

MAURÍLIO JOSÉ INÁCIO

**DETECÇÃO E CLASSIFICAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO
UTILIZANDO TRANSFORMADA WAVELET E REDE LÓGICA NEUROFUZZY
COM APRENDIZADO PARTICIPATIVO**

Belo Horizonte

Maio de 2010.

UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**DETECÇÃO E CLASSIFICAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO
UTILIZANDO TRANSFORMADA WAVELET E REDE LÓGICA NEUROFUZZY
COM APRENDIZADO PARTICIPATIVO**

Proposta de dissertação apresentada ao Curso de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais como requisito parcial para a obtenção do grau de Mestre em Engenharia Elétrica.

MAURÍLIO JOSÉ INÁCIO

Belo Horizonte

Maio de 2010.

Resumo

Nos Sistemas Elétricos de Potência a linha de transmissão é o elemento mais vulnerável, pois está sujeita a faltas provocadas por fatores externos e internos. Sistemas de proteção são empregados para minimizar os impactos causados pelas faltas sendo que, atualmente, os relés digitais cumprem o papel principal no diagnóstico das faltas. Diversos algoritmos para diagnóstico de faltas podem ser utilizados nos relés digitais e, recentemente, as pesquisas têm se concentrado no uso de técnicas de análise de sinais e em sistemas inteligentes, na tentativa de superar as desvantagens dos métodos convencionais. Neste trabalho é apresentada uma metodologia de detecção e classificação de faltas do tipo curto-circuito e tipo circuito aberto em linhas de transmissão. A metodologia proposta utiliza a Transformada Wavelet para detecção da falta e utiliza a Rede Lógica *Neurofuzzy* para classificação da mesma, a partir da extração de informações dos sinais de tensão e corrente da linha de transmissão. No treinamento da Rede Lógica *Neurofuzzy* foi incluído o Aprendizado Participativo na etapa de geração das funções de pertinência dos subconjuntos *fuzzy*. Os algoritmos foram implementados em um Sistema de Detecção e Classificação de Faltas e resultados obtidos através de simulações demonstraram a robustez e eficiência da metodologia proposta.

Abstract

In the Power Electric Systems the transmission line is the most vulnerable element, since they are subject to faults caused by external and internal factors. Protection systems are employed to minimize the impacts caused by the faults and, currently, digital relays meet the lead role in the fault diagnosis. Several algorithms for fault diagnosis can be used in digital relays and, recently, researches have focused on the use of techniques of signal analysis and intelligent systems, in an attempt to overcome the disadvantages of conventional methods. This work presents a methodology for fault detection and classification of short circuit and open circuit faults on transmission lines. The proposed methodology uses the Wavelet Transform for detection and uses the Logic Neurofuzzy Network for classification of the fault, from the extraction of information of current and voltage signals of the transmission line. In the training of the Logic Neurofuzzy Network was included the Participatory Learning in step generation of membership functions of fuzzy subsets. The algorithms were implemented in a Fault Detection and Classification System and results obtained through simulations had demonstrated the robustness and efficiency of the methodology proposal.

Agradecimentos

A minha família, esposa, filhos, pais e irmãos, pelo apoio e incentivo, os quais me ajudaram a vencer os desafios.

Ao meu orientador professor Walmir Matos Caminhas, pela orientação, a qual permitiu a realização desse trabalho.

Aos colegas do Laboratório de Inteligência Computacional, pelas muitas contribuições, as quais contribuíram para superar dificuldades.

Aos professores do CPDEE, pelos muitos conhecimentos transmitidos durante as aulas, os quais foram de grande importância para minha formação acadêmica.

À FACIT pelo apoio financeiro.

Sumário

1	Introdução.....	1
1.1	Motivação	3
1.2	Objetivo	5
1.3	Proposta	5
1.4	Estrutura do trabalho	6
2	Linhas de Transmissão	7
2.1	Descrição	7
2.2	Representação	8
2.3	Faltas envolvidas	11
2.4	Modelo.....	14
2.5	Simulação	16
3	Diagnóstico de faltas em linhas de transmissão.....	18
3.1	Métodos convencionais	18
3.2	Métodos baseados em análise de sinais	20
3.2.1	Transformada de <i>Fourier</i>	21
3.2.2	Exemplo empregando Transformada de <i>Fourier</i>	22
3.2.3	Transformada Wavelet.....	24
3.2.4	Exemplos empregando Transformada Wavelet.....	29
3.3	Métodos inteligentes.....	34
3.3.1	Redes Neurais Artificiais	34
3.3.2	Exemplos empregando redes neurais artificiais	34
3.3.4	Lógica <i>Fuzzy</i>	38
3.3.5	Exemplos empregando Lógica <i>Fuzzy</i>	39
3.3.6	Redes <i>Neurofuzzy</i>	43
3.3.7	Exemplos empregando redes <i>neurofuzzy</i>	43
4	Metodologia proposta.....	46
4.1	Visão geral	46
4.2	Detecção da falta.....	47
4.3	Classificação da falta.....	52
5	Resultados	60
5.1	Modelo utilizado	60
5.2	Simulações no PSCAD	61
5.3	Implementações no MATLAB.....	72
5.4	Resultados obtidos.....	74

6 Conclusões.....	83
6.1 Trabalhos futuros	84
6.2 Produção científica	84
Apêndices	85
A. Algoritmo de Agrupamento Participativo.....	85
B. Parâmetros dos componentes utilizados na implementação do SEP no PSCAD	89
Referências Bibliográficas	90

Lista de figuras

Figura 1. 1: Etapas do procedimento de proteção de um relé digital.	2
Figura 1. 2: Histórico do desenvolvimento dos relés de proteção (Bo, Redfern e Weller, 2000).....	3
Figura 2. 1: Torre de linha de transmissão aérea.	8
Figura 2. 2: Circuito equivalente de uma linha de transmissão curta.....	9
Figura 2. 3: Circuito equivalente de uma linha de transmissão média.	10
Figura 2. 4: Circuito equivalente de uma linha de transmissão longa.	11
Figura 2. 5: Diagrama simplificado de uma falta tipo LL.	12
Figura 2. 6: Diagrama simplificado de uma falta tipo LLL.....	12
Figura 2. 7: Diagrama simplificado de uma falta tipo LG.....	13
Figura 2. 8: Diagrama simplificado de uma falta tipo curto-circuito LLG.	13
Figura 2. 9: Diagrama simplificado de uma falta tipo LO.....	14
Figura 2. 10: Diagrama simplificado de uma falta tipo LLO.	14
Figura 2. 11: Linha de transmissão com uma falta fase-terra.....	16
Figura 2. 12: Resultados de simulação de falta tipo curto-circuito fase-terra.	17
Figura 2. 13: Resultados de simulação de falta tipo fase aberta.	17
Figura 3. 1: Aplicação da Transformada de Fourier.	22
Figura 3. 2: Método baseado em FFT para diagnóstico de faltas (Bo, et al., 1997).	23
Figura 3. 3: Diferenças entre uma onda senoidal e uma wavelet.	24
Figura 3. 4: Aplicação da Transformada Wavelet.	25
Figura 3. 5: Exemplos de <i>wavelets</i> mãe.	26
Figura 3. 6: Filtro multi-estágio para implementação da DWT.....	27
Figura 3. 7: Decomposição de um sinal de falta utilizando wavelet mãe db4.....	29
Figura 3. 8: Algoritmo de detecção de faltas utilizando DWT (Kim et al., 2002).....	30
Figura 3. 9: Algoritmo de classificação de faltas utilizando DWT (Reddy e Mohanta, 2007).....	31
Figura 3. 10: Algoritmo de detecção e classificação de faltas utilizando DWT (Zhao, Song e Min, 2000).	32
Figura 3. 11: Fluxograma do método de diagnóstico de faltas utilizando DWT (Makming et at., 2002).	33
Figura 3. 12: Estrutura do método de detecção de faltas baseado em RNA (Vásquez, Altuve, e Chacón, 1996).	35
Figura 3. 13: Diagrama de uma rede FIRANN com duas camadas ocultas (Fernandez e Ghonaim, 2002).	36
Figura 3. 14: Diagrama do sistema para detecção e classificação de faltas baseado em RNA (Fernandez e Ghonaim, 2002).	36
Figura 3. 15: Esquema do método de diagnóstico de faltas baseado em RNAs (Oleskovicz, Coury e Aggarwal, 2001).	38
Figura 3. 16: Diagrama em bloco do FIS empregado para classificação de faltas proposto por Das e Reddy (2005).	40
Figura 3. 17: Diagrama em bloco do FIS empregado para classificação de faltas proposto por Mahanty e Gupta (2007).	41

Figura 3. 18: Diagrama em bloco do FIS empregado para classificação de faltas proposto por Youssef (2004).....	42
Figura 3. 19: Estrutura da rede neurofuzzy para detecção e classificação de faltas proposta por Wang e Keerthipala (1998).	44
Figura 3. 20: Esquema de redes neurofuzzy para classificação e localização de faltas proposto por Dash, Pradhan e Panda (2000).....	45
Figura 4. 1: Decomposição de um sinal $x(n)$ nos coeficientes wavelet A1 e D1.....	48
Figura 4. 2: Coeficiente D1 de um sinal de tensão em falta fase-terra utilizando wavelet db4.	48
Figura 4. 3: Coeficiente D1 de um sinal de corrente em falta fase-terra utilizando wavelet db4.	49
Figura 4. 4: Fluxograma do algoritmo proposto para detecção de faltas em linhas de transmissão.	50
Figura 4. 5: Resultado da aplicação do método de detecção da falta em um sinal de tensão.	51
Figura 4. 6: Resultado da aplicação do método de detecção da falta em um sinal de corrente.	51
Figura 4. 7: Estrutura da Rede Lógica Neurofuzzy proposta por Caminhas, Tavares e Gomide, (1996).	52
Figura 4. 8: Funções de pertinência triangulares não uniformemente distribuídas.....	54
Figura 4. 9: Esquema simplificado do método de classificação proposto.	58
Figura 4. 10: Funções de pertinência para a entrada 1.	58
Figura 4. 11: Funções de pertinência para a entrada 2.	59
Figura 4. 12: Sinais de entrada e saída da rede lógica neurofuzzy.	59
Figura 5. 1: Modelo de SEP utilizado para simulações de faltas.....	60
Figura 5. 2: Modelo de SEP como implementado no PSCAD.	61
Figura 5. 3: Simulação de falta tipo curto-circuito fase A-G.....	64
Figura 5. 4: Simulação de falta tipo curto-circuito fase B-G.....	64
Figura 5. 5: Simulação de falta tipo curto-circuito fase C-G.....	65
Figura 5. 6: Simulação de falta tipo curto-circuito fases AB-G.....	65
Figura 5. 7: Simulação de falta tipo curto-circuito fases AC-G.....	66
Figura 5. 8: Simulação de falta tipo curto-circuito fases BC-G.....	66
Figura 5. 9: Simulação de falta tipo curto-circuito fases AB.....	67
Figura 5. 10: Simulação de falta tipo curto-circuito fases AC.....	67
Figura 5. 11: Simulação de falta tipo curto-circuito fases BC.....	68
Figura 5. 12: Simulação de falta tipo curto-circuito fases ABC.	68
Figura 5. 13: Simulação de falta tipo fase A-aberta.....	69
Figura 5. 14: Simulação de falta tipo fase B-aberta.....	69
Figura 5. 15: Simulação de falta tipo fase C-aberta.....	70
Figura 5. 16: Simulação de falta tipo fases AB-aberta.....	70
Figura 5. 17: Simulação de falta tipo fases AC-aberta.....	71
Figura 5. 18: Simulação de falta tipo fases BC-aberta.	71
Figura 5. 19: Estrutura do sistema para detecção e classificação de faltas implementado.	72
Figura 5. 20: Diagnóstico realizado pelo sistema de detecção e classificação de faltas em uma sequência de faltas.	74

Lista de tabelas

Tabela 1. 1: Ocorrência de faltas no SEP em um sistema de 500 kV, num período de 10 anos.....	2
Tabela 2. 1: Classificação das linhas de transmissão em função do comprimento.....	8
Tabela 4. 1: Coeficientes do filtros associados à wavelet db4.....	48
Tabela 5. 1: Lógica de decisão.....	73
Tabela 5. 2: Resultados dos testes com variação da distância para faltas do grupo 1.....	75
Tabela 5. 3: Resultados dos testes com variação da distância para faltas do grupo 2.....	75
Tabela 5. 4: Resultados dos testes com variação da distância para faltas do grupo 3.....	75
Tabela 5. 5: Resultados dos testes com variação da distância para faltas do grupo 4.....	76
Tabela 5. 6: Resultados dos testes com variação da distância para faltas do grupo 5.....	76
Tabela 5. 7: Resultados dos testes com variação da distância para faltas do grupo 6.....	76
Tabela 5. 8: Resultados dos testes com variação da resistência para faltas do grupo 1.....	77
Tabela 5. 9: Resultados dos testes com variação da resistência para faltas do grupo 2.....	77
Tabela 5. 10: Resultados dos testes com variação da resistência para faltas do grupo 3.....	77
Tabela 5. 11: Resultados dos testes com variação da resistência para faltas do grupo 4.....	77
Tabela 5. 12: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 1.....	78
Tabela 5. 13: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 2.....	78
Tabela 5. 14: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 3.....	79
Tabela 5. 15: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 4.....	79
Tabela 5. 16: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 5.....	79
Tabela 5. 17: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 6.....	79
Tabela 5. 18: Resultados dos testes com variação do ângulo de carga para faltas do grupo 1.....	80
Tabela 5. 19: Resultados dos testes com variação do ângulo de carga para faltas do grupo 2.....	80
Tabela 5. 20: Resultados dos testes com variação do ângulo de carga para faltas do grupo 3.....	80
Tabela 5. 21: Resultados dos testes com variação do ângulo de carga para faltas do grupo 4.....	81
Tabela 5. 22: Resultados dos testes com variação do ângulo de carga para faltas do grupo 5.....	81
Tabela 5. 23: Resultados dos testes com variação do ângulo de carga para faltas do grupo 6.....	81
Tabela 5. 24: Resultados gerais dos testes realizados.....	82

Lista de abreviaturas

AAP	Algoritmo de Agrupamento Participativo
AB	Falta fases AB
ABC	Falta fases ABC
AB-G	Falta fases AB - terra
AC	Falta fases AC
AC-G	Falta fases AC - terra
A-G	Falta fase A - terra
ANFIS	<i>Adaptive Network based Fuzzy Inference System</i>
AP	Aprendizado Participativo
BC	Falta fases BC
BC-G	Falta fases BC - terra
B-G	Falta fase B - terra
CA	Corrente alternada
CAD	<i>Computer Aided Design</i>
CC	Corrente Alternada
C-G	Falta fase B - terra
CWT	<i>Continuous Wavelet Transform</i>
db4	<i>Wavelet mãe Daubechies 4</i>
DLG	<i>Double line ground</i>
DTFS	<i>Discrete Time Fourier Series</i>
DTFT	<i>Discrete Time Fourier Transform</i>
DWT	<i>Discrete Wavelet Transform</i>
EMTC	<i>Eletromagnetic Transient with DC Analysis</i>
FFT	<i>Fast Fourier Transform</i>
FIR	<i>Finite Impulse Response</i>
FIRANN	<i>Finite Impulse Response Artificial Neural Network</i>
FIS	<i>Fuzzy Inference System</i>
FS	<i>Fourier Series</i>
FT	<i>Fourier Transform</i>
HIF	<i>High Impedance Fault</i>
LG	<i>Line-ground</i>
LL	<i>Line-line</i>
LLG	<i>Line-line-ground</i>
LLL	<i>Line-line-line</i>
LLO	<i>Line-line-open</i>
LO	<i>Line-open</i>
MLP	<i>Multilayer Perceptron</i>
QMF	<i>Quadrature Mirror Filter</i>
R-L	Resistência-indutância
RMS	<i>Root mean Square</i>
RNA	Rede Neural Artificial
SEP	Sistema Elétrico de Potência
SLG	<i>Single line ground</i>
STFT	<i>Short Time Fourier Transform</i>
TC	Transformador de corrente

Capítulo 1

1 Introdução

Nos últimos anos têm ocorrido no país *blackouts*, ou “apagões” na linguagem popular, que atingem um grande número de estados, deixando milhões de consumidores sem o fornecimento de energia elétrica e causando grandes prejuízos econômicos. Esses acontecimentos tornam evidente a importância que o Sistema de Energia Elétrica ou Sistema Elétrico de Potência (SEP) tem para a sociedade moderna. Para minimizar os impactos causados pela falta no sistema, adotam-se mecanismos de diagnóstico da falta que, se detectada, classificada e localizada com rapidez e precisão, permite o restabelecimento do funcionamento do sistema elétrico no menor tempo possível.

O SEP é responsável pelo fornecimento da energia elétrica consumida em todo o país. Esse sistema é composto por diversos componentes: usinas geradoras de energia elétrica, subestações, transformadores elevadores e abaixadores, linhas de transmissão e linhas de distribuição. Cada componente do sistema possui uma função específica e definida. Os geradores de energia transformam uma determinada forma de energia (mecânica, térmica, eólica ou solar) em energia elétrica e injetam a potência gerada nas linhas de transmissão. As linhas de transmissão por sua vez realizam a transferência da energia, de um centro gerador até um centro consumidor. Como a transmissão da energia é efetuada em tensões elevadas, são necessários transformadores. Normalmente são classificadas como linhas de transmissão aquelas com tensão igual ou superior a 230 kV e como linhas de distribuição aquelas com tensões entre 69 e 138 kV (Coury, 2002).

É desejável que um SEP funcione correta e ininterruptamente, fornecendo energia com determinado padrão de qualidade aos consumidores, sejam eles residenciais, comerciais ou industriais. Entretanto, devido a faltas na operação, isto nem sempre é conseguido. Por “falta” em um SEP, entende-se como a falha total ou parcial no fornecimento da energia elétrica. A causa de uma falta pode ser devido a um fenômeno interno (exemplo: sobrecarga dos equipamentos) ou externo ao sistema (exemplo: sobretensões devido a descargas atmosféricas). Na ocorrência da falta podem surgir os mais diversos problemas, tais como danos aos equipamentos, desligamento de áreas que não estão sob falta, explosões, dentre outras. As faltas podem ser permanentes ou transitórias, sendo as faltas permanentes irreversíveis, o que significa que após a abertura dos dispositivos de proteção, o fornecimento de energia não poderá ser restabelecido. Já as faltas transitórias são as que ocorrem sem provocar danos físicos ao sistema, sendo que após a atuação da proteção, o fornecimento de energia poderá ser restabelecido sem maiores problemas.

Em um SEP, a linha de transmissão é o elemento mais vulnerável a faltas, uma vez que, devido a sua dimensão física, ela fica exposta a vários fatores, tais como curtos-circuitos causados por árvores, isoladores danificados, descargas atmosféricas, dentre outros. A título

de exemplificação, a tabela 1.1 apresenta um cenário de ocorrência de faltas em um SEP. Como pode ser observado, cerca de 80% das faltas são originadas nas linhas de transmissão ou provocadas por elas.

Tabela 1. 1: Ocorrência de faltas no SEP em um sistema de 500 kV, num período de 10 anos.

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

Fonte: (Coury, 2002).

Para proteção das linhas de transmissão, o SEP conta com um sistema de proteção, cuja função é proteger o sistema como um todo de faltas que possam ocorrer internamente ou externamente a esse. O sistema de proteção é composto de disjuntores, transdutores e relés.

O relé é um dispositivo analógico ou digital que fica permanentemente conectado ao sistema elétrico, monitorando sinais de tensão e corrente proveniente dos transdutores, sendo responsável pela detecção de condições intoleráveis ou indesejáveis ao sistema elétrico. O relé corresponde a parte lógica do sistema de proteção, cabendo a ele tomar a decisão de abertura ou não dos disjuntores adequados, de forma que a parte defeituosa da linha seja retirada de operação. Esse processo permite manter a continuidade do fornecimento da energia elétrica e limitar os danos aos equipamentos existentes no sistema.

Atualmente, os relés do sistema de proteção são totalmente digitais, baseados em microprocessadores e tem sua funcionalidade controlada por software, onde os dados de entrada são digitais. Os relés digitais efetuam várias funções, tais como: proteção, supervisão, transmissão de sinais, dentre outras. Conforme o fluxograma mostrado na figura 1.1, o procedimento de proteção realizado pelo relé digital é normalmente dividido em tarefas distintas: detecção da falta, classificação da falta e localização (cálculo da distância) da falta. Em cada etapa, diferentes algoritmos podem ser utilizados (Vásquez, Altuve e Chacón, 1996).




Figura 1. 1: Etapas do procedimento de proteção de um relé digital.

1.1 Motivação

O diagnóstico de faltas em linhas de transmissão é uma importante tarefa nos sistemas de proteção dos SEPs. A operação segura de sistemas elétricos de altas tensões requer metodologias de proteção para detectar, classificar e localizar faltas com elevada precisão e tão rápido quanto possível, permitindo que as consequências da falta sejam minimizadas.

O desenvolvimento de sistemas de proteção dos SEP teve início a mais de 100 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 (Bo, Redfern e Weller, 2000). A figura 1.2 ilustra o histórico do desenvolvimento dos relés de proteção

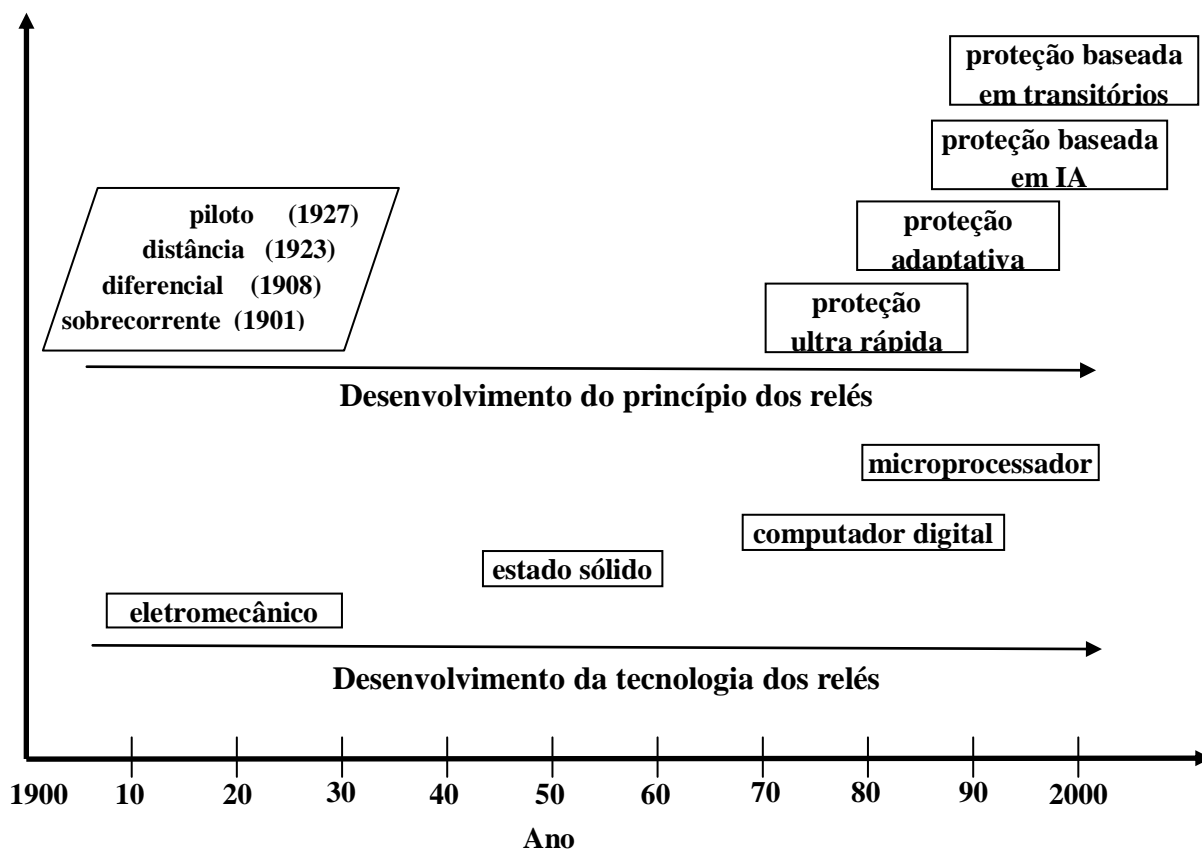


Figura 1. 2: Histórico do desenvolvimento dos relés de proteção (Bo, Redfern e Weller, 2000).

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 (Thorp, 2007). Os relés digitais executam um algoritmo que processa os dados de entrada (amostras

da 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 (Horowitz e Phadke, 2008).

No estágio inicial do seu desenvolvimento, os relés digitais empregavam algoritmos desenvolvidos a partir dos mesmos métodos de diagnóstico de faltas dos relés convencionais, que se baseiam em parâmetros da linha (tensão, corrente, impedância. etc.). 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 análise de sinais, tais como Transformada de *Fourier* e Transformada Wavelet, e em sistemas inteligentes, tais como Redes Neurais Artificiais (RNA), Lógica *Fuzzy* e Redes *Neurofuzzy*.

O diagnóstico de faltas empregando a Transformada de *Fourier* e a Transformada Wavelet é denominada de “proteção baseada em transitório”, que utiliza as componentes de alta frequência do sinal de falta para análise, ao invés da frequência fundamental. Nesse esquema de proteção é necessário que o sinal da falta seja analisado com precisão. Os trabalhos na área de proteção de SEP têm demonstrado que a análise de transitórios baseada na Transformada de *Fourier*, como em Bo *et al.* (1997), às vezes não é suficientemente precisa em alguns tipos de faltas, como apontado por Das, Singh e Sinha (2006) e Gayathri e Kumarappan (2008). Mais recentemente, verificou-se que a Transformada Wavelet é capaz de permitir a investigação de transitórios gerados em sistemas de potência de forma mais eficiente. Em alguns trabalhos a Transformada Wavelet é utilizada apenas para detecção da falta, como em Kim *et al.* (2002), e Osman e Malik (2004) ou apenas para classificação da falta, como em Silveira, Seara e Zurn (1999); Chanda, Kishore e Sinha (2003), e Reddy e Mohanta (2007). Já em outros trabalhos, a Transformada Wavelet é utilizada não somente para detecção, mas também para classificação da falta, como em Liang, Elangovan e Devotta (1998); Zhao, Song e Min (2000). E há ainda trabalhos em que Transformada Wavelet é utilizada na detecção, classificação e localização da falta, como em Makming *et al.*, (2002). Apesar de a Transformada Wavelet ser muito eficaz em diagnóstico de faltas, ela pode não ser suficiente para uma caracterização mais completa.

O diagnóstico de faltas empregando RNA, Lógica *Fuzzy* e Redes *Neurofuzzy* é uma tentativa de superar os problemas encontrados nos esquemas de proteção baseados em cálculos determinísticos a partir do modelo do sistema a ser protegido. Em tais esquemas, 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, e sinais que contêm incertezas. Muitos trabalhos têm demonstrado que os esquemas de proteção baseados nos “sistemas inteligentes” são capazes de superar a maioria das dificuldades citadas anteriormente. Nos trabalhos com RNAs, o diagnóstico de faltas é tratado como um problema de classificação de padrões sendo que, normalmente, os padrões de entrada consistem em amostras da tensão e/ou corrente da linha, como em Vásquez, Altuve e Chacón (1996); Fernandez e Ghonaim (2002); Oleskovicz, Coury e Aggarwal (2001), e Mahanty e Gupta (2004). Já em outros trabalhos, os padrões de entrada para a RNA são componentes dos sinais extraídos através da Transformada de *Fourier*, como em Gayathri e Kumarappan (2008), ou através da Transformada Wavelet, como em Chiradeja e Ngaopitakkul (2009). Nos trabalhos com Lógica *Fuzzy*, o diagnóstico de faltas é realizado por

um Sistema de Inferência *Fuzzy* baseado em regras do tipo SE-ENTÃO, a partir de dados calculados com as amostras de tensão e/ou corrente da linha, como em Das e Reddy (2005), e Mahanty e Gupta (2007) ou a partir de dados calculados com componentes dos sinais extraídos através da Transformada Wavelet, como em Youssef (2004). Há ainda trabalhos que empregam as Redes *Neurofuzzy*, que integram as melhores características das RNAs e dos Sistemas de Inferência *Fuzzy* para o diagnóstico de faltas, como em Wang e Keerthipala (1998), e Dash, Pradhan e Panda (2000).

Apesar de todo o desenvolvimento alcançado, o diagnóstico de faltas em linhas de transmissão está longe de ser uma tarefa trivial, dados os inúmeros fatores que afetam a eficácia dos diversos métodos existentes, tais como: resistência de falta, local da falta, ângulo de incidência da falta, ruídos nos sinais, dentre outros.

As técnicas baseadas em inteligência computacional para diagnóstico de faltas em linhas de transmissão tem se mostrado as mais eficientes, devido a sua capacidade de aprendizado, generalização e robustez, o que contribui para superar as deficiências dos outros métodos de proteção de linhas de transmissão. A adição de métodos de análise de sinais mais precisos, como a Transformada Wavelet, com sistemas inteligentes como as Redes Lógicas *Neurofuzzy*, torna possível a implementação de algoritmos de diagnóstico de faltas em linhas de transmissão que, aliado a outros algoritmos, tornam a proteção ainda mais eficiente.

1.2 Objetivo

O trabalho apresentado nesta dissertação tem como objetivo o desenvolvimento de uma metodologia de detecção e classificação de faltas do tipo curto-circuito e tipo circuito aberto em linhas de transmissão, baseada em análise de sinais e em técnicas de inteligência computacional. A detecção da falta é realizada com extração de informações dos sinais da falta por Transformada Wavelet e a classificação é realizada por uma Rede Lógica *Neurofuzzy*, modificada com a inclusão do Aprendizado Participativo. Esta metodologia consiste em algoritmos que podem ser implementados computacionalmente.

1.3 Proposta

A metodologia proposta utiliza a Transformada Wavelet para detecção da falta a partir da extração de informações dos sinais de tensão e corrente da linha de transmissão. A Transformada Wavelet é uma ferramenta matemática muito utilizada em análise de sinais e apresenta vantagens em relação a outras, como a Transformada de *Fourier*, pois permite obter informações do sinal analisado tanto no domínio do tempo, quanto no domínio da frequência, com precisão (Makming *et al.*, 2002).

A classificação da falta utiliza a Rede Lógica *Neurofuzzy*, onde as entradas da rede são os sinais de tensão e corrente durante a ocorrência da falta. Esta rede é constituída por neurônios lógicos tipo *and* e *or* que são modelados por normas *s* (*s-norms*) e *t* (*t-norms*). Sua estrutura permite a inserção e extração de conhecimento na forma de regras nebulosas do tipo se-então, estabelecendo um mapeamento entre regras nebulosas e o conhecimento presente em sua arquitetura. O algoritmo de treinamento da rede é do tipo supervisionado, mas sem a utilização de derivadas (Caminhas, Tavares e Gomide, 1996).

O algoritmo de treinamento original da Rede Lógica *Neurofuzzy* foi modificado com a inclusão de Aprendizado Participativo (Yagger, 1990) na etapa de geração das funções de pertinência dos subconjuntos *fuzzy*, o que permite reduzir o número de regras. O Aprendizado Participativo é um modelo de aprendizado que tenta captar muitas das características relevantes do aprendizado humano. Representa um paradigma importante com diversas aplicações, dentre elas o treinamento de redes neurais (Hell, Costa e Gomide, 2007), algoritmos de agrupamento (Silva, Gomide e Yagger, 2005) e diagnóstico de falhas em sistemas dinâmicos (Inácio *et al.*, 2009).

Utilizando somente os sinais de tensão e corrente da linha de transmissão, o esquema proposto é capaz de detectar e classificar corretamente faltas tipo curto-circuito fase-terra, fase-fase-terra, fase-fase e trifásico, além de fase aberta. Para avaliação da eficiência do algoritmo, as rotinas foram implementadas no software MATLAB (MATLAB, 2008) e realizadas simulações de faltas em uma linha de transmissão, empregando o software PSCAD (PSCAD, 2005), levando em conta todas as características da linha e com diversos cenários de falta diferentes.

1.4 Estrutura do trabalho

Na sequência desta introdução, no Capítulo 2, são apresentados os aspectos teóricos sobre linhas de transmissão, as faltas que envolvem esta parte dos SEPs, modelos e simulações empregados nos estudos de sistemas de proteção. No Capítulo 3 são apresentados os métodos de diagnóstico de faltas, divididos em métodos baseados em parâmetros, métodos baseados em análise de sinais e métodos inteligentes. No Capítulo 4 é exposta em detalhes a metodologia proposta para detecção e classificação de faltas. No Capítulo 5 são apresentados os resultados obtidos a partir das simulações e implementações realizadas. Finalmente, no Capítulo 6 são feitas as considerações gerais sobre o trabalho e sugestões de trabalhos futuros.

Capítulo 2

2 Linhas de Transmissão

As linhas de transmissão são componentes dos SEPs responsáveis por transportar a energia elétrica dos centros geradores aos centros consumidores. As linhas de transmissão também interligam centros geradores, constituindo o chamado sistema de transmissão, o que permite a otimização na distribuição da energia produzida no país ou mesmo entre países vizinhos. As linhas de transmissão podem ter de dezenas a centenas de quilômetros de extensão, sendo que, essa característica favorece a ocorrência de faltas no sistema elétrico. Isso também traz a necessidade de se adotar sistemas de proteção eficientes, de forma que as faltas possam ser isoladas rapidamente garantindo a continuidade de funcionamento do sistema. Podem ser utilizados modelos de linhas de transmissão e de faltas para estudo e desenvolvimento de metodologias de diagnóstico de faltas, o que viabiliza a simulação destas por meio de programas de computador.

2.1 Descrição

Linhas de transmissão podem ser divididas basicamente em dois grupos: linhas aéreas de cabos nus ou linhas subterrâneas de cabos isolados. O grupo das linhas aéreas se divide ainda em linhas de circuito simples ou circuito duplo, sendo que a transmissão da energia elétrica pode ser em corrente alternada (CA) ou em corrente contínua (CC). Em sua quase totalidade, quando em corrente alternada, as linhas de transmissão são trifásicas.

As linhas de transmissão aéreas de circuito simples em CA, que constituem objeto de estudo deste trabalho, são constituídas por um conjunto de fases formado por condutores suspensos em uma torre e isolados entre si por meio de isoladores, cujo número é determinado pela tensão da linha. Dois braços curtos acima dos condutores das fases suportam cabos usualmente feitos de aço. Esses cabos são de diâmetro muito menor que os condutores das fases e são eletricamente conectados à torre e ao potencial de terra. Esses cabos são denominados de cabo guarda ou cabo terra e protegem os condutores das fases contra descargas atmosféricas (Grainger e Stevenson, 1994). A figura 2.1 exibe uma típica torre de linha de transmissão aérea.



Figura 2. 1: Torre de linha de transmissão aérea.

2.2 Representação

Segundo Grainger e Stevenson (1994), dependendo do comprimento da linha de transmissão, a linha pode ser classificada como linha curta, linha média ou linha longa, conforme mostra a tabela 2.1, para operação em frequência de 60Hz.

Tabela 2. 1: Classificação das linhas de transmissão em função do comprimento.

Classe	Comprimento (L)
Curta	$L \leq 80$ km
Média	$80 \text{ km} < L \leq 240$ km
Longa	$L \geq 240$ km

O modelo a ser utilizado na representação da linha é de acordo com esta característica, pois conforme a extensão da linha, alguns dos seus parâmetros podem ser desprezados para análise, sem perda de precisão.

Nos modelos apresentados a seguir, serão adotados os seguintes símbolos:

- l = comprimento da linha.
- z = impedância série por unidade de comprimento de fase.

- y = admitância *shunt* por unidade de comprimento de fase-neutro.
- $Z = zl$ = impedância série nominal por fase.
- $Y = yl$ = admitância nominal por fase-neutro.

O modelo para linhas de transmissão curtas é apresentado na figura 2.2. Nesse modelo são considerados apenas os parâmetros da linha resistência série e impedância série, sendo que a capacitância da linha é desprezada por ser muito pequena. No circuito equivalente, as relações entre as correntes e tensões da linha são dadas pelas equações 2.1 e 2.2, respectivamente (Grainger e Stevenson, 1994).




Figura 2. 2: Circuito equivalente de uma linha de transmissão curta.

$$I_S = I_R \quad (2.1)$$

$$V_S = V_R + I_R Z \quad (2.2)$$

Onde:

I_S Corrente do transmissor;

I_R Corrente do receptor;

V_S Tensão no transmissor;

V_R Tensão no receptor;

Z Impedância total da linha.

O modelo para linhas de transmissão médias é apresentado na figura 2.3. Nesse modelo é incluída a admitância *shunt*, usualmente capacitiva pura. Se a admitância *shunt* total da linha é dividida em duas partes iguais, metade no lado do transmissor e metade no lado do receptor, o circuito equivalente é chamado de circuito PI. As relações entre as correntes e tensões da linha para esse circuito são dadas pelas equações 2.3 e 2.4, respectivamente (Grainger e Stevenson, 1994).

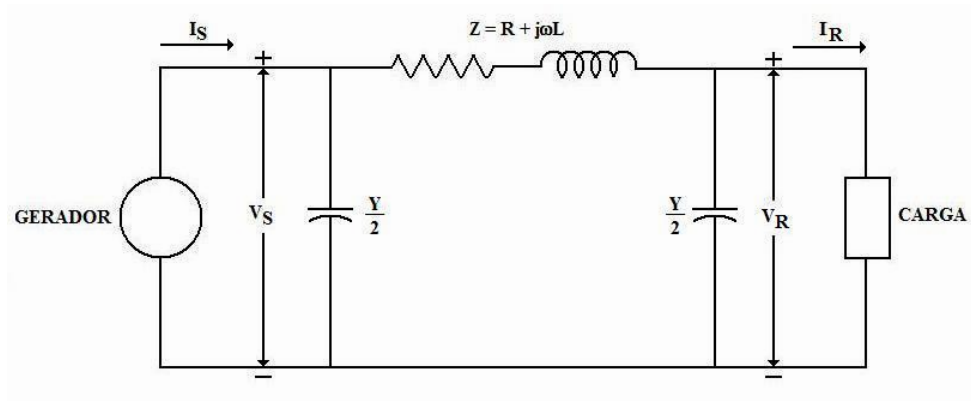


Figura 2. 3: Circuito equivalente de uma linha de transmissão média.

$$I_S = V_R Y \left(1 + \frac{ZY}{4} \right) + \left(\frac{ZY}{2} + 1 \right) I_R \quad (2.3)$$

$$V_S = \left(\frac{ZY}{2} + 1 \right) V_R + Z I_R \quad (2.4)$$

Onde:

I_S Corrente do transmissor;

I_R Corrente do receptor;

V_S Tensão no transmissor;

V_R Tensão no receptor;

Z Impedância total da linha.

Y Admitância *shunt* total da linha.

O modelo para linhas de transmissão longas é apresentado na figura 2.4. Nesse modelo é considerado o fato de que os parâmetros da linha não são concentrados, mas, em vez disso, são distribuídos uniformemente ao longo do comprimento da linha. No circuito equivalente, é considerado um elemento diferencial dx na linha, a uma distância x do lado do receptor. Dessa forma, zdx e ydx são, respectivamente, a impedância série e a admitância *shunt* da seção. Os fasores V e I são fasores que variam com a distância x . A solução para esse circuito é dada por equações diferenciais (equações 2.5 e 2.6), cuja dedução resulta nas equações 2.7 e 2.8 (Grainger e Stevenson, 1994).




Figura 2. 4: Circuito equivalente de uma linha de transmissão longa.

$$\frac{dI}{dx} = yV \quad (2.5)$$

$$\frac{dV}{dx} = zI \quad (2.6)$$

$$V = \frac{V_R + I_R Z_C}{2} e^{\gamma x} + \frac{V_R - I_R Z_C}{2} e^{-\gamma x} \quad (2.7)$$

$$I = \frac{V_R / Z_C + I_R}{2} e^{\gamma x} - \frac{V_R / Z_C - I_R}{2} e^{-\gamma x} \quad (2.8)$$

Onde:

I_S Corrente do transmissor;

I_R Corrente do receptor;

V_S Tensão no transmissor;

V_R Tensão no receptor;

Z_C Impedância característica da linha ($Z_C = \sqrt{z/y} \Omega$).

γ Constante de propagação ($\gamma = \sqrt{zy} \text{ m}^{-1}$).

2.3 Faltas envolvidas

Uma falta em um SEP é uma condição anormal que envolve uma falha elétrica em um elemento do sistema, operando em uma das tensões primária dentro do sistema. Geralmente, dois tipos de faltas podem ocorrer: curto-circuito (assimetria *shunt*) e circuito aberto (assimetria *série*). A falta tipo curto-circuito ocorre por uma falha de isolamento, como por

exemplo, resultado de estresse e degradação de um isolador ao longo do tempo ou devido a uma condição de sobretensão súbita. A falta tipo circuito aberto ocorre por uma interrupção no fluxo de corrente (Tleis, 2008).

Em linhas de transmissão, as faltas tipo curto-circuito podem ocorrer entre fases, entre fases e terra ou ambos os casos. Dessa forma, os casos de curto-circuito podem ser classificados como:

- fase-terra (line-ground – *LG*);
- fase-fase (line-line – *LL*);
- fase-fase-terra (line-line-ground – *LLG*).
- trifásico (line-line-line – *LLL*);

Os diagramas simplificados nas figuras 2.5 a 2.8 ilustram cada tipo de falta de curto-circuito, onde Z_f representa a impedância da falta.




Figura 2. 5: Diagrama simplificado de uma falta tipo LL.

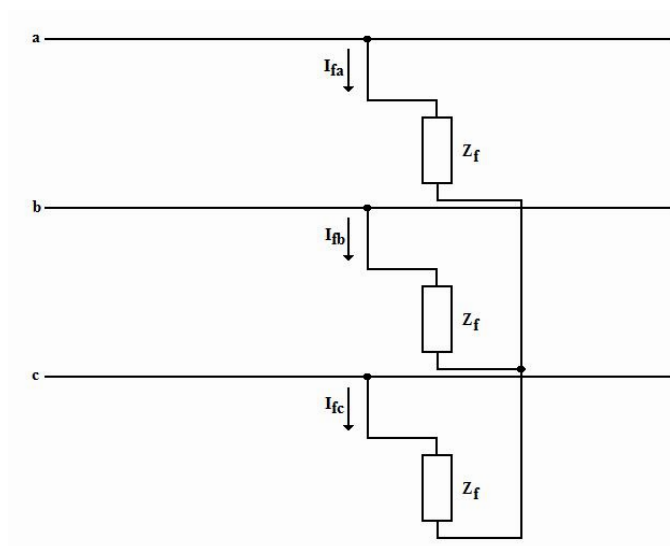


Figura 2. 6: Diagrama simplificado de uma falta tipo LLL.




Figura 2. 7: Diagrama simplificado de uma falta tipo LG.




Figura 2. 8: Diagrama simplificado de uma falta tipo curto-circuito LLG.

A falta tipo trifásica que afeta simetricamente as três fases do circuito trifásico é dita balanceada, enquanto todos os tipos de falta são não-balanceadas. Podem ocorrer faltas que são uma combinação de dois ou mais tipos de falta ao mesmo tempo. E faltas iguais ou diferentes também podem ocorrer no mesmo local ou em locais diferentes. Por exemplo, um condutor de fase que cai ao solo é, simultaneamente, uma falta tipo curto-circuito e tipo circuito-aberto. Faltas em uma fase afeta as outras fases que estão normais, causando perturbações. A maioria das faltas não muda de tipo durante o período de ocorrência das faltas, mas algumas faltas podem evoluir de uma falta tipo fase-terra para uma fase tipo fase-fase-terra, por exemplo. Isso pode ocorrer em linhas de transmissão aéreas onde o arco elétrico do curto-circuito propaga para as outras fases normais.

Faltas tipo curto-circuito podem ser causadas por fatores meteorológicos, tais como: descargas atmosféricas, chuva torrenciais, ventos fortes, ou ainda por outros fatores como poluição depositada em isoladores, inundações e incêndios debaixo de linhas de transmissão e contato com árvores. Vandalismos, acidentes com veículos, pessoas e animais também podem ser a causa de curto-circuito.

As faltas tipo circuito aberto podem ocorrer em uma fase ou duas fases simultaneamente. Apesar de ser possível ocorrer, o caso de três fases abertas normalmente não é uma falta, mas uma operação de comutação normal do sistema, tal como a abertura das três fases de um disjuntor. Assim, os casos de circuito aberto podem ser classificados como:

- fase aberta (*line-open* – *LO*);
- fase-fase aberta (*line-line-open* – *LLO*).

Os diagramas simplificados nas figuras 2.9 e 2.10 ilustram cada tipo de falta de circuito aberto, onde Z_f representa a impedância da falta.




Figura 2. 9: Diagrama simplificado de uma falta tipo LO.




Figura 2. 10: Diagrama simplificado de uma falta tipo LLO.

Faltas tipo circuito aberto podem ser causadas por falhas em junções de cabos ou falha em um dispositivo de proteção instalado ao longo da linha, como por exemplo, um disjuntor.

2.4 Modelo

Em análises de faltas em linhas de transmissão, muitas vezes assume-se que a falta em questão é um curto-circuito ideal, ou seja, de resistência zero. Na realidade, para faltas entre fases, a falta será devido a um arco elétrico entre dois condutores de alta-tensão, enquanto que para faltas entre fases e terra, a falta será devido a um arco elétrico entre o condutor de alta-tensão e um objeto aterrado, como o cabo terra ou a própria torre em si.

Em qualquer caso, a falta terá uma resistência, que pode consistir na resistência do arco ou na resistência do arco em série com a resistência à terra da base da torre, no caso de faltas envolvendo a terra. A resistência da base da torre é praticamente constante durante a falta (com valores entre 5 e 50Ω), enquanto a resistência do arco varia no tempo, conforme flui a corrente da falta. Durante o período inicial do arco, a resistência é insignificante e como o canal do arco vai alongando, a resistência aumenta. Para fins de análise de faltas, geralmente assume-se que a resistência do arco é constante, dada pela seguinte fórmula empírica (Horowitz e Phadke, 2008):

$$R_{arc} = \frac{76V^2}{S_{sc}} \quad (2.9)$$

Onde:

V Tensão do sistema em kV.

S_{sc} Potência do curto-circuito em kVA no ponto da falta.

Por exemplo, a resistência do arco elétrico em uma linha de transmissão de 345kV no ponto de um curto-circuito com potência de 1500MVA será:

$$R_{arc} = \frac{76 \times 345^2}{1500 \times 10^3} \cong 6\Omega$$

Outra fórmula empírica para determinar resistência do arco elétrico, segundo Warrington (1978), é a seguinte:

$$R_{arc} = \frac{8750L}{I_{sc}^{1,4}} \quad (2.10)$$

Onde:

L Comprimento do arco em pés.

I_{sc} Corrente do curto-circuito em valor eficaz.

A resistência da falta introduz uma dificuldade no diagnóstico da falta, especialmente na estimativa da distância da falta. Conforme mostra a figura 2.11, em uma linha de transmissão com falta fase-terra em um determinado ponto F, a corrente na resistência de falta terá a contribuição da corrente do terminal remoto da linha, de forma que a corrente de falta será:

$$I_f = I + I_r \quad (2.11)$$




Figura 2. 11: Linha de transmissão com uma falta fase-terra.

A tensão na barra A é dada pela equação 2.11 e a impedância aparente vista a partir de A é dada pela equação 2.12.

$$V_a = Z_f I + R_f (I + I_r) \quad (2.12)$$

$$Z_a = V_a / I = Z_f + R_f \left(\frac{I_r}{I} + 1 \right) \quad (2.13)$$

Onde:

I Corrente da linha.

I_r Corrente remota.

Z_f Impedância da linha até o ponto da falta.

R_f Resistência da falta.

Como as correntes I e I_r podem não estar em fase, isso provocará uma alteração tanto na resistência quanto na reatância do segmento da linha de transmissão antes do ponto da falta, dificultando o diagnóstico da falta (Horowitz e Phadke, 2008).

2.5 Simulação

A utilização de dados reais de tensão e corrente de linhas de transmissão em estudos de diagnóstico de faltas nem sempre é possível, visto que normalmente tais dados ficam disponíveis apenas para os sistemas de proteção das empresas concessionárias de energia elétrica. Dessa forma, os trabalhos relacionados com diagnóstico de faltas em linhas de transmissão normalmente utilizam programas computacionais para simular faltas em linhas, a fim de resolver o problema de escassez de dados.

A simulação de faltas requer a utilização de modelos adequados dos componentes do SEP, tais como geradores, linhas de transmissão e cargas. Com esses modelos, é possível

implementar um dado sistema e inserir nele as faltas desejadas. As tensões e correntes da linha podem ser monitoradas e os dados armazenados para utilização posterior.

As figuras 2.12 e 2.13 apresentam, a título de exemplo, as formas de onda de tensão e corrente em uma linha de transmissão de 230 kV resultantes de simulações de falta tipo curto-circuito fase-terra e falta tipo fase aberta, respectivamente. As faltas foram inseridas entre os instantes de tempo 0,2s e 0,3s. Nas formas de ondas pode-se observar as distorções provocadas pela inserção das faltas.




Figura 2. 12: Resultados de simulação de falta tipo curto-circuito fase-terra.




Figura 2. 13: Resultados de simulação de falta tipo fase aberta.

Capítulo 3

3 Diagnóstico de faltas em linhas de transmissão

Ao longo do desenvolvimento das tecnologias de proteção de SEP, foram criados vários métodos para diagnóstico de faltas em linhas de transmissão. Atualmente, os métodos podem ser divididos em métodos convencionais, métodos baseados em análise de sinais e métodos baseados em sistemas inteligentes. Os métodos convencionais utilizam uma variedade de parâmetros para tomada de decisão sobre a ocorrência da falta, sendo que os parâmetros mais comuns são a tensão e a corrente da linha. Os métodos baseados em análise de sinais utilizam os transitórios de alta frequência gerados pela falta na linha para sua detecção, onde os transitórios são extraídos dos sinais de tensão ou corrente empregando ferramentas matemáticas, tais como a Transformada de *Fourier* ou a Transformada Wavelet. E os métodos baseados em sistemas inteligentes utilizam dados extraídos da linha como padrões de entrada para o sistema inteligente, tais como RNAs, Lógica *Fuzzy* ou *Redes Neurofuzzy*.

3.1 Métodos convencionais

Em geral, quando ocorre faltas tipo curto-circuito em linhas de transmissão, a magnitude das correntes aumenta e das tensões diminui. Além das mudanças de magnitudes nessas grandezas, outras mudanças podem ocorrer em um ou mais dos seguintes parâmetros: ângulos de fase entre tensão e corrente, componentes harmônicas, potências ativa e reativa, frequência, etc. O princípio de funcionamento dos relés de proteção pode ser baseado na detecção dessas mudanças (Horowitz e Phadke, 2008).

Ao longo da evolução dos relés digitais de proteção, muitos algoritmos de diagnóstico de faltas foram desenvolvidos a partir dos métodos convencionais de proteção de SEP, que se baseiam na mudança das grandezas da linha, principalmente tensão, corrente e impedância vista. Desses métodos, os mais empregados para diagnóstico de faltas em linhas de transmissão são (Phadke e Thorp, 2009):

- Proteção de sobrecorrente: é o método de proteção mais simples, que utiliza a magnitude da corrente como um indicador da falta. Nesse método, o relé de proteção irá operar quando a máxima corrente de carga for maior que a mínima corrente de falta ajustada previamente (conhecida como corrente de “*pickup*” do relé), ou seja:

$$\begin{aligned} |I_L| &\geq I_p : \text{falta} \\ |I_L| &< I_p : \text{operação normal} \end{aligned} \tag{3.1}$$

onde I_L é a corrente da carga e I_P é a corrente de *pickup*. A atuação pode ser instantânea ou temporizada, onde o tempo de atuação é inversamente proporcional ao valor da corrente de falta.

- Proteção direcional: quando o circuito na qual a linha de transmissão está inserida é formado por múltiplas fontes é necessária uma proteção de sobrecorrente direcional, para limitar a operação do relé para faltas em apenas uma direção. Os chamados relés de sobrecorrente direcionais utilizam o ângulo de fase entre a corrente de falta e uma grandeza de referência (a tensão correspondente, por exemplo) para determinar a direção da falta. Considerando que o circuito da falta consiste na maior parte de linhas de transmissão quase puramente indutivas, o atraso da corrente de falta em relação a tensão é quase 90° . Se o ângulo entre o fasor de referência (tensão) e a corrente de falta é θ , a operação do relé é descrita por:

$$\begin{aligned} -\pi \leq \theta \leq 0 & : \text{operação} \\ 0 \leq \theta \leq \pi & : \text{bloqueio} \end{aligned} \quad (3.2)$$

- Proteção de distância: em redes de extra-alta tensão, os valores da máxima corrente de carga e mínima corrente de falta nem sempre são bem definidos, nem são suficientemente afastados para permitir uma escolha segura da corrente de *pickup*. Para esses casos os chamados relés de distância fornecem uma proteção mais eficiente. Considerando uma linha de transmissão com uma falta tipo curto-circuito fase-fase a uma distância k da posição do relé, tem-se a seguinte relação:

$$\frac{E_x - E_y}{I_x - I_y} = kZ_1 \quad (3.3)$$

onde E_x , E_y , I_x , e I_y são as tensões e correntes nas fases x e y , respectivamente. Z_1 é a impedância de sequência positiva da linha inteira. De forma similar, para uma falta tipo curto-circuito fase-terra, tem-se a seguinte relação:

$$\frac{E_x}{I_x - mI_0} = kZ_1 \quad (3.4)$$

onde $m = (Z_0 - Z_1)/Z_1$ e Z_0 é a impedância de sequência zero da linha. As relações dadas nas equações 3.3 e 3.4 representam a fração da impedância da linha na qual a falta ocorre. Se essa fração for menor que a impedância total da linha, o relé irá operar.

- Proteção piloto: a proteção piloto é utilizada quando se deseja que a linha inteira (e não apenas uma parte dela) seja provida de uma proteção de alta velocidade. Nesse tipo de proteção, os relés de proteção remotos transmitem a informação da localização da falta um para outro, permitindo a isolamento da zona sob a falta no menor tempo possível. Um canal de comunicação deve ser usado, podendo ser uma portadora de alta frequência na linha, um canal de microondas, um cabo de fibra ótica ou ainda um fio ao longo da linha, o chamado fio piloto.

Os algoritmos baseados nos métodos convencionais utilizam as componentes de frequência fundamental da tensão e corrente obtidas a partir das amostras extraídas da linha. O desempenho desses algoritmos depende da estimativa precisa das componentes de frequência fundamental de um sinal composto por algumas amostras (Phadke e Thorp, 2009). Várias técnicas de estimação de parâmetros podem ser utilizadas, sendo as mais citadas na literatura:

- Mínimos quadrados;
- Transformada Discreta de *Fourier*;
- Funções *Walsh*;
- Equação diferencial do modelo R-L;
- Filtro de *Kalman*.

Outros métodos convencionais também são utilizados em algoritmos para diagnóstico de faltas em linhas de transmissão. No método das componentes simétricas, aplicando uma matriz de transformação adequada na tensão e corrente de cada fase, obtêm-se as componentes de sequência positiva, sequência negativa e sequência zero. Calculando as relações entre as componentes simétricas obtêm-se a fração da impedância da linha em que ocorre a falta e, por comparação com a impedância da linha, é possível detectar a falta. Já no método das componentes de *Clarke*, também aplicando uma matriz de transformação adequada na tensão e corrente de cada fase, obtêm-se as chamadas componentes zero, alfa e beta. Através de comparações dos valores calculados a partir das componentes de *Clarke*, é possível classificar corretamente o tipo de falta (Phadke e Thorp, 2009).

Os métodos convencionais baseados em parâmetros são amplamente empregados em sistemas de proteção de linhas de transmissão, mas vários fatores afetam a precisão desses métodos, tais como: resistência de falta, distância da falta, influência de efeitos mútuos nas componentes de sequência zero em linhas paralelas, efeitos de reatância, imprecisão do modelo da linha, dentre outros. (Silveira, Seara e Zurn, 1999).

3.2 Métodos baseados em análise de sinais

As mudanças nos sinais de tensão e corrente da linha de transmissão devido à ocorrência de uma falta, quando analisadas no domínio da frequência, permitem observar que as mudanças ocorrem tanto na componente de frequência fundamental, quanto nas componentes de alta frequência dos sinais. E nota-se ainda que a mudança nas componentes de alta frequência ocorre mais rapidamente do que na componente de frequência fundamental, e tal mudança também depende das características da falta. Dessa forma, se o espectro dos sinais de falta for extraído, o diagnóstico da falta pode ser realizado (Makming *et al.*, 2002).

Sabe-se que as componentes de alta frequência dos sinais gerados pela falta contêm uma riqueza de informações sobre a mesma, tais como o tipo da falta, sua localização, direção e duração. O uso desses sinais transitórios de alta frequência permite a criação de novos

princípios de proteção que não podem ser implementados usando somente com sinais na frequência fundamental do sistema. Isto levou ao desenvolvimento das tecnologias denominadas “proteção baseada em transitório” e “identificação de transitório” (Bo; Redfern; Weller, 2000).

Os esquemas de proteção baseada em transitório operam extraíndo os sinais transitórios de alta frequência gerados pela falta, através de dispositivos de detecção especialmente projetados e seus algoritmos associados. Os sinais de corrente de altas frequências são extraídos diretamente de transformadores de corrente (TC). Apesar do TC’s convencionais atenuarem sinais de altas frequências, suas características são tais que um sinal suficiente pode ser detectado e medido, e vários pesquisadores tem estudado o uso de sinais de altas frequências em métodos de proteção. Após os sinais extraídos passarem por uma filtragem analógica, são utilizados algoritmos rápidos de processamento de sinais para permitir a realização da identificação da falta (Bo, Redfern e Weller, 2000). Desses algoritmos, dentre os mais utilizados estão a Transformada de *Fourier* e a Transformada Wavelet.

3.2.1 Transformada de *Fourier*

A análise de sinais e sistemas usando representações senoidais é denominada análise de *Fourier* e pode ser dividida em quatro representações distintas, uma para cada classe de sinais (Haykin e Venn, 2001):

- Série de *Fourier* (*Fourier Series – FS*): se aplica a sinais periódicos de tempo contínuo;
- Série de *Fourier* de Tempo Discreto (*Discrete Time Fourier Series – DTFS*): se aplica a sinais periódicos de tempo discreto;
- Transformada de *Fourier* (*Fourier Transform – FT*): se aplica a sinais não-periódicos de tempo contínuo;
- Transformada de *Fourier* de Tempo Discreto (*Discrete Time Fourier Transform – DTFT*): se aplica a sinais não-periódicos de tempo discreto.

Como nos esquemas de proteção de linhas de transmissão com relés digitais a informação é tratada na forma discreta (amostras da tensão e corrente da linha), a representação utilizada na análise dos sinais é a DTFS. Considerando um sinal discreto $x(n)$, a DTFS desse sinal é expressa como:

$$X(k) = \frac{1}{N} \sum_{n=0}^{N-1} x(n) e^{-jk\Omega_0 n} \quad (3.5)$$

E a DTFS inversa é expressa como:

$$x(n) = \sum_{k=0}^{N-1} X(k) e^{jk\Omega_0 n} \quad (3.6)$$

Onde:

N período fundamental.

Ω_0 frequência angular fundamental ($\Omega_0 = 2\pi/N$).

A representação pelos coeficientes da *DTFS* também é conhecida como representação de domínio de frequência, porque cada coeficiente da *DTFS* é associado com uma senóide complexa de frequência diferente. A equação 3.5 é a *DTFS* de $x(n)$, uma vez que ela converte o sinal no domínio do tempo para sua representação no domínio da frequência. Já a equação 3.6 é a *DTFS* inversa, uma vez que ela converte a representação no domínio da frequência de volta ao domínio de tempo.

A *DTFS* é mais frequentemente citada na literatura como transformada discreta de *Fourier* ou *Discrete Fourier Transform – DFT*, apesar de que a terminologia *DTFS* é mais descritiva e tem menos probabilidade de acarretar confusão com a *DTFT* (Haykin e Venn, 2001). A figura 3.1 ilustra a aplicação da Transformada de *Fourier* em um sinal.



Figura 3. 1: Aplicação da Transformada de Fourier.

O uso da *DTFS* em sistemas computacionais é viabilizado pela disponibilidade de algoritmos eficientes, chamados genericamente de Transformadas Rápidas de *Fourier* (*Fast Fourier Transform – FFT*). Esses algoritmos rápidos operam de acordo com o princípio “dividir para conquistar”, dividindo a *DTFS* numa série *DTFS* de ordem mais e explorando as propriedades de simetria e periodicidade da senóide complexa $e^{jk2\pi m}$. É necessária uma menor quantidade de operações para calcular a *DTFS* de ordem mais baixa do que para calcular a *DTFS* original (Haykin e Venn, 2001).

3.2.2 Exemplo empregando Transformada de *Fourier*

Normalmente, a *FFT* é empregada nos algoritmos de diagnóstico de falta em linhas de transmissão na etapa de extração de características dos sinais da linha, onde os sinais de altas

frequências são convertidos para o domínio da frequência e suas componente são empregados nas etapas seguintes do diagnóstico da falta.

Como apresentado no trabalho de Bo, *et al.* (1997), o problema de diagnóstico de faltas é tratado como um problema de classificação de padrões, ou seja, um padrão de dados extraído da linha de transmissão pode ser classificado como um padrão normal (sem falta) ou um padrão anormal (com falta). Como classificador os autores propõe o uso de uma RNA, que deve ser previamente treinada com padrões de dados correspondentes aos diversos tipos de faltas. A utilização da Transformada de *Fourier* ocorre na geração dos padrões de dados.

A geração dos padrões de dados inicia-se na extração de amostras das tensões de cada fase da linha de transmissão. Os três sinais de tensão (V_a , V_b , V_c) passam por um filtro *anti-aliasing*, que elimina as frequências não desejadas, e são amostrados a uma taxa de 200 kHz. Em seguida, são obtidas as amplitudes das componentes de altas frequências dos sinais empregando um algoritmo FFT. Os sinais no domínio da frequência são então divididos em 6 faixas de frequência, resultando em um vetor de entrada para a RNA com 18 características associadas com as três fases. Assim, partir dos dados de entrada, a RNA produz em cada uma das suas três saídas um valor 0 para indicar fase em operação normal ou 1 para indicar fase com ocorrência da falta. A figura 3.2 apresenta a configuração básica do método de diagnóstico de faltas proposto.

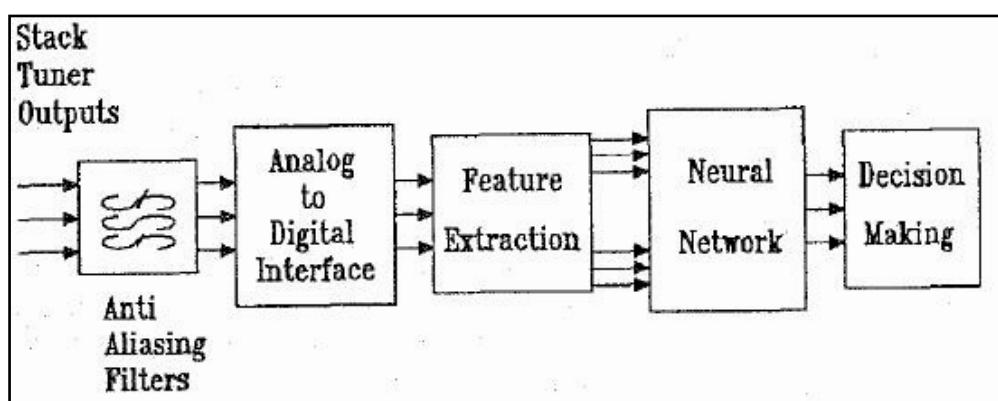


Figura 3. 2: Método baseado em FFT para diagnóstico de faltas (Bo, et al., 1997).

Nos trabalhos que empregam a Transformada de *Fourier* para diagnóstico de faltas em linhas de transmissão, os resultados obtidos demonstram que os métodos propostos são eficientes e precisos para a maioria dos tipos de faltas. Mas, segundo Das, Singh e Sinha (2006), e Gayathri e Kumarappan (2008), para alguns tipos de faltas (especificamente, curto-circuitos fase-fase e fase-fase-terra) os métodos falharam na identificação das mesmas. Além disso, os autores apontam uma desvantagem da Transformada de *Fourier* para fins de detecção de faltas, que é a falta da informação temporal, uma vez que a transformada apenas fornece informação sobre a frequência. Ou seja, através da Transformada de *Fourier* não é possível determinar o instante de tempo em que cada componente de frequência do sinal ocorre, o que é fundamental para um diagnóstico de faltas mais eficiente e preciso.

3.2.3 Transformada Wavelet

Wavelets são funções que satisfazem certos requisitos matemáticos e são usadas na representação de dados ou outras funções. A idéia de aproximação com superposição de funções não é nova, pois desde 1800 *Josep Fourier* já havia descoberto que era possível sobrepor senos e cossenos para representar outras funções. Mas, na chamada análise de *wavelet*, a escala que se usa para examinar os dados desempenha um papel especial. Os algoritmos que empregam *wavelets* processam dados em diferentes escalas ou resoluções. Se o sinal for examinado com uma “janela” grande, pode-se observar características “grossas”. Da mesma forma, se o sinal for examinado com uma “janela” pequena, pode-se observar características “finas”. Atualmente as *wavelets* são empregadas em uma vasta gama de aplicações e em diversas áreas, tais como, matemática, física, engenharia e computação (Graps, 1995).

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 análise 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 (Misiti *et al.*, 2007). A Figura 3.3 ilustra estas diferenças.




Figura 3. 3: Diferenças entre uma onda senoidal e uma wavelet.

A análise de *Fourier* consiste em dividir um sinal em ondas senoidais de diferentes frequências. Da mesma forma, a análise de *wavelet* é a divisão de um sinal em versões deslocadas e escalonadas da *wavelet* original, comumente chamada de “*wavelet* mãe”.

Para muitos sinais, a análise de *Fourier* é muito útil porque o conteúdo de frequência do sinal é de grande importância. Mas, a análise de *Fourier* tem um sério inconveniente. Na transformação para o domínio da frequência, a informação tempo é perdida. Observando-se uma Transformada de *Fourier* de um sinal, é impossível dizer quando um evento ocorreu. A fim de 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 de Transformada de *Fourier* de Janela ou *Short Time Fourier Transform – STFT*, mapeia um sinal em uma função de duas dimensões: tempo e frequência. No entanto, 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 (Misiti *et al.*, 2007).

A análise de *wavelet* representa o próximo passo em métodos de análise de sinais: uma técnica de “janelamento” com regiões de tamanho variável. A análise de *wavelet* permite o uso de intervalos de tempo longos onde se deseja informação de baixas frequências mais precisa, e intervalo de tempos curtos onde se deseja informação de altas frequências mais precisa. A figura 3.4 ilustra a aplicação da Transformada Wavelet em um sinal.



Figura 3. 4: Aplicação da Transformada Wavelet.

Matematicamente, a Transformada Wavelet Contínua (*Continuous Wavelet Transform – CWT*) de um sinal contínuo $x(t)$ com relação a uma *wavelet* mãe $g(t)$ é genericamente definida como (Kim e Aggarwal, 2000):

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) g\left(\frac{t-b}{a}\right) dt \quad (3.7)$$

Onde:

a dilatação ou fator de escala.

b fator de translação.

t tempo.

Na equação 3.7 as variáveis a e b são contínuas. Essa equação mostra que a *CWT* mapeia o sinal original de uma dimensão no domínio do tempo para uma nova função de duas dimensões através do fator da escala a e do fator de translação b . Um coeficiente *wavelet* $CWT(a,b)$ a uma determinada escala e translação representa o quão semelhante são o sinal original $x(t)$ e a *wavelet* mãe $g(t)$ escalonada e transladada. Assim, o conjunto de todos os coeficientes *wavelet* $CWT(a,b)$ associados com um sinal em particular são a representação *wavelet* do sinal original $x(t)$ com relação à *wavelet* mãe $g(t)$. A *wavelet* mãe pode ser vista como uma função de janelamento, onde o fator de escala a representa a largura da janela. Dessa forma, é possível analisar os componentes de frequência de banda estreita de um sinal com um pequeno fator de escala, e componentes de frequência de banda larga com um grande fator de escala. Isto permite capturar todas as características de um determinado sinal.

Uma grande família de *wavelets*, também conhecidas como “*wavelets* filhas”, pode ser gerada a partir de uma *wavelet* mãe variando-se os fatores de escala e translação. O número de coeficientes e o nível de iteração para gerar uma *wavelet* filha dentro de uma família é usado

para distinguir de outra *wavelet* da família. Existem muitos tipos de *wavelets* mãe que podem ser empregadas na prática. A figura 3.5 apresenta algumas das *wavelets* mãe comumente utilizadas: as *wavelets* de *Haar*, *Symmlet*, *Daubechies* e *Morlet*. Dessas, as de *Haar* e de *Morlet* são classificadas como ortogonais, enquanto as de *Symmlet* e de *Daubechies* são não-ortogonais (Kim e Aggarwal, 2000). A referência Misiti *et al.* (2007) apresenta as características das principais famílias de *wavelets* utilizadas em processamentos de sinais.




Figura 3. 5: Exemplos de *wavelets* mãe.

Assim como existem as Transformadas de *Fourier* Contínua e Transformada de *Fourier* Discreta, a Transformada Wavelet Contínua possui sua versão discreta implementável digitalmente, chamada de Transformada Wavelet discreta (*Discrete Wavelet Transform – DWT*), e definida como (Kim e Aggarwal, 2000):

$$DWT(m, k) = \frac{1}{\sqrt{a_o^m}} \sum_n x(n) g\left(\frac{k - nb_o a_o^m}{a_o^m}\right) \quad (3.8)$$

Onde:

$x(n)$ sinal discreto.

m passo na escala discreta.

n passo na translação discreta.

k amostra.

Na *DWT*, os parâmetros de escala e translação são funções dos parâmetros inteiros m e n , isto é, $a = a_o^m$ e $b = nb_o a_o^m$, originando uma família de *wavelets* dilatadas, ou seja, as *wavelets* filhas. O resultado é um escalonamento geométrico, isto é, $1, 1/a, 1/a^2 \dots$ e translação por $0, n, 2n, \dots$. Esse escalonamento proporciona à *DWT* uma análise espectral logarítmica, em contraste com a análise espectral uniforme da *STFT*.

Trocando as variáveis n , k e rearranjando a DWT da equação 3.8, obtém-se (Kim e Aggarwal, 2000):

$$DWT(m, n) = \frac{1}{\sqrt{a_o^m}} \sum_k x(k) g(a_o^{-m} n - b_o k) \quad (3.9)$$

Observando a equação 3.9 nota-se uma há uma semelhança com a equação do Filtro de Resposta Finita (*Finite Impulse Response – FIR*), a saber:

$$y(n) = \frac{1}{c} \sum x(k) h(n - k) \quad (3.10)$$

Onde:

$h(n-k)$ resposta ao impulso do filtro FIR

Comparando as equações 3.9 e 3.10 fica evidente que a resposta ao impulso da DWT é dada por:

$$g(a_o^{-m} n - b_o k) \quad (3.11)$$

Escolhendo $a_o = 2$, ou $a_o^{-m} = 1, 1/2, 1/4, 1/8, \dots$, e $b_o = 1$, a DWT pode ser implementada usando um filtro multi-estágio, com a *wavelet* mãe como o filtro passa-baixa $l(n)$ e sua complementar como o filtro passa-alta $h(n)$. Essa implementação está ilustrada na figura 3.6. Como mostra essa figura, a sub-amostragem (*downsampling*) realizada nas saídas dos filtros passa-baixa por um fator de 2 ($\downarrow 2$) equivale a escalonar a *wavelet* por um fator de 2 para o próximo estágio, simplificando o processo de dilatação. Os filtros passa-alta e passa-baixa estão relacionados por:

$$h(L - 1 - n) = (-1)^n l(n) \quad (3.12)$$

Onde:

L comprimento do filtro

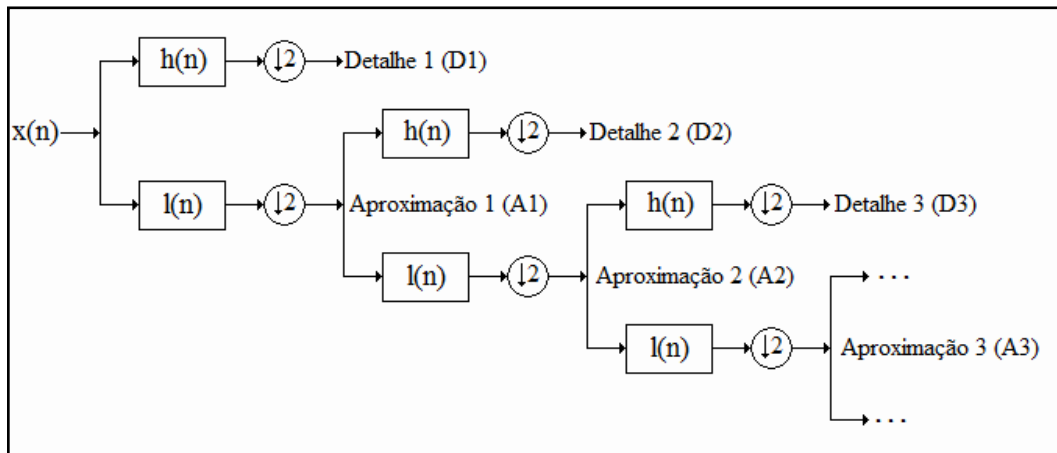


Figura 3. 6: Filtro multi-estágio para implementação da DWT.

Os dois filtros são versões invertidas e alternadas um do outro, sendo que a conversão de passa-baixa para passa-alta é fornecida pelo termo $(-1)^n$, condição satisfeita em filtros comumente usados em processamento de sinais e conhecidos como filtros espelho em quadratura (*Quadrature Mirror Filters – QMF*). A implementação da *DWT* com um banco de filtros é eficiente do ponto de vista da computação necessária para tal. As saídas de cada filtro passa-alta da figura 3.8 fornece a versão detalhada da componente de alta frequência do sinal. E as saídas de cada filtro passa-baixa é novamente dividida para se obter as outras versões detalhadas do sinal de entrada. Assim como a técnica *STFT*, a *DWT* pode ser representada em um gráfico de duas dimensões, mas com uma divisão de tempo e frequência diferente. Por exemplo, para um sinal amostrado numa frequência F_s , a frequência mais alta do sinal amostrado que pode ser representada fielmente é $F_s/2$, de acordo com o teorema de *Nyquist*. Isto seria visto na saída do primeiro filtro passa-alta do banco de filtros da figura 3.6, isto é, o primeiro detalhe (D1) captura a banda de frequências entre $F_s/2$ e $F_s/4$. De forma semelhante, o segundo detalhe (D2) captura a banda de frequências entre $F_s/4$ e $F_s/8$, e assim por diante (Kim e Aggarwal, 2000).

A decomposição consiste num procedimento comumente denominado de análise multiresolução (*Multiresolution Analysis – MRA*), onde é empregado o algoritmo da *DWT* para se obter os coeficientes de aproximação (A_j) e os coeficientes de detalhe (D_j) do sinal em diferentes níveis de resolução. O procedimento é definido como (Kim e Aggarwal, 2001):

$$A_j(n) = \sum_k l(k)A_{j-1}(n-k) \quad (3.13)$$

$$D_j(n) = \sum_k h(k)A_{j-1}(n-k) \quad (3.14)$$

Onde:

$h(k)$ filtro discreto passa-alta.

$l(k)$ filtro discreto passa-baixa.

j resolução.

k comprimento do filtro ($k = 1, 2, 3, \dots, K$).

Um coeficiente de aproximação é uma representação de baixa resolução do sinal original e contém uma tendência geral do sinal, enquanto um coeficiente de detalhe é a diferença entre duas representações de baixa resolução sucessivas do sinal original e incorpora o conteúdo de alta frequência do sinal. O número máximo de níveis é determinado por vários fatores, tais como o comprimento do sinal original, a *wavelet* mãe selecionada e o nível de detalhe requerido. Os filtros passa-baixa e passa-alta são determinados pela função de escalonamento e função *wavelet*, respectivamente. A figura 3.7 apresenta, a título de exemplo, a decomposição de um típico sinal de corrente de falta em linha de transmissão nos coeficientes de aproximação (A3) e de detalhe (D1 a D3), utilizando a *wavelet* mãe *db4* (Daubechies 4).

Observando a figura, pode-se notar nos instantes de início e fim da falta a presença de componentes de alta frequência indicados pelos coeficientes de detalhe D1 a D3.




Figura 3. 7: Decomposição de um sinal de falta utilizando wavelet mãe db4.

3.2.4 Exemplos empregando Transformada Wavelet

O diagnóstico de faltas baseada na Transformada Wavelet emprega a decomposição dos sinais de tensão ou corrente da linha de transmissão nos chamados coeficientes *wavelet*, onde cada um desses coeficientes representa uma parte dos sinais localizados tanto no tempo quanto na frequência. Os coeficientes são então utilizados como dados de entrada nos algoritmos.

O trabalho de Kim *et al.* (2002) apresenta um método para detecção de faltas de alta impedância (*High Impedance Fault – HIF*) em linhas de transmissão baseada na Transformada Wavelet. Nesse artigo é abordado inicialmente um estudo realizado para selecionar a *wavelet* mãe mais adequada para detecção de HIF. Os autores empregam a *DWT* para determinar o valor máximo do somatório dos coeficientes de detalhe D1 dos sinais de correntes extraídos da linha de transmissão utilizando diferentes famílias de *wavelets*. É escolhida então a *wavelet* mãe que apresentou maiores amplitudes nos somatórios da fase sob falta e maior diferença entre os somatórios da fase sob falta e das fases normais, nesse caso a *db4*. A seguir, os autores apresentam o algoritmo proposto para detecção de faltas, que inicia determinando através da *DWT* os coeficientes D1 dos sinais de correntes de fase durante um ciclo (a frequência de amostragem é de 3.840 Hz, o que equivalente a 64 amostras/período em 60Hz). Com base nesses coeficientes, é calculado o somatório do valor absoluto dos coeficientes da três fases, nomeado de *SUM_d1*. O valor do somatório é comparado com um

valor de limiar predefinido, nomeado de FC . Caso o somatório supere o limiar, uma variável tipo contador, nomeada de FI , é incrementada, caso contrário, ela é zerada. A variável FI é comparada com um número de amostras predefinido, nomeado de D , de forma que a falta é detectada somente quando o valor de FI superar D amostras. Com essa lógica de decisão, a falta deve persistir durante um determinado tempo, de forma que o algoritmo evita a detecção de falsas faltas, como transitórios provocados por comutação de cargas, por exemplo. Segundo os autores, para o sistema estudado, os valores ótimos de FC e D são 0,085 e 128, respectivamente. O algoritmo de detecção de faltas proposto é apresentado na figura 3.8.

No trabalho de Reddy e Mohanta (2007) é apresentado um método para classificação de faltas em linha de transmissão baseado na Transformada Wavelet semelhante ao método apresentado no trabalho de Chanda, Kishore e Sinha (2003). Em ambos os artigos, o coeficiente de detalhe D3 da DWT é utilizado como parâmetro de classificação. A partir dos sinais de correntes extraídos da linha de transmissão durante um ciclo (com uma frequência de amostragem de 12,5kHz), a DWT é empregada para determinar o valor do somatório dos coeficientes de detalhe D3 (detalhe três). Os somatórios são nomeados de Sa , Sb e Sc , em relação as fases a , b , e c , respectivamente. Comparando as magnitudes dos três somatórios, o algoritmo proposto realiza a classificação das faltas tipo curto-circuito fase-fase (LL), trifásica (LLL), fase-terra (LG) ou fase-fase-terra (LLG). Segundo os autores, a escolha do coeficiente de detalhe D3 entre os diversos níveis de decomposição obtidos pela DWT é justificada pelo fato de que, os valores absolutos do somatório dos coeficientes D3 para todos os ângulos de incidência da falta considerados são mais altos, quando comparados com os obtidos com os outros níveis. Outra razão para a escolha dos coeficientes D3 como parâmetro de classificação de faltas é que o somatório dos coeficientes de nível 3 satisfaz as relações características para todos os tipos de faltas para fins de classificação. O algoritmo de classificação de faltas baseado na Transformada Wavelet proposto em Reddy e Mohanta (2007) é apresentado na figura 3.9.

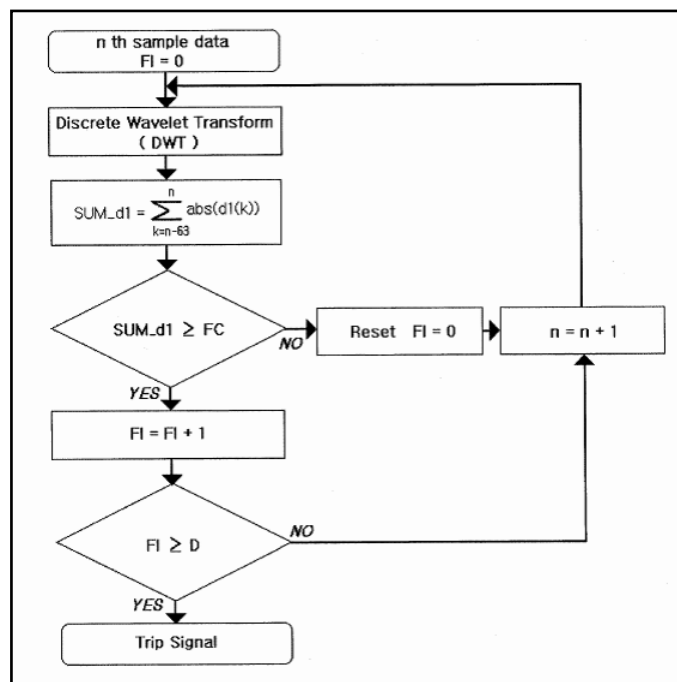


Figura 3. 8: Algoritmo de detecção de faltas utilizando DWT (Kim et al., 2002).

No trabalho de Zhao, Song e Min (2000) é apresentado um método para detecção e classificação de faltas em linha de transmissão baseado na Transformada Wavelet semelhante ao método apresentado no trabalho de Liang, Elangovan e Devotta (1998). Em ambos os artigos, a detecção de faltas é baseada na detecção de mudanças abruptas em determinados coeficientes da *DWT*, e a classificação de faltas é baseada na comparação de diversos fatores calculados a partir dos mesmos coeficientes com limiares pré-definidos. Na etapa de detecção, a partir dos sinais de correntes extraídos da linha de transmissão a cada intervalo de amostragem ($25\mu\text{s}$), a *DWT* é empregada para determinar o valor dos coeficientes de detalhe *D4* e *D9*. O valor absoluto do coeficiente *D4* de cada uma das três fases é comparado com um limiar ϵ , e se durante três intervalos consecutivos qualquer um dos coeficientes superar o limiar, é considerada a ocorrência da falta. A seguir, na etapa de classificação, são calculados três fatores nomeados de r_a , r_b e r_c a partir de outras variáveis calculadas a partir dos coeficientes *D4*. Esses três fatores, juntamente com o valor máximo do somatório dos coeficientes *D9* nomeado de $md9$, são utilizados em um conjunto de regras para determinar o tipo da falta. Em cada regra, relações entre os fatores e somatório são comparados com diferentes limiares e, conforme o resultado, a falta é classificada como falta tipo curto-circuito fase-fase (AB, BC, AC), trifásica (ABC), fase-terra (A-G, B-G, C-G) ou fase-fase-terra (AB-G, BC-G, AC-G). O algoritmo de detecção e classificação de faltas proposto em Zhao, Song e Min (2000) é apresentado na figura 3.10.

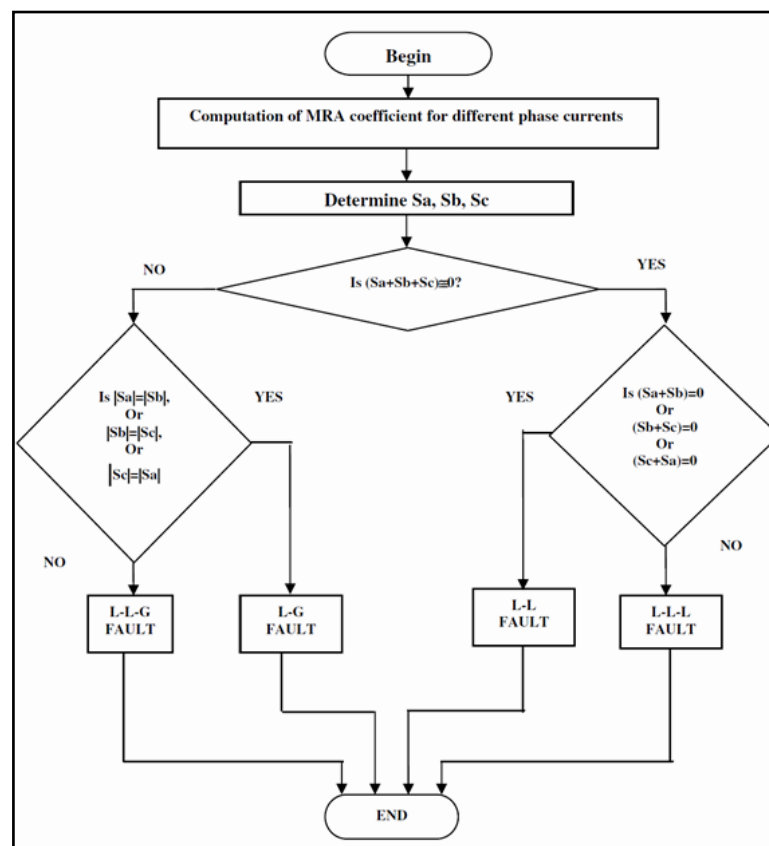


Figura 3. 9: Algoritmo de classificação de faltas utilizando DWT (Reddy e Mohanta, 2007).

No trabalho de Makming *et al.*, (2002) é apresentado um método para diagnóstico de faltas em linhas de transmissão baseado na Transformada Wavelet. Nesse artigo, o método proposto emprega os coeficientes da *DWT* para realizar a detecção, classificação e localização da falta. O algoritmo proposto inicia determinando os coeficientes da *DWT* a partir dos sinais das correntes de sequência positiva extraídos da linha. Como é utilizada uma frequência de amostragem elevada (200 kHz), os coeficientes de detalhe no nível 1 (D1) capturam a banda de frequência dos sinais entre 50 kHz e 100 kHz. A detecção da falta é baseada na mudança abrupta dos coeficientes do sinal de corrente, por comparação entre os coeficientes da corrente de pré-falta e corrente de falta. Os coeficientes D1 de cada corrente de fase são elevados ao quadrado de modo que uma mudança abrupta nesse sinal possa ser encontrada mais facilmente.

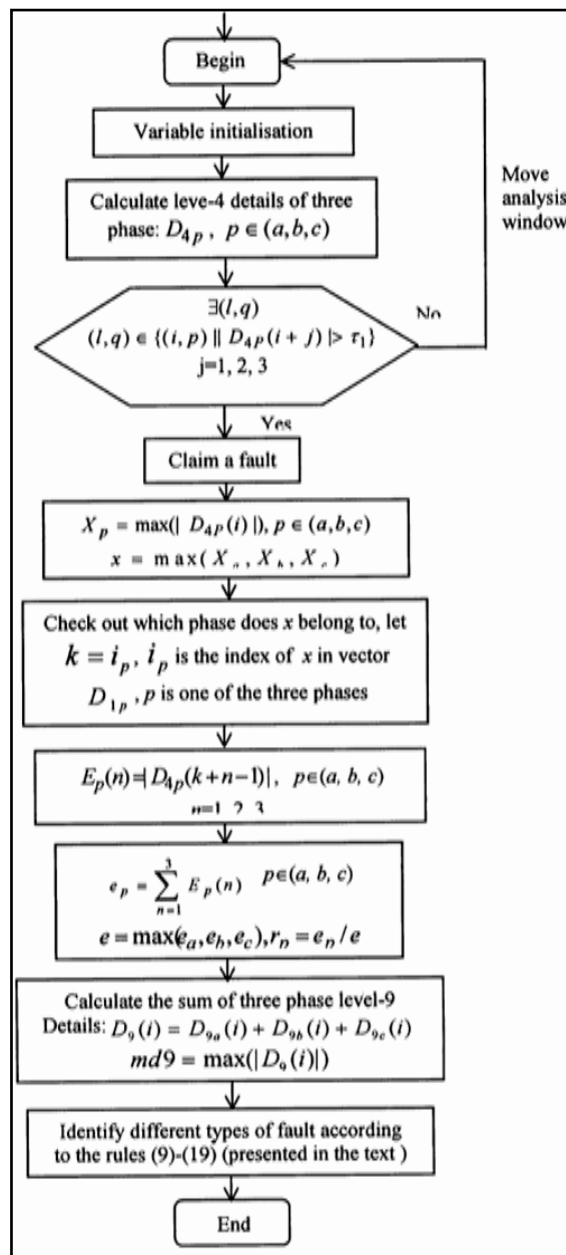


Figura 3. 10: Algoritmo de detecção e classificação de faltas utilizando DWT (Zhao, Song e Min, 2000).

A condição para determinar a ocorrência da falta é um aumento na amplitude dos coeficientes de cerca de cinco vezes em relação à amplitude antes da falta. A classificação da falta é baseada nos coeficientes da *DWT* obtidos para os sinais de corrente de sequência zero e corrente pós-falta extraídos da linha. Os fatores nomeados de X_{COM}^L , e Ph_{MAX}^L são calculados a partir dos coeficientes da *DWT* de cada fase e são empregados em uma regra. Nessa regra, as relações entre os fatores são comparadas com determinados limiares e, conforme o resultado, a fase é declarada com falta ou normal. E conforme o resultado da regra em cada fase, a falta é classificada como falta tipo curto-circuito fase-fase (*L-L*), trifásica (*3P*), fase-terra (*SLG*) ou fase-fase-terra (*DLG*). A localização da falta é baseada no cálculo da distância da falta em função do tempo em que o sinal da falta gasta para alcançar o final da linha de transmissão. Esse cálculo emprega a teoria das ondas viajantes, onde são utilizados como parâmetros os instantes de tempo obtidos na detecção da falta tanto no lado transmissor quanto no lado receptor da linha de transmissão, e a velocidade da onda viajante. O fluxograma do método para diagnóstico de faltas proposto é apresentado na Figura 3.11.

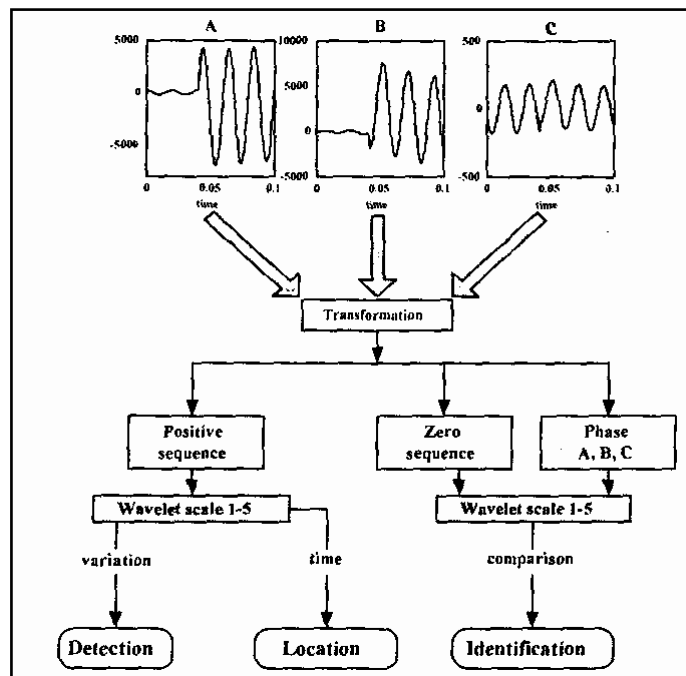


Figura 3. 11: Fluxograma do método de diagnóstico de faltas utilizando DWT (Makming et al., 2002).

Nos trabalhos citados que empregam a Transformada Wavelet para diagnóstico de faltas em linhas de transmissão, os resultados obtidos demonstram que os métodos propostos atingiram o desempenho igual ou superior aos outros métodos. Os autores destacam a principal vantagem da Transformada Wavelet em relação a outras técnicas de análise de sinais, em especial a Transformada de *Fourier*, que é a sua capacidade de fornecer informações de tempo e frequência dos sinais extraídos da linha. Além disso, os autores ainda destacam que o uso da Transformada Wavelet, com suas excelentes características para análise de sinais, confere aos algoritmos de detecção de faltas diversas qualidades, tais como precisão, robustez, confiabilidade e velocidade. Essas qualidades são importantes para a

aplicação prática dos métodos, visto que a detecção de faltas está sujeita a vários fatores que afetam a eficiência dos algoritmos, tais como mudanças dos parâmetros da linha, alterações nas condições da falta, transitórios causados por outros eventos, dentre outros.

3.3 Métodos inteligentes

Muitos métodos de diagnóstico de falhas em linhas de transmissão são baseados em cálculos determinísticos ou em modelo do sistema, o que traz algumas dificuldades para tais métodos, devido a fatores como complexidade do modelo do sistema, falta de conhecimento de seus parâmetros, grande quantidade de informações a serem processadas e incapacidade de adaptação dinâmica às variações de operação do sistema (Youssef, 2004).

Com o desenvolvimento dos algoritmos para diagnóstico de falhas baseado em análise de transitórios, verificou-se que a Transformada Wavelet permite a investigação dos sinais transitórios gerados no SEP, onde a decomposição dos sinais de falta em várias escalas da Transformada Wavelet permite que o diagnóstico seja alcançado. Apesar da Transformada Wavelet ser muito eficaz em detectar sinais transitórios gerados pelas faltas, ela pode não ser suficiente para uma caracterização completa (Chiradeja e Ngaopitakkul, 2009).

Para superar tais dificuldades, nos últimos anos têm sido propostos métodos inteligentes baseados em RNA e Lógica *Fuzzy*, e Redes *Neurofuzzy*, sendo que, as Redes *Neurofuzzy* aproveitam a capacidade de aprendizado das RNAs e a capacidade de tratamento da incerteza da Lógica *Fuzzy* na construção de métodos de diagnóstico de falhas mais eficientes.

3.3.1 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) ou simplesmente Redes Neurais, representam uma tecnologia que está presente em muitas áreas, tais como neurociências, matemática, estatística, física, ciência da computação e engenharia. As RNAs são aplicadas em diversos campos, como por exemplo: modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controle de processos. Isto se deve a uma importante propriedade das RNAs: a capacidade de aprender a partir de dados de entrada com ou sem professor (Haykin, 1999).

3.3.2 Exemplos empregando redes neurais artificiais

Normalmente, o uso das RNAs para diagnóstico de faltas em linhas de transmissão é tratado como um problema de reconhecimento de padrões, ou seja, a rede é treinada para reconhecer sinais senoidais puros como um indicador de condição normal do sistema e

mudanças de amplitude, fase, ou presença de transitórios como indicador de ocorrência da falta. Sinais de tensão ou corrente podem ser utilizados para detecção da falta, mas geralmente o sinal de corrente é mais sensível à ocorrência da falta do que o sinal de tensão (Vásquez; Altuve; Chacón, 1996).

No trabalho de Vásquez, Altuve e Chacón (1996) é apresentado um método para detecção de faltas em linhas de transmissão baseado em redes neurais. Nesse artigo é proposto o uso de uma RNA tipo *Multilayer Perceptron* (MLP), com uma camada de entrada de 5 ou 10 nós fonte (depende do tamanho da janela de dados empregada), uma camada oculta com 20 neurônios e uma camada de saída de apenas um neurônio. Os padrões de entrada da rede consistem em sinais de corrente extraídos da linha, que passam por um filtro *anti-aliasing* e depois são amostrados a uma frequência de 960Hz. Diferentes redes foram treinadas e avaliadas quanto a sua capacidade de identificar transições entre os estados de pré-falta e falta da linha. Com rede treinada, a mesma classifica os padrões de entrada em duas classes, ou seja, a saída igual a 1 para indicar a linha com falta e saída igual a 0 para indicar a linha sem falta. A figura 3.12 apresenta a estrutura do método de detecção de faltas baseado em RNA proposto.

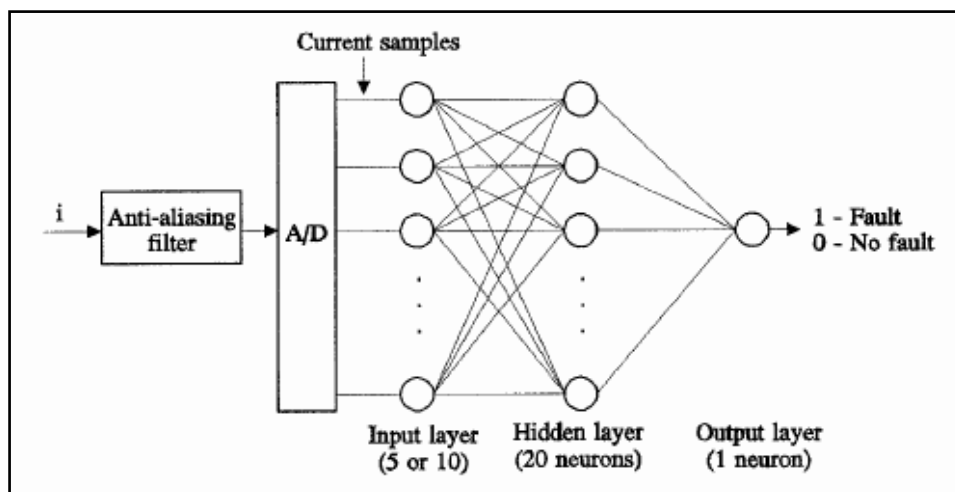


Figura 3. 12: Estrutura do método de detecção de faltas baseado em RNA (Vásquez, Altuve, e Chacón, 1996).

No trabalho de Fernandez e Ghonaim (2002) é apresentado um método para detecção e classificação de faltas em linhas de transmissão baseado em redes neurais. Nesse artigo é proposto o uso de uma RNA tipo *Finite Impulse Response Artificial Neural Network* (FIRANN). A rede FIRANN consiste de neurônios tipo FIR, que difere do neurônio normal por possuir um filtro FIR de ordem m em cada entrada. A figura 3.13 mostra o diagrama de uma rede FIRANN com duas camadas ocultas. Esse tipo de RNA possui bom desempenho em tarefas como previsão de séries temporais e utiliza um algoritmo de treinamento denominado *back-propagation* temporal. Os autores utilizaram uma rede FIRANN com uma camada de entrada de 8 nós fonte, duas camadas ocultas com 45 e 35 neurônios, respectivamente, e uma camada de saída com 5 neurônios. Os padrões de entrada consistem em sinais de tensão e corrente extraídos da linha, amostrados a uma frequência de 2 kHz. Mais especificamente, são utilizadas 3 entradas para tensão (V_a , V_b , V_c), 3 entradas para corrente (I_a , I_b , I_c), uma

entrada para o somatório das tensões ($V_a+V_b+V_c$) e uma entrada para o somatório das correntes ($I_a+I_b+I_c$). Das cinco saídas da rede utilizada, três indicam a fase com falta (A, B, C), uma indica a detecção da falta (DET) e outra indica a direção da falta (DIR). Há ainda uma saída derivada da saída DET que indica a ocorrência de subtensão ou subcorrente na linha (ST). Durante o processo de treinamento, foi empregada uma estratégia para determinar a configuração ótima para a rede FIRANN, isto é, número de neurônios em cada camada, número de unidades de atraso e parâmetros da função de ativação. O método proposto pelos autores utiliza além da rede FIRANN, alguns outros elementos para auxiliar no processamento dos sinais, tais como comparadores lógicos. A FIRANN mais os outros elementos constituem um sistema para detecção e classificação de faltas em linhas de transmissão. O diagrama completo do sistema proposto é apresentado na figura 3.14.

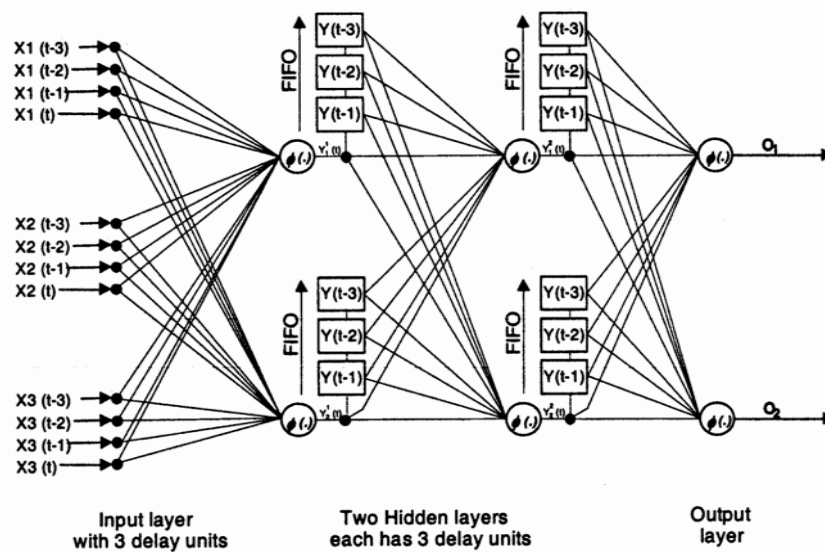


Figura 3. 13: Diagrama de uma rede FIRANN com duas camadas ocultas (Fernandez e Ghonaim, 2002).

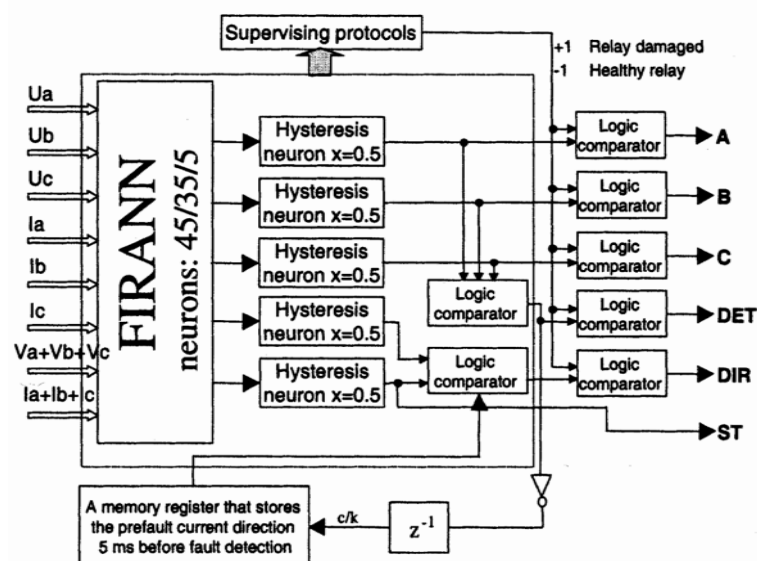


Figura 3. 14: Diagrama do sistema para detecção e classificação de faltas baseado em RNA (Fernandez e Ghonaim, 2002).

No trabalho de Oleskovicz, Coury e Aggarwal (2001) é apresentado um método para diagnóstico de faltas em linha de transmissão. Nesse artigo, é proposto um método baseado em associação de várias RNAs tipo MLP com diferentes topologias, onde uma ou mais RNA é realiza cada etapa do processo de diagnóstico de faltas: detecção, classificação e localização. Os padrões de entrada consistem em janelas de dados com 4 amostras da tensão trifásica e 4 amostras da corrente trifásica cada (12 amostras de tensão e 12 amostras de corrente). No chamado módulo de detecção, a RNA utilizada possui 24 nós fonte na camada de entrada, 9 neurônios na camada oculta e 2 neurônios na camada de saída. As saídas do módulo de detecção, nomeadas de D1 e D2, indicam a ocorrência da falta e a sua direção. Quando uma falta é detectada, a última janela de dados é transferida para o segundo módulo, chamado módulo de classificação. Nesse módulo é utilizada uma RNA com 24 nós fonte na camada de entrada, 16 neurônios na camada oculta e 4 neurônios na camada de saída. As saídas do módulo de classificação, nomeadas de C1, C2, C3 e C4 indicam o tipo da falta entre os 10 tipos considerados (faltas tipo curto-circuito fase-terra, fase-fase-terra, fase-fase e trifásica). Após a classificação da falta, conforme o seu tipo, as amostras de dados são direcionadas para uma das quatro RNAs do terceiro módulo, chamado módulo de localização. Nesse módulo, a RNA que localiza faltas tipo fase-terra possui 24 nós fonte na camada de entrada, 48 neurônios na primeira camada oculta, 44 neurônios na segunda camada oculta e 3 neurônios na camada de saída; a RNA que localiza faltas tipo fase-fase e a RNA que localiza faltas tipo fase-fase-terra possuem, ambas, 24 nós fonte na camada de entrada, 44 neurônios na primeira camada oculta, 40 neurônios na segunda camada oculta e 4 neurônios na camada de saída; e a RNA que localiza faltas tipo trifásica possui 24 nós fonte na camada de entrada, 24 neurônios na primeira camada oculta, 20 neurônios na segunda camada oculta e 3 neurônios na camada de saída. As saídas de todas as RNAs do módulo de localização, nomeadas de L1, L2 e L3, são iguais e indicam a localização da falta em termos de zonas de proteção (zona 1, zona 2 ou zona 3) para os respectivos tipos de faltas. A figura 3.15 apresenta um esquema com o método para diagnóstico de falta baseado em RNAs proposto.

Em outros trabalhos sobre métodos de diagnóstico de faltas baseados em RNAs encontrados na literatura, os padrões de entrada para as redes são constituídos de informações das componentes de frequência dos sinais de tensão e correntes e não de amostras de amplitude dos mesmos. No trabalho de Gayathri e Kumarappan (2008) é utilizada a Transformada de *Fourier* para extrair as componentes de frequência fundamental dos sinais, que são utilizados para detecção da falta pela RNA. No trabalho de Chiradeja e Ngaopitakkul (2009) é utilizada a Transformada Wavelet para decompor os sinais de forma a se obter as componentes de altas frequências, que são utilizadas para classificação da falta pela RNA.

Nos trabalhos citados que empregam RNAs para diagnóstico de faltas em linhas de transmissão, os resultados obtidos demonstram que os métodos propostos alcançam índices de desempenho superior a outros métodos de diagnóstico de faltas. Os autores destacam que as principais vantagens do uso de RNAs para diagnóstico de faltas em relação a outros métodos são a alta precisão e a alta velocidade de resposta. Outros fatores que contribuem para a eficiência dos métodos propostos são a capacidade de aprendizado e generalização das RNAs. Com a capacidade de aprendizado, o diagnóstico de faltas pode ser aplicado em qualquer

linha de transmissão, independente de suas características, desde que se disponha de dados de treinamento. E com a capacidade de generalização, mesmo as situações de faltas não apresentadas durante o treinamento são corretamente diagnosticadas. Dessa forma, as características dos métodos de diagnóstico de faltas baseados em RNAs os tornam mais indicados para serem aplicados em proteção de SEP do que os métodos convencionais.

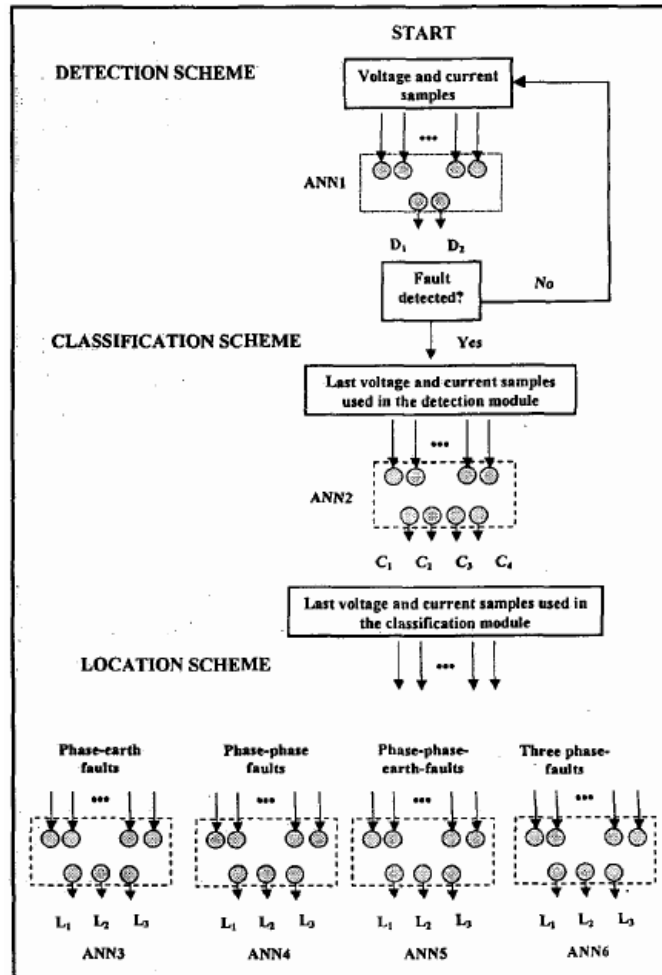


Figura 3. 15: Esquema do método de diagnóstico de faltas baseado em RNAs (Oleskovicz, Coury e Aggarwal, 2001).

3.3.4 Lógica Fuzzy

A lógica *fuzzy* (ou lógica nebulosa) é a lógica baseada na teoria dos conjuntos *fuzzy* (ou conjuntos nebulosos) introduzida por Lotfi A. Zadeh em um artigo publicado em 1965. Lógica *fuzzy* e conjuntos *fuzzy* se tornaram uma das áreas consolidadas nas tecnologias de processamento de informações. Estudos recentes estão espalhados por várias áreas, tais como controle de processos, reconhecimentos de padrões, sistemas especialistas, visão computacional e vida artificial. Um grande número de aplicações para o mundo real foram desenvolvidas e vão desde aplicações domésticas até aplicações industriais, envolvendo

apenas lógica *fuzzy* ou lógica *fuzzy* em conjunto com outras abordagens, como redes neurais. (Pedrycz e Gomide, 1998).

3.3.5 Exemplos empregando Lógica *Fuzzy*

A abordagem utilizada no diagnóstico de falhas em linhas de transmissão com uso da lógica *fuzzy* é geralmente o Sistema de Inferência *Fuzzy* (*Fuzzy Inference Systems - FIS*) padrão, constituído basicamente de três componentes: fuzzyficação, máquina de inferência e defuzzyficação. Nesse sistema, as entradas são valores numéricos (amostras de tensão e/ou corrente) que são convertidos em variáveis *fuzzy*. As entradas fuzzyficadas são aplicadas na máquina de inferência *fuzzy*, que produz a saída na forma *fuzzy* de acordo com a base de regras *fuzzy*. A regra *fuzzy* é selecionada conforme o tipo da falta. A saída da máquina de inferência é defuzzyficada para se obter a saída numérica (informação sobre a falta) (Mahanty; Gupta, 2006).

O trabalho de Das e Reddy (2005) apresenta um método para classificação de faltas em linhas de transmissão baseado em lógica *fuzzy*. Nesse artigo é proposto um algoritmo de classificação que emprega a diferença angular entre as componentes de sequência das correntes de falta, bem como as magnitudes relativas das mesmas, como informações sobre a falta. As diferenças angulares foram nomeadas de ang_A , ang_B e ang_C , e são calculadas a partir das amostras das correntes de falta como a diferença entre as componentes de sequência positiva (I_{a1f} , I_{b1f} , I_{c1f}) e sequência negativa (I_{a2f} , I_{b2f} , I_{c2f}) das fases A, B e C, respectivamente, ou seja:

$$\begin{aligned} ang_A &= |Arg(I_{a1f}) - Arg(I_{a2f})| \\ ang_B &= |Arg(I_{b1f}) - Arg(I_{b2f})| \\ ang_C &= |Arg(I_{c1f}) - Arg(I_{c2f})| \end{aligned} \quad (3.15)$$

As magnitudes relativas foram nomeadas de R_{0f} e R_{2f} , e calculadas como a relação entre componentes de sequência zero (I_{a0f} , I_{b0f} , I_{c0f}) e sequência negativa com as componentes de sequência positiva, para cada tipo de falta. Por exemplo, para uma falta A-terra, as relações são:

$$R_{0f} = \left| \frac{I_{a0f}}{I_{a1f}} \right| \text{ e } R_{2f} = \left| \frac{I_{a2f}}{I_{a1f}} \right| \quad (3.16)$$

No caso de faltas que envolvam duas fases, as relações R_{0f} e R_{2f} são substituídas por dois fatores, nomeados de K e K_I , sendo estes calculados a partir da impedância de sequência zero e impedância de sequência negativa da linha, e impedância da falta.

Para realizar a classificação, os autores utilizaram um FIS padrão, que recebe as quantidades numéricas de ang_A , ang_B e ang_C , R_{0f} e R_{2f} e realiza a fuzzyficação para converter tais quantidades em variáveis *fuzzy*. Em seguida, a máquina de inferência *fuzzy*

utiliza a base de regras *fuzzy* para determinar a variável *fuzzy* de saída, que representa o tipo da falta. Por exemplo, a regra para classificar falta tipo A-terra é descrita como:

- “Se ang_A é aproximadamente 30° e ang_B é aproximadamente 150° e ang_C é aproximadamente 90° e R_{of} é alto e R_{2f} é alto, então a falta é tipo A-terra”.

Neste caso, foram utilizados o operador mínimo para conectar múltiplos antecedentes nas regras, o operador de implicação mínimo e o operador de agregação máximo. Na representação de todas as variáveis *fuzzy* (tanto na parte antecedente, quanto na parte consequente das regras) foram utilizadas funções de pertinência triangulares. Para determinar a saída numérica relativa ao tipo de falta, foi utilizado o método de defuzzificação centróide de área. O diagrama em bloco do FIS empregado pelos autores para classificação das faltas é apresentado na figura 3.16.




Figura 3. 16: Diagrama em bloco do FIS empregado para classificação de faltas proposto por Das e Reddy (2005).

O trabalho de Mahanty e Gupta (2007) apresenta um método para classificação de faltas em linhas de transmissão baseado em lógica *fuzzy*. Nesse artigo é proposta uma técnica de classificação que emprega apenas amplitude das correntes de falta como informação sobre a falta. Nesse caso, a amplitude da corrente em cada fase é utilizada na obtenção de três variáveis principais, denominadas Δ_1 , Δ_2 , Δ_3 , calculadas a partir de outras variáveis. Inicialmente, a partir das amostras da corrente pós-falta, as relações entre elas, r_1 , r_2 , e r_3 são calculadas como:

$$r_1 = \frac{\max\{abs(Ia)\}}{\max\{abs(Ib)\}}, \quad r_2 = \frac{\max\{abs(Ic)\}}{\max\{abs(Ia)\}}, \quad r_3 = \frac{\max\{abs(Ib)\}}{\max\{abs(Ic)\}} \quad (3.17)$$

onde Ia , Ib , Ic são as correntes pós-falta das respectivas fases. Em seguida, os valores normalizados r_{1n} , r_{2n} , e r_{3n} são calculados como:

$$r_{1n} = \frac{r_1}{\max\{r_1, r_2, r_3\}}, \quad r_{2n} = \frac{r_2}{\max\{r_1, r_2, r_3\}}, \quad r_{3n} = \frac{r_3}{\max\{r_1, r_2, r_3\}} \quad (3.18)$$

Então, os valores de Δ_1 , Δ_2 , Δ_3 , são calculados como:

$$\Delta_1 = r_{1n} - r_{2n}, \quad \Delta_2 = r_{2n} - r_{3n}, \quad \Delta_3 = r_{3n} - r_{1n} \quad (3.19)$$

Como mecanismo de classificação os autores utilizaram um FIS padrão, que recebe como entrada as variáveis Δ_1 , Δ_2 , Δ_3 , que são convertidas nas suas variáveis *fuzzy* correspondentes

na etapa de fuzzyficação. As entradas fuzzyficadas são aplicadas na máquina de inferência, que produz uma saída *fuzzy* (tipo da falta), de acordo com a base de regras *fuzzy*. A base regras *fuzzy* foi dividida em duas partes, um conjunto de regras para faltas envolvendo terra e outro conjunto de regras para faltas envolvendo apenas fases. A decisão de qual conjunto de regras usar é feita com base no valor máximo do somatório das correntes de fase ($I_a + I_b + I_c$). Segundo os autores, foi observado que valores altos desse somatório (maior que 100) indica faltas envolvendo terra e valores baixos (menor que 1) indica faltas sem envolvimento de terra. Por exemplo, a regra que classifica faltas tipo A-terra e a regra que classifica faltas tipo A-B, são descritas como:

- “Se Δ_1 é alto_g e Δ_2 é médio_g e Δ_3 é baixo_g, então a falta é A-terra”.
- “Se Δ_1 é baixo_{ph} e Δ_2 é alto_{ph} e Δ_3 é baixo_{ph}, então a falta é A-B”.

onde alto_g, médio_g e baixo_g são variáveis *fuzzy* definidas para as faltas envolvendo terra e alto_{ph}, médio_{ph} e baixo_{ph} são variáveis *fuzzy* definidas para as faltas envolvendo apenas fases. Na representação de todas as variáveis *fuzzy* (tanto na parte antecedente, quanto na parte consequente das regras) foram utilizadas funções de pertinência triangulares. A saída da máquina de inferência *fuzzy* é defuzzyficada para extrair a saída na forma numérica. O diagrama em bloco do FIS empregado pelos autores para classificação das faltas é apresentado na figura 3.17.




Figura 3. 17: Diagrama em bloco do FIS empregado para classificação de faltas proposto por Mahanty e Gupta (2007).

O trabalho de Yosef (2004) apresenta um método para classificação de faltas em linhas de transmissão baseado em lógica *fuzzy*. Nesse artigo é proposto um algoritmo de classificação que emprega relações entre amplitudes e relações entre ângulos de fase das componentes simétricas das correntes de falta como informação sobre a falta. Inicialmente, a partir de amostras das correntes extraídas da linha, é utilizado o algoritmo da Transformada Wavelet para remover as componentes de alta frequência dos sinais. Os sinais de corrente filtrados são utilizados para calcular as componentes simétricas e o ângulo de fase das correntes, nomeadas de $i_{a(k)}$, $i_{b(k)}$ e $i_{c(k)}$. A seguir, três variáveis representando as diferenças entre os ângulos de fase, nomeadas de $Ci_{ab(k)}$, $Ci_{bc(k)}$ e $Ci_{ca(k)}$ são calculadas como:

$$\begin{aligned}
 Ci_{ab(k)} &= \varphi_{ia(k)} - \varphi_{ib(k)} \\
 Ci_{bc(k)} &= \varphi_{ib(k)} - \varphi_{ic(k)} \\
 Ci_{ca(k)} &= \varphi_{ic(k)} - \varphi_{ia(k)}
 \end{aligned} \tag{3.20}$$

onde $\varphi_{ia(k)}$, $\varphi_{ib(k)}$, $\varphi_{ic(k)}$ são os ângulos de fase das correntes das fases a , b e c , respectivamente.

Dessa forma, as relações entre amplitudes e ângulos de fase, nomeadas de IP_1 , IP_2 , IP_3 , IP_4 , são calculadas como:

$$IP_1 = \frac{I_{ab}}{I_{bc}}, \quad IP_2 = \frac{I_{bc}}{I_{ca}}, \quad IP_3 = \frac{I_{ca}}{I_{ab}}, \quad IP_4 = \frac{|I_0|}{|I_1|} \quad (3.21)$$

onde I_0 e I_1 são vetores das componentes de sequência zero e sequência positiva das correntes de fase.

A abordagem utilizada pelos autores para realizar a classificação é a utilização de um FIS dividido em blocos de fuzzyficação, inferência, composição e defuzzyficação. As entradas do sistema são as variáveis IP_1 , IP_2 , IP_3 , IP_4 , que são transformadas em variáveis *fuzzy* na etapa de fuzzyficação. As entradas fuzzyficadas são utilizadas na etapa de inferência para determinar a variável *fuzzy* de saída de cada regra *fuzzy*. Por exemplo, a regra que classifica faltas tipo A-terra é descrita como:

- “Se IP_1 é baixo e IP_2 é baixo e IP_3 é alto e IP_4 é alto, então a falta é A-terra”.

As variáveis de saída das regras são combinadas na etapa de composição para formar um única variável fuzzy de saída (tipo da falta). Os conjuntos *fuzzy* definidos para as entradas e saídas foram representados por funções de pertinência trapezoidais e funções de pertinência triangulares, respectivamente. E finalmente, na etapa de defuzzyficação, a variável de saída *fuzzy* é defuzzyficada para extrair a saída na forma numérica. O diagrama em bloco do FIS empregado pelos autores para classificação das faltas é apresentado na figura 3.18.




Figura 3. 18: Diagrama em bloco do FIS empregado para classificação de faltas proposto por Youssef (2004).

Nos trabalhos citados que empregam lógica *fuzzy* para diagnóstico de faltas em linhas de transmissão, os resultados obtidos demonstram que os métodos propostos alcançam índices de desempenho igual a outros métodos de diagnóstico de faltas. Porém, os autores destacam que os métodos propostos possuem vantagens em relação à outros métodos de diagnóstico de faltas, que são vantagens inerentes à lógica fuzzy, como a capacidade de lidar com a incerteza que surge devido à variação dos parâmetros da linha de transmissão, simplificação do método devido à menor complexidade para se implementar um sistema *fuzzy* e, conseqüentemente, redução do custo computacional. Um aspecto comum nos métodos propostos é a utilização de apenas amostras da corrente da linha para extração de informações sobre a falta, o que também contribui para a eficiência dos métodos, por envolver o processamento de um menor número de variáveis. Dessa forma, tendo em vista as vantagens apresentadas, os métodos de diagnóstico de faltas baseados em lógica *fuzzy* podem substituir outros métodos menos eficientes, principalmente nos casos onde é desejada menor complexidade na solução do problema.

3.3.6 Redes *Neurofuzzy*

Tanto as RNAs quanto os sistemas baseados em lógica *fuzzy* apresentam alguns pontos fracos. RNAs tem o problema da representação implícita do conhecimento, enquanto sistemas *fuzzy* são subjetivos e heurísticos. A determinação das regras *fuzzy*, fatores de escala para entrada e saída e escolha das funções de pertinência dependem do método da tentativa e erro, o que faz com que o projeto de sistemas *fuzzy* seja uma tarefa demorada. Estas desvantagens das RNAs e sistemas *fuzzy* são superadas pela integração da capacidade de aprendizado das RNAs como a robustez dos sistemas *fuzzy*, de forma que os conceitos da lógica *fuzzy* são embutidos na estrutura da rede, resultando num ambiente natural que combina a informação numérica na forma de pares entrada/saída com a informação linguística na forma de regras SE-ENTÃO de maneira uniforme (Dash, Pradhan e Panda, 2000). De forma geral, todas as combinação de RNAs e sistemas *fuzzy* são denominadas de sistemas *neurofuzzy*.

Muitas arquiteturas de redes *neurofuzzy* têm sido propostas na literatura. Uma das mais populares é a Rede Adaptativa Baseada em Sistema de Inferência Fuzzy (*Adaptive Network based Fuzzy Inference System – ANFIS*), proposta por R. R. Jang (Jang, Sun e Mizutani, 1997). Essa rede consiste em um sistema *neurofuzzy* híbrido que é funcionalmente equivalente a um sistema *fuzzy*. As características apresentadas pelas redes *neurofuzzy* como a *ANFIS* permitem que essas substituam RNAs e sistema *fuzzy* em diversas aplicações e com vantagens. A capacidade de adaptabilidade da *ANFIS*, sua não-linearidade e a representação do conhecimento de forma estruturada, são as principais vantagens desse sistema em relação à abordagens clássicas (Jang, Sun e Mizutani, 1997). Em contrapartida, as redes *neurofuzzy* apresentam uma limitação com relação ao número de entradas, pois, devido à chamada explosão combinatória do número de regras (o número de regras é igual o número de funções de pertinência elevado ao número de entradas). Com um número de entradas grande, o número de regras torna a rede impraticável.

3.3.7 Exemplos empregando redes *neurofuzzy*

Assim como no caso das RNAs, as redes *neurofuzzy* são utilizadas no diagnóstico de falhas em linhas de transmissão sob a ótica da classificação de padrões, ou seja, a rede é treinada para reconhecer sinais de tensão e/ou corrente da linha como padrões normais (sem perturbações) ou padrões de falta (com perturbações). As diferenças entre as abordagens utilizando RNAs e redes *neurofuzzy* estão nas próprias características das redes, que determinarão o desempenho das mesmas na tarefa de diagnóstico de falhas.

No trabalho de Wang e Keerthipala (1998) é apresentado um método para detecção e classificação de faltas em linhas de transmissão baseado em redes *neurofuzzy*. Nesse artigo é proposto o uso de uma típica rede *neurofuzzy* de três camadas: uma camada de fuzzyficação, uma camada de inferência e uma camada de defuzzyficação. Como padrões de entrada da

rede, os autores utilizaram variáveis que representam as relações entre componentes de sequência e a taxa de variação das correntes extraídas da linha, sendo essas variáveis definidas como:

- I_0/I_p = relação entre as componentes de sequência zero e sequência positiva;
- I_p/I_{rated} = relação entre a componente de sequência positiva e taxa de variação;
- I_n/I_p = relação entre as componentes de sequência negativa e sequência positiva;

A rede *neurofuzzy* é treinada a partir de padrões de entrada, de forma a atualizar a estrutura e definir os parâmetros da rede, utilizando o algoritmo de treinamento *backpropagation*. A saída defuzzyficada da rede indica o tipo da falta, entre os tipos: falta entre fases (*LL*), falta entre uma fase e terra (*LG*), falta entre duas fases e terra (*LLG*) e faltas trifásica e terra (*TLG*). A figura 3.19 apresenta a estrutura da rede *neurofuzzy* para detecção e classificação de faltas proposto.

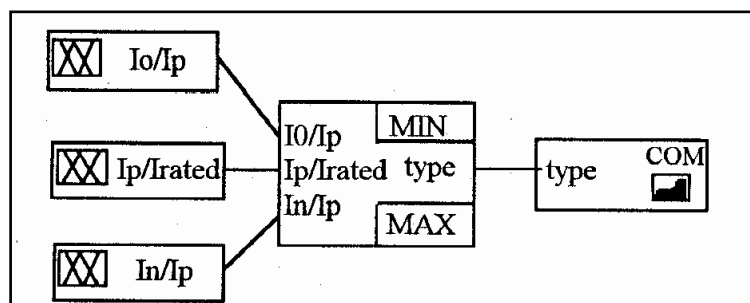


Figura 3. 19: Estrutura da rede neurofuzzy para detecção e classificação de faltas proposta por Wang e Keerthipala (1998).

No trabalho de Dash, Pradhan e Panda (2000) é apresentado um método para classificação e localização de faltas em linhas de transmissão baseado em redes *neurofuzzy*. Nesse artigo é proposto o uso de um esquema de redes *neurofuzzy* de quatro camadas (camada de entrada, camada de fuzzyficação, camada de inferência e camada de defuzzyficação), sendo uma rede para classificação da falta e quatro redes para localização da falta. A topologia das redes é definida durante o treinamento, uma vez que é empregada uma técnica de poda (*pruning*) da rede. Nessa técnica, regras e neurônios redundantes são eliminados, o que contribui para redução de complexidade e aumento da performance da rede. Os autores utilizaram como padrões de entrada valores de pico das correntes e tensões da linha na frequência fundamental, e ainda os valores das componentes CC. Esses valores foram estimados a partir das amostras extraídas da linha, com auxílio de um filtro de Kalman estendido. As redes neurofuzzy são treinadas a partir dos padrões de entrada, de forma a definir a estrutura das redes e seus parâmetros, utilizando o algoritmo *backpropagation*. Para classificação das faltas foi empregada uma rede *neurofuzzy* que possui três saídas, denominadas de *a*, *b* e *c*, representando as respectivas fases da linha, onde cada saída por produzir 1 ou 0, indicando se a fase em questão está envolvida na falta ou não (por exemplo, para uma falta envolvendo apenas a fase B, as saídas “*abc*” teriam valores iguais a “010”). Para localização da falta foram empregadas quatro redes *neurofuzzy*, uma rede para cada categoria de falta: falta fase-terra (*LG*), falta fase-fase-terra (*LLG*), falta fase-fase (*LL*) e falta fase-fase-fase (*LLL*). A saída

de cada rede produz um valor que representa a distância da falta em relação ao ponto de medição. A figura 3.20 apresenta o esquema de redes *neurofuzzy* para classificação e localização de faltas proposto.

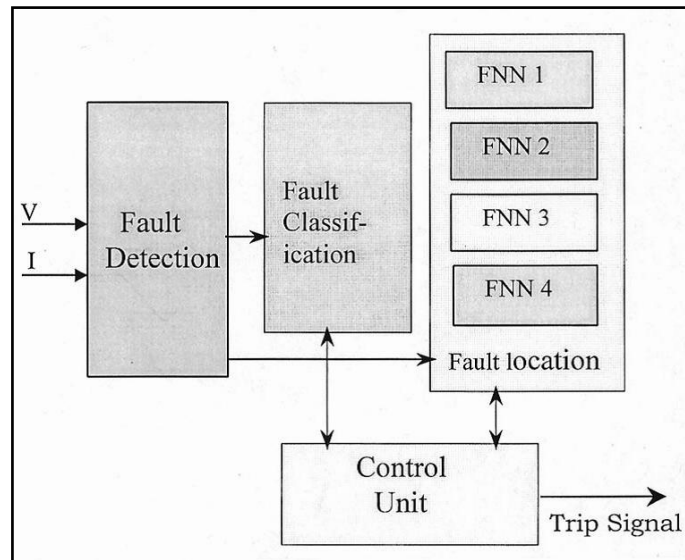


Figura 3. 20: Esquema de redes neurofuzzy para classificação e localização de faltas proposto por Dash, Pradhan e Panda (2000).

Nos trabalhos citados que empregam redes *neurofuzzy* para diagnóstico de faltas em linhas de transmissão, os resultados obtidos demonstram que os métodos propostos alcançam índices de desempenho superiores a outros métodos de diagnóstico de faltas baseados apenas em RNAs ou lógica *fuzzy*. Segundo os autores, o uso da rede *neurofuzzy* proporciona aos métodos propostos precisão, velocidade e robustez no diagnóstico das faltas. Outro aspecto dos métodos destacado pelos autores é a capacidade de adaptação da rede *neurofuzzy* às diversas condições das faltas, considerando que os métodos provaram ser eficientes mesmos com a variação dos parâmetros das linhas de transmissão empregadas na avaliação, tais como ângulo de incidência da falta e condições de carga, e ainda variação dos parâmetros da falta, tais como distância e resistência de falta. Assim, as características apresentadas pelos métodos de diagnóstico de faltas baseados em redes *neurofuzzy* indicam que tais métodos podem ser aplicados em linhas de transmissão mais complexas, onde a grande quantidade de fatores que afetam a qualidade do diagnóstico pode ser superada.

Capítulo 4

4 Metodologia proposta

Neste capítulo é apresentada em detalhes a metodologia proposta para detecção e classificação de faltas em linhas de transmissão. A metodologia é dividida em um método de detecção e um método de classificação. A detecção da falta é baseada na detecção de mudança abrupta dos coeficientes da Transformada Wavelet e a classificação da falta é baseada no reconhecimento de padrões realizado pela Rede Lógica *Neurofuzzy* modificada com o Aprendizado Participativo.

4.1 Visão geral

Conforme já mencionado neste trabalho, o diagnóstico de faltas em linhas de transmissão normalmente é realizado como etapas distintas, sendo que a primeira etapa é a detecção da falta e a segunda etapa é a classificação da falta

Para a primeira etapa, o método de detecção proposto consiste em um algoritmo que detecta faltas a partir de amostras digitalizadas dos sinais de tensão e corrente extraídos da linha de transmissão. O algoritmo recebe como entrada vetores contendo os dados registrados em um intervalo de amostragem. O algoritmo realiza a extração das características dos sinais e conforme tais características é considerada a ocorrência da falta ou não. Caso seja detectada a falta, o algoritmo fornece um vetor de saída contendo as amostras da tensão e corrente apenas no intervalo de ocorrência da falta, para que esse seja utilizado na classificação da mesma. Na extração das características da falta é empregada a Transformada Wavelet, onde as características extraídas são os coeficientes de detalhe dos sinais de tensões e correntes. Na detecção da falta é empregada uma técnica de detecção de mudança abrupta, que compara os coeficientes obtidos pela Transformada Wavelet com um limiar calculado para obter os instantes de início e fim da falta.

Para a segunda etapa, o método de classificação proposto consiste em um algoritmo que classifica a falta utilizando como entrada os vetores com amostras da tensão e corrente fornecidos pelo algoritmo de detecção. Os dados são tratados como um padrão e, conforme suas características, o algoritmo o classifica como um padrão relacionado à operação normal da linha ou como um padrão relacionado com algum tipo de falta conhecida. Nesse caso, os padrões de falta conhecidas são obtidos através de um processo de treinamento realizado *a priori*. O algoritmo fornece um dado de saída cujo valor é associado ao padrão classificado, sendo adotados os valores 1 (operação normal), 2 (curto-circuito entre fases), 3 (curto-circuito entre fases e terra) e 4 (fase aberta). Na classificação dos padrões é empregada uma Rede

Lógica *Neurofuzzy*, que determina a classe ao qual o padrão de entrada pertence a partir do conhecimento adquirido durante o processo de treinamento. O processo de treinamento da rede utiliza na etapa de geração das funções de pertinência dos subconjuntos *fuzzy* um algoritmo de agrupamento baseado no Aprendizado Participativo, com o objetivo de reduzir número de regras.

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

4.2 Detecção da falta

O algoritmo de detecção inicialmente realiza a decomposição das amostras dos sinais de tensão e corrente extraídos da linha de transmissão empregando a versão discreta da Transformada Wavelet (*DWT*), apresentada na seção 3.2.3. A decomposição permite obter os coeficientes de aproximação (A_j) e de detalhe (D_j) em diferentes níveis de resolução, sendo que os coeficientes de aproximação contém as componentes de baixa frequência do sinal, enquanto os coeficientes de detalhe contém as componentes de alta frequência do sinal. Como os transitórios provocados pela falta na linha de transmissão são sinais de altas frequências, são utilizados somente os coeficientes de detalhe para detecção da falta.

Considerando $x(n)$ um sinal discreto de tensão ou corrente e utilizando a técnica análise multiresolução (*MRA*) definida nas equações 3.13 e 3.14, a decomposição do sinal na forma dos coeficientes *wavelet* no nível 1 (A_1 e D_1) é dada por:

$$A_1(n) = \sum_k l(k)x(n-k) \quad (4.1)$$

$$D_1(n) = \sum_k h(k)x(n-k) \quad (4.2)$$

onde $l(k)$ é o filtro passa-baixa, $h(k)$ é o filtro passa-alta e k é comprimento do filtro ($k = 1, 2, 3, \dots, K$). Os filtros passa-baixa e passa-alta são determinados pela função de escalonamento e função *wavelet*, respectivamente. A figura 4.1 ilustra graficamente a decomposição de $x(n)$ nos coeficientes de aproximação e detalhe no nível 1, seguida de um operação de subamostragem por um fator de 2 ($\downarrow 2$).

A *wavelet* mãe e o nível da decomposição escolhidos são importantes para a eficiência do método de detecção da falta. Depois de realizados estudos na literatura e experimentos com simulações empregadas neste trabalho, verificou-se que os melhores resultados foram obtidos utilizando a *wavelet db4* e o nível de decomposição 1 (D_1) do sinal de tensão e do sinal corrente.




Figura 4. 1: Decomposição de um sinal $x(n)$ nos coeficientes wavelet A_1 e D_1 .

Os coeficientes dos filtros passa-baixa e passa-alta associados à wavelet *db4* são mostrados na tabela 4.1.

Tabela 4. 1: Coeficientes dos filtros associados à wavelet *db4*.

n	$l(n)$	$h(n)$
1	-0.0106	-0.2304
2	0.0329	0.7148
3	0.0308	-0.6309
4	-0.1870	-0.0280
5	-0.0280	0.1870
6	0.6309	0.0308
7	0.7148	-0.0329
8	0.2304	-0.0106

Fonte: Misiti *et al.*, 2007.

As figuras 4.2 e 4.3 mostram como exemplo, o coeficiente D_1 resultantes da decomposição com a *wavelet* mãe *db4* dos sinais de tensão e corrente de fase, respectivamente. Esses sinais foram obtidos por simulação de uma falta tipo curto-circuito fase-terra em uma linha de transmissão.




Figura 4. 2: Coeficiente D_1 de um sinal de tensão em falta fase-terra utilizando wavelet *db4*.




Figura 4. 3: Coeficiente $D1$ de um sinal de corrente em falta fase-terra utilizando wavelet db4.

Ambas as figuras mostram claramente que há uma mudança abrupta no nível dos coeficientes $D1$ nos instantes de início e fim da falta, devido à presença dos transitórios de alta frequência nesses instantes. Dessa forma, utilizando os coeficientes $D1$ dos sinais, o algoritmo proposto determina os instantes de início e fim da falta empregando uma técnica de detecção de mudança abrupta.

A técnica de detecção de mudança abrupta consiste em verificar a cada instante se o valor absoluto dos coeficientes $D1$ da tensão e da corrente excedem um determinado limiar, calculado conforme proposto por Donoho e Johnstone (1994) para uma aproximação de primeira ordem. O limiar T é definido como (Ukil e Zivanovic, 2006):

$$T = \sigma \sqrt{2 \log_e n} \quad (4.3)$$

onde σ é o desvio médio absoluto dos coeficientes *wavelets* dividido por 0,6725 e n é o número de amostras dos coeficientes *wavelets*. Em vez de utilizar o desvio médio padrão é usado o desvio médio absoluto porque o primeiro é muito influenciado por uma pequena fração de valores extremos.

Assim, os instantes de início (k_i) e fim da falta (k_f) são determinados da seguinte forma:

$$\begin{aligned} k_i &= k, \text{ se } \text{abs}(D_1) > T \\ k_f &= k, \text{ se } \text{abs}(D_1) > T \text{ e } k_i > 1 \end{aligned} \quad (4.4)$$

onde k é o número da amostra do vetor de entrada.

Após determinar o instante de início da falta, as amostras dos sinais são armazenadas no vetor de saída pelo algoritmo até o instante de fim da falta. Dessa forma, o algoritmo fornece na saída um vetor que contém as amostras dos sinais somente no intervalo de ocorrência da

falta. O vetor de saída será utilizado pelo método de classificação da falta a ser apresentado na seção 4.3.

A figura 4.4 apresenta o fluxograma do algoritmo para detecção de faltas em linhas de transmissão proposto neste trabalho.

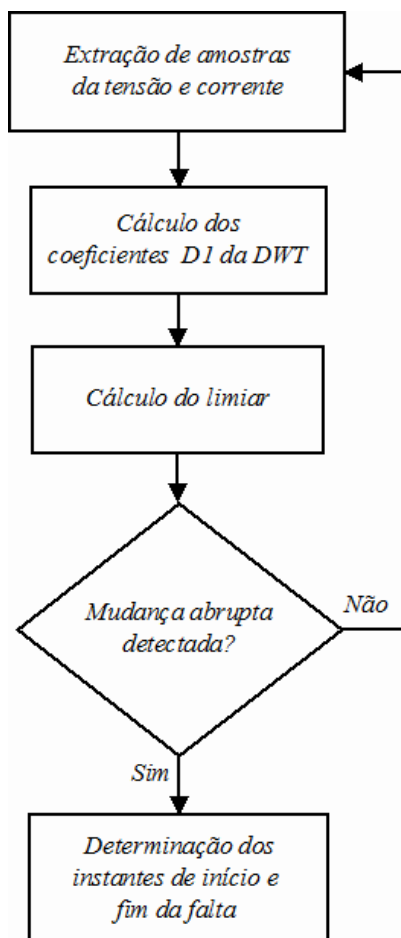


Figura 4. 4: Fluxograma do algoritmo proposto para detecção de faltas em linhas de transmissão.

As figuras 4.5 e 4.6 mostram o resultado da aplicação do método proposto para detecção de faltas nos sinais de tensão e corrente dados como exemplo nas figuras 4.2 e 4.3, onde há a ocorrência de uma falta tipo curto-circuito fase-terra. Neste caso, a falta foi detectada corretamente, sendo determinado o intervalo da falta entre 0.2s e 0.3s aproximadamente. Observando o sinal de saída pode-se notar que foi isolado apenas o sinal da falta, sendo eliminados os sinais de pré-falta e pós-falta.




Figura 4. 5: Resultado da aplicação do método de detecção da falta em um sinal de tensão.




Figura 4. 6: Resultado da aplicação do método de detecção da falta em um sinal de corrente.

4.3 Classificação da falta

O algoritmo de classificação emprega a Rede Lógica *Neurofuzzy* para classificar as faltas a partir das amostras dos sinais de tensão e corrente de fase extraídas da linha, mas apenas no intervalo de ocorrência da falta determinado pelo método de detecção de faltas apresentado na secção 4.2.

A Rede Lógica *Neurofuzzy* é um tipo de rede *neurofuzzy* para classificação de padrões baseada em neurônios lógicos *AND* e *OR*, que são modelados por S-normas e T-normas. Sua estrutura permite a inserção e extração de conhecimento na forma de regras *fuzzy* do tipo SE-ENTÃO, estabelecendo um mapeamento entre regras *fuzzy* e o conhecimento presente em sua arquitetura. O algoritmo de treinamento da rede é do tipo supervisionado, mas sem a utilização de derivadas (Caminhas, Tavares e Gomide, 1996). A figura 4.7 apresenta a estrutura da Rede Lógica *Neurofuzzy* generalizada, considerando n entradas e N_c classes de saída.




Figura 4. 7: Estrutura da Rede Lógica Neurofuzzy proposta por Caminhas, Tavares e Gomide, (1996).

A Rede Lógica *Neurofuzzy* é capaz de implementar um conjunto de regras do tipo:

- SE $(xp_l \in F_l^{kl}$ com peso da conexão = w_{jl}) ... E $(xp_i \in F_i^{ki}$ com peso da conexão = w_{ji}) ... E $(xp_n \in F_n^{kn}$ com peso da conexão = w_{jn}) ENTÃO Xp pertence a classe l , com peso da conexão = v_j

onde x_{p_l} a x_{p_n} são as n coordenadas de entrada da rede; x_{ji} é o grau de pertinência da variável x_{p_i} na regra j ao subconjunto *fuzzy* F_i^{ki} ; w_{ji} é o peso da conexão da entrada “ i ” para o neurônio *AND* indexado por j ; v_j é o peso da conexão de entrada “ j ” do neurônio *OR* indexado por l ; Z_l é a saída da classe l ; Z_q é a saída máxima e C_q é a classe correspondente a Z_q e N_{pi} é o número de subconjuntos *fuzzy*. Os neurônios *AND* e *OR* são definidos como:

$$y_j = \mathbf{T}_{i=1}^n (w_{ji} \mathbf{S} x_{ji}) \quad (4.5)$$

$$z_l = \mathbf{S}_{j=1}^{n_l} (v_j \mathbf{t} y_j) \quad (4.6)$$

onde S é uma S-norma (por exemplo máximo, soma probabilística, soma limitada, dentre outras) e T é uma T-norma (por exemplo mínimo, produto, produto limitado, dentre outras), e n_l o número de neurônios tipo *AND* conectados ao neurônio *OR* indexado por “ l ”. O índice “ j ” que indexa um neurônio tipo *AND* é determinado a partir dos índices dos subconjuntos *fuzzy* das coordenadas de entrada, k_i , da seguinte forma:

$$j = f(K) = k_n + \sum_{i=2}^n (k_{(n-i+1)}) \cdot \left(\prod_{j=1}^{i-1} N_{p_{(n+1-j)}} \right) \quad (4.7)$$

onde $K = (k_1, \dots, k_i, \dots, k_n)$ é o vetor que contém os índices dos subconjuntos *fuzzy*.

O treinamento da Rede Lógica *Neurofuzzy* é do tipo supervisionado, ou seja, dado um padrão de entrada Xp qualquer sabe-se *a priori* qual é sua classificação. Além disso, é um treinamento competitivo, não utilizando derivadas para ajuste dos pesos. Os passos do algoritmo são:

1. Gerar as funções de pertinência;
2. Gerar as conexões da rede e inicializar os pesos w_{ji} e v_j ;
3. Processo iterativo:
 - 3.1 apresentar um padrão p à rede (normalmente escolhido de forma aleatória);
 - 3.2 determinar os neurônios *AND* e *OR* ativos;
 - 3.3 efetuar a fuzzyficação;
 - 3.4 determinar a classe vencedora;
 - 3.5 atualizar os pesos w_{ji} e v_j ;
 - 3.6 testar a condição de parada (todos os padrões de entrada classificados corretamente ou número de iterações alcançado);
 - se satisfeita vá para o passo 4;
 - se não satisfeita volte ao passo 3.1;
4. Fim.

Cada passo do algoritmo de treinamento será detalhado a seguir:

- Geração das funções de pertinência:

No algoritmo proposto por Caminhas, Tavares e Gomide (1996), a geração das funções de pertinência baseia-se no uso de funções triangulares normais e uniformemente distribuídas. Mas, o uso desse tipo de função de pertinência pode não ser interessante em situações onde há concentração de padrões em determinadas regiões e dispersão em outras. Uma alternativa para contornar este problema é utilizar funções triangulares não uniformemente distribuídas, como mostra a figura 4.8. Dessa forma, nas regiões de baixa concentração de padrões pode-se trabalhar com um número de subconjuntos *fuzzy* menor. Neste trabalho é proposta a geração automática das funções de pertinência utilizando o Algoritmo de Agrupamento Participativo (AAP), onde os centros dos grupos formados pelos padrões de entrada são encontrados pelo algoritmo e adotados como centros das funções de pertinência.




Figura 4. 8: Funções de pertinência triangulares não uniformemente distribuídas.

O AAP é baseado no paradigma do Aprendizado Participativo (AP) proposto por Ronald R. Yager (Yagger, 1990), como um novo modelo para implementação de aprendizado computacional. É um modelo de aprendizado que tenta captar muitas das características relevantes do aprendizado humano. O termo “aprendizado participativo” enfatiza o fato de que o conhecimento atual participa do processo de aprendizagem em si (por exemplo: aprender uma teoria nova com base na teoria antiga). Representa um paradigma importante com diversas aplicações, dentre elas o algoritmo de agrupamento *fuzzy* (Silva; Gomide e Yager 2005), treinamento de redes *neurofuzzy* (Hell; Costa e Gomide, 2007) e detecção de falhas em sistemas dinâmicos (Inácio, *et al.* 2009).

Utilizando os conceitos do aprendizado participativo, o AAP consiste em um algoritmo de agrupamento não supervisionado, ou seja, não é necessário conhecer o número de grupos *a priori*. Nesse algoritmo, empregando o mecanismo de aprendizagem participativa, os centros dos grupos são encontrados gradativamente, de acordo com a entrada de dados. O algoritmo inclui ainda um mecanismo de exclusão de centro de grupos redundantes, visto que a redundância não acrescenta informação do ponto de vista do aprendizado participativo. Os procedimentos do AAP são detalhados no Apêndice A.

O conjunto de padrões de treinamento é fornecido ao AAP que encontra os centros de grupos formados por esses padrões. Cada centro de grupo corresponde ao centro de uma função de pertinência. Uma vez definido os centros das funções de pertinência pelo AAP, o número dos subconjuntos *fuzzy* será igual o número de centros. O cálculo das funções de pertinência triangulares pode ser realizado como:

$$\mu_{F_i^r}(x_{pi}) = \begin{cases} \frac{x_{pi} - a_{ir}}{a_{ir} - a_{ir-1}} + 1, & \text{se } a_{ir-1} \leq x_{pi} \leq a_{ir} \\ \frac{x_{pi} - a_{ir}}{a_{ir} - a_{ir+1}} + 1, & \text{se } a_{ir} < x_{pi} \leq a_{ir+1} \\ 0, & \text{caso contrário} \end{cases} \quad (4.8)$$

onde a_{ir} é centro da função de pertinência da entrada “ i ” indexada por “ r ”, que corresponde ao ponto onde a função possui o valor máximo.

- Geração das conexões da rede e inicialização dos pesos w_{ji} e v_j :

Nesse passo são estabelecidas as conexões entre os neurônios *AND* e *OR*, o que pode ser visto como a geração automática das regras. Os procedimentos são os seguintes:

Para $j=1$ até $(Npi)^n$ faça:

a) Geração das conexões

Calcule β_l para $l=1,2,\dots,Nc$:

$$\beta_l = \sum_{x_p \in \text{Classe } l} \prod_{i=1}^n x_{ji} \quad (4.9)$$

Determine a classe q tal que:

$$q = \max_l \{\beta_1, \dots, \beta_1, \dots, \beta_{Nc}\} \quad (4.10)$$

Isto define a conexão do neurônio *AND* indexado por “ j ” ao neurônio *OR* indexado por “ q ”. Se $\beta_q = 0$ ou existir mais de um máximo para β_q , então o neurônio *AND* “ j ” não conecta a nenhuma classe de saída.

b) Inicialização dos pesos:

Calcule:

$$w_{ji} = 0, \forall i = 1, 2, \dots, n \quad (4.11)$$

$$v_j = \frac{\beta_q - \sum_{l=q} \beta_l / (Nc - 1)}{\sum \beta_l}$$

(4.12)

Os pesos v_j poderiam ser inicializados com zero, porém, a utilização da equação 4.12 implica em redução de tempo de processamento do algoritmo, pois melhora a superfície de separação.

- Determinação dos neurônios *AND* e *OR* ativos:

Empregando funções de pertinência como as mostradas na figura 4.8, para cada padrão apresentado à rede, os respectivos graus de pertinência são diferente de zero no máximo para dois subconjuntos *fuzzy*. Estes serão definidos como subconjuntos ativos e, conseqüentemente, os neurônios *AND* associados a esses subconjuntos serão definidos como neurônios *AND* ativos. Com isso, dos $(Npi)^n$ neurônios *AND*, no máximo 2^n serão ativos. Os neurônios *AND* ativos são determinados da seguinte maneira:

- Dado um padrão de entrada $X_P = (x_{p1}, \dots, x_{pi}, \dots, x_{pn})$, sejam $K^1 = (k_1^1 \dots k_i^1 \dots k_n^1)$ o vetor que contém os índices da primeira função de pertinência para cada coordenada do padrão, diferente de zero e K^2 um vetor tal que:

$$K_i^2 = \begin{cases} k_i^1 + 1, & \text{se } \mu_{k_i^1}(x_{pi}) \neq 1 \\ k_i^1, & \text{caso contrário} \end{cases} \quad (4.13)$$

O número de neurônios *AND* ativos, N_a , é igual a 2^{Pa} , que é no máximo igual a 2^n , onde Pa é igual ao número de elementos tal que $k_i^1 \neq k_i^2$, para $i = 1, 2, \dots, n$. Estes neurônios podem ser determinados a partir da combinação dos vetores K^1 e K^2 .

Considerando L^* o conjunto dos neurônios *AND* ativos, este conjunto e as conexões estabelecidas no passo 2 determinam o conjunto Q^* que indexa os neurônios *OR* ativos.

- Fuzzyficação

A fuzzyficação consiste em calcular os graus de pertinência correspondentes às coordenadas de entrada, mas somente para os subconjuntos ativos definidos em K^1 . Caso $K_i^1 \neq K_i^2$, calcula-se também $\mu_{k_i^2}(x_{pi})$. Como as funções de pertinência são complementares, tem-se que:

$$\mu_{k_i^2}(x_{pi}) = 1 - \mu_{k_i^1}(x_{pi}) \quad (4.14)$$

- Determinação da classe vencedora:

- Calcule $Z_l \forall l \in Q^*$ (somente para os neurônios *OR* ativos)

$$z_l = \mathbf{S}_{j=1}^{n_l} (v_j \mathbf{t} y_j) \quad (4.15)$$

$$y_j = \mathbf{T}_{i=1}^n (w_{ji} \mathbf{S} x_{ji}) \quad (4.16)$$

O valor de Z_l normalizado fornece o grau de pertinência do padrão X_P à classe l .

b) Defuzzyficação para determinar a classe vencedora

O índice da classe vencedora, q , é determinado a partir da defuzzyficação utilizando o operador max como critério:

$$z_q = \max_{l \in Q^*} \{z_l\} \quad (4.17)$$

- Atualização dos pesos:

A atualização dos pesos das conexões da rede é feito de tal forma que, se a rede classificar corretamente o padrão, os pesos das conexões mais significativas são aumentados, caso contrário, os pesos são reduzidos. Dessa forma, a atualização dos pesos w_{ij} e v_j é feita da seguinte maneira:

- Seja q o índice da classe vencedora

Se q é também o índice da classe correta, então:

$$v_j(k+1) = v_j(k) + \alpha_1 \cdot [1 - v_j(k)] \quad (4.18)$$

$$w_{II}(k+1) = w_{II}(k) + \alpha_2 \cdot [1 - w_{II}(k)] \quad (4.19)$$

senão:

$$v_j(k+1) = v_j(k) - \alpha_3 \cdot v_j(k) \quad (4.20)$$

$$w_{II}(k+1) = w_{II}(k) + \alpha_4 \cdot w_{II}(k) \quad (4.21)$$

onde “ I ” e “ J ” são indexadores das conexões mais significativas para a classificação, sendo determinados da seguinte maneira:

$$J = \max_j \{ [v_j \mathbf{T} y_j] \mid \forall j \in L^* \text{ e } X_p \in Cq \} \quad (4.22)$$

$$I = \min_i \{ [x_{ji} \mathbf{S} w_{ji}] \mid \forall i = 1, 2, \dots, n \text{ e } j = J \}$$

(4.23)

Para as equações de 4.18 a 4.21, os parâmetros α_1 , α_2 , α_3 , α_4 , são tais que $0 < \alpha_1 < \alpha_3 < 1$ e $0 < \alpha_2 < \alpha_4 < 1$. Uma característica deste algoritmo de aprendizado é que o mesmo não utiliza informações de derivadas.

Após o treinamento, a Rede Lógica *Neurofuzzy* recebe o vetor de dados fornecido pelo método de detecção como padrão de entrada, contendo as amostras de corrente e tensão apenas no intervalo da falta. A rede fornece um dado de saída cujo valor é associado ao padrão classificado, sendo adotados os valores 1 (operação normal), 2 (curto-circuito entre fases), 3 (curto-circuito entre fases e terra) e 4 (fase aberta). A figura 4.9 apresenta um esquema simplificado do método de classificação de faltas proposto.

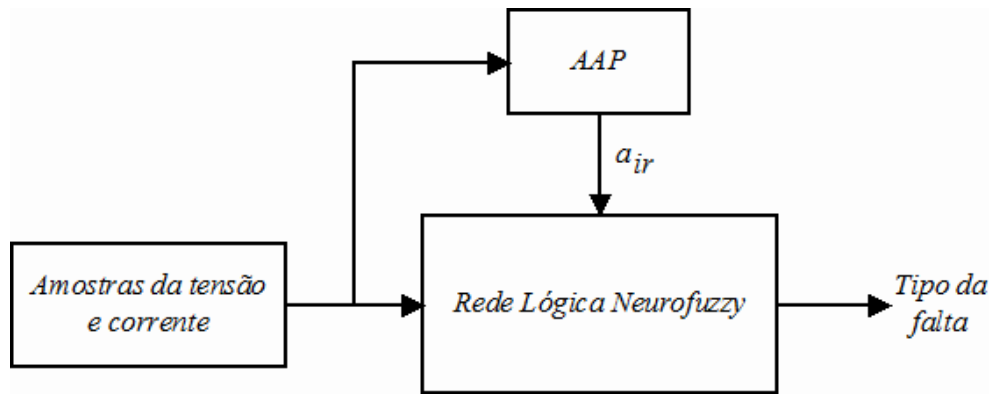


Figura 4. 9: Esquema simplificado do método de classificação proposto.

As figuras 4.10 a 4.12 apresentam, a título de exemplo, os resultados da aplicação do método de classificação de faltas nos sinais de tensão e corrente da fase A de uma linha de transmissão, obtidos por simulação. Foram gerados três tipos de faltas diferentes em sequência, com um intervalo de operação normal entre elas. As faltas geradas são tipo: curto-circuito entre fases A-B, curto-circuito entre fase A-terra e fase A aberta. O conjunto de dados extraídos foi separado em um conjunto de treinamento e um conjunto de validação. Durante o treinamento da rede, os centros de grupos encontrados pelo AAP determinaram as funções de pertinência utilizadas em cada entrada. Para a entrada 1 ($X_{P(1)} =$ tensão) foram utilizadas 4 funções de pertinência e para a entrada 2 ($X_{P(2)} =$ corrente) 3 funções de pertinência, mostradas nas figuras 4.10 e 4.11, respectivamente.




Figura 4. 10: Funções de pertinência para a entrada 1.




Figura 4. 11: Funções de pertinência para a entrada 2.

Após o treinamento, a resposta da Rede Lógica *Neurofuzzy* foi avaliada pela aplicação dos padrões de entrada do conjunto de validação. Conforme mostra a figura 4.12, a rede classificou corretamente as faltas durante o intervalo de ocorrência das mesmas, uma vez que os valores de saída obtidos foram 2 (curto-circuito entre fases), 3 (curto-circuito entre fase e terra) e 4 (fase aberta). Durante todos os intervalos compreendidos entre uma falta e outra, o valor de saída obtido foi 1 (operação normal).




Figura 4. 12: Sinais de entrada e saída da rede lógica neurofuzzy.

Capítulo 5

5 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 visto no capítulo anterior, os métodos utilizam sinais de tensão e corrente de falta extraídos da linha para obtenção de informações sobre as mesmas, de forma que seja possível realizar o diagnóstico. Normalmente, em uma linha de transmissão real, esses sinais seriam obtidos através de equipamentos de aquisição de dados instalados ao longo da linha. Entretanto, dada a grande quantidade de dados necessários para o treinamento, o processo de aquisição de dados reais para este trabalho seria inviável, devido aos tempo e custos necessários para tal. Dessa forma, para avaliação dos métodos propostos, optou-se por realizar simulações em software de um modelo de SEP. Utilizando o modelo, foram realizadas simulações de diversos cenários de falta, variando-se tanto os parâmetros do sistema, quanto as condições da falta. Para simulação do SEP foi utilizado o software PSCAD, onde os sinais extraídos da linha durante as simulações eram 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.

5.1 Modelo utilizado

O modelo de SEP utilizado para realizar as simulações de faltas em linhas de transmissão é mostrado na figura 5.1. O sistema consiste de duas fontes de 230 kV interligadas por uma linha de transmissão de 200 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 5. 1: Modelo de SEP utilizado para simulações de faltas.

As faltas consideradas neste sistema são do tipo curto-circuito e tipo circuito aberto. As faltas podem ocorrer em qualquer localização da linha, entre os barramentos 1 e 2. Na

ocorrência de uma falta tipo curto-circuito entre fases ou curto-circuito entre fase e terra, a resistência entre os pontos da falta é baixa, geralmente menor que 100Ω . E na ocorrência de uma falta tipo circuito aberto em uma ou mais fases, ao contrário, a resistência entre os pontos da falta é alta, geralmente maior que de $1 \text{ M}\Omega$.

5.2 Simulações no PSCAD

PSCAD (Power Systems CAD) é uma interface gráfica poderosa e flexível para o software de simulação EMTDC (*Electromagnetic Transients with DC analysis*), que permite ao usuário construir um circuito esquematicamente, executar a simulação, analisar os resultados e gerenciar os dados, em um ambiente gráfico completamente integrado. Também estão incluídas funções para visualização de sinais, controles e medidores *on-line*, de modo que o usuário pode alterar os parâmetros do sistema durante uma simulação e ver os resultados diretamente (PSCAD, 2005).

O modelo de SEP mostrado na figura 5.1 foi implementado no PSCAD utilizando os modelos dos componentes existentes nas bibliotecas do mesmo. A figura 5.2 mostra a parte principal do sistema como visto na janela do software.

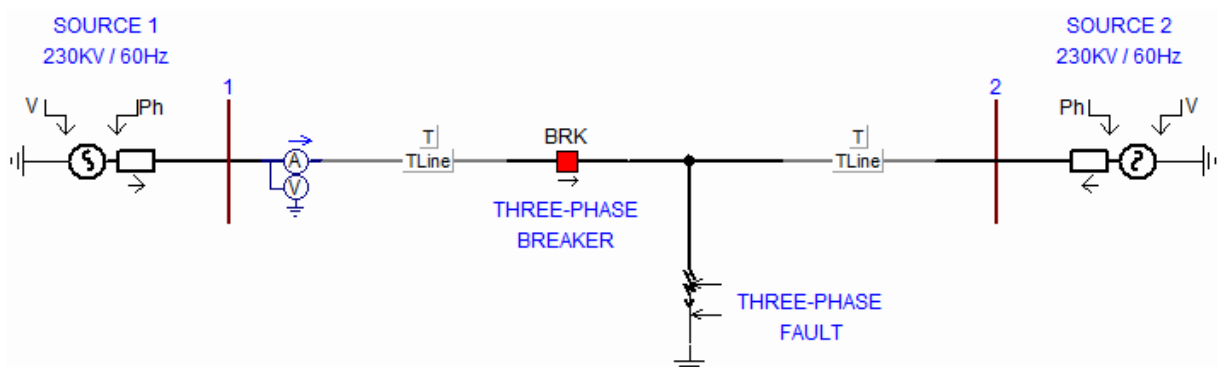


Figura 5. 2: Modelo de SEP como implementado no PSCAD.

Para as fontes CA foi utilizado o componente *Three-Phase Voltage Source Model 3*, que consiste em um modelo de fonte CA, onde o usuário pode especificar as componentes de sequência positiva e sequência zero, ou então selecionar fonte ideal (barramento infinito). A impedância da fonte é modelada como uma impedância RL série. Este componente é controlado externamente por duas entradas, descritas como:

- V: amplitude da tensão de linha em kV RMS.
- Ph: ângulo de fase em $^{\circ}$.

Para a linha de transmissão (dividida em dois segmentos) foi utilizado o componente *Overhead Transmission Line (T-Line)*, que consiste em um modelo de linha de transmissão aérea, onde o usuário pode especificar além das características básicas (frequência,

comprimento e número de condutores), as características físicas e elétricas da torre e dos condutores.

Para permitir a simulação das faltas na linha de transmissão foram utilizados dois componentes, o *Three-Phase Fault* e o *Three-Phase Breaker*. O primeiro componente permite a geração de faltas tipo curto-circuito entre fases e curto-circuito entre fases e terra, já o segundo componente permite a geração de faltas tipo circuito aberto em uma ou mais fases. O componente *Three-Phase Fault* modela uma falta resistiva, onde podem ser configuradas as resistências do componente nos estados *ON* e *OFF*, ou seja, a resistência apresentada pela falta em si e a resistência durante a operação sem falta. O controle da falta e o tipo da falta são determinadas por duas entradas externas, definidas como:

- Controle:
 - 0 = aberto (normal);
 - 1 = fechado (falta).
- Tipo da falta:
 - 0 = sem falta;
 - 1 = falta A-G;
 - 2 = falta B-G;
 - 3 = falta C-G;
 - 4 = falta AB-G;
 - 5 = falta AC-G;
 - 6 = falta BC-G;
 - 7 = falta ABC-G;
 - 8 = falta AB;
 - 9 = falta AC;
 - 10 = falta BC;
 - 11 = falta ABC.

O componente *Three-Phase Breaker* modela um disjuntor trifásico, onde podem ser configuradas as resistências dos estados *ON* e *OFF*, ou seja, as resistências dos contatos do disjuntor fechado e aberto, respectivamente, e ainda o estado inicial dos mesmos. O componente é controlado por uma entrada externa, que determina o abertura ou fechamento de cada fase, sendo definida como:

- Controle:
 - 0 = fechado (*ON*);
 - 1 = aberto (*OFF*).

Os parâmetros dos componentes utilizados na implementação do SEP no PSCAD estão descritos no Apêndice B.

Para permitir a simulação de faltas no sistema, foi implementado uma lógica adicional para controlar os componentes do sistema. Essa lógica envia os sinais necessários para os componentes conforme a falta a ser simulada. Por exemplo, se a falta a ser simulada é uma falta tipo curto-circuito A-G, a lógica de controle envia sinais para que o *Three-Phase Fault* ajuste somente a resistência da fase A para o estado *ON*, permanecendo as resistências da

outras fase no estado *OFF*. Além disso, a lógica de controle envia os sinais para que a *Three-Phase Breaker* ajuste os contatos de todas as fases no estado *ON*. Na lógica de controle foi adicionado também um componente que permite ajustar o instante de ocorrência e a duração da falta.

As faltas simuladas foram organizadas em vários cenários. Cada cenário corresponde à simulação de todos os tipos de falta com valores específicos para as seguintes variáveis:

- distância da falta;
- resistência de falta;
- ângulo de incidência da falta;
- ângulo de carga.

A distância da falta em relação ao barramento 1 foi variada de 10% a 90% do comprimento total da linha, em intervalos de 10%. Para as faltas tipo curto-circuito entre fases ou entre fases e terra, as resistências de falta utilizadas foi variada de 0,01 Ω a 100 Ω . Para faltas tipo circuito aberto foi utilizada apenas uma resistência de falta no valor de 1 M Ω . O ângulo de incidência da falta foi variado de 30° a 150°, em passos de 30°. O ângulo de carga (ângulo de fase da fonte 2) foi variado de 10° a 30°, em passos de 10°. Foram simulados dez tipos de falta tipo curto-circuito: seis entre fases e terra (A-G, B-G, C-G, AB-G, AC-G, BC-G) e quatro entre fases (AB, AC, BC, ABC). E ainda foram simulados seis faltas tipo circuito aberto (A-aberta, B-aberta, C-aberta, AB-aberta, AC-aberta, BC-aberta), resultando num total de 16 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 3.840Hz, o que corresponde a 64 amostras/ciclo na frequência de operação da linha (60Hz). As figuras de 5.3 a 5.18 mostram um exemplo de cada tipo de falta simulada no sistema, onde podem ser visualizados os sinais de tensão e corrente medidos na linha de transmissão. A duração da simulação foi ajustada para 0,5s e a ocorrência das faltas foi ajustada para o intervalo entre 0,2s e 0,3s.




Figura 5. 3: Simulação de falta tipo curto-circuito fase A-G.




Figura 5. 4: Simulação de falta tipo curto-circuito fase B-G.




Figura 5. 5: Simulação de falta tipo curto-circuito fase C-G.




Figura 5. 6: Simulação de falta tipo curto-circuito fases AB-G.





Figura 5. 7: Simulação de falta tipo curto-circuito fases AC-G.





Figura 5. 8: Simulação de falta tipo curto-circuito fases BC-G.




Figura 5. 9: Simulação de falta tipo curto-circuito fases AB.




Figura 5. 10: Simulação de falta tipo curto-circuito fases AC.





Figura 5. 11: Simulação de falta tipo curto-circuito fases BC.





Figura 5. 12: Simulação de falta tipo curto-circuito fases ABC.





Figura 5. 13: Simulação de falta tipo fase A-aberta.





Figura 5. 14: Simulação de falta tipo fase B-aberta.




Figura 5. 15: Simulação de falta tipo fase C-aberta.




Figura 5. 16: Simulação de falta tipo fases AB-aberta.





Figura 5. 17: Simulação de falta tipo fases AC-aberta.





Figura 5. 18: Simulação de falta tipo fases BC-aberta.

5.3 Implementações no MATLAB

Para realizar a detecção e classificação de faltas no modelo de SEP utilizado, foi implementado no MATLAB um sistema composto de três módulos de detecção e três módulos de classificação, um para cada fase, utilizando os métodos propostos neste trabalho. A estrutura do sistema é mostrada na figura 5.19.

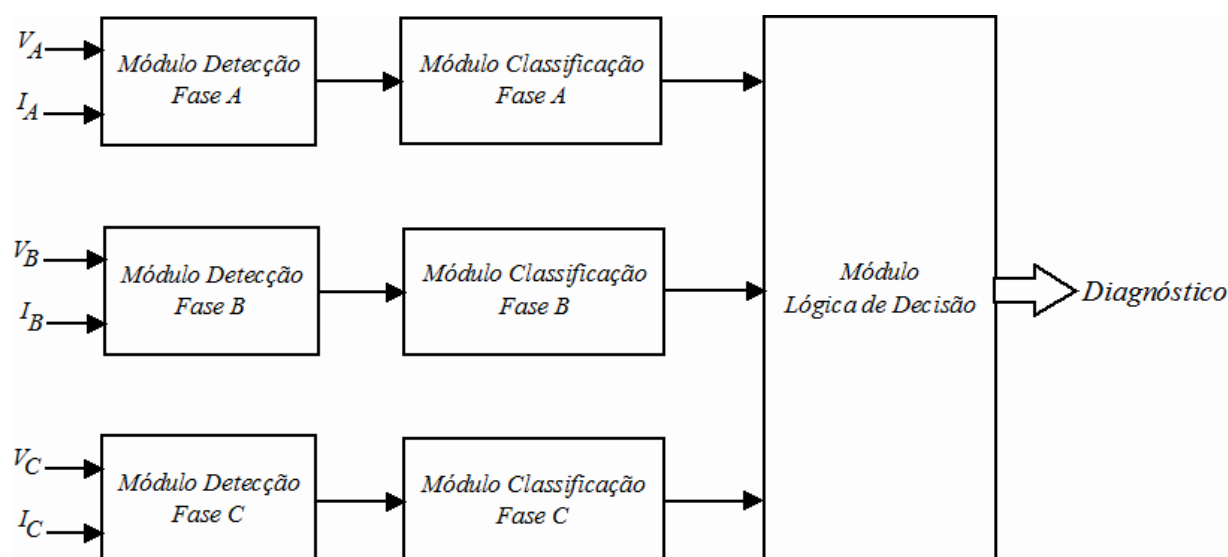


Figura 5. 19: Estrutura do sistema para detecção e classificação de faltas implementado.

O módulo de detecção foi implementado conforme o algoritmo apresentado na figura 4.4. Na etapa de cálculo da *DWT* foi empregada uma função do *Wavelet Toolbox* do MATLAB. A entrada de cada módulo de detecção consiste nas amostras de tensão e corrente da fase em questão, medidas no barramento 1. Cada módulo de detecção fornece na saída um vetor contendo somente as amostras de tensão e corrente no intervalo de ocorrência da falta.

O módulo de classificação foi implementado conforme o algoritmo descrito na seção 4.3. Na etapa de geração das funções de pertinência foi implementado o AAP, descrito no Apêndice A. Os parâmetros empregados no AAP foram: $\alpha = 0,1$; $\beta = 0,1$; $\tau = 0,1$ e $\lambda = 0,9$. Os parâmetros empregados na Rede Lógica *Neurofuzzy* foram: $\alpha_1 = \alpha_2 = 0,001$ e $\alpha_3 = \alpha_4 = 0,1$. A entrada do módulo de classificação consiste no vetor fornecido pelo módulo de detecção correspondente. A saída de cada módulo de classificação consiste no valor de saída da Rede Lógica *Neurofuzzy*, que está associado a uma das quatro condições de operação da linha de transmissão: 1 = operação normal; 2 = curto-circuito entre fases; 3 = curto-circuito entre fase e terra; 4 = fase aberta.

Para permitir a interpretação do valor de saída dos módulos de classificação foi implementado um módulo adicional, o módulo da lógica de decisão. As saídas dos módulos de classificação são utilizadas como entrada para o módulo da lógica de decisão, cuja saída

fornece o diagnóstico da falta. A tabela 5.1 resume a lógica de decisão utilizada nesse último módulo.

Tabela 5. 1: Lógica de decisão.

Índice da falta	Saída Fase A	Saída Fase B	Saída Fase C	Diagnóstico da Falta
1	1	1	1	Operação normal
2	2	2	1	Curto-circuito fases AB
3	1	2	2	Curto-circuito fases BC
4	2	1	2	Curto-circuito fases AC
5	2	2	2	Curto-circuito fases ABC
6	3	1	1	Curto-circuito fase A-G
7	1	3	1	Curto-circuito fase B-G
8	1	1	3	Curto-circuito fase C-G
9	3	3	1	Curto-circuito fases AB-G
10	1	3	3	Curto-circuito fases BC-G
11	3	1	3	Curto-circuito fases AC-G
12	4	1	1	Fase A-aberta
13	1	4	1	Fase B-aberta
14	1	1	4	Fase C-aberta
15	4	4	1	Fases AB-aberta
16	1	4	4	Fases BC-aberta
17	4	1	4	Fases AC-aberta

O sistema de detecção e classificação de faltas implementado em MATLAB possui dois modos de operação: treinamento e diagnóstico. No modo de treinamento, a partir de um conjunto de dados de treinamento (amostras de tensão e corrente da linha de transmissão em operação normal e sob falta), o sistema utiliza os módulos de detecção para detectar as faltas e fornecer os dados aos módulos de classificação para que esses realizem o treinamento das suas respectivas redes, sem fornecer valor de saída para o módulo da lógica de decisão. No modo de diagnóstico, os módulos de detecção recebem continuamente as amostras de tensão e corrente da linha de transmissão, caso seja detectada uma falta, os módulos de detecção fornecem os vetores com as amostras no intervalo da falta para os módulos de classificação, e esses por sua vez, fornecem os valores de saída para o módulo de diagnóstico. A saída desse módulo fornece o valor do índice do tipo da falta em questão. A figura 5.20 mostra, como exemplo, o diagnóstico realizado pelo sistema de detecção e classificação de faltas em uma sequência de faltas diferentes, simuladas no modelo de SEP descrito anteriormente. A sequência inclui as seguintes faltas: curto-circuito fases AB-G, curto-circuito fases AC, fase B-aberta, curto-circuito fase B-terra, fases AC-aberta. Observando a figura 5.20, pode-se notar que todas as faltas foram detectadas e classificadas corretamente, conforme o índice das faltas obtidos. O tempo médio entre o instante de ocorrência de cada falta e o instante que a saída do sistema fornece o diagnóstico foi de aproximadamente 1,5 ms.




Figura 5. 20: Diagnóstico realizado pelo sistema de detecção e classificação de faltas em uma sequência de faltas.

5.4 Resultados obtidos

O sistema de detecção e classificação de faltas apresentado na seção 5.3 foi avaliado utilizando os dados obtidos na simulação das faltas. Foram considerados 16 tipos de faltas (dez tipos curto-circuito e seis tipos circuito-aberto) simuladas sob diversas condições de falta (distancia da falta, resistência de falta, ângulo de incidência da falta e ângulo de carga). As faltas foram organizadas em cenários, onde cada cenário contém uma simulação de todos os tipos de falta em uma dada condição, resultado num total de 384 simulações. O conjunto total de dados foi dividido em um conjunto de dados para treinamento e um conjunto de dados para validação, correspondendo a 80% e 20% do total, respectivamente.

Para permitir melhor análise dos resultados obtidos, os resultados foram divididos em grupos, onde cada grupo consiste dos resultados dos testes aplicados à faltas de um mesmo tipo. Os grupos são os seguintes:

- Grupo 1: Faltas tipo curto-circuito fase-terra (A-G, B-G, C-G).

- Grupo 2: Faltas tipo curto-circuito fase-fase-terra (AB-G, AC-G, BC-G).
- Grupo 3: Faltas tipo curto-circuito fase-fase (AB, AC, BC).
- Grupo 4: Falta tipo curto-circuito trifásico (ABC).
- Grupo 5: Faltas tipo fase aberta (A-aberta, B-aberta, C-aberta).
- Grupo 6: Faltas tipo fase-fase aberta (AB-aberta, AC-aberta, BC-aberta).

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 variação da distância da falta:

Tabela 5. 2: Resultados dos testes com variação da distância para faltas do grupo 1.

Faltas	DISTÂNCIA DA FALTA									Média	Un.
	0,1D	0,2D	0,3D	0,4D	0,5D	0,6D	0,7D	0,8D	0,9D		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	2,2	3,3	3,3	2,2	2,3	2,3	2,3	2,3	3,3	2,6	%
detectadas / classificadas	97,8	96,7	96,7	97,8	97,7	97,7	97,7	97,7	96,7	97,4	%

Condições de falta: Resistência = 0,01Ω; ângulo de incidência = 30°; ângulo de carga = 10°.

Tabela 5. 3: Resultados dos testes com variação da distância para faltas do grupo 2.

Faltas	DISTÂNCIA DA FALTA									Média	Un.
	0,1D	0,2D	0,3D	0,4D	0,5D	0,6D	0,7D	0,8D	0,9D		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	2,0	2,1	2,6	2,6	2,8	1,0	1,3	2,3	3,3	2,2	%
detectadas / classificadas	98,0	97,9	97,4	97,4	97,2	98,9	98,7	97,7	96,7	97,8	%

Condições de falta: Resistência = 0,01Ω; ângulo de incidência = 30°; ângulo de carga = 10°.

Tabela 5. 4: Resultados dos testes com variação da distância para faltas do grupo 3.

Faltas	DISTÂNCIA DA FALTA									Média	Un.
	0,1D	0,2D	0,3D	0,4D	0,5D	0,6D	0,7D	0,8D	0,9D		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	1,2	1,0	1,1	1,2	1,1	1,2	1,4	1,4	1,4	1,2	%
detectadas / classificadas	98,8	99,0	98,9	98,8	98,9	98,8	98,6	98,6	98,6	98,8	%

Condições de falta: Resistência = 0,01Ω; ângulo de incidência = 30°; ângulo de carga = 10°.

Tabela 5. 5: Resultados dos testes com variação da distância para faltas do grupo 4.

Faltas	DISTÂNCIA DA FALTA									Média	Un.
	0,1D	0,2D	0,3D	0,4D	0,5D	0,6D	0,7D	0,8D	0,9D		
não detectadas	0,0	0,0	0,0	2,3	0,8	1,0	3,4	3,1	3,1	1,5	%
detectadas / não classificadas	3,9	3,9	4,2	4,1	4,9	5,5	2,8	1,3	1,1	3,5	%
detectadas / classificadas	96,1	96,1	95,8	93,6	94,3	93,5	93,8	95,6	95,8	95,0	%

Condições de falta: Resistência = 0,01Ω; ângulo de incidência = 30°; ângulo de carga = 10°.

Tabela 5. 6: Resultados dos testes com variação da distância para faltas do grupo 5.

Faltas	DISTÂNCIA DA FALTA									Média	Un.
	0,1D	0,2D	0,3D	0,4D	0,5D	0,6D	0,7D	0,8D	0,9D		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	0,3	0,3	0,5	2,3	1,3	1,4	2,6	1,5	4,5	1,6	%
detectadas / classificadas	99,7	99,7	99,5	97,7	98,7	98,6	97,4	98,5	95,5	98,4	%

Condições de falta: Resistência = 0,01Ω; ângulo de incidência = 30°; ângulo de carga = 10°.

Tabela 5. 7: Resultados dos testes com variação da distância para faltas do grupo 6.

Faltas	DISTÂNCIA DA FALTA									Média	Un.
	0,1L	0,2L	0,3L	0,4L	0,5L	0,6L	0,7L	0,8L	0,9L		
não detectadas	0,0	0,0	1,0	0,0	0,0	0,0	0,0	8,8	5,5	1,7	%
detectadas / não classificadas	1,5	1,6	1,7	2,7	1,7	2,5	2,5	5,0	2,8	2,4	%
detectadas / classificadas	98,5	98,4	97,3	97,3	98,3	97,5	97,5	86,2	91,7	95,9	%

Condições de falta: Resistência = 0,01Ω; ângulo de incidência = 30°; ângulo de carga = 10°.

As tabelas de 5.2 a 5.7 apresentam os resultados dos testes com variação da distância da falta. Nesses testes, a distância foi variada de 10% a 90% do comprimento total da linha de transmissão (L). Normalmente, as faltas ocorridas a uma maior distância do ponto de medição dos sinais na linha de transmissão apresentam maiores dificuldades para serem detectadas e classificadas, pois quanto maior a distância, menores serão as correntes envolvidas na falta. Nos resultados obtidos, observa-se que o sistema de detecção e classificação de faltas implementado neste trabalho obteve um bom desempenho sob a variação da distancia da falta, especialmente para os grupos de faltas 1, 2, 3 e 5. Nos grupos de faltas 4 (curto-circuito trifásico) e 6 (fase-fase-aberta) o desempenho foi um pouco menor que nos grupos anteriores. De forma geral, pode-se considerar que o sistema avaliado é robusto com relação à variação da distância da falta.

- Testes com variação da resistência de falta:

Tabela 5. 8: Resultados dos testes com variação da resistência para faltas do grupo 1.

Faltas	RESISTÊNCIA DE FALTA					Média	Un.
	0,01Ω	0, 1Ω	1Ω	10Ω	100Ω		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	2,2	2,2	2,1	1,2	9,0	3,3	%
detectadas / classificadas	97,8	97,8	97,9	98,8	91,0	96,7	%

Condições de falta: Distância = 0,5L; ângulo de incidência = 30°; ângulo de carga = 10°.

Tabela 5. 9: Resultados dos testes com variação da resistência para faltas do grupo 2.

Faltas	RESISTÊNCIA DE FALTA					Média	Un.
	0,01Ω	0, 1Ω	1Ω	10Ω	100Ω		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	2,7	2,7	2,9	1,5	1,2	2,2	%
detectadas / classificadas	97,3	97,3	97,1	98,5	98,8	97,8	%

Condições de falta: Distância = 0,5L; ângulo de incidência = 30°; ângulo de carga = 10°.

Tabela 5. 10: Resultados dos testes com variação da resistência para faltas do grupo 3.

Faltas	RESISTÊNCIA DE FALTA					Média	Un.
	0,01Ω	0, 1Ω	1Ω	10Ω	100Ω		
não detectadas	0,0	0,0	0,0	0,0	1,1	0,2	%
detectadas / não classificadas	1,4	2,6	1,5	1,3	1,2	1,6	%
detectadas / classificadas	98,6	97,4	98,5	98,7	97,7	98,2	%

Condições de falta: Distância = 0,5L; ângulo de incidência = 30°; ângulo de carga = 10°.

Tabela 5. 11: Resultados dos testes com variação da resistência para faltas do grupo 4.

Faltas	RESISTÊNCIA DE FALTA					Média	Un.
	0,01Ω	0, 1Ω	1Ω	10Ω	100Ω		
não detectadas	0,0	0,0	0,0	3,1	0,0	0,6	%
detectadas / não classificadas	4,6	4,6	4,7	3,4	5,5	4,6	%
detectadas / classificadas	95,4	95,4	95,3	93,5	94,5	94,8	%

Condições de falta: Distância = 0,5L; ângulo de incidência = 30°; ângulo de carga = 10°.

As tabelas de 5.8 a 5.11 apresentam os resultados dos testes com variação da resistência de falta. Nesses testes, a resistência foi variada de $0,01\Omega$ a 100Ω . Nesse caso, os testes aplicam apenas para os grupos de faltas tipo curto-circuito (grupos 1, 2, 3 e 4). A influência da resistência de falta no diagnóstico das faltas deveria ser, teoricamente, mais significativa quanto maior for a resistência, uma vez que o aumento da resistência implica na diminuição da corrente de falta. Com uma baixa corrente de falta, dependendo do método adotado, pode ser impossível distinguir a corrente de falta da corrente de operação normal da linha de transmissão. Nos resultados obtidos, observa-se um bom desempenho obtido pelo sistema de detecção e classificação de faltas implementado neste trabalho, nos testes sob variação da resistência de falta, mesmo para os valores de resistência de faltas maiores (10Ω e 100Ω). Um desempenho pouco menor foi obtido nos testes com grupo de faltas 4 (curto-circuito trifásico). De forma geral, os resultados demonstram que o sistema avaliado possui pouca sensibilidade à variação deste fator de influência no diagnóstico das faltas.

- Testes com variação do ângulo de incidência da falta:

Tabela 5. 12: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 1.

Faltas	ÂNGULO DE INCIDÊNCIA DA FALTA					Média	Un.
	30°	60°	90°	120°	150°		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	2,2	2,3	3,1	2,6	2,3	2,5	%
detectadas / classificadas	97,8	97,7	96,9	97,4	97,7	97,5	%

Condições de falta: Distância = $0,5L$; resistência = $0,01\Omega$; ângulo de carga = 10° .

Tabela 5. 13: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 2.

Faltas	ÂNGULO DE INCIDÊNCIA DA FALTA					Média	Un.
	30°	60°	90°	120°	150°		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	2,7	2,4	2,8	3,2	3,0	2,8	%
detectadas / classificadas	97,3	97,6	97,2	96,8	97,0	97,2	%

Condições de falta: Distância = $0,5L$; resistência = $0,01\Omega$; ângulo de carga = 10° .

Tabela 5. 14: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 3.

Faltas	ÂNGULO DE INCIDÊNCIA DA FALTA					Média	Un.
	30°	60°	90°	120°	150°		
não detectadas	0,0	1,0	2,2	4,2	0,0	1,5	%
detectadas / não classificadas	1,3	1,8	1,4	0,5	2,6	1,5	%
detectadas / classificadas	98,7	97,2	96,4	95,3	97,4	97,0	%

Condições de falta: Distância = 0,5L; resistência = 0,01Ω; ângulo de carga = 10°.

Tabela 5. 15: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 4.

Faltas	ÂNGULO DE INCIDÊNCIA DA FALTA					Média	Un.
	30°	60°	90°	120°	150°		
não detectadas	0,0	0,0	0,0	0,0	3,1	0,6	%
detectadas / não classificadas	4,6	5,5	3,9	4,7	4,7	4,7	%
detectadas / classificadas	95,3	94,5	96,1	95,3	92,2	94,7	%

Condições de falta: Distância = 0,5L; resistência = 0,01Ω; ângulo de carga = 10°.

Tabela 5. 16: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 5.

Faltas	ÂNGULO DE INCIDÊNCIA DA FALTA					Média	Un.
	30°	60°	90°	120°	150°		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	2,3	1,2	6,8	2,2	2,6	3,0	%
detectadas / classificadas	97,7	98,8	93,2	97,8	97,4	97,0	%

Condições de falta: Distância = 0,5L; resistência = 0,01Ω; ângulo de carga = 10°.

Tabela 5. 17: Resultados dos testes com variação do ângulo de incidência para faltas do grupo 6.

Faltas	ÂNGULO DE INCIDÊNCIA DA FALTA					Média	Un.
	30°	60°	90°	120°	150°		
não detectadas	0,0	1,1	0,0	0,0	0,0	0,2	%
detectadas / não classificadas	1,6	3,2	3,2	8,8	5,2	4,4	%
detectadas / classificadas	98,3	95,7	96,8	91,2	94,8	95,4	%

Condições de falta: Distância = 0,5L; resistência = 0,01Ω; ângulo de carga = 10°.

As tabelas de 5.12 a 5.17 apresentam os resultados dos testes com variação do ângulo de incidência da falta. Nesses testes, o ângulo de incidência foi variado de 30° a 150°. Em uma linha de transmissão real, as faltas podem ocorrer em qualquer ponto da forma de onda da tensão, o que significa que o ângulo de incidência pode variar de 0° a 180° no semiciclo. Dependendo do ângulo de incidência da falta, há maior ou menor presença de harmônicos na linha. Nos resultados obtidos, observa-se que o sistema de detecção e classificação de faltas implementado neste trabalho obteve um bom desempenho sob a variação do ângulo de incidência da falta. Apenas nos grupos 4 (curto-circuito trifásico) e 6 (fase-fase-aberta) o desempenho foi um pouco menor. De forma geral, os resultados demonstram uma baixa influência do ângulo de incidência da falta no diagnóstico realizado pelo sistema avaliado.

- Testes com variação do ângulo de carga:

Tabela 5. 18: Resultados dos testes com variação do ângulo de carga para faltas do grupo 1.

Faltas	ÂNGULO DE CARGA					Média	Un.
	10°	15°	20°	25°	30°		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	2,3	2,3	2,2	2,3	2,4	2,3	%
detectadas / classificadas	97,7	97,7	97,8	97,7	97,6	97,7	%

Condições de falta: Distância = 0,5L; resistência = 0,01Ω; ângulo de incidência = 30°.

Tabela 5. 19: Resultados dos testes com variação do ângulo de carga para faltas do grupo 2.

Faltas	ÂNGULO DE CARGA					Média	Un.
	10°	15°	20°	25°	30°		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	2,7	3,4	2,8	2,9	2,8	2,9	%
detectadas / classificadas	97,3	96,6	97,2	97,1	97,2	97,1	%

Condições de falta: Distância = 0,5L; resistência = 0,01Ω; ângulo de incidência = 30°.

Tabela 5. 20: Resultados dos testes com variação do ângulo de carga para faltas do grupo 3.

Faltas	ÂNGULO DE CARGA					Média	Un.
	10°	15°	20°	25°	30°		
não detectadas	0,0	0,0	0,0	1,0	2,1	0,6	%
detectadas / não classificadas	1,4	1,1	1,3	1,1	0,9	1,2	%
detectadas / classificadas	98,6	98,9	98,7	97,9	97,0	98,2	%

Condições de falta: Distância = 0,5L; resistência = 0,01Ω; ângulo de incidência = 30°.

Tabela 5. 21: Resultados dos testes com variação do ângulo de carga para faltas do grupo 4.

Faltas	ÂNGULO DE CARGA					Média	Un.
	10°	15°	20°	25°	30°		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	5,3	5,9	4,2	4,9	4,4	4,9	%
detectadas / classificadas	94,7	94,1	95,8	95,1	95,6	95,1	%

Condições de falta: Distância = 0,5L; resistência = 0,01Ω; ângulo de incidência = 30°.

Tabela 5. 22: Resultados dos testes com variação do ângulo de carga para faltas do grupo 5.

Faltas	ÂNGULO DE CARGA					Média	Un.
	10°	15°	20°	25°	30°		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	0,3	0,3	0,3	1,4	1,4	0,7	%
detectadas / classificadas	99,7	99,7	99,7	98,6	98,6	99,3	%

Condições de falta: Distância = 0,5L; resistência = 0,01Ω; ângulo de incidência = 30°.

Tabela 5. 23: Resultados dos testes com variação do ângulo de carga para faltas do grupo 6.

Faltas	ÂNGULO DE CARGA					Média	Un.
	10°	15°	20°	25°	30°		
não detectadas	0,0	0,0	0,0	0,0	0,0	0,0	%
detectadas / não classificadas	2,7	1,7	1,7	1,7	1,8	1,9	%
detectadas / classificadas	97,3	98,3	98,3	98,3	98,2	98,1	%

Condições de falta: Distância = 0,5L; resistência = 0,01Ω; ângulo de incidência = 30°.

As tabelas de 5.18 a 5.23 apresentam os resultados dos testes com variação do ângulo de carga. Nesses testes, o ângulo de carga foi variado de 10° a 30°. Num SEP o ângulo de carga representa a diferença angular entre as tensões nos terminais transmissor e receptor do sistema, e determina o fluxo de potência na linha de transmissão. Dessa forma, o ângulo de carga pode influenciar no diagnóstico das faltas, uma vez que a variação do fluxo de potência na linha implica na variação da corrente na mesma, dificultando a distinção entre a corrente normal e corrente de falta. Nos resultados obtidos, observa-se que o sistema de detecção e classificação de faltas implementado neste trabalho obteve bom desempenho nos testes sob variação do ângulo de carga. Somente no grupo 4 (curto-circuito trifásico) o desempenho foi um pouco menor. De forma geral, os resultados demonstram uma baixa influência do ângulo de carga no diagnóstico realizado pelo sistema avaliado.

A partir dos resultados obtidos nos testes realizados com cada um dos grupos de faltas, pode-se obter uma idéia geral da eficiência do sistema de detecção e classificação de faltas implementado neste trabalho nos resultados gerais apresentados na tabela 5.24.

Tabela 5. 24: Resultados gerais dos testes realizados.

Faltas	TESTE				Média	Un.
	Distância	Resistência	Âng. de incidência	Âng. de carga		
não detectadas	0,5	0,1	0,4	0,1	0,3	%
detectadas / não classificadas	2,3	2,5	3,1	2,3	2,6	%
detectadas / classificadas	97,2	97,4	96,5	97,6	97,1	%

Os resultados obtidos demonstraram que o sistema apresentou um desempenho promissor e motivador, pois detectou corretamente 99,7% das faltas e classificou corretamente 97,1% das faltas. O percentual de faltas não detectadas foi muito baixo, da ordem de 0,3%. Esses resultados podem ser considerados iguais aos melhores resultados obtidos pelos diversos métodos para diagnóstico de faltas em linhas de transmissão encontrados na literatura. Considerando ainda que esses resultados foram obtidos sob variação de diversos parâmetros que determinam a condição da falta, o sistema avaliado mostrou-se robusto à todos os fatores de influência.

Capítulo 6

6 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 propôs-se 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 encontrada 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 e trifásico, além de fase aberta. Este fato representa uma vantagem em relação às metodologias convencionais que necessitam de informações sobre vários parâmetros da linha, como impedância, por exemplo. Uma vez que os parâmetros da linha de transmissão alteram-se em função de diversos fatores, uma metodologia que seja independente dos mesmos é mais vantajosa.

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 Lógica *Neurofuzzy* modificada com a inclusão do Aprendizado Participativo. 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 em uma linha de transmissão.

Os resultados obtidos demonstraram que o sistema avaliado possui bom desempenho, pois a eficiência na detecção das faltas foi acima de 99% e na classificação das faltas foi acima de 97%. O percentual de faltas não detectadas pelo sistema foi muito baixo, menor que 1%. Os resultados foram obtidos sob variação dos fatores que influenciam no diagnóstico das faltas, a distância da falta, a resistência de falta, o ângulo de incidência da falta e o ângulo de carga. 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.

A abordagem proposta que combina técnicas de análise de sinais e inteligência computacional se mostrou uma alternativa promissora, principalmente dada a sua capacidade de identificação e aprendizado das características das faltas, com uma eficiência superior à outras metodologias que empregam uma ou outra técnica separadamente. 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 pode não ser viável.

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

6.1 Trabalhos futuros

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

- Aperfeiçoamento da metodologia proposta para obter melhores resultados nos casos onde o desempenho foi menor;
- Validação da metodologia proposta a partir de estudos de casos baseados em dados obtidos de linhas de transmissão reais;
- Estudo de outros modelos de redes neurofuzzy e outros tipos de algoritmos de treinamento que possibilitem a melhoria dos resultados obtidos;
- Incorporação de técnicas na metodologia proposta que possibilitem não somente a detecção e classificação da falta, mas também a identificação de outras características da falta (por exemplo, se a falta tipo curto-circuito é decorrente do contato da linha de transmissão com árvores ou com o solo).

6.2 Produção científica

O seguinte artigo foi produzido a partir dos estudos realizados nessa dissertação:

- Inácio, M. J., Maia, R. D., Lemos, A. P. e Caminhas, W. M. (2009). Aprendizado Participativo Aplicado à Detecção e Diagnóstico On-Line da Falhas em Sistemas Dinâmicos. IX Congresso Brasileiro de Redes Neurais / Inteligência Computacional (CBRN 2009).

O seguinte artigo foi submetido com aceitação ainda pendente:

- Inácio, M. J., Maia, R. D., e Caminhas, W. M. (2010). Detecção e Classificação de Falhas em Linhas de Transmissão baseadas em Transformada Wavelet e Rede Lógica Neurofuzzy modificada com Aprendizado Participativo. XVII Congresso Brasileiro de Automática (CBA 2010).

Apêndices

A. Algoritmo de Agrupamento Participativo

O Algoritmo de Agrupamento Participativo (AAP) é baseado no paradigma do Aprendizado Participativo (AP) proposto por Ronald R. Yager (Yager, 1990). A idéia central do aprendizado participativo é que observações coerentes com o conhecimento atual devem atualizar o sistema de aprendizado e observações pouco coerentes devem ser subestimadas. Um mecanismo de alerta é empregado para indicar que o sistema de aprendizado precisa ser revisado caso muitas observações sejam rejeitadas. Esse esquema permite rápida aprendizagem de novos conhecimentos. O aprendizado participativo pode ser visto como um processo de aprendizado passo a passo e que pode ser implementado recursivamente. A figura 1 mostra a estrutura do sistema de aprendizado participativo, cujo procedimento de aprendizagem é descrito a seguir.

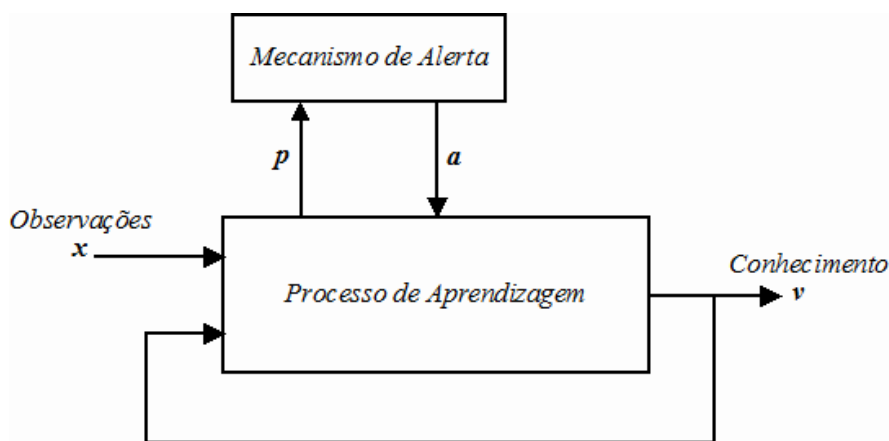


Figura 1: Estrutura do sistema de Aprendizado Participativo.

Considere a representação do conhecimento do sistema uma variável $v_k \in [0,1]^p$, a qual se deseja aprender os valores a partir de sequência de observações $x_k \in [0,1]^p$, onde x_k é uma manifestação dos valores de v na k -ésima observação. De acordo com o paradigma do aprendizado participativo, a contribuição de x_k no processo de aprendizagem depende da sua aceitação por v_k , ou seja, uma nova observação será usada no processo de aprendizagem dependendo da sua compatibilidade com o conhecimento atual. Dessa forma, a atualização do conhecimento será:

$$v_{k+1} = v_k + \alpha \rho_k (x_k - v_k) \quad (1)$$

onde $\alpha \in [0,1]$ é a taxa de aprendizagem e $\rho_k \in [0,1]$ é o índice de compatibilidade entre x_k e v_k na observação $k=1, 2, \dots$

O índice de compatibilidade expressa o quanto a observação é compatível com conhecimento atual, sendo que, $\rho_k=0$ significa mínima compatibilidade e $\rho_k=1$ significa máxima compatibilidade. Em outras palavras, caso a observação seja incompatível com o conhecimento atual, o sistema irá descartá-la, pois com $\rho_k=0$:

$$v_{k+1} = v_k \quad (2)$$

No caso oposto, caso a observação seja totalmente compatível com o conhecimento atual, o sistema estará aberto a incorporar a nova informação, pois com $\rho_k=1$:

$$v_{k+1} = v_k + \alpha(x_k - v_k) \quad (3)$$

Sendo ρ_k uma medida de similaridade entre uma observação x_k e o conhecimento atual v_k , uma possível formulação para ρ_k é:

$$\rho_k = 1 - \frac{1}{\rho} \sum_{j=1}^{\rho} d_{kj} \quad (4)$$

onde $d_{kj} = |x_{kj} - v_{kj}|$ é uma medida de distância. Outra forma mais simples de calcular o grau de compatibilidade é:

$$\rho_k = 1 - d_k \quad (5)$$

onde $d_k = \|x_k - v_k\|$ e $\|\cdot\|$ é uma norma.

Uma característica indesejável desse procedimento de aprendizagem é o fato de ignorar a situação onde ocorre uma sequência de baixos valores de ρ_k durante um período de tempo mais longo. Essa situação indica que o conhecimento atual precisa ser revisto, porque as novas observações representam um novo conhecimento. Para contornar esse problema, o mecanismo de alerta monitora os valores do índice de compatibilidade das observações com o conhecimento atual, e gera um índice de alerta, $a_k \in [0,1]$, que indicará quando o sistema de aprendizagem necessita ser revisado. O índice de alerta pode ser determinado da seguinte forma:

$$\begin{aligned} a_{k+1} &= (1 - \beta)a_k + \beta(1 - \rho_{k+1}) \\ a_{k+1} &= a_k + \beta((1 - \rho_{k+1}) - a_k) \end{aligned} \quad (6)$$

onde $\beta \in [0,1]$ é uma constante que controla a taxa de variação do índice de alerta. Esse parâmetro pode ser visto como um tipo de sensibilidade do sistema ou ainda como um complemento do grau de conservadorismo do sistema.

Com o índice de alerta, a atualização do conhecimento será:

$$v_{k+1} = v_k + \alpha(\rho_k)^{1-a_k} (x_k - v_k) \quad (7)$$

Dessa forma, quanto maior o índice de alerta, menor deverá ser a influência do índice de compatibilidade na atualização do sistema de aprendizado. Isso significa que o sistema de aprendizado estará aberto a incorporar um novo conhecimento.

Conforme mostra a figura 1, a associação do mecanismo de alerta com o processo de aprendizagem permite que o sistema de aprendizado não apenas atualize o conhecimento atual com as novas observações, mas também permite a incorporação de novos conhecimentos. Em síntese, essas são as principais características do aprendizado participativo.

Utilizando os conceitos da aprendizagem participativa é possível construir um algoritmo de agrupamento não supervisionado, como o AAP. Nesse algoritmo, empregando o mecanismo de aprendizagem participativa, os centros dos grupos são encontrados gradativamente, de acordo com a entrada de dados.

Relacionando a aprendizagem participativa com o agrupamento de dados, considere os pontos x_k e os centros dos grupos v_i como as observações e o conhecimento do sistema, respectivamente. O índice de compatibilidade ρ_{ki} entre a observação k com a i -ésimo conhecimento é visto como um grau de compatibilidade entre x_k e o centro do grupo v_i . O índice de alerta a_{ki} é visto como um grau de incompatibilidade entre o conhecimento atual e as observações, ou seja, indica o quão longe os pontos x_k , $k = 1, 2, \dots$, estão dos centros de grupos v_i , $i = 1, 2, \dots, c$. Um novo parâmetro $\tau \in [0, 1]$ será utilizado como um limiar, cujo propósito é avisar quando uma observação é incompatível com o conhecimento atual e o sistema precisa ser revisado para acrescentar o novo conhecimento. No agrupamento de dados isso significa que se um ponto x_k estiver muito longe de todos os centros de grupos, deve ser criado um novo grupo e o ponto x_k declarado como o novo centro de grupo.

No AAP, dado os valores iniciais de α , β , e τ , os dois primeiros pontos podem ser utilizados para formar os centros de grupos iniciais. A partir disso, para a entrada k , são calculados os índices de compatibilidade ρ_{ki} e de alerta a_{ki} para todos os centros de grupo v_i . O limiar τ é comparado com o índice de alerta de todos os centros de grupos. Se o índice de alerta for maior que o limiar τ , então x_k é declarado com o centro de um novo grupo, senão o centro de grupo que tiver o maior índice de compatibilidade com x_k é atualizado.

Com a atualização de grupos ou a criação de novos grupos, é necessário verificar se grupos redundantes estão sendo formados, ou seja, centros de grupos sendo colocados próximos a outros centros de grupo. Para isso é utilizado um mecanismo de exclusão de centro de grupos redundantes, visto que a redundância não acrescenta informação do ponto de vista do aprendizado participativo. O mecanismo de exclusão de centros de grupos calcula um índice de compatibilidade entre centros de grupos usando a medida de distância. Um centro é excluído quando o seu índice de compatibilidade é maior que um limiar de compatibilidade entre grupos $\lambda \in [0, 1]$. A seguir são apresentados os procedimentos do AAP:

Definir os parâmetros $\alpha \in [0,1]$, $\beta \in [0,1]$, $\tau \in [0,1]$, e $\lambda \in [0,1]$.

Inicializar o número de centros de grupos c_k , os centros de grupos v_i e os índices de alerta a_i^k .

Para $x_k \in [0,1]^p$, $k = 1,2,\dots$

Para $i = 1,2,\dots,c_k$

Calcular índice de compatibilidade: $\rho_i^k = 1 - d(v_i, x_k)$;

Calcular índice de alerta: $a_i^{k+1} = a_i^k + \beta((1 - \rho_i^k) - a_i^k)$;

Se $a_i^{k+1} \geq \tau$, $\forall i = 1,2,\dots, c_k$ então

$c_k = c_k + 1$;

novo centro de grupo: $v_{c_k} = x_k$;

Senão

Obter grupo mais compatível: $s = \arg \max_{i=1,2,\dots,c_k} \{\rho_i^k\}$;

Atualizar grupo s : $v_s^{k+1} = v_s^k + \alpha(\rho_s^k)^{1-a_s^{k+1}}(x_k - v_s^k)$

fim se

fim para

Para $i = 1,2,\dots,(c_k - 1)$ e $j = (i + 1),\dots,c_k$

Calcular compatibilidade entre centros: $\rho_{ij}^k = 1 - d(v_i^k, v_j^k)$

Se $\rho_{ij}^k \geq \lambda$ para algum j então

excluir grupo v_i ;

redefinir grupo v_j ;

$c_k = c_k - 1$;

fim se

fim para

$c_{k+1} = c_k$;

fim para.

B. Parâmetros dos componentes utilizados na implementação do SEP no PSCAD

- Fontes (*Three-Phase Voltage Source Model 3*)
 - Tensão = 230 kV;
 - Potência = 100 MVA;
 - Frequência = 60 Hz;
 - Impedância de sequência positiva = $1,0 + 0,1 \Omega$;
 - Impedância de sequência zero = $1,0 + 0,1 \Omega$.
- Linha de Transmissão (*T-Line*)
 - Comprimento = 200 km.
 - Impedância de sequência positiva = $3,57 + 50,78 \Omega$;
 - Impedância de sequência negativa = $3,57 + 50,78 \Omega$;
 - Impedância de sequência zero = $36,32 + 132,65 \Omega$.
- Resistência de falta (*Three-Phase Fault*)
 - Resistência ON = 0,01 Ω ; 0,1 Ω ; 1 Ω ; 10 Ω ; 100 Ω ;
 - Resistência OFF = 1 M Ω ;
- Disjuntor (*Three-Phase Breaker*)
 - Resistência ON = 0, 1 Ω ;
 - Resistência OFF = 1 M Ω .

Referências Bibliográficas

Bo, Z.Q.; Aggarwal, R. K.; Johns, A. T.; Song, Li, H. Y e Song, Y., H. (1997). A New Approach to Phase Selection using Fault Generated High Frequency Noise and Neural Networks. IEEE Transaction on Power Delivery, Vol. 12, No. 1, pp. 106 - 115.

Bo, Z.Q.; Redfern, M.A. e Weller, G.C. (2000). Positional protection of transmission line using fault generated high frequency transient signals. IEEE Transaction on Power Delivery, vol. 15, n. 3, p. 888 - 894.

Caminhas, W. M.; Tavares, H. M. F. e Gomide, F. A. C. (1996). A Neurofuzzy Approach for Fault Diagnosis in Dynamic Systems. IEEE International Conference on Fuzzy Systems, vol. 3, p. 2032-2037.

Chanda, D.; Kishore, N. K. e Sinha, A. K. (2003). Application of Wavelet Mutiresolution Analysis for Classification on Faults on Transmission Lines. TENCON 2003 - Conference on Convergent Technologies for Asia-Pacific Region, vol. 4, p. 1464 - 1469.

Chiradeja, P. e Ngaopitakkul A. (2009). Identification of Fault Types for Single Circuit Transmission Line using Discrete Wavelet Transform and Artificial Neural Networks. Proceeding of the International MultiConference of Engineers and Computer Scientists, vol. 2, p. 1520 - 1525.

Coury, D. V. (2002). Introdução aos Sistemas Elétricos de Potência. Disponível em <<http://www.sel.eesc.sc.usp.br/protecao/apostilaprotecaosell183.pdf>>. Acesso em 01 out. 2009.

Das, Biswarup e Reddy, J. Vittal (2005). Fuzzy-Logic-Based Fault Classification Scheme for Digital Distance Protection. IEEE Transaction on Power Delivery, vol. 20, n. 2, p. 609 - 616.

Das, D.; Singh, N.K. e Sinha, A.K. (2006). A Comparison of Fourier Transform and Wavelet Transform Methods for Detection and Classification of Faults on Transmission Lines. Proc. IEEE Power India Conference, New Delhi, India.

Dash, P. K; Pradhan, A. K. e Panda, G. (2000). A Novel Fuzzy Neural Network Based Distance Relaying Scheme. IEEE Transaction on Power Delivery, vol. 15, n. 3, p. 902 - 907.

Donoho, D.L. e Johnstone, I.M. (1994). Ideal spatial adaptation by wavelet shrinkage. Biometrika, vol. 81, n. 3, p. 425 - 455.

Fernandez, Ángel L.Orille e Ghonaim, Nabil Khalil (2002). A Novel Approach using a FIRANN for Fault Detection and Direction Estimation for High-Voltage Transmission Lines. IEEE Transaction on Power Delivery, vol. 17, n. 4, p. 894 - 900.

Gayathri, K. e Kumarappan, N. (2008). Comparative Study of Fault Identification and Classification on EHV Lines using Discrete Wavelet Transform and Fourier Transform Based ANN. International Journal of Electrical, Computer, and Systems Engineering, vol. 2, n. 2, p. 125 - 136.

- Grainger, John J. e Stevenson, William D. (1994). Power System Analysis. McGraw-Hill Books, New York, NY, USA.
- Graps, Amara L. (1995). Introduction to Wavelets. IEEE Computational Sciences and Engineering, vol. 2, n. 2, p. 50 - 61.
- Haykin, Simon (1999). Neural Networks: a comprehensive foundation. 2 ed. Prentice Hall, Upper Saddle River, New Jersey, USA.
- Haykin, Simon; Veen, Barry Van (2001). Sinais e Sistemas. Bookman, Porto Alegre, RS, Brasil.
- Hell, M. B.; Costa, P. e Gomide, Fernando Antonio Campos (2007). New Neurofuzzy Training Procedure Based on Participatory Learning Paradigm. IEEE International Conference on Fuzzy Systems, p.1952 - 1957.
- Horowitz, Stanley H. e Phadke, Arun G. (2008). Power System Relaying. 3 ed. John Wiley & Sons Ltd, West Sussex, England.
- Inácio, M. J., Maia, R. D., Lemos, A. P. e Caminhas, W. M. (2009). Aprendizado Participativo Aplicado à Detecção e Diagnóstico On-Line da Falhas em Sistemas Dinâmicos. In: IX Congresso Brasileiro de Redes Neurais / Inteligência Computacional. Anais do IX Congresso Brasileiro de Redes Neurais / Inteligência Computacional.
- Jang, Roger Jyh-Shing; Sun, Chuen-Tsai e Mizutani, Eiji (1997). Neuro-Fuzzy and Soft Computing: A computational approach to learning and machine intelligence. Prentice Hall, Upper Saddle River, New Jersey, USA.
- Kim, Chul-Hwan e Aggarwal, Raj (2000). Wavelet Transform in Power Systems - Part 1: General introduction to the wavelet transform. Power Engineering Journal, vol. 14, n. 2, pp. 81 - 87.
- Kim, Chul-Hwan e Aggarwal, Raj (2001). Wavelet Transform in Power Systems - Part 2: Examples of application to actual power system transients. Power Engineering Journal, vol. 15, n. 4, pp. 193 - 202.
- Kim, Chul-Hwan *et al.* (2002). A Novel Fault-Detection Technique of High-Impedance Arcing Faults in Transmission Lines using the Wavelet Transform. IEEE Transaction on Power Delivery, vol. 17, n. 4, pp. 921 - 929.
- Liang, J.; Elangovan, S. e Devotta, J. B. X. (1998). A Wavelet Multiresolution Analysis Approach to Fault Detection and Classification in Transmission Lines. Electric Power & Energy Systems, vol. 20, n. 5, pp. 327 - 332.
- Mahanty, R. N. e Gupta, P. B. Dutta (2004). Application of RBF Neural Network to Fault Classification and Location in Transmission Lines. IEE Proceedings Generation, Transmission & Distribution, vol. 151, n. 2, pp. 201 - 212.

- Mahanty, R. N. e Gupta, P. B. Dutta (2007). A Fuzzy Logic based Fault Classification Approach using Current Samples only. *Electric Power Systems Research*, vol. 77, ed. 5-6, pp. 501-507.
- Makming, P. *et al.* (2002). Fault Diagnosis in Transmission Lines using Wavelet Transform Analysis. *Transmission and Distribution Conference and Exhibition 2002: Asia Pacific. IEEE/PES*, vol. 3, pp. 2246 - 2250.
- MATLAB (2008). User Guide. The MathWorks Inc., Natick, MA, USA.
- Misiti, M.; Misiti, Y.; Oppenheim, G. e Poggi, J-M. (2007). *Wavelet Toolbox User's Guide 4*. The MathWorks Inc., Natick, MA, USA.
- Oleskovicz, M.; Coury, D. V. e Aggarwal, R. K. (2001). A Complete Scheme For Fault Detection, Classification and Location In Transmission Lines Using Neural Networks. *IEE Seventh International Conference on Developments in Power System Protection*, pp. 335 - 338.
- Osman, A. H. e Malik, O. P. (2004). Protection of Parallel Transmission Lines using Wavelet Transform. *IEEE Transaction on Power Delivery*, vol. 19, n. 1, pp. 49 - 55.
- Pedrycz, Witold e Gomide, Fernando (1998). *An Introduction to Fuzzy Sets: Analysis and Design*. MIT Press.
- Phadke, Arun G. e Thorp, James S. (2009). *Computer Relaying for Power Systems*. 2 ed. John Wiley & Sons Ltd, West Sussex, England.
- PSCAD (2005). User's Guide. Manitoba HVDC Research Centre Inc. Manitoba, Canada.
- Reddy, M. Jayabharata e Mohanta, D. K. (2007). A Wavelet-Fuzzy Combined Approach for Classification and Location of Transmission Line Faults. *International Journal of Electric Power & Energy Systems*, vol. 29, ed. 9, pp. 669 - 678.
- Silva, L.; Gomide, F. e Yager, R. R. (2005). Participatory Learning in Fuzzy Clustering. *Proc. 14th IEEE International Conference on Fuzzy Systems*, pp. 857 - 861.
- Silveira, P. M.; Seara, R. e Zurn, H. H. (1999). An Approach using Wavelet Transform for Fault Type Identification in Digital Relaying. *IEEE Power Engineering Society Summer Meeting*, vol. 2, pp. 937 - 942.
- Thorp, James S. (2007). *Digital Relaying*. In: Grigsby, Leonard L. *Power System Stability and Control*. CRC Press, Boca Raton, FL, USA.
- Tleis, Nasser D. (2008). *Power Systems Modelling and Fault Analysis - Theory and Practice*. Newnes, Oxford, OX, UK.
- Ukil, Abhisek e Zivanovic, Rastko (2006). Abrupt change detection in power system fault analysis using adaptive whitening filter and wavelet transform. *Electric Power Systems Research*, vol. 76, ed. 9-10, pp. 815 – 823.

- Vásquez, Ernesto; Altuve, Héctor J. e Chacón, Oscar L. (1996). Neural Network Approach To Fault Detection In Electric Power Systems. IEEE International Conference on Neural Networks, vol. 4, pp. 2090 - 2095.
- Vieira, José; Dias, Fernando M. e Mota, Alexandre (2004). Neuro-Fuzzy Systems: A Survey. 5th WSEAS Transactions On Systems, vol. 3, n. 2, pp. 414 – 419.
- Wang, Huisheng e Keerthipala, W. W. L. (1998). Fuzzy-Neuro Approach to Fault Classification for Transmission Line Protection. IEEE Transaction on Power Delivery, vol. 13, n. 4, pp. 1093 - 1104.
- Warrington, A. R. van C. (1978). Protective Relays Their Theory and Practice. vol. 2. 3rd ed. Springer, London, UK.
- Yager, R. R. (1990). A model of Participatory Learning. IEEE Transaction on System, Man and Cybernetics, vol. 20, n. 5, pp. 1229 - 1234.
- Youssef, Omar A. S. (2004). Combined Fuzzy-Logic Wavelet-Based Fault Classification Technique for Power System Relaying. IEEE Transaction on Power Delivery, vol. 19, n. 2, pp. 582 - 589.
- Zhao, W.; Song, Y. H. e Min, Y. (2000). Wavelet Analysis based Scheme for Fault Detection and Classification in Underground Power Cable Systems. Electric Power Systems Research, vol. 53, ed. 1, pp. 23 – 30.