa-baixa, ter algum conteúdo harmônico. A classificação de faltas, utilizando informações provenientes da frequência fundamental, requer uma correta extração dos fasores fundamentais das ondas de entrada, de modo a não influenciar negativamente os resultados, obtendo-se um maior grau de precisão na classificação da falta.

Para a tarefa de estimação dos fasores fundamentais, foi escolhida uma variação [34] do método dos erros mínimos quadrados de Sachdev & Baribeau [35]. Nesta abordagem, para determinação dos fasores foram considerados os sinais de entrada de tensão e corrente, formados por uma exponencial decrescente e onda senoidal fundamental da forma:

$$y(t) = a_0 e^{-t/\tau} + a_1 sen(\omega_0 t + \phi_1) + v'(t)$$
(5.2)

Onde ϕ_1 é o ângulo de fase, ω 0 é a frequência angular fundamental e v'(t), o erro cometido ao se aproximarem as amostras pela função composta da exponencial e da senóide. Em seguida, foram consideradas aproximações polinomiais para a exponencial decrescente, através da série de Taylor, como apresentado na Equação (5.3):

$$e^{-t/\tau} = 1 - \frac{t}{\tau} + \frac{1}{2!} \left(\frac{t}{\tau}\right)^2 - \frac{1}{3!} \left(\frac{t}{\tau}\right)^3 + \dots$$
(5.3)

Truncando-se a série de Taylor no segundo termo e substituindo o resultado obtido em (5.2), tem-se:

$$y(t) = a_0 - \left(\frac{a_0}{\tau}\right)t + a_1 sen(\omega_0 t + \phi_1) + v(t)$$
(5.4)

onde v(t) é o erro v'(t) anterior mais o erro que se cometeu ao considerar apenas as duas primeiras parcelas da expansão de Taylor.

Reescrevendo-se a Equação (5.4) de outra maneira, chega-se em:

$$y(t) = a_0 + a_1 \cos\phi_1 \operatorname{sen}(\omega_0 t) + a_1 \operatorname{sen}\phi_1 \cos(\omega_0 t) - \left(\frac{a_0}{\tau}\right)t + v(t)$$
(5.5)

ou ainda

$$y(t) = \theta_1 + \theta_2 sen(\omega_0 t) + \theta_3 cos(\omega_0 t) + \theta_4 t + v(t)$$
(5.6)

onde os coeficientes de $\,\theta_{\scriptscriptstyle 1}$ a $\,\theta_{\scriptscriptstyle 4}\,{\rm correspondem}\,{\rm a}$

$$\theta_{1} = a_{0}$$

$$\theta_{2} = a_{1} \cos \phi_{1}$$

$$\theta_{3} = a_{1} \sin \phi_{1}$$

$$\theta_{4} = -a_{0} / \tau$$
(5.7)

A função y(t) expressa em (5.6) pode ser escrita na forma matricial como

$$y(t) = \overline{x}^{T}(t) \cdot \overline{\theta} + v(t)$$
(5.8)

sendo \bar{x} o vetor de regressores e $\bar{\theta}$ o vetor de coeficientes, dados por

$$\overline{x}^{T}(t) = \begin{bmatrix} 1 & sen\omega_0 t & \cos\omega_0 t & t \end{bmatrix}$$
(5.9)

$$\boldsymbol{\theta}^{'} = \begin{bmatrix} \theta_1 & \theta_2 & \theta_3 & \theta_4 \end{bmatrix}$$
(5.10)

Em (5.8), tomando-se m amostras y(tk) = yk em instantes discretos tk = k Δ t, o vetor $\overline{x}^{T}(t)$ torna-se $\overline{x}^{T}(t_{k})$. Colocando na forma matricial, as m equações podem ser escritas para o instante k na forma

y _k	1	$sen \omega_0 t_k$	$\cos \omega_0 t_k$	t _k	
<i>Уk</i> −1	1	$sen \omega_0 t_{k-1}$	$\cos \omega_0 t_{k-1}$	t_{k-1}	
<i>Уk</i> -2	1	$sen \omega_0 t_{k-2}$	$\cos \omega_0 t_{k-2}$	t_{k-2}	
<i>Уk</i> -3	1	$sen \omega_0 t_{k-3}$	$\cos \omega_0 t_{k-3}$	t_{k-3}	$\left \begin{array}{c} \theta_{1} \\ \theta_{2} \end{array} \right $
Ук-4	= 1	$sen \omega_0 t_{k-4}$	$\cos \omega_0 t_{k-4}$	t_{k-4}	$\left \begin{array}{c} \theta_2\\ \theta_3\end{array}\right $
<i>Уk</i> -5	1	$sen \omega_0 t_{k-5}$	$\cos \omega_0 t_{k-5}$	t_{k-5}	$\begin{bmatrix} 0 \\ \theta_4 \end{bmatrix}$
Ук-6	1	$sen \omega_0 t_{k-6}$	$\cos \omega_0 t_{k-6}$	t_{k-6}	
:	:	:	÷	÷	
$y_{k-(m-1)}$	1	$sen \omega_0 t_{k-(m-1)}$	$\cos \omega_0 t_{k-(m-1)}$	$t_{k-(m-1)}$	

(5.11)

e no instante k+1, tem-se

$\begin{bmatrix} y_{k+1} \end{bmatrix}$	[1	$sen\omega_0 t_{k+1}$	$\cos \omega_0 t_{k+1}$	t_{k+1}]	
Уk	1	$sen\omega_0 t_k$	$\cos \omega_0 t_k$	t_k		
<i>yk</i> –1	1	$sen\omega_0 t_{k-1}$	$\cos \omega_0 t_{k-1}$	t_{k-1}		
<i>y</i> _{<i>k</i>-2}	1	$sen\omega_0 t_{k-2}$	$\cos \omega_0 t_{k-2}$	t_{k-2}	$\begin{bmatrix} \theta_1 \\ 0 \end{bmatrix}$	
<i>y</i> _{<i>k</i>-3}	= 1	$sen \omega_0 t_{k-3}$	$\cos \omega_0 t_{k-3}$	t_{k-3}	$\begin{bmatrix} \theta_2 \\ \theta_3 \end{bmatrix}$	
<i>Уk</i> -4	1	$sen \omega_0 t_{k-4}$	$\cos \omega_0 t_{k-4}$	t_{k-4}	$\left \begin{array}{c} \theta_{3} \\ \theta_{4} \end{array} \right $	
y_{k-5}	1	$sen \omega_0 t_{k-5}$	$\cos \omega_0 t_{k-5}$	t_{k-5}		
:	1:	÷	÷	:		
$y_{k-(m-2)}$	1	$sen \omega_0 t_{k-(m-2)}$	$\cos \omega_0 t_{k-(m-2)}$	$t_{k-(m-2)}$		
	L .				-	

ou seja,

$$\underbrace{\overline{Y}}_{(mx1)} = \underbrace{X}_{(mx4)} \cdot \underbrace{\overline{\theta}}_{(4x1)}$$
(5.13)

onde \overline{Y} é o vetor das amostras conhecidas, \widetilde{X} a matriz dos regressores e $\overline{\theta}$ o vetor dos coeficientes desejados. A solução, para um número de amostras maior que o número de coeficientes, pode ser obtida pelo método da pseudo-inversa [36] [37], determinando-se assim o vetor dos coeficientes $\overline{\theta}$ expresso por:

$$\overline{\theta} = \left(\tilde{X}^T \cdot \tilde{X}\right)^{-1} \cdot \tilde{X}^T \cdot \overline{Y}$$
(5.14)

O fasor associado à fundamental é calculado através dos coeficientes θ_2 e θ_3 , dados por:

$$Y = \theta_2 + j\theta_3 = |Y|e^{j\alpha}$$
(5.15)

Na Figura 5.7, é mostrada a resposta em frequência do filtro de mínimos quadrados, para a janela de dados de um ciclo, 16 pontos por ciclo, considerando os dois primeiros termos da componente contínua e os termos da fundamental.



Figura 5.7: Resposta em frequência do filtro dos erros mínimos quadrados.

Na Figura 5.8 e Figura 5.9, são mostradas a amplitude e a fase dos fasores estimados a partir da falta real, plotada na Figura 5.7.



Figura 5.8: Ondas de tensão e corrente de uma falta real, após aplicação do filtro passa-baixa.



Figura 5.9: Amplitude e fase dos fasores estimados a partir das ondas de tensão da Figura 5.7.



Figura 5.10: Amplitude e fase dos fasores estimados a partir das ondas de corrente da Figura 5.7. Nota-se, nestas figuras, que os valores estimados durante o período de tempo subsequente ao curto-circuito apresentam oscilações e comportamento muitas vezes não esperado, principalmente devido ao fato de a janela de dados apresentar valores pré e pós-falta, comprometendo as estimativas.

5.8 Classificação de Faltas

Esta etapa classifica os distúrbios através da utilização de redes neurais artificiais. Ao final desta, o resultado obtido deve ser a classificação correta do distúrbio presente no sinal analisado. Para se chegar a este objetivo, é necessário treinar a rede neural para que ela atinja, de forma eficiente, os resultados esperados.

Conforme mencionado, anteriormente, na etapa de detecção de faltas foram realizadas várias simulações alterando-se o tipo, localização, resistência e ponto de falta. Cada uma dessa simulação apresentou um tempo de falta detectado. Esses tempos foram armazenados em um vetor para serem usados, em seguida, tanto no treinamento da rede neural, quanto para a classificação das faltas.

De posse dos tempos de falta, foi consolidada, por meio de várias simulações, uma rede neural robusta e eficiente, cuja configuração apresenta 08 neurônios na camada de entrada, 06 na camada intermediária e 04 na camada de saída.

Para a fase de treinamento da rede neural, foram utilizados 280 sinais de falta simulados, com suas respectivas identificações, dentre elas: faltas fase-terra (AT, BT e CT), fase-fase (AB, BC e CA); fase-fase-terra (ABT, BCT e CAT) e trifásica (ABC).

Em seguida, todos esses sinais de corrente e tensão de falta, foram separados em pré e pós falta, através da comparação do tempo de simulação dos sinais com os tempos de falta detectados e armazenados em um vetor. Para o treinamento da rede neural foram utilizados os sinais pré e pós falta, enquanto que para a classificação dos sinais analisados, somente os sinais pós falta foram considerados.

Outra importante fase na etapa de treinamento da rede é o preenchimento dos *targets* de falta, ou alvos, a serem alcançados. Para tanto, foram montadas matrizes onde -1 indica fase não faltosa e 1, o contrário. Para cada tipo de falta há uma matriz com seus alvos correspondentes.

Enquanto todas as 280 simulações de falta foram consideradas para o treinamento, ao alcançar a simulação 280 foi criada a rede neural. A rede criada recebe os sinais de pré e pós falta e os analisa em relação aos *targets* informados. O resultado dessas análises permite

saber se os alvos foram alcançados. Caso esses não tenham sido alcançados, é necessário melhorar a interação entre os neurônios e, portanto, alterar a quantidade dos mesmos para as diferentes camadas, ou até mesmo, alterar o número de camadas. Este é um trabalho de ajuste que pode aumentar em algumas horas o tempo de simulação do programa. O ideal nesse caso é alcançar uma rede neural capaz de detectar os sinais a serem analisados, porém, com uma certa quantidade de casos simulados que contenha amostras de todos os tipos de faltas, mas que não aumente tanto o tempo de simulação, ou seja, uma rede eficiente e concisa.

Após treinada a rede, é possível salvá-la para os casos de classificação de faltas. Nesta etapa, são utilizados somente os sinais pós falta. Esses sinais são enviados à rede neural e a mesma fornece como resposta o diagnóstico da falta com base na lógica apresentada na Tabela 5.3.

Índice de Falta	Saída Fase A	Saída Fase B	Saída Fase C	Saída Neutro	Diagnóstico da Falta
1	0,5 a 1	-0,5 a -1	-0,5 a -1	0,5 a 1	Curto-circuito AT
2	-0,5 a -1	0,5 a 1	-0,5 a -1	0,5 a 1	Curto-circuito BT
3	-0,5 a -1	-0,5 a -1	0,5 a 1	0,5 a 1	Curto-circuito CT
4	0,5 a 1	0,5 a 1	-0,5 a -1	-0,5 a -1	Curto-circuito AB
5	-0,5 a -1	0,5 a 1	0,5 a 1	-0,5 a -1	Curto-circuito BC
6	0,5 a 1	-0,5 a -1	0,5 a 1	-0,5 a -1	Curto-circuito CA
7	0,5 a 1	0,5 a 1	-0,5 a -1	0,5 a 1	Curto-circuito ABT
8	-0,5 a -1	0,5 a 1	0,5 a 1	0,5 a 1	Curto-circuito BCT
9	0,5 a 1	0,5 a 1	0,5 a 1	0,5 a 1	Curto-circuito CAT
10	0,5 a 1	0,5 a 1	0,5 a 1	-0,5 a -1	Curto-circuito ABC
11	-0,5 a -1	-0,5 a -1	-0,5 a -1	-0,5 a -1	Sem Falta

Tabela 5.3: Lógica de diagnóstico das faltas.

Neste trabalho, foram analisados 60 casos simulados e 04 casos reais. Os casos simulados foram agrupados, inicialmente, por tipo de falta e, cada um desses grupos foi enviado à rede, separadamente. Em seguida, todos os 60 casos simulados foram enviados à rede neural para classificação. Os resultados obtidos são apresentados no capítulo seguinte.

6 Resultados

Neste capítulo, são apresentados os resultados obtidos com a implementação dos métodos de detecção e classificação de faltas em linhas de transmissão propostos neste trabalho. Conforme apresentado no capítulo anterior, esses métodos utilizam sinais extraídos de uma linha de transmissão para obtenção de informações sobre as mesmas, de forma que seja possível realizar um diagnóstico do sistema. Normalmente, em uma linha de transmissão, esses sinais são obtidos através de registradores oscilográficos instalados ao longo da mesma. Entretanto, dada a grande quantidade e variedade de dados necessários para o treinamento de uma rede neural eficiente, o processo de aquisição de dados reais para este trabalho torna-se inviável. Para a avaliação dos métodos propostos, optou-se por analisar casos simulados e reais. Os casos reais foram obtidos junto a Companhia Energética de Minas Gerais (CEMIG) e as simulações foram feitas em software por meio de um modelo de SEP. Utilizando esse modelo, foram realizadas simulações de diversos cenários de falta, variando-se tanto parâmetros do sistema, quanto condições da falta. Para simulação do SEP foi utilizado o software ATP, no qual os sinais extraídos da linha durante as simulações foram exportados e armazenados em uma base de dados para utilização posterior. Os algoritmos dos métodos de detecção e classificação de faltas foram implementados utilizando o software MATLAB e, utilizando a base de dados das faltas simuladas, o desempenho dos algoritmos foi avaliado a partir dos resultados obtidos.

6.1 Modelo utilizado

O modelo de SEP utilizado para realizar as simulações de faltas em linhas de transmissão é mostrado na Figura 6.1. O sistema consiste de duas fontes de 345 kV interligadas por uma linha de transmissão de 400 km de comprimento e frequência nominal do sistema de 60 Hz. Considera-se que os sinais de tensão e corrente trifásicos da linha são medidos no barramento 1.



Figura 6.1: Modelo de SEP utilizado para simulações de faltas.

As faltas consideradas neste sistema são do tipo curto-circuito. Elas podem ocorrer em qualquer ponto da linha, entre os barramentos 1 e 2. Na ocorrência de uma falta tipo curtocircuito entre fases, a resistência entre os pontos de falta é baixa, geralmente menor que 5 Ω . Na ocorrência de uma falta que envolva a terra, ao contrário, a resistência entre os pontos da falta é alta, podendo atingir valores de 120 Ω .

6.2 Simulações no ATP

Nas simulações realizadas foi utilizada uma linha de transmissão trifásica de 345 kV. A geometria desta linha, assim como o circuito simulado são apresentados na Figura 6.2 e Figura 6.3. Além disso, os parâmetros desta linha e os dados das fontes simuladas nos casos em estudo estão evidenciados nas Tabela 6.1 eTabela 6.2 a seguir.



Figura 6.2: Geometria da linha de 345 kV.

	Se	quência Positi	va	Sequência Zero			
Linha	r ₁ (ohm/km)	x ₁ (ohm/km)	c₁ (nF/km)	r _o (ohm/km)	x ₀ (ohm/km)	c₀ (nF/km)	
345 kV	0,031432	0,3649	12,05	0,423463	1,2515	7,786	





Figura 6.3: Circuito simulado no ATP.

Tabela 6.2: Dados das fontes utilizadas nas faltas simuladas

Linha	Terminal	Sequência Positiva (ohms)	Sequência Zero (ohms)
345 kV	Local	6,5+j150,8	6,5+j150,8
	Remoto	6,5+j150,8	6,5+j150,8

Com as formulações dos parâmetros de interesse devidamente estabelecidas, foram realizadas diversas simulações computacionais (através do ATP) que permitiram uma série de análises de sensibilidade.

• Tipo de faltas simuladas:

- 1 = falta AT;
- 2 = falta BT;
- 3 = falta CT;
- 4 = falta AB;
- 5 = falta BC;
- 6 = falta CA;
- 7 = falta ABT;
- 8 = falta BCT;
- 9 = falta CAT;
- 10 = falta ABC.

As faltas simuladas foram organizadas em vários cenários. Cada cenário corresponde à simulação de um tipo de falta: fase-terra, fase-fase, fase-fase-terra ou trifásica com valores específicos para as seguintes variáveis:

- distância de falta;
- resistência de falta;
- instante de falta.

A distância da falta em relação ao barramento 1 foi variada de 10 % a 90 % do comprimento total da linha, em intervalos de 20 %. Para as faltas tipo curto-circuito entre fases, as resistências de falta utilizadas foram de 0 Ω , 01 Ω e 05 Ω . Para faltas tipo fase-terra e fasefase-terra foram utilizadas resistências de falta no valor de 0 Ω , 30 Ω e 100 Ω . O instante da falta foi analisado para os valores máximo e mínimo de tensão. Foram simulados dez tipos de falta tipo curto-circuito: seis entre fases e terra (AT, BT, CT, ABT, BCT, CAT) e quatro entre fases (AB, BC, CA, ABC), resultando num total de 10 tipos de faltas diferentes.

Em cada falta simulada, os sinais de tensão e corrente trifásicos da linha foram medidos no barramento 1 através de um componente de medição, que automaticamente realiza a amostragem e armazenamento dos dados em arquivo. A frequência de amostragem escolhida foi de 960 Hz, o que corresponde a 16 amostras/ciclo na frequência de operação da linha (60Hz). Da Figura 6.4 à Figura 6.13 são mostrados exemplos de cada tipo de falta simulada no sistema, onde podem ser visualizados os sinais de tensão e corrente medidos na linha de transmissão.



Figura 6.4: Simulação de falta tipo curto-circuito fase AT.



Figura 6.5: Simulação de falta tipo curto-circuito fase BT.


Figura 6.6: Simulação de falta tipo curto-circuito fase CT.



Figura 6.7: Simulação de falta tipo curto-circuito fases ABT.



Figura 6.8: Simulação de falta tipo curto-circuito fases BCT.



Figura 6.9: Simulação de falta tipo curto-circuito fases CAT.



Figura 6.10: Simulação de falta tipo curto-circuito fases AB.



Figura 6.11: Simulação de falta tipo curto-circuito fases BC.



Figura 6.12: Simulação de falta tipo curto-circuito fases CA.



Figura 6.13: Simulação de falta tipo curto-circuito fases ABC.

6.3 Implementações no MATLAB

Para realizar a detecção e classificação de faltas no modelo de SEP utilizado, foi implementado no MATLAB um sistema composto de duas etapas: uma de detecção e outra

de classificação, utilizando os métodos propostos neste trabalho. A estrutura do sistema é mostrada na Figura 6.14.



Figura 6.14: Estrutura implementada do sistema para detecção e classificação de faltas.

Na etapa de detecção dos sinais de falta foi utilizada a *Toolbox* correspondente à Transforma Wavelet do MATLAB. Os dados necessários à detecção consistem nas amostras de tensão e corrente de fase, medidas no barramento 1. A etapa de detecção fornece na sua saída um vetor contendo os tempos de ocorrência das faltas. Na etapa de classificação das faltas foi implementada uma rede neural artificial. A entrada desta rede apresenta amostras de tensão e corrente das linhas de transmissão sob estudo, além do vetor com os tempos de falta obtidos na etapa de detecção. O resultado proveniente da etapa de classificação das faltas em análise.

6.4 Resultados da Etapa de Detecção de Faltas

Conforme mencionado anteriormente, no item 5.4, para a etapa de detecção das faltas, foram necessárias várias simulações computacionais para definições da wavelet mãe, nível de decomposição da Transformada Wavelet e valor de *pickup* das ondas. Após essas simulações, foi possível obter as definições necessárias para a implementação da Transformada Wavelet. Essas simulações são mostradas a seguir.

6.4.1 Curto-circuito na fase A; impedância de falta: 0 Ω ; wavelet mãe: db4









6.4.2 Curtos-circuitos nas fases A e B; impedância de falta: 10 Ω ; wavelet mãe: db4







Figura 6.18: Tensão na Fase B.









6.4.3 Curtos-circuitos nas fases A, B e C; impedância de falta: 10 $\Omega;$ wavelet mãe: db4







Figura 6.22: Tensão na Fase B.

















6.4.4 Curto-circuito na fase A; impedância de falta: 0 Ω ; wavelet mãe: db8







Figura 6.28: Corrente na Fase A.

6.4.5 Curtos-circuitos nas fases A e B; impedância de falta: 10 Ω ; wavelet mãe: db8







Figura 6.30: Tensão na Fase B.













Figura 6.34: Tensão na Fase B.

















6.4.7 Curto-circuito na fase A; impedância de falta: 0 Ω ; wavelet mãe: coiflet5







Figura 6.40: Corrente na Fase A.

6.4.8 Curtos-circuitos nas fases A e B; impedância de falta: 10 Ω ; wavelet mãe: coiflet5







Figura 6.42: Tensão na Fase B.









6.4.9 Curtos-circuitos nas fases A, B e C; impedância de falta: 10 $\Omega;$ wavelet mãe: coiflet5







Figura 6.46: Tensão na Fase B.

















6.4.10 Curto-circuito na fase A; impedância de falta: 0 Ω ; wavelet mãe: symlet8







Figura 6.52: Corrente na Fase A.

6.4.11 Curtos-circuitos nas fases A e B; impedância de falta: 10 $\Omega;$ wavelet mãe: symlet8







Figura 6.54: Tensão na Fase B.





























Figura 6.61: Corrente na Fase B.





Com base nas simulações apresentadas anteriormente e nos valores de tempo obtidos nos instantes dessas faltas, observou-se que todas as wavelets mães utilizadas foram capazes de detectar as faltas simuladas.

Para os tempos de falta encontrados nos sinais de tensão e corrente, os níveis de decomposição 1, 2, 3 e 4 dos sinais apresentaram melhores desempenhos, sendo o nível 3 o mais eficiente dentre esses e o nível 8 o menos preciso.

Quanto às wavelets mãe, symlet8 e coiflet5 obtiveram os piores resultados na detecção, tanto para os sinais de corrente quanto para os de tensão. Porém, a db4 mostrou-se mais eficiente e consistente com os tempos detectados para esses mesmos sinais. Os valores de *pickup* considerados nas detecções desses sinais analisados variaram de 0,5 a 1 pu. Com 0,7 pu foi possível obter, em todos os sinais analisados, os valores de tempo mais próximos daqueles simulados.

Portanto, wavelet mãe db4, nível de decomposição 3 e valor de *pickup* de 0,7 pu foram os dados considerados para a implementação da Transformada Wavelet e detecção dos tempos de falta.

6.5 Resultados da Etapa de Classificação de Faltas

A etapa de classificação das faltas foi realizada em dois momentos: um para casos simulados em *software* e o outro para casos reais de sinais de tensão e corrente obtidos de uma concessionária brasileira - CEMIG.

6.5.1 Casos Simulados

O sistema de detecção e classificação de faltas apresentado na seção anterior foi avaliado utilizando, inicialmente, os dados obtidos nas simulações realizadas. Foram considerados 10 tipos de faltas (tipos curto-circuito) simuladas sob diversas condições (distância da falta, resistência de falta, posição da falta). As faltas foram organizadas em cenários, onde cada cenário contém uma simulação de todos os tipos de falta em uma dada condição, resultando num total de 340 simulações. O conjunto total de dados foi dividido em um conjunto de dados para treinamento e um conjunto de dados para validação, correspondendo a, aproximadamente, 80 % e 20 % do total, respectivamente.

Para permitir melhor análise dos resultados obtidos, esses foram divididos em grupos, onde cada grupo consiste dos resultados dos testes aplicados às faltas de um mesmo tipo. E, no final, foi realizada uma única simulação com todas as 60 faltas a serem classificadas. Os grupos são os seguintes:

- Grupo 1: Faltas tipo curto-circuito fase-terra (AT, BT, CT).
- Grupo 2: Faltas tipo curto-circuito fase-fase-terra (ABT, BCT, CAT).
- Grupo 3: Faltas tipo curto-circuito fase-fase (AB, BC, CA).

- Grupo 4: Falta tipo curto-circuito trifásico (ABC).
- Grupo 5: Todas as 60 faltas simuladas.

Nos testes com cada grupo, foi avaliado o desempenho do sistema de detecção e classificação de falta, sendo medido o percentual de faltas não detectadas, faltas detectadas mas não classificadas corretamente, faltas detectadas e classificadas corretamente, em relação ao total de faltas simuladas. As tabelas a seguir apresentam os resultados obtidos.

• Testes com o grupo 1:

Faltas		Média	Un				
	15%	35 %	55%	70%	90%	Wieula	OII.
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / classificadas	100,0	100,0	100,0	100,0	100,0	100,0	%

Tabela 6.3: Resultados dos testes com o grupo 1.

• Testes com o grupo 2:

Faltas		Mádia	Un				
	15%	35 %	55%	70%	90%	Wieula	OII.
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / classificadas	100,0	100,0	100,0	100,0	100,0	100,0	%

Tabela 6.4: Resultados dos testes com o grupo 2.

• Testes com o grupo 3:

Faltas		Mádia	Un				
	15%	35 %	55%	70%	90%	Weula	011.
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / classificadas	100,0	100,0	100,0	100,0	100,0	100,0	%

Tabela 6.5: Resultados dos testes com o grupo 3.

• Testes com o grupo 4:

Tabela 6	6. Re	sultados	dos	testes	com o	gruno 4
Tubciu 0	.0. nc	Juitados	u05	icsics	como	grupo 4.

Faltas		Mádia	Un				
	15%	35 %	55%	70%	90%	Weula	OII.
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / classificadas	100,0	100,0	100,0	100,0	100,0	100,0	%

• Testes com o grupo 5:

Tabela 6.7: Resultados dos testes com o grupo 5.

Faltas		Mádia	Un				
	15%	35 %	55%	70%	90%	wieula	OII.
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / classificadas	100,0	100,0	100,0	100,0	100,0	100,0	%

Nos resultados acima, observa-se um excelente desempenho obtido pelo sistema de detecção e classificação de faltas implementado neste trabalho.

Os resultados obtidos demonstraram que o sistema apresentou um desempenho promissor e motivador, pois detectou corretamente 100 % das faltas e classificou corretamente 100 % das mesmas. Esses resultados podem ser considerados semelhantes aos melhores resultados obtidos pelos diversos métodos para diagnóstico de faltas em linhas de transmissão encontrados na literatura.

6.5.2 Casos Reais

Diante do bom desempenho do método aplicado para os casos simulados, o mesmo foi, em seguida, testado para casos reais.

Para cada caso real analisado, foi necessário dividir as ondas de tensão e corrente obtidas em trechos, de forma que cada trecho contenha somente um evento, como por exemplo: falta, abertura de disjuntor ou religamento. Cada trecho foi entregue à rede neural e analisado separadamente pela mesma. Ao final dessa análise, o programa apresenta um diagnóstico geral do sistema.

6.5.2.1 Caso 1

Sinais de corrente e tensão, respectivamente, obtidos da CEMIG.





Sinais de corrente e tensão, respectivamente, considerados no trecho de análise.

Figura 6.65: Corrente no trecho de análise – Caso 1.



Figura 6.66: Tensão no trecho de análise – Caso 1.

Tipo de falta classificada pela rede neural: AT.

Tipo de falta informada pela CEMIG: AT, causa: queimada.

6.5.2.2 Caso 2

Sinais de corrente e tensão, respectivamente, obtidos da CEMIG.


Figura 6.68: Tensão – Caso 2.



Sinais de corrente e tensão, respectivamente, considerados no trecho de análise.





Tipo de falta classificada pela rede neural: CT.

Tipo de falta informada pela CEMIG: CT, causa: descarga atmosférica.

6.5.2.3 Caso 3

Sinais de corrente e tensão, respectivamente, obtidos da CEMIG.









Sinais de corrente e tensão, respectivamente, considerados no trecho de análise.









Tipo de falta classificada pela rede neural: BT.

Tipo de falta informada pela CEMIG: BT, causa: descarga atmosférica.

6.5.2.4 Caso 4

Sinais de corrente e tensão, respectivamente, obtidos da CEMIG.



Figura 6.75: Corrente – Caso 4.



Figura 6.76: Tensão – Caso 4.

Sinais de corrente e tensão, respectivamente, considerados no trecho 1 de análise.







Figura 6.78: Tensão no trecho 1 de análise – Caso 4. Tipo de falta classificada pela rede neural: ACT.

Tipo de falta informada pela CEMIG: ACT, causa: descarga atmosférica.







Figura 6.80: Tensão no trecho 2 de análise – Caso 4.

Tipo de falta classificada pela rede neural: sem falta.

Tipo de falta informada pela CEMIG: sem falta.

Conforme mostrado, os 4 casos reais foram classificados de forma correta. Mesmo nos casos onde a falta provocou um aumento das correntes das demais fases não faltosas, a rede neural treinada foi capaz de classificar corretamente o tipo de falta ocorrida e fornecer um diagnóstico confiável.

7 Conclusões e Propostas de Continuidade

7.1 Conclusões

Os problemas decorrentes de faltas no sistema elétrico de potência, em especial nas linhas de transmissão, têm evidenciado a importância do desenvolvimento de metodologias de diagnóstico de faltas eficientes. Consciente dessa importância foi proposta nesta dissertação uma metodologia de detecção e classificação de faltas em linhas de transmissão baseada em técnicas de análise de sinais e inteligência computacional.

Diferente de outras metodologias encontradas na literatura, a metodologia proposta utiliza somente as informações obtidas a partir dos sinais de tensão e corrente medidos na linha para detectar e classificar corretamente faltas tipo curto-circuito fase-terra, fase-fase, fase-fase-terra e trifásico. Este fato representa uma técnica alternativa em relação às metodologias convencionais que necessitam de informações sobre vários parâmetros da linha, como impedância, por exemplo.

Ao longo do trabalho apresentou-se a metodologia para detecção e classificação de faltas em linhas de transmissão dividida em dois métodos: o método de detecção da falta baseado na Transformada Wavelet e o método de classificação da falta baseado na Rede Neural Artificial. Os algoritmos foram implementados na forma de um sistema de detecção e diagnóstico de faltas e o sistema foi avaliado a partir de faltas simuladas e reais em linhas de transmissão. A validação dos algoritmos em sistemas reais garante maior confiabilidade aos métodos desenvolvidos, uma vez que, em condições reais os sistemas não se comportam de maneira uniforme e previsível como nos casos simulados. Eles sofrem influências de uma quantidade maior de variáveis, muitas vezes, não consideradas nas simulações, como por exemplo: tempo de extinção de arcos elétricos, fuga de correntes, falhas nas medições, dentre outras.

Os resultados obtidos demonstraram que o sistema avaliado possui bom desempenho, pois a eficiência na detecção e classificação das faltas foi de 100 %. O percentual de faltas não detectadas pelo sistema foi nulo. Os resultados foram obtidos sob variação dos fatores que influenciam no diagnóstico das faltas: distância, resistência e o ponto de falta. Entretanto, a influência desses fatores foi pouco significativa no sistema avaliado, evidenciando a sua robustez e capacidade de adaptação às variações das condições da falta ou de operação da linha.

Além disso, outro ponto a se destacar nesse trabalho é o pouco número de casos simulados, se comparado aos demais casos presentes nas referências bibliográficas levantadas, para treinar a rede neural considerada. Para a rede neural em questão, foram utilizados 280 casos simulados, enquanto que nas demais referências bibliográficas esse número é de aproximadamente 1000 casos simulados. Essa eficiência é resultado do tratamento dos sinais realizado anteriormente à etapa de detecção.

A abordagem proposta que combina técnicas de análise de sinais e inteligência computacional se mostrou uma alternativa promissora, principalmente dada a sua eficiência na capacidade de identificação e aprendizado das características das faltas. Entretanto, o emprego dessa abordagem exige uma grande quantidade de dados para o seu treinamento, o que normalmente só pode ser obtido através de simulações, visto que a obtenção de dados de faltas reais não é viável.

Sendo assim, conclui-se que a metodologia apresentada neste trabalho é eficiente e promissora, podendo ser aperfeiçoada para viabilizar a sua aplicação em um sistema auxiliar à proteção de linhas de transmissão, incorporada a sistemas de proteção atuais.

7.2 Propostas de Continuidade

De forma a aperfeiçoar a metodologia proposta, aumentando a sua confiabilidade e abrangência de aplicação, propõe-se algumas sugestões de trabalhos a serem realizadas no futuro:

- Aplicação da metodologia proposta para outros casos reais;
- Estudo de outros modelos de redes e tipos de algoritmos de treinamento que possibilitem uma melhoria no custo computacional;
- Identificação de defeitos na atuação do sistema de proteção e do sistema elétrico através da análise oscilográfica.

Referências Bibliográficas

- [1]. Inácio, M. J. Detecção e Classificação de Faltas em Linhas de Transmissão Utilizando Transformada Wavelet e Rede Lógica Neurofuzzy com Aprendizado Participativo. 2010. 104 f. Dissertação (Mestrado em Engenharia elétrica) - Universidade Federal de Minas Gerais (UFMG), Belo Horizonte, 2010.
- [2]. Coury, D. V. Introdução aos Sistemas Elétricos de Potência, Escola de Engenharia de São Carlos (EESP), Universidade de São Paulo (USP), São Carlos, 2002.
- [3]. Horowitz, S. H.; Phadke, A. G., Power System Relaying, Research Studies Press, 3a. Edição, Inglaterra, 2008.
- [4]. Phadke, A. G.; Thorp, J. S., Computer Relaying for Power System, Research Studies Press, 1a. Edição, Nova Iorque, 1988.
- [5]. Bo, Z. Q.; Redfern, M. A.; Weller, G. C. Positional Protection of Transmission Line Using Fault Generated High Frequency Transient Signals, IEEE Transaction on Power Delivery, v. 15, n. 3, p. 888 - 894, Julho 2000.
- [6]. Thorp, J. S.. Digital Relaying. In: Grigsby, L. L. Power System Stability and Control. Boca Raton, FL, USA: CRC Press, 2007. p. 937-942.
- [7]. Kim, C.; Aggarwal, R. Wavelet Transform in Power Systems Part 1: General Introduction to the Wavelet Transform, Power Engineering Journal, v. 14, n. 2, p. 81 87, Abril 2000.
- [8]. Osman, A. H.; Malik, O. P. Protection of Parallel Transmission Lines using Wavelet Transform, IEEE Transaction on Power Delivery, v. 19, n. 1, p. 49 – 55, Janeiro 2004.
- [9]. Jensen, A.; La Cour-Harbo, A. Ripples in Mathematics: the Discret Wavelet Transform. Berlin, Heidelberg, Nova Iorque: Springer-Verlang, 2001. 246 p.
- [10]. Ribeiro, P. F. Wavelet Transform: an Advanced Tool for Analyzing Non-Stationary Harmonic Distortion in Power System, In: International Conference on Harmonics in Power System - IEEE (ICHPS), Bologna (Itália), IV, p. 364 - 369, 21-23 Setembro 1994.
- [11]. Robertson, D. C.; Camps, O. I.; Mayer, J. S.; Gish, W. B, Wavelets and Electromagnetic Power System Transients, IEEE Transactions on Power Delivery, v. 11, n.2, p. 1050-1058, Abril 1996.
- [12]. Santoso, S.; Powers, E. J.; Grady, W. M.; Hofmann, P. Power Quality Assessment Via Wavelet Transform Analysis, IEEE Transactions on Power Delivery, v. 15, n.1, p. 222-228, Janeiro 2000.
- [13]. Santoso, S.; Powers, E. J.; Grady, W. M.; Electric Power Quality Disturbance Detection Using Wavelet Transform Analysis, In: Proceedings of the IEEE-SP International Symposium on Time-Frequency and Time Scale Analysis, IEEE Xplore Press, Philadelphia, p. 166-169, 25-28 Outubro 1994.
- [14]. Liang, J.; Elangovan, S.; Devotta, J. B. X. A Wavelet Multi Resolution Analysis Approach to Fault Detection and Classification in Transmission Lines, Electrical Power and Energy Systems, v. 20, n. 5, p. 327-332, 1998.
- [15]. Chowdhury, F. N.; Aravena, J. L. A Modular Methodology for Fast Fault Detection and Classification in Power Systems, IEEE Transactions on Control Technology, v. 6, p. 623-634, Setembro 1998.
- [16]. Giovanini, R.; Coury, D. V. Classificação Rápida de Faltas em Sistemas Elétricos Utilizando Redes Neurais Artificiais, In: IV Congresso Brasileiro de Redes Neurais, p. 281-286, São José dos Campos, Julho 1999.
- [17]. Zheng, T.; Makram, E. B.; Girgis, A. A. Power System Transient and Harmonic Studies Using Wavelet Transform, IEEE Transactions on Power Delivery, v. 14, n. 4, p. 1461-1467, Outubro 1999.
- [18]. Zhaoa, W.; Songb, Y. H.; Minb, Y. Wavelet Analysis Based Scheme for Fault Detection and Classification in Underground Power Cable Systems, Electric Power Systems Research, v. 53, p. 1-71, Janeiro 2000.
- [19]. Fernández, R.; Rojas, H. An Overview of Wavelet Transforms Application in Power Systems, In: 14th Power Systems Computation Conference, p. 1-8, Sevilla, 24-28 Junho 2002.
- [20]. Huang, J.; Negnevitsky, M.; Nguyen, D. T. A Neural-Fuzzy Classifier for Recognition of Power Quality Disturbances, IEEE Transactions on Power Delivery, v. 17, n. 2, p. 609-616, Abril 2002.
- [21]. Arruda, G. A. G. Análise de Faltas Utilizando Redes Neurais, In: Internacional Joint Conference on Neural Networks , Honolulu (EUA), 2002.
- [22]. Souza, B. A.; Brito, N. S. D.; Neves, W. L. A.; Silva, K. M.; Lima, R. B.; Silva, S. S. B. Comparison Between Backpropagation and RPROP Algorithms Applied to Fault Classification in Transmission Lines, In:

International Joint Conference on Neural Networks & International Conference on Fuzzy Systems, Budapeste, 2004.

- [23]. Silva, K. M.; Souza, B. A.; Brito, N. S. D.; Costa, F. B.; Dantas, K. M. C. Um Algoritmo para Detecção e Classificação de Faltas em Linhas de Transmissão Baseado em Transformada Wavelet e RNA, In: VII Congresso Brasileiro de Redes Neurais, Natal, 2005.
- [24]. Graps, A. L. An Introduction to Wavelets, IEEE Computational Sciences and Engineering, v. 2, n. 2, p. 50-61, 1995.
- [25]. Misiti, M.; Misiti, Y.; Oppenheim, G.; Poggi, J-M. Wavelet Toolbox User's Guide 4, The MathWorks, Natick (USA), 2007.
- [26]. Domingues, M. O.; Júnior, O. M.; Costa, A. M. Algumas Aplicações Wavelet na Análise de Sinais Atmosféricos, In: 20. Congresso Temático de Aplicações de Dinâmica e Controle da Sociedade Brasileira de Matemática Aplicada e Computacional (SBMAC), São José dos Campos, 2003.
- [27]. Santos, C. K. S. Caracterização de Distúrbios em Redes de Energia Elétrica Através da Transformada Wavelet de Segunda Geração. 2004. 132 f. Dissertação (Mestrado em Engenharia elétrica) -Universidade Federal do Rio Grande do Norte (UFRN), Natal, 2004.
- [28]. Fonseca, M. S. Um Estudo sobre a Influência das Famílias Wavelets na Compressão da Imagem. 2004. 136 f. Dissertação (Mestrado em Engenharia elétrica) - Universidade Federal Fluminense (UFF), Niterói, 2004.
- [29]. Daubechies, I. Ten Lectures on Wavelets, In: Society for Industrial and Applied Mathematics XIX, p. 357, Philadelphia, 1992.
- [30]. Kim, C. H.; Aggarwal, R. Wavelet Transformers in Power Systems: Part 1 General Introduction to the Wavelet Transforms, Power Engineering Journal, v. 14, n. 2, p. 81-87, Abril 2000.
- [31]. Haykin, S. Redes Neurais Princípios e Práticas, Bookman Companhia Editora, 2a. Edição, Porto Alegre, 2001.
- [32]. Vieira, R. C.; Roisenberg, M. Redes Neurais Artificiais: Um Tutorial, Laboratório de Conexionismo e Ciências Cognitivas, Universidade Federal de Santa Catarina (UFSC), Florianópolis, 2010.
- [33]. IEEE Common Format for Transient Data Exchange (Comtrade) for Power Systems Relay of the IEEE Power Engineering Society, New York, USA, IEEE Standard C37.111-1999.
- [34]. Pereira, C.; Cruz, F. D. Análise do Comportamento Estático e Dinâmico dos Filtros Digitais de Mínimos Quadrados na Proteção de Linhas de Transmissão, In: XV SNPTEE, Foz do Iguaçu, 1999.
- [35]. Sachdev, M. S.; Baribeau, M. A. A New Algorithm for Digital Impedance Relays, IEEE Transactions on Power Apparatus and Systems, v. PAS-98, n. 6, p. 2232-2240, Novembro-Dezembro 1979.
- [36]. Norton, J. P. Introduction to Identification, Academic Press, London, 1986.
- [37]. IEEE Guide for Determining Fault Location on AC Transmission and Distribution Lines, Power Systems Relaying Committee, New York, USA, IEEE Standard C37.114-2004.