# PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA (PPGEL) ASSOCIAÇÃO AMPLA ENTRE UFSJ E CEFET-MG





Henrique dos Reis Paula

ALGORITMOS PARA DETECTAR, CLASSIFICAR, LOCALIZAR FALTAS E DETERMINAR RESISTÊNCIAS DE FALTAS EM LINHAS DE TRANSMISSÃO: MÉTODOS QUE UTILIZAM DADOS DE UM E DOIS TERMINAIS

> BELO HORIZONTE NOVEMBRO DE 2015

### Henrique dos Reis Paula

# ALGORITMOS PARA DETECTAR, CLASSIFICAR, LOCALIZAR FALTAS E DETERMINAR RESISTÊNCIAS DE FALTAS EM LINHAS DE TRANSMISSÃO: MÉTODOS QUE UTILIZAM DADOS DE UM E DOIS TERMINAIS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro Federal de Educação Tecnológica de Minas Gerais como requisito parcial para obtenção do grau de Mestre em Engenharia Elétrica

ORIENTADOR: Eduardo Gonzaga da Silveira COORIENTADOR: Giovani Guimarães Rodrigues

BELO HORIZONTE, NOVEMBRO DE 2015

### Henrique dos Reis Paula

# ALGORITMOS PARA DETECTAR, CLASSIFICAR, LOCALIZAR FALTAS E DETERMINAR RESISTÊNCIAS DE FALTAS EM LINHAS DE TRANSMISSÃO: MÉTODOS QUE UTILIZAM DADOS DE UM E DOIS TERMINAIS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro Federal de Educação Tecnológica de Minas Gerais como requisito parcial para obtenção do grau de Mestre em Engenharia Elétrica

Aprovado em novembro de 2015

### BANCA EXAMINADORA

Prof. Dr. Eduardo Gonzaga da Silveira PPGEL/CEFETMG

Prof. Dr. Giovani Guimarães Rodrigues PPGEL/CEFETMG

Prof. Dr. Clever Sebastião Pereira PPGEE/UFMG

Prof. Dr. Rafael Silva Alípio PPGEL/CEFETMG

Dedico este trabalho a minha família, pelo apoio incondicional, que possibilitou a realização dessa etapa.

### **AGRADECIMENTOS**

Agradeço a Deus por conduzir e estar sempre presente, ajudando a superar os momentos de dificuldade encontrados não só na vida acadêmica, mas também no cotidiano.

Agradeço aos meus pais, Maria das Graças Reis e José Bonifácio de Paula, que mesmo diante das dificuldades, possibilitaram e incentivaram o início dessa caminhada amparada nos estudos.

Aos meus familiares, especialmente minha Tia Celeste, a minha avó Donária e a minha irmã Amanda pelas orações e amor.

Ao meu irmão Fabrício, pelas boas conversas e dedicação com nossa família. A minha cunhada Michelle pela ajuda na etapa final.

À Katiana pelo apoio e carinho, estando sempre presente e tornando essa caminhada mais amena.

Agradeço ao professor Eduardo Gonzaga pela dedicação e interesse em ajudar. A sua orientação é um exemplo que levo para minha vida profissional.

Ao professor Giovani Guimarães, por estar sempre disponível e pelas importantes orientações que contribuíram para elaboração desse trabalho.

À Coordenação de Eletrotécnica, em especial ao professor Anderson Arthur Rabello, que apoiou minha caminhada no mestrado, mesmo eu estando a pouco tempo nessa coordenação.

### **RESUMO**

Esse trabalho propõe três algoritmos, que podem ser integrados à proteção de Sistemas Elétricos de Potência, capazes de detectar, classificar, localizar faltas e determinar resistências de faltas em linhas de transmissão. Para realizar tais funções, os algoritmos 1 e 2 utilizam dados obtidos a partir das medições realizadas em um único terminal da linha, enquanto que o algoritmo 3 utiliza dados de dois terminais. Inicialmente os dados de um evento de falta são pré-processados. Essa etapa é semelhante nos três algoritmos e nela ocorre a detecção da falta, que é baseada na Transformada Wavelet Estacionária (TWE), wavelet mãe do tipo daubechies 4 (dB4) e teorema de Parseval. Além disso, a partir dos sinais registrados no período pré-falta, é realizada a estimação fasorial das fontes equivalentes. Esse processo contribui para reduzir os cenários de faltas necessários para treinamentos das Redes Neurais Artificiais (RNAs), uma vez que será conhecido o fluxo de potência na linha de transmissão. Por fim, são gerados 504 cenários de falta, no software Alternative Transient Program (ATP), necessários para treinamento das RNAs. Para classificação, localização de faltas e determinação da resistência de falta, os três algoritmos utilizam inteligência computacional por meio de RNAs, implementadas com topologia denominada Multilayer Perceptron (MLP), método de aprendizagem supervisionado backpropagation e com algoritmo de treinamento Levenberg-Marquardt. Para treinamento e testes das RNAs, o algoritmo proposto 1 apresenta nova metodologia, que seleciona os dados de energia dos coeficientes detalhes extraídos dos sinais de corrente e tensão registrados em único terminal da linha, durante os primeiros 1/8 de ciclo do período de falta. Já o algoritmo proposto 2, seleciona os módulos fasoriais dos sinais de tensão e corrente registrados também em único terminal, durante os primeiros 1/4 de ciclo do período de falta. E o algoritmo proposto 3, seleciona os módulos fasoriais apenas dos sinais de corrente registrados nos dois terminais, também durante os primeiros 1/4 de ciclo do período de falta. A extração dos fasores é obtida através de uma variação do método dos erros mínimos quadrados. Os três algoritmos propostos apresentaram resultados precisos quando foram testados diante de diferentes cenários de falta, obtidos a partir do software ATP. Quando foram avaliadas situações reais de falta, o algoritmo proposto 1 não apresentou convergência, enquanto que os algoritmos

propostos 2 e 3 obtiveram bons resultados.

**Palavras-chave:** Transformada Wavelet, Teorema de Parseval, Erros Mínimos Quadrados e Redes Neurais Artificiais.

### **ABSTRACT**

This paper proposes three algorithms that may be integrated to the Electric Power System protection, which is able to detect, classify, locate faults and determine resistance faults in transmission lines. In order to execute such functions, algorithms 1 and 2 use data obtained from measurements carried out in a one line terminal, whilst algorithm 3 uses data from two terminals. Initially, the data of a fault event is pre-processed. This stage is similar in the three algorithms and this is the stage in which the fault detection occurs, and it is based on the Stationary Wavelet Transform (SWT), mother wavelet daubechies4 (db4), and the theorem of Parseval. Furthermore, from the signals registered in the pre-fault period, the phasor estimate of the equivalent sources is executed. This process contributes to reduce the fault scenarios required for the Artificial Neural Network (ANN) training, since the power flow will become known in the transmission line. Finally, 504 fault scenarios are generated in Alternative Transient Program (ATP) software, which are required for the ANN training. For the classification, fault Location and determination of the fault resistance, the three algorithms use Computational Intelligence by means of the ANN, implemented with a topology named Multilayer Perception (MLP), a supervised learning method of backpropagation and with a training algorithm Levenberg-Marquardt. For the ANN tests and training, the proposed algorithm 1 presents a new methodology, which selects the energy data of the detail coefficient extracted from the current and voltage signals registered in a single terminal in the line, during the first 1/8 of the fault period cycle. Whereas algorithm 2 selects the phasor magnitude of the current and voltage signals registered also in a single terminal, during the first 1/4 of the fault period cycle. And proposed algorithm 3, selects the phasor magnitude of only the current signals registered in the two terminals, also during the first 1/4 of the fault period cycle. The phasors extraction is obtained through a variation in the method of least errors. The three proposed algorithm presented accurate results when tested given different fault scenarios, obtained from the ATP software. When actual fault events were assessed, algorithm 1 did not present any convergence, while proposed algorithms 2 and 3 obtained good results

**Keywords:** Wavelet Transform, Theorem of Parseval, Method of Least Errors and Artificial Neural Network

## Lista de Figuras

Figura 1 - Formas de onda: a) senoidal; b) wavelet Dubechies	. 18
Figura 2 - Função wavelet do tipo Haar	. 18
Figura 3 - Função escala do tipo Haar	. 19
Figura 4- Família Daubechies (MISITI, MISITI, et al., 2015)	. 19
Figura 5 - Função escala $\phi(t)$ e função wavelet $\Psi(t)$ de ordem 2 (FILHO, Maio, 2007)	. 20
Figura 6 - Transformada de Fourier janelada (MISITI, MISITI, et al., 2015)	. 20
Figura 7 - Transformada wavelet (MISITI, MISITI, et al., 2015)	. 21
Figura 8 - Efeito do fator escala (a) em uma função senoidal	. 22
Figura 9 - Efeito do fator de escala (a) em uma função wavelet (MISITI, MISITI, et al., 2015)	. 22
Figura 10 - Translação de uma função wavelet: a) Função wavelet $\Psi(t)$ ; b) Função wavelet	
transladada Ψ (t-b)	. 23
Figura 11 - Wavelet: condição inicial (MISITI, MISITI, et al., 2015)	. 23
Figura 12 - Wavelet transladada (MISITI, MISITI, et al., 2015)	. 23
Figura 13 - TWD: Processo de filtragem ao primeiro nível de decomposição	. 24
Figura 14 - TWD: Processo de filtragem ao primeiro nível de decomposição considerando um sinal	
real (MISITI, MISITI, et al., 2015)	. 25
Figura 15 - Processo de decomposição de um sinal em 3 níveis (Multiresolução)	. 25
Figura 16 - Processo de decomposição de um sinal real em 3 níveis (Multiresolução) (MISITI, MISIT	Π,
et al., 2015)	. 26
Figura 17 - Representação da Região tempo-escala	. 26
Figura 18 - Função wavelet em diferentes níveis de decomposição (RODRIGUES, 2008)	. 27
Figura 19 - TWE: Processo de filtragem ao primeiro nível de decomposição	. 28
Figura 20 - Transformada wavelet estacionária: Decomposição em múltiplos níveis e upsample de	
filtros (MISITI, MISITI, et al., 2015)	. 28
Figura 21 – Evolução de um sinal <b>S</b> ao ser submetido a TWE e energia de Parserval	. 30
Figura 22 - Neurônio biológico (MATSUNAGA, 2012)	. 31
Figura 23 - Conexão entre dois neurônios (MENEZES, 2008)	. 31
Figura 24 - Configuração neurônio artificial (DEMUTH e BEALE, 2015)	. 32
Figura 25 - Funções de ativação: a) Linear; b) Sigmoide; c) Tangente hiperbólica	. 33
Figura 26 - Rede Neural com uma camada (DEMUTH e BEALE, 2015)	. 34
Figura 27 - Rede neural de múltiplas camadas (DEMUTH e BEALE, 2015)	. 35
Figura 28 - Rede MLP com aprendizagem supervisionada backpropagation (MENEZES, 2008)	. 37
Figura 29 – Topologia do sistema elétrico	. 39
Figura 30 - Diferentes tipos de falta: A) fase-terra; B) bifásico; C) trifásica; D) bifásico-terra	. 40
Figura 31 - Estrutura do algoritmo para pré-processamento de dados	. 41

Figura 32 - Evolução do sinal de corrente ao passar pelos processos de interpolação, normalizaç	ão,
TWE e energia de Parserval	42
Figura 33 - Sinais de corrente no domínio do tempo e suas respectivas energias dos coeficientes	i
detalhe	43
Figura 34 - Modelo linha de transmissão: circuito pré-falta	45
Figura 35 - Sinais reais registrados no terminal <b>S</b>	46
Figura 36 - Estrutura do algoritmo para processamento de dados	48
Figura 37 - Seleção de dados para testes e treinamentos das RNAs. Energia do coeficiente detal	he
da corrente e tensão	49
Figura 38 - RNAs modulares para classificação de falta. Cada RNA recebe os dados de uma únic	са
fase ou neutro (A, B, C e N)	50
Figura 39 - (a) RNAs modulares para localizar falta; (b) RNAs modulares para determinar resistê	ncias
de falta. Cada RNA recebe os dados de acordo com o tipo de falta	51
Figura 40 - Estrutura do algoritmo para processamento de dados	52
Figura 41 - Seleção de dados para testes e treinamentos das RNAs. Módulos fasoriais de corren	te e
tensão	53
Figura 42 - Sinais recuperados no tempo. Filtro de 2ª ordem e frequência de corte de 100 Hz	54
Figura 43 - Sinais recuperados no tempo. Filtro de 6ª ordem e frequência de corte de 80 Hz	54
Figura 44 - RNA convencional para classificação de falta. A RNA recebe os dados de todos os	
cenários de falta	55
Figura 45 - (a) RNAs modulares para localizar falta; (b) RNAs modulares para determinar resistê	ncias
de falta. Cada RNA recebe os dados de acordo com o tipo de falta	56
Figura 46 - Pré-processamento de dados: inserção processo de sincronização	57
Figura 47 - Estrutura do algoritmo para processamento de dados: Inserção processo sincronização	ão.59
Figura 48 - a) Sinal simulado (ATP); b) Sinal real; c) Sobreposição dos sinais	63
Figura 49 - a) Sinal simulado (ATP); b) Sinal real; c) Sobreposição dos sinais	63
Figura 50 - Energia coeficiente detalhe: Sinais de corrente das fase A, B e C	64
Figura 51 - Energia coeficiente detalhe: Sinais de tensão das fases A, B e C	65
Figura 52 - Módulos Fasoriais sinais de tensão: Fases A, B e C	67
Figura 53 - Módulos Fasoriais sinais de corrente: Fases A, B e C. Comportamento semelhante	
principalmente no período de início da falta	67

## Lista de Tabelas

Tabela 1 - Topologias de redes neurais	37
Tabela 2 - Algoritmos de treinamento	38
Tabela 3 - Parâmetros sistema elétrico real	45
Tabela 4 - Fontes equivalentes: Valores estimados para terminais emissor <b>S</b> e receptor <b>R</b>	
considerando dados de um terminal	46
Tabela 5 - Conjunto de variáveis para gerar padrões de treinamento	47
Tabela 6 - Arquitetura das RNAs para classificar, localizar falta e determinar resistência de falta:	
algoritmo proposto 3	60
Tabela 7 - Classificação de faltas	61
Tabela 8 - Localização de falta e determinação da resistência de falta: algoritmo proposto 1	62
Tabela 9 - Sinais reais: algoritmo proposto 2	66
Tabela 10 - Localização de falta e determinação da resistência de falta: algoritmo proposto 3	68
Tabela 11 - Sinais reais: algoritmo proposto 3	69

### Lista de Abreviatura e Símbolos

a Fator de escala para a transformada wavelet

ATP Alternative Transient Program

b Fator de translação para a transformada wavelet

cA Coeficientes de aproximaçãocD Coeficientes de detalhe

CEMIG Companhia Energética de Minas Gerais

E Energia do coeficiente wavelet dB Família wavelet daubechies

ES Tensão da fonte no terminal emissor
ER Tensão da fonte no terminal receptor

IS Corrente no terminal emissor
IR Corrente no terminal receptor

MLP Multilayer Perceptron

NPC Número de Pontos por Ciclo

RNA Rede Neural Artificial
TW Transformada Wavelet

TWC Transformada Wavelet Contínua
TWD Transformada Wavelet Discreta
TWE Transformada Wavelet Estacionária

w Peso

φ Função escala ψ Função wavelet

VS Tensão no terminal emissor VR Tensão no terminal receptor

ZS1 Impedância da fonte no terminal emissor
ZR1 Impedância da fonte no terminal receptor

ZL1 Impedância da Linha

## SUMÁRIO

1	INTRODUÇÃO
	1.1 CONTEXTUALIZAÇÃO E RELEVÂNCIA
	1.2 OBJETIVO
	1.3 ORGANIZAÇÃO DO TEXTO
2	REVISÃO DA LITERATURA
	2.1 LOCALIZAÇÃO DE FALTAS
	2.1.1 ARTIFICIAL NEURAL NETWORK APPROACH TO SINGLE-ENDED FAULT LOCATOR FO
	TRANSMISSION LINES
	2.1.2 VOLTAGE AND CURRENT PATTERNS FOR FAULT LOCATION IN TRANSMISSION LINES
	2.1.3 DISCRETE WAVELET TRANSFORM AND BACK-PROPAGATION NEURAL NETWORKS ALGORITHM
	FOR FAULT LOCATION ON SINGLE-CIRCUIT TRANSMISSION LINE
	2.1.4 ARTIFICIAL NEURAL NETWORK APPROACH FOR LOCATING FAULTS IN POWER TRANSMISSION
	SYSTEM
	2.2 DETECÇÃO E CLASSIFICAÇÃO DE FALTAS
	2.2.1 NEURAL FAULT CLASSIFIER FOR TRANSMISSION LINE PROTECTION - A MODULAR APPROACH
	2.2.2 FAULT DETECTION AND CLASSIFICATION IN TRANSMISSION LINES BASED ON WAVELE
	TRANSFORM AND ANN
	2.2.3 TRANSMISSION LINE FAULT DETECTION AND CLASSIFICATION
	2.3 CLASSIFICAÇÃO E LOCALIZAÇÃO DE FALTAS
	2.3.1 FAULTS LOCATION IN TRANSMISSION LINES THROUGH NEURAL NETWORKS
	2.3.2 BEST ANN STRUCTURES FOR FAULT LOCATION IN SINGLE AND DOUBLE-CIRCUIT TRANSMISSION
	LINES
	2.3.3 A FEEDFORWARD ARTIFICIAL NEURAL NETWORK APPROACH TO FAULT CLASSIFICATION AND
	LOCATION ON A 132 KV TRANSMISSION LINE USING CURRENT SIGNALS ONLY
	2.4 DETECÇÃO, CLASSIFICAÇÃO E LOCALIZAÇÃO1
	2.4.1 WAVELET-BASED ANN APPROACH FOR TRANSMISSION LINE PROTECTION
	2.4.2 A HYBRID FRAMEWORK FOR FAULT DETECTION, CLASSIFICATION, AND LOCATION—PART
	CONCEPT, STRUCTURE, AND METHODOLOGY14
	2.5 CONSIDERAÇÕES FINAIS
3	TRANSFORMADA WAVELET E REDES NEURAIS ARTIFICIAIS
	3.1 TRANSFORMADA WAVELET

3.1.1	WA	VELETS	18
3.1.2	DEF	INIÇÃO: TRANSFORMADA WAVELET	20
3.1.3	TRA	NSFORMADA WAVELET CONTÍNUA (TWC)	21
3.2	1.3.1	Fator de Escala	22
3.2	1.3.2	Fator de Translação	23
3.1.4	TRA	NSFORMADA WAVELET DISCRETA (TWD)	24
3.1.5	DEC	OMPOSIÇÃO EM MÚLTIPLOS NÍVEIS (MULTIRESOLUÇÃO)	25
3.1.6	TRA	NSFORMADA WAVELET ESTACIONÁRIA (TWE)	27
3.1.7	TEO	REMA DE PARSEVAL	29
3.2 RED	ES NE	URAIS ARTIFICIAIS (RNAs)	30
3.2.1	NEU	IRÔNIO BIOLÓGICO	30
3.2.2	NEU	IRÔNIO ARTIFICIAL	32
3.2.3	ARC	QUITETURA DE REDES NEURAIS ARTIFICIAIS	33
3.2	2.3.1	Número de camadas	33
3.2	2.3.2	Número de Neurônios	35
3.2	2.3.3	Métodos de Aprendizagem	36
3.2.4	MU	LTILAYER PERCEPTRON (MLP) COM APRENDIZADO SUPERVISIONADO BACKPROPAGA	TION E
ALGO	RITM	O DE TREINAMENTO LEVENBERG-MARQUARDT	36
3.3 CON	ISIDE	RAÇÕES FINAIS	38
		A: ALGORITMOS PARA DETECTAR, CLASSIFICAR, LOCALIZAR FALTAS E DETER	
		ALTA	
		GIA DO SISTEMA ELÉTRICO	
		CESSAMENTO	
		ECTOR DE FALTA	
		MAÇÃO FASORIAL DAS FONTES EQUIVALENTES	
4.2.3	SIM	ULAÇÃO: GERANDO BANCO DE DADOS	47
4.3 ALG	ORIT	MO PROPOSTO 1: ENERGIA DOS COEFICIENTES DETALHE DE WAVELET DE CORRENTE E T	ΓENSÃΟ
PARA TRE	INAN	NENTO E TESTE DE RNAS. DADOS DE UM TERMINAL	47
4.3.1	PRC	CESSAMENTO DE DADOS:	48
4.3.2	APL	ICAÇÃO DE RNAs PARA CLASSIFICAR, LOCALIZAR FALTA E DETERMINAR RESISTÊNC	CIAS DE
FALTA	٠		49
4.3	3.2.1	RNAS Modulares Para Classificar Faltas	50
4.3	3.2.2	RNAS modulares para localizar falta e RNAS modulares para determinar resistências de falta	50
4.4 ALG	ORIT	MO PROPOSTO 2: MÓDULOS FASORIAIS DE CORRENTE E TENSÃO PARA TREINAMENTO	E TESTE
DE RNAs.	DAD	OS DE UM TERMINAL	52
4.4.1	PRC	CESSAMENTO DE DADOS:	52

	4.5 ALGORITMO PROPOSTO 3: MÓDULOS FASORIAIS DE CORRENTE PARA TREINAMENTO E TESTE D	DE RNAs.
	DADOS DE DOIS TERMINAIS.	56
	4.5.1 SINCRONIZAÇÃO DOS DADOS	57
	4.5.1.1 Pré-processamento:	57
	4.5.1.2 Processamento de Dados:	59
	4.5.2 RNAS PARA CLASSIFICAR, LOCALIZAR FALTA E DETERMINAR RESISTÊNCIAS DE FALTA	59
	4.6 CONSIDERAÇÕES FINAIS	60
5	RESULTADOS	61
	5.1 RESULTADOS DO ALGORITMO PROPOSTO 1	61
	5.1.1 SINAIS SIMULADOS	61
	5.1.2 SINAIS REAIS E DISCUSSÕES	62
	5.2 RESULTADOS DO ALGORITMO PROPOSTO 2	65
	5.2.1 SINAIS SIMULADOS	65
	5.2.2 SINAIS REAIS E DISCUSSÕES	66
	5.3 RESULTADOS DO ALGORITMO PROPOSTO 3	68
	5.3.1 SINAIS SIMULADOS E SINAIS REAIS	68
	5.4 CONSIDERAÇÕES FINAIS	69
6	CONCLUSÃO	71
J	6.1 PROPOSTAS PARA TRABALHOS FUTUROS	
	0.1 THOI OSTAGE ANA TRADALTIOST OTORIOS	73
7	BIBLIOGRAFIA	74

## 1 INTRODUÇÃO

## 1.1 CONTEXTUALIZAÇÃO E RELEVÂNCIA

Os Sistemas Elétricos de Potência (SEP) são complexos, possuindo elementos interligados uns aos outros, resultando em uma grande rede elétrica, que pode conter milhares de barramentos e equipamentos, tais como geradores síncronos, transformadores, autotransformadores, cargas e linhas de transmissão.

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

Como podem ter diversas origens, as faltas em linha de transmissão são definidas como fenômenos aleatórios e com características próprias, como: instante que se iniciou, resistência de falta, tipo de falta (fase-terra, bifásico, bifásico-terra e trifásico) e local onde ocorreu. Dentro dessas características, a determinação, principalmente, do local onde ocorreu a falta é de fundamental importância, pois, evita a inspeção completa da linha na procura do defeito, possibilitando um rápido restabelecimento do fornecimento de energia. Esse é um interesse tanto das concessionárias de energia, que evitam pagar multas por longos períodos de desligamento, e também, do mercado consumidor industrial e residencial que solicita fornecimento de energia de qualidade sem interrupções.

#### 1.2 OBJETIVO

Diante disso, é objetivo desse trabalho desenvolver algoritmos computacionais que possam ser integrados ao sistema de proteção, capazes de detectar, classificar e localizar faltas e determinar resistências de falta em linhas de transmissão. Esses algoritmos são aplicáveis à sistemas elétricos modelados por fontes equivalentes no terminal emissor e receptor, interligadas por uma linha de

transmissão. É nesse cenário que os algoritmos devem detectar as faltas, classificalas quanto ao tipo (fase-terra, trifásica, bifásica, bifásica-terra), localiza-las, informando em quilômetros onde a falta ocorreu e determinar a resistência, em ohms, associada à falta.

Dessa forma, são desenvolvidos três algoritmos, que se baseiam em métodos matemáticos para processamentos de sinais (filtragem, interpolação, transformada wavelet, erros mínimos quadrados e energia de Parseval) e inteligência computacional por meio de Redes Neurais Artificiais (RNAs). Os algoritmos 1 e 2 utilizam dados processados, obtidos a partir das medições realizadas em apenas um terminal (CHEN e MAUN, 2000; AMORIM e HUAIS, 2004; SOUZA, SILVA e A.C.S.LIMA, 2007; KALAM, JAMIL e ANSARI, 2010 e LOUT e AGGARWAL, 2012), enquanto que, o algoritmo 3 utiliza dados processados obtidos das medições realizadas nos dois terminais (NGAOPITAKKUL e POTHISARN, 2009 e TEKLIC, FILIPOVIC-GRCIC e I.PAVICIC, july, 2013). As implementações foram realizadas no software Matlab e os diversos cenários de falta necessários para treinamentos e testes das RNAs foram gerados no software Alternative Transient Program (ATP)

## 1.3 ORGANIZAÇÃO DO TEXTO

O estudo realizado neste trabalho está organizado em seis capítulos.

O presente capítulo apresenta uma introdução geral e define como objetivos desse trabalho, desenvolver algoritmos para detecção, classificação e localização de faltas, e determinação de resistências de faltas em linhas de transmissão.

No capítulo 2, está apresentada uma revisão da literatura, cujos textos focam em temas centrais como detecção, classificação e localização de faltas.

No capítulo 3, ocorre descrição de duas ferramentas utilizadas de forma crescente em algoritmos da área, denominadas transformada wavelet e redes neurais artificiais.

No capítulo 4, são apresentados os três algoritmos, de forma detalhada, bem como a topologia do sistema elétrico em que esses algoritmos podem ser aplicados.

No capítulo 5, são apresentados os resultados obtidos por cada algoritmo.

Por fim, o capítulo 6 é destinado para a conclusão, em que é abordada a análise geral do trabalho desenvolvido, assim como propostas de trabalhos futuros.

### 2 REVISÃO DA LITERATURA

Novos algoritmos para análise de faltas em linhas de transmissão veem sendo estudados há vários anos, por pesquisadores do mundo inteiro, buscando melhores resultados nos métodos já desenvolvidos.

Diante disso, é objetivo deste capítulo apresentar uma revisão da literatura, em que os artigos escolhidos tratam de detectar, classificar e localizar faltas, e determinar resistências de faltas em linhas de transmissão. Para realizar tais funções, os artigos utilizam diferentes métodos, dentre os quais destacam-se transformada wavelet e inteligência computacional por meio de redes neurais artificiais.

## 2.1 LOCALIZAÇÃO DE FALTAS

# 2.1.1 ARTIFICIAL NEURAL NETWORK APPROACH TO SINGLE-ENDED FAULT LOCATOR FOR TRANSMISSION LINES

Em 2000, CHEN e MAUN descrevem a aplicação de um algoritmo baseado em Redes Neurais Artificiais (RNAs) para localizar faltas e determinar resistências de falta em linhas de transmissão, usando dados de tensão e corrente de um único terminal. Nesse trabalho as linhas de transmissão são submetidas somente a falta fase-terra.

As redes neurais são do tipo feedforward com três camadas, sendo a função de ativação tangente hiperbólica para as camadas ocultas e linear para camada de saída. As RNAs utilizam método de aprendizagem supervisionado backpropagation e algoritmo de treinamento de Levenberg-Marquardt. Como entrada para rede neural, esse método seleciona fasores de tensão e corrente de todas as fases dos circuitos pré-falta e superposto. As saídas da rede neural são a posição da falta e resistência de falta.

Em uma primeira análise, as RNAs são treinadas e testadas considerando as impedâncias da fonte do terminal remoto como forte, média ou fraca, enquanto que a impedância da fonte do terminal emissor é sempre definida como fraca.

Para cada uma das impedâncias da fonte do terminal remoto (fraca, média,

forte), foram aplicados nas RNAs 540 treinamentos e 4319 testes. Os resultados mostraram que as RNAs podem estimar a posição da falta com menos de 1% de erro, e os erros da resistência de falta são menores do que 3%.

Numa segunda análise, a impedância da fonte remota é submetida a grandes variações. Assim, foram realizados 1080 treinamentos e 3000 testes nas RNAs. Os resultados mostraram que as RNAs foram capazes de se adaptarem as novas condições, localizando a posição da falta com erro menor que 3,5%.

Os diferentes cenários de falta, para testes e treinamentos, consideraram diferentes condições de operação do sistema como carga pré-falta, diferentes resistências de falta e locais de falta.

Com base nos resultados apresentados verificou-se que o método é preciso. Além disso, esse método converge com alta velocidade, o que é ideal para situações práticas (desejável que a localização da falta ocorra em tempo real).

## 2.1.2 VOLTAGE AND CURRENT PATTERNS FOR FAULT LOCATION IN TRANSMISSION LINES

Em 2007 SOUZA, SILVA e A.C.S.LIMA utilizam redes neurais para mapear a relação entre sinais elétricos e locais de defeitos em linhas de transmissão.

O sistema analisado é formado por uma linha de transmissão de 300 km de comprimento, com uma fonte de tensão de 400kV, com medições de tensão e corrente realizadas em único terminal. A fim de construir um conjunto de dados para treinamentos e testes das redes neurais, as seguintes condições foram simuladas usando o software ATP: locais de falta variando de 20 km até 270 km, com incremento de 50 km; resistência de falta variando aleatoriamente entre 1 e 50  $\Omega$ ; cargas de 150 MVA e 250 MVA por fase (equilibrado); fator de potência de 0,85 e 0,95; ângulo de incidência da falta de 0°, 90°, 180° e 270°; e apenas falta fase-terra, por ser o tipo mais frequente.

Neste artigo, grande destaque é dado à parte de processamento de sinais e do seu impacto à localização de faltas. Assim, os sinais de tensões e correntes, antes de serem enviados aos módulos de localização de falta, passam por três formas diferentes de processamento de sinais. O primeiro método extrai as informações dos sinais de tensão e corrente com base na transformada de Fourier

considerando os dados de regime transitório. O segundo método também considera os dados de regime transitório e extrai as informações de tensão e corrente com base na transformada wavelet e, por fim, o terceiro método considera as informações de tensão e corrente extraídos com base na transformada de Fourier registrados no primeiro ciclo do período pré-falta (regime permanente) e no primeiro ciclo do período de falta (regime transitório).

Para localização de faltas, foram programadas 3 redes neurais no programa computacional Matlab através do Toolbox Neural Network, sendo desenvolvidas com base na topologia multilayer perceptron (MLP), método de aprendizagem supervisionado backpropagation e algoritmo de treinamento Levenberg-Marquardt. Outras 3 redes neurais foram desenvolvidas com base na teoria de Máquina Vetor Suporte (MVS).

Os resultados mostram que as redes neurais do tipo MLP são mais precisas do que a topologias MVS para localização de falta. Mesmo assim, cabe salientar que os erros obtidos pelas redes neurais MVS são pequenos.

# 2.1.3 DISCRETE WAVELET TRANSFORM AND BACK-PROPAGATION NEURAL NETWORKS ALGORITHM FOR FAULT LOCATION ON SINGLE-CIRCUIT TRANSMISSION LINE

Em 2008, NGAOPITAKKUL e POTHISARN, propõem uma técnica, usando Transformada Discreta de Wavelet (TDW) e redes neurais artificiais para localização de falta em linhas de transmissão de circuitos simples. As RNAs são do tipo feedforward, com método de aprendizagem backpropagation, e algoritmo de treinamento Levenberg- Marquardt.

O sistema elétrico em estudo é baseado no sistema de transmissão da Thailândia e é composto por uma linha de transmissão de 325 km e nível de tensão de 500 kV. Foram realizadas diferentes simulações de falta usando o ATP/EMTP, variando os seguintes parâmetros: tipos de falta (fase-terra, bifásico, bifásico-terra e trifásico.); locais de falta variando de 10% a 90% do comprimento da linha com incremento de 10%; ângulo de incidência da onda de tensão variando de 0° a 330° com incremento de 30°; e resistência de falta com valor fixo de 10 Ω.

Os sinais de tensão e corrente obtidos nas simulações eram importados para

o MATLAB. Através da matriz de Transformada de Clarke calcularam-se correntes e tensões de sequência positiva e zero. Os sinais de corrente e tensão de sequência positiva são aplicados ao pacote wavelet toolboox do Matlab e é realizado o processo de detecção de falta.

Para localização de falta são estudadas duas situações: A primeira situação considera os coeficientes de pico das correntes de sequência positiva, obtidos pela transformada discreta de wavelet. Esses coeficientes são os mesmos encontrados no processo de detecção de falta e são usados para treinar as redes neurais. A arquitetura para essa situação é composta de dois neurônios de entradas (coeficientes de pico das correntes de sequência positiva dos terminais emissor e receptor), duas camadas ocultas (dois e seis neurônios respectivamente) e um neurônio de saída (corresponde ao ponto de defeito medido a partir do barramento emissor). Já a segunda situação considera os coeficientes de pico obtido pela transformada discreta de wavelet, calculado em 1/4 de ciclo, dos sinais de corrente e tensão pós falta das fases A, B, C e sequencia zero. Esses coeficientes são usados para treinar as redes neurais. A arquitetura para essa situação é composta de oito neurônios de entradas (coeficientes de pico dos sinais de corrente e tensão pós falta das fases A, B, C e sequência zero), duas camadas ocultas (seis e dez neurônios respectivamente) e um neurônio de saída (corresponde ao ponto de defeito medido a partir do barramento emissor).

Para os testes realizados, os resultados mostram que o processo de detecção de falta é preciso. Além disso, o processo de localização de falta é altamente satisfatório para todos os parâmetros variados (ângulo de incidência da onda de falta, diferentes pontos de falta e tipos de falta).

# 2.1.4 ARTIFICIAL NEURAL NETWORK APPROACH FOR LOCATING FAULTS IN POWER TRANSMISSION SYSTEM

Em 2013,TEKLIC, FILIPOVIC-GRCIC e I.PAVICIC descrevem a aplicação de Redes Neurais Artificiais (RNAs) para localizar faltas e determinar resistência de falta em linhas de transmissão. A linha de transmissão em estudo apresenta nível de tensão de 110 kV e comprimento de 60 km.

Para avaliação do algoritmo desenvolvido, essa linha de transmissão foi

modelada, considerando a teoria de parâmetros distribuídos, no software EMTP-RV. A fim de obter os valores de correntes e tensões trifásicas nos dois terminais, necessários para treinamentos e testes das RNA, um conjunto de dados foi gerado por meio de várias simulações no EMTP-RV, considerando diferentes locais de falta (0 km, 20 km, 30 km, 40 km, 50 km e 60 km), condições de fluxo de carga (energia ativa entre 0 e 100 MW e energia reativa entre 10 e 30 MVA) e valores de resistência de falta (0  $\Omega$ , 10  $\Omega$ , 25  $\Omega$  e 50  $\Omega$ ).

Os dados obtidos via EMTP-RV, são enviados ao software Matlab, que utiliza o Toolbox Neural Network para treinar a RNA. O algoritmo tinha RNA Feedforward com método de aprendizagem supervisionado backpropagation e algoritmo de treinamento do gradiente descendente. A RNA foi formada com uma camada de entrada, duas camadas ocultas e uma camada de saída (24-3-2-2), sendo que, a primeira camada tinha os módulos e ângulos dos sinais de corrente e tensão medidos nos dois terminais e a camada de saída apontavam o local da falta e o valor da resistência de falta.

Os resultados mostram, na maioria das situações, que o erro percentual para localização de falta e estimativa da resistência de falta foi menor que 10 %. O Valor médio do erro percentual para localização de faltas foi igual a 6,6 %. Já o valor médio do erro percentual para resistência de falta foi igual a 4,3 %. De forma geral, os resultados mostram que esta abordagem fornece a localização de faltas e estima resistências de falta para diferentes condições de operação do sistema de energia, mesmo utilizando uma arquitetura simples de RNA.

## 2.2 DETECÇÃO E CLASSIFICAÇÃO DE FALTAS

# 2.2.1 NEURAL FAULT CLASSIFIER FOR TRANSMISSION LINE PROTECTION - A MODULAR APPROACH

Em 2006, PRADHAN, MOHANTY e ROUTRAY, introduzem o conceito de rede neural modular para classificação de faltas em linhas de transmissão.

O novo conceito diz que a classificação da falta deve ser realizada por um conjunto de módulos de redes neurais (três módulos para os sinais de tensão e corrente das fases A, B e C e um módulo para os sinais de tensão e corrente que

envolvem a terra). Posteriormente, a solução global é obtida combinando-se o resultado de cada módulo.

As redes neurais foram desenvolvidas com topologia PNN (Probabilistic Neural Network), pois apresentam grande velocidade de treinamento com elevada precisão. O software Matlab foi utilizado como simulador dessas redes neurais.

É estudado um sistema de linha de transmissão trifásico, com nível de tensão de 230 kV, frequência de 50 Hz, comprimento de 200 km e com duas fontes de 50 GVA de potência cada. O conjunto de dados de treinamento e testes para as simulações consideram uma variação na frequência da rede elétrica na faixa de 48 Hz a 52 Hz, condição pré-falta, ângulo de incidência da falta, resistência de falta, localização e tipos de falta.

Os resultados mostram que a técnica de rede neural modular para classificar faltas em linhas de transmissão apresenta vantagens como, maior precisão nos resultados encontrados e menor tempo de treinamento das RNAs.

# 2.2.2 FAULT DETECTION AND CLASSIFICATION IN TRANSMISSION LINES BASED ON WAVELET TRANSFORM AND ANN

Em 2006, SILVA, SOUSA e BRITO, propõem um novo método, para detecção e classificação de faltas em linhas de transmissão.

O método proposto é formado por dois módulos. O primeiro é denominado módulo de detecção. A partir de registros oscilográficos, esse módulo normaliza as amostras de tensão e corrente antes de calcular a transformada discreta wavelet. A partir de um conjunto de regras, baseados na análise das formas de onda de corrente no domínio do tempo e na energia do coeficiente de wavelet da corrente, o módulo realiza ou não a detecção da falta. Se detectada a falta, os dados registrados entre o início e fim da falta (tempo de eliminação da falta), são transferidos para o módulo de classificação. Na situação de não falta, os dados não são transferidos.

Assim, o segundo módulo (módulo de classificação), é responsável por indicar se as fases (A, B e C) e a terra estão envolvidas na falta. Para isso, esse módulo utiliza de uma Rede Neural Artificial (RNA) com topologia MultiLayer Perceptron (MLP), que foi implementada em linguagem C++. Os padrões de entrada da RNA

são execultados por janelas de amostras dentro do tempo de eliminação da falta, juntando-se cinco amostras consecutivas de tensão e corrente (fases e componente de sequência zero) em um único padrão de entrada. O conjunto de dados necessário para treinamento da RNA foi obtido através de simulações no software ATP. As simulações consideravam como parâmetros variáveis os diferentes tipos de falta, ângulos de incidência de falta, locais e resistências de falta. As simulações foram realizadas com os dados de uma linha de transmissão real, pertencente à Companhia Hidroelétrica de São Francisco (CHESF), localizada na região nordeste do Brasil, cuja tensão nominal é de 230 kV e comprimento de 188 km.

Os resultados mostram que o método proposto é eficiente. Foram simulados 720 tipos de falta através do software ATP, no qual verificou-se 100% de sucesso para os módulos de detecção e classificação. Além de faltas simuladas, foram obtidos a partir do banco de dados da CHESF, registros reais que consideram linhas de transmissão com diferentes tensões nominais e geometrias, submetidas a várias situações de falta, afundamentos de tensão, transitórios e operações de manutenção. Para esses registros, o módulo de detecção de faltas era quase sempre bem-sucedido, exceto para alguns afundamentos de tensão. Já o módulo de classificação de falta era sempre correto, exceto para uma falta AT, em uma linha de transmissão de 230 kV, que foi classificada como ABT.

### 2.2.3 TRANSMISSION LINE FAULT DETECTION AND CLASSIFICATION

Em 2011, PANIGRAHI e MAHESHWARI, apresentam um esquema de proteção denominado Classificador de Faltas, baseado na Transformada Discreta de Wavelet (TDW) e Máquinas Vetor Suporte (MVS), para detectar e classificar diferentes tipos de falta em linhas de transmissão.

Para avaliação do esquema de proteção proposto, um sistema de energia com nível de tensão 400 kV, operando na frequência de 50 Hz, com duas fontes e extensão de 128 km de extensão é simulado uma série de vezes para gerar um conjunto de dados necessários para treinamentos e testes dos SVM. Essas simulações foram realizadas empregando PSCAD / EMTDC, variando os seguintes parâmetros: tipo de falta, local de falta, ângulo de incidência de falta e variação do ângulo de carga.

Então, os dados gerados são aplicados ao esquema proposto que inicialmente decompõe os sinais medidos (tensões e correntes trifásicas) em coeficientes aproximação (A1) e coeficientes de detalhe (D1) utilizando TDW. A TDW é aplicada em tempo real e utiliza wavelet mãe db4. Os coeficientes de detalhes extraídos pela TDW apresentam energia transitória muito maior no período de falta em relação ao período pré-falta. Através dessa comparação o algoritmo realiza a detecção da falta. Em seguida, estes valores de energia transitória de corrente são exportados para treinamento da SVM. São três SVM (fases A, B e C) e a saída de cada SVM indica se a fase relacionada está envolvida ou não na falta. Cabe salientar que o conjunto de parâmetros escolhidos para os SVM são: função gaussiana de Kemel de base radial (RBF), C=10 e σ =20. Já o envolvimento da terra na falta é descoberta através da detecção da componente de sequência zero da corrente.

Os resultados mostram que o esquema proposto é um classificador robusto para relés digitais de proteção, pois, além de rápido, os valores obtidos apresentam entre 90 e 100% de precisão.

## 2.3 CLASSIFICAÇÃO E LOCALIZAÇÃO DE FALTAS

# 2.3.1 FAULTS LOCATION IN TRANSMISSION LINES THROUGH NEURAL NETWORKS

Em 2004, AMORIM e HUAIS, verificam a viabilidade de aplicação de redes neurais artificiais para classificação e localização de falta em linhas de transmissão usando sinais de tensões e correntes registrados em um terminal da linha. Um modelo de RNA foi utilizado para classificação da falta e outros quatro foram utilizados para localização, sendo uma RNA para cada tipo de falta: fase-terra, bifásico, bifásico-terra e trifásico.

Para treinamento das RNAs os dados de tensão e corrente foram registrados através do relé numérico modelo P442 da Alstom. Já para implementação dos módulos de classificação e localização de faltas, as RNAs foram desenvolvidas com topologia MultiLayer Perceptron com método de aprendizagem supervisionado backpropagation. Diversas arquiteturas de redes neurais foram implementadas

através do toolbox Rede Neurais do software MATLAB.

Assim, foram realizados diferentes testes nos módulos de classificação e localização de faltas. O módulo de classificação obteve excelente capacidade de identificar a ocorrência de uma falta nos testes realizados. Já o módulo de localização de falta também apresentou ótimos resultados, localizando o ponto de ocorrência de defeito com erros menores que 2%.

# 2.3.2 BEST ANN STRUCTURES FOR FAULT LOCATION IN SINGLE AND DOUBLE-CIRCUIT TRANSMISSION LINES

Em 2005, GRACIA, MAZÓN e ZAMORA, mostram em seu artigo diferentes estruturas de Redes Neurais Artificiais (RNAs) que podem ser aplicadas para classificação e localização de faltas, e determinar resistências de falta em linhas de transmissão aéreas de dois terminais, com circuitos simples e duplos.

Assim, a classificação da falta era obtida por uma RNA que determinava o tipo de falta, a partir dos valores de tensão e corrente, pré-falta e pós-falta, medidos em um dos terminais da linha. Já a localização das faltas permitia obter a posição do defeito a partir dos mesmos valores usados no processo de classificação de falta, aplicados em outra RNA. Os dados para treinamento e testes das RNAs antes de serem utilizados nos processos de classificação e localização de faltas eram filtrados através da técnica Transformada Rápida de Fourier (TRF)

Para o processo de classificação de falta duas topologias de RNAs foram analisadas, MultiLayer Perceptron (MLP) e Learning Vector Quantization (LVQ). A topologia MLP apresentou menores erros e um menor tempo de treinamento. Portanto, essa estrutura foi selecionada e treinada de forma supervisionada pelo algoritmo de backpropagation com otimização de Levenberg-Marquardt.

Os testes envolveram seis linhas de transmissão, sendo 3 de circuitos simples e 3 de circuitos duplos. Os resultados obtidos não apresentaram erros no processo de classificação de faltas para as linhas de transmissão de circuitos simples. Já para as linhas de transmissão de circuito duplo os erros foram menores que 1% no processo de classificação de faltas.

Da mesma forma, para o processo de localização de faltas e determinação da resistência de falta, foram utilizadas RNAs com topologia MLP, treinadas de

forma supervisionada pelo algoritmo de backpropagation com otimização de Levenberg-Marquardt, sendo que, para cada tipo de falta (fase-terra, bifásico, bifásico-terra e trifásico) foi desenvolvida uma Rede Neural Artificial.

Os testes também envolveram seis linhas de transmissão, sendo 3 de circuitos simples e 3 de circuitos duplos e os resultados obtidos apresentaram erros médios entre 0,015% e 0,4% para localização de falta. Já para determinar a resistência de falta, verificou que os erros variaram entre 0,017% e 0,46%.

# 2.3.3 A FEEDFORWARD ARTIFICIAL NEURAL NETWORK APPROACH TO FAULT CLASSIFICATION AND LOCATION ON A 132 KV TRANSMISSION LINE USING CURRENT SIGNALS ONLY

Em 2012,LOUT e AGGARWAL, desenvolvem um algoritmo rápido, confiável e preciso para classificação e localização de faltas em linhas de transmissão, a partir de medições de corrente em apenas um terminal. Para isso, o algoritmo proposto é baseado em Redes Neurais Artificiais (RNAs) com topologia feedforward com aprendizagem supervisionada backpropagation e algoritmo de treinamento Levenberg-Marquardt.

De forma simplificada, o sistema em estudo possui as seguintes características: Linha de transmissão 132 kV, frequência de operação 50 Hz, comprimento de 100 km, alimentada em dois terminais por fontes de tensão com capacidades de 550 MVA e 450 MVA. Para treinamento das redes neurais, o sistema mencionado foi simulado através do software ATP, e um conjunto de dados foi gerado. Esses dados, antes de serem enviados aos processos de classificação e localização de faltas, eram processados com o auxílio da Transformada de Fourier (TF).

Os resultados foram apresentados em duas etapas considerando uma falta bifásico-terra e resistência de falta de 2 Ω. Em uma primeira etapa, os resultados mostraram que a RNA1 (12-24-4) para classificação de faltas é precisa e robusta, uma vez que alcançam os valores esperados e não são afetadas por mudanças de ângulos de incidência de falta (45°). Já para localização, as RNAs (12-24-1) desenvolvidas, uma para cada tipo de falta (RNA2: fase-terra, RNA3: bifásico, RNA4: bifásico-terra e RNA5: trifásico), obtiveram resultados precisos, com erros

menores que 1% quando são considerados ângulos de incidência de falta de 0° e 90°. No entanto, quando o ângulo de incidência de falta é modificado para 45°, verifica-se que as distâncias estimadas apresentavam diferenças de até 3 quilômetros do ponto de ocorrência da falta. Esta imprecisão pode ser explicada pelo fato de que as RNAs utilizadas para localização de faltas não foram treinadas com vários ângulos de incidência de falta (valores entre 0° e 90°).

Posteriormente, a fim de avaliar melhor o algoritmo desenvolvido, as RNAs foram testadas considerando as seguintes variações: impedância de falta (4  $\Omega$ , 6  $\Omega$  e 10  $\Omega$ ); comprimento da linha (± 5% do comprimento da linha); e capacidade das fontes. Os resultados mostraram que a RNA para classificação de faltas é imune as variações citadas e as RNAs para localização de faltas apresentam erros maiores quando são submetidas a essas mesmas variações.

## 2.4 DETECÇÃO, CLASSIFICAÇÃO E LOCALIZAÇÃO

# 2.4.1 WAVELET-BASED ANN APPROACH FOR TRANSMISSION LINE PROTECTION

Em 2003, MARTÍN e AGUADO, desenvolvem um módulo de préprocessamento de sinais baseado em Transformada Discreta de Wavelet (TDW), que combinado com Redes Neurais Artificiais (RNAs) são utilizados para detectar, classificar e localizar faltas em linhas de transmissão.

O sistema em estudo foi simulado no software ATP-EMTP e é composto por dois geradores e três linhas de transmissão em série (modelo parâmetro distribuído). Várias simulações foram realizadas incluindo diferentes pontos de falta (20, 40, 60, 80 e 90 km), várias resistência de falta (0, 10, 20, 30 e 40  $\Omega$ ) e diferentes ângulos de incidência da falta (0, 20, 40 e 60°).

A TDW decompõe cada sinal transitório de tensão e corrente das três fases, em duas novas ondas denominadas detalhes (sinais de alta frequência) e aproximações (sinais de baixa frequência), tendo cada onda 16 pontos por ciclo. Então, as RNAs são alimentadas com os dados denominados detalhes (três correntes e três tensões), extraídos da janela de 1/4 de ciclo, totalizando 24 dados de entrada para cada RNA.

A RNA para detecção tem um neurônio de saída que indica a existência de uma falta. Já a RNA para localização tem um neurônio de saída que indica se a falta ocorreu na zona de proteção do relé. Por fim, a RNA para classificação tem quatro neurônios de saída, que indicam se as fases (A, B, C) e neutro estão envolvidos no evento de falta. Cabe salientar que as RNAs foram treinadas de forma supervisionada pelo algoritmo backpropagation.

Em relação ao desempenho, as RNAs para detecção apresentaram um sucesso de 100% e as RNAs destinadas à localização e classificação apresentaram erros inferiores a 1%.

# 2.4.2 A HYBRID FRAMEWORK FOR FAULT DETECTION, CLASSIFICATION, AND LOCATION - PART I: CONCEPT, STRUCTURE AND METHODOLOGY

Em 2011, JIANG, CHUANG, et al, propõem uma nova metodologia para desenvolver um sistema de proteção capaz de, rapidamente, detectar, classificar e localizar faltas em linhas de transmissão. O sistema proposto pode analisar faltas ocorridas entre dois barramentos que são equipados com unidades de medição de correntes e tensões trifásicas.

A arquitetura desse sistema de proteção é baseada em módulos de detecção, classificação e localização de faltas. Assim, o módulo de detecção indica a presença de falta em tempo real no sistema de energia. Esse fenômeno é facilmente detectado pelo cálculo das componentes de sequência negativa dos sinais de corrente e tensão e com o auxílio de algumas funções matemáticas (triangulares e Heaviside). Já o módulo de classificação, iniciado depois de detectada a falta, realiza a medição de tensões e correntes trifásicas sob a condição de pós falta ao longo de um ciclo. Esses sinais são analisados usando transformada wavelet, Análise de Componentes Principais e Máquina de Vetor Suporte e então o módulo indica o tipo de falta ocorrido (fase-terra, bifásico, bifásica terra, trifásico, trifásica terra e alta impedância). Por fim, após classificada a falta o módulo de localização de faltas é iniciado e determina o ponto de ocorrência da falta. Para isso, esse módulo utiliza um conjunto de Redes Neurais de Estruturas Adaptativas (RNEA), que possuem técnicas de treinamento "runtime", o que possibilita melhor desempenho. Para treinamento dessas RNEA foram obtidas amostras a partir de

sistemas reais e a partir de simulações.

O desempenho do sistema de proteção proposto foi avaliado através de simulações realizadas em computadores. Os resultados mostram que para uma linha de transmissão de dois terminais, o sistema de proteção apresentou 99,9% de precisão na detecção de falta, 99,84% e 99,9% na sensibilidade e especificação da classificação da falta e erro médio de 0,54% na localização da falta. Já para um segundo sistema (IEEE 14 barramentos), o sistema de proteção apresentou 99,9% de precisão na detecção de falta, 99,73% e 99,9% na sensibilidade e especificação da classificação da falta e erro médio de 0,61% na localização da falta. Além de preciso, conforme mostrado, o sistema de proteção possui tempo de resposta global rápido (aproximadamente 1,28 ciclos (0,021 s), que é significativamente menor que o tempo de eliminação de falta que está entre 6 e 10 ciclos).

## 2.5 CONSIDERAÇÕES FINAIS

Neste capítulo foi apresentada uma revisão da literatura, em que se procurou descrever diversos estudos que relatam sobre detecção, classificação e localização de faltas e determinação das resistências de faltas em linhas de transmissão.

Verificou-se que a transformada wavelet discreta em associação com o teorema de Parseval, tem sido um método matemático bastante utilizado em processos de detecção de faltas.

Já nos processos para classificação, localização e determinação das resistências de faltas, os estudos apontam para o uso preferencial de inteligência computacional utilizando redes neurais artificiais. Dentro das diversas topologias existentes, sobressaíram as RNAs conhecidas com Mulitlayer Perceptron, por capacidade de se adaptarem a problemas de reconhecimento de padrões e estimação de valores.

Ainda a partir dos artigos apresentados, verificou-se que a classificação de falta é uma tarefa realizada com sucesso por meio de RNAs, sendo que, destaca-se o artigo intitulado Neural Fault Classifier for Transmission Line Protection - A Modular Approach (item 2.2.1), por utilizar redes neurais modulares, que são estruturas menores de RNAs que possibilitam maior precisão dos resultados e exigem menor tempo de treinamento. Ficou evidente também que, as RNAs conseguem identificar

os locais de faltas apresentando resultados com erros pequenos. Nesse contexto, destacam-se os artigos intitulados Artificial Neural Network Approach to Single-Ended Fault Locator for Transmission Lines (item 2.1.1) e Faults Location in Transmission Lines through Neural Networks (item 2.3.1), que localizam a posição de falta com erros menores que 3,5% e 2%, respectivamente. Esses são bons resultados, considerando que há medições em apenas um dos terminais da linha de transmissão.

Além disso, uma característica comum aos artigos apresentados se deve a utilização de apenas sinais simulados nos processos de treinamentos e testes das RNAs. Esse é um fator que dificulta o uso das RNAs em situações práticas, pois como não existem vários registros de faltas reais, são geradas simulações que tentam reproduzir a realidade para treinamento das RNAs, o que pode comprometer os resultados diante de teste reais. Nesse sentido, novos estudos devem explorar o emprego de RNAs em situações práticas, buscando obter resultados confiáveis diante de testes reais mesmo após as RNAs serem treinadas com dados simulados. Todavia, os artigos apresentados possuem méritos, principalmente no que refere aos métodos de processamentos de sinais utilizados para tratamento dos sinais de tensão e corrente, e também com relação às próprias RNAs, mostrando que as RNAs são ferramentas confiáveis e apresentam bons resultados diante dos métodos já desenvolvidos.

### 3 TRANSFORMADA WAVELET E REDES NEURAIS ARTIFICIAIS

Conforme revisão da literatura apresentada no capítulo anterior, a Transformada Wavelet (TW) é uma ferramenta utilizada de forma crescente por pesquisadores, para extrair características de sinais registrados em linhas de transmissão. A sua utilização é notória tanto em processos de detecção de falta como para tratamento de sinais. Da mesma forma, as Redes Neurais Artificiais (RNAs) também vem sendo utilizadas frequentemente, em processos para classificação e localização de faltas, e determinação resistências de faltas em linhas de transmissão.

Como as metodologias desenvolvidas neste trabalho também adotam TW e RNAs nos processos de detecção, classificação e localização de faltas, e determinação resistência de falta, é objetivo deste capítulo uma apresentação a respeito dessas ferramentas.

Diante disso, este capítulo é dividido em duas partes, denominadas, transformada wavelet e redes neurais artificiais. São abordados alguns conceitos básicos, necessários para aplicação dessas ferramentas no software Matlab. Vale enfatizar que, o desenvolvimento teórico é baseado nas bibliografias de MISITI, MISITI, et al., 2015 e RODRIGUES, 2008, quando o tema é referente à transformada wavelet. Já para o tema de redes neurais artificiais o texto baseia-se em DEMUTH e BEALE, 2015 e MENEZES, 2008.

### 3.1 TRANSFORMADA WAVELET

Nessa primeira parte são apresentados os conceitos referentes à transformada wavelet, que estão organizados em tópicos, nomeados da seguinte forma: Wavelets, Definição: Transformada Wavelet, Transformada Wavelet Contínua (TWC), Transformada Wavelet Discreta (TWD), Decomposição em Múltiplos Níveis (Multiresolução), Transformada Wavelet Estacionária (TWE) e Teorema de Parseval.

### 3.1.1 WAVELETS

Para melhor compreender o que é uma wavelet, na Figura 1 estão representadas duas ondas, uma senoidal e uma wavelet, denominada Daubechies. As ondas senoidais não são limitadas no tempo (estendem de menos a mais infinito), são suaves e previsíveis, enquanto que, a wavelet é uma forma de onda com duração limitada, que tem valor médio zero, possui irregularidades e assimetrias. Vale destacar que algumas referências tratam função wavelet como função mãe.

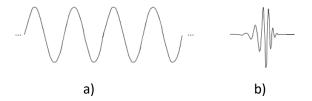


Figura 1 - Formas de onda: a) senoidal; b) wavelet Dubechies

Existem outras famílias de wavelets, com propriedades semelhantes, entre as quais destacam-se as famílias de wavelets do tipo Haar, Daubechies, Biorthogonal, Coiflets, Symlets, Morlet, Mexican Hat e Meyer. Informações detalhadas para essas famílias de wavelets podem ser encontradas em (MISITI, MISITI, et al., 2015); (RODRIGUES, 2008). No entanto, esse trabalho se limitará em uma breve discussão sobre as wavelets Haar, por ser a primeira e mais simples, e waveletes Daubechies, por ser amplamente utilizada na análise de sinais de sistemas elétricos de potência e, consequentemente, adotada neste trabalho.

Qualquer discussão a respeito de wavelets começa com a família de wavelets do tipo Haar. A função wavelet Haar é descontínua e representa uma função degrau. A Figura 2 apresenta uma função wavelet Haar.

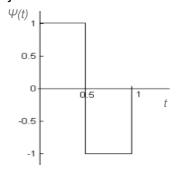


Figura 2 - Função wavelet do tipo Haar

Além das funções wavelets, existem também as funções escala, que tem origem associada à função wavelet. Na Figura 3 está representada a função escala, que teve origem associada a função wavelet Haar da Figura 2.

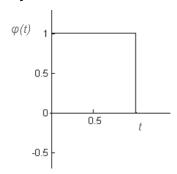


Figura 3 - Função escala do tipo Haar

Já as funções wavelets do tipo Daubechies, foram desenvolvidas por Ingrid Daubechies, uma importante pesquisadora sobre wavelets.

Os nomes da família Daubechies são escritos como dBN, onde N é a ordem da wavelet e dB refere-se ao nome da pesquisadora. A função wavelet dB1 é semelhante a função wavelet Haar representada na Figura 2. Na Figura 4 estão representadas algumas waveletes da família Daubechies.

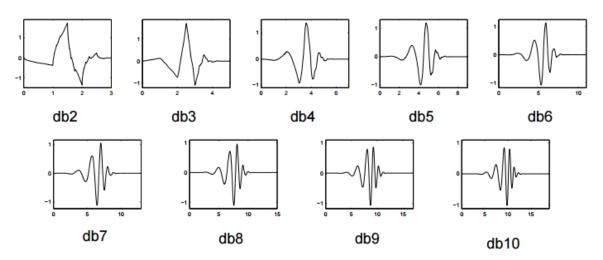


Figura 4- Família Daubechies (MISITI, MISITI, et al., 2015)

Da mesma forma que existe a função escala associada a função wavelet Haar, para a função wavelet Daubechies também existe uma função escala associada. Na Figura 5, estão representadas uma função escala e uma função wavelet do tipo daubechies de ordem 2.

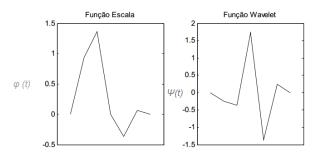


Figura 5 - Função escala **φ(t)** e função wavelet **Ψ(t)** de ordem 2 (FILHO, Maio, 2007)

Como será apresentado a seguir, a transformada wavelet Discreta é um processo de convolução, entre o sinal a ser analisado e filtros passa-baixa e passa alta. Esses filtros são derivados, respectivamente, da função escala e da função wavelet. O processo para determinar os filtros envolve cálculos e alguns conceitos de álgebra linear, como norma e ortogonalidade, aplicados à família de wavelet em estudo (FILHO, 2007).

### 3.1.2 DEFINIÇÃO: TRANSFORMADA WAVELET

Inicialmente será apresentada a Transformada de Fourier Janelada (TFJ). Essa transformada divide o sinal em análise em segmentos iguais no tempo (janelas). Em cada janela é aplicada a Transformada de Fourier, que determina as diferentes frequências naquele intervalo de tempo, mapeando o sinal no tempo e frequência conforme Figura 6.



Figura 6 - Transformada de Fourier janelada (MISITI, MISITI, et al., 2015)

Uma desvantagem é que esse método utiliza o mesmo tamanho de janelas para determinar todas as frequências, o que limita a precisão do método, uma vez que, ao analisar um sinal, deveriam ser usadas janelas de intervalos maiores quando deseja obter informações mais precisas sobre baixas frequências e janelas

de intervalos menores quando se deseja informações mais precisas sobre altas frequências.

Nesse cenário, surge a Transformada Wavelet (TW), que é uma evolução em relação a TFJ, pois utiliza janelas de tamanhos variáveis, para análise de sinais no domínio do tempo e frequência.

A Figura 7, mostra a relação entre as informações no tempo e na frequência (escala) de um sinal que é submetido a TW. Conforme é de interesse, na TW as informações de baixa frequência são obtidas por meio de janelas que utilizam grandes intervalos de tempo, maiores níveis de escala, sendo ideais para análise de sinais em regimes permanente sem grandes variações no tempo, enquanto que, janelas de curtas regiões, como primeiro nível de escala, fornecem mais precisamente as características de altas frequências, ideais para análise de períodos transitórios, que possuem mudanças rápidas de comportamento no tempo.



Figura 7 - Transformada wavelet (MISITI, MISITI, et al., 2015)

A TW é uma ferramenta matemática que pode trabalhar tanto com dados contínuos como sinais amostrados, distinguindo em duas versões diferentes, denominadas respectivamente em Transformada Wavelet Contínua (TWC) e Transformada Wavelet Discreta (TWD).

## 3.1.3 TRANSFORMADA WAVELET CONTÍNUA (TWC)

A TWC é matematicamente representada pela equação (1) e pode ser definida como a soma ao longo do tempo de uma função f(t) multiplicado por versões escalonadas e transladadas da função wavelet  $\Psi(t)$ , também chamada de wavelet mãe. As funções f(t) e  $\Psi(t)$  são contínuas.

TWC (a,b) = 
$$\int f(t) \Psi_{a,b}(t) dt$$
 (1)

Os parâmetros **a** e **b** são respectivamente o fator de escala e o fator de translação. Apesar de não ser utilizada neste trabalho, é necessária a apresentação da formulação das TWC, pois conceitos como fator de escala e fator de translação, inerentes à sua definição, são também aplicados as TWD.

#### 3.1.3.1 Fator de Escala

O fator de escala **a** é responsável por dilatar ou contrair uma função wavelet. Para facilitar o entendimento, na Figura 8 estão representados os efeitos do fator de escala a uma função senoidal.

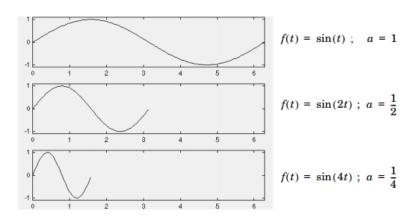


Figura 8 - Efeito do fator escala (a) em uma função senoidal

O fator de escala trabalha da mesma forma com funções wavelets, conforme pode-se verificar na Figura 9.

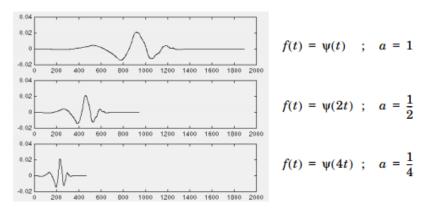


Figura 9 - Efeito do fator de escala (a) em uma função wavelet (MISITI, MISITI, et al., 2015)

A partir da Figura 8 e da Figura 9, nota-se que quanto menor o valor do fator de escala **a**, mais contraídas estão as funções senoidal e wavelet, respectivamente.

Associando as informações anteriores com a Figura 7, verifica-se que uma função wavelet com fator de escala maior, representaria uma janela maior (ideal para analisar baixas frequências), enquanto que, uma função wavelet com fator de escala menor, representaria uma janela menor (para analisar altas frequências).

#### 3.1.3.2 Fator de Translação

O fator de translação  $\mathbf{b}$  é responsável pelo deslocamento (atrasar ou adiantar) da função wavelet ao longo do eixo do tempo. Matematicamente, o atraso de uma função wavelet  $\Psi(\mathbf{t})$ , por  $\mathbf{b}$ , é representado por  $\Psi(\mathbf{t}-\mathbf{b})$ . A Figura 10, ilustra o efeito do fator de translação aplicado à uma função wavelet.



Figura 10 - Translação de uma função wavelet: a) Função wavelet  $\Psi(t)$ ; b) Função wavelet transladada  $\Psi(t-b)$ 

Geralmente, os sinais submetidos a TW possuem tamanhos maiores que as funções wavelets, conforme Figura 11

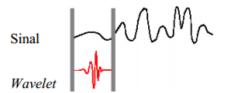


Figura 11 - Wavelet: condição inicial (MISITI, MISITI, et al., 2015)

No entanto, quando é realizada a TW, a função wavelet deve deslocar-se até cobrir todo o comprimento do sinal em análise. Esse efeito é conseguido transladando a função wavelet, como mostra a Figura 12.

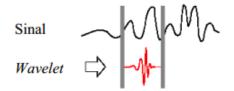


Figura 12 - Wavelet transladada (MISITI, MISITI, et al., 2015)

#### 3.1.4 TRANSFORMADA WAVELET DISCRETA (TWD)

A TWD é a transformada correspondente a Transformada Wavelet Contínua (TWC), aplicada para análise de sinais amostrados, sendo assim, uma ferramenta muito utilizada em implementações computacionais. Como será detalhado a seguir, a TWD é um processo de filtragem digital no domínio do tempo (via convolução), usando filtros passa-baixa e passa-alta, seguido da subamostragem de 2 (downsampling).

Uma maneira eficiente de implementar esse esquema foi desenvolvida por Mallat. O algoritmo de Mallat, conhecido como *two-channelsubbandcoder* (MISITI, MISITI, *et al.*, 2015), parte da existência de duas funções básicas, uma função wavelet Ψ(t), que determina o filtro passa-alta, e uma função de escala φ (t) que determina o filtro passa-baixa. O método consiste na decomposição de um sinal discreto S por meio da convolução desse sinal S e filtros passa-baixa e passa-alta, gerando dois novos conjuntos de sinais, um de baixas frequências, denominado coeficientes de aproximação cA e outro de altas frequências, denominado coeficientes detalhe cD. Cada conjunto de coeficientes possui a metade de amostras do sinal discreto S (subamostragem de 2), sendo aproveitados somente os coeficientes de índice ímpar e rejeitando os coeficientes de índice par. A Figura 13 apresenta o processo descrito anteriormente.

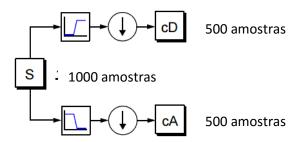


Figura 13 - TWD: Processo de filtragem ao primeiro nível de decomposição

Vale destacar que o processo de subamostragem de 2, foi uma medida para reduzir à metade o número de amostras de cada coeficiente **cA** e **cD**, para evitar que após o processo de filtragem a soma das amostras seja o dobro de amostras do sinal **S.** Por esse motivo a TWD é muito utilizada na compressão de imagens digitais. Para melhor ilustrar, a Figura 14 considera um sinal real submetido a TWD.

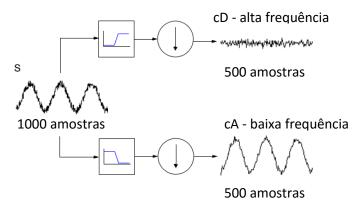


Figura 14 - TWD: Processo de filtragem ao primeiro nível de decomposição considerando um sinal real (MISITI, MISITI, et al., 2015)

### 3.1.5 DECOMPOSIÇÃO EM MÚLTIPLOS NÍVEIS (MULTIRESOLUÇÃO)

O processo de decomposição pode ser iterativo. A primeira decomposição é do sinal discreto **S**, a próxima decomposição é do coeficiente aproximação do primeiro nível **cA**<sup>1</sup> gerando também dois novos conjuntos **cA**<sup>2</sup> e **cD**<sup>2</sup> e assim sucessivamente até que o coeficiente aproximação consista de uma única amostra. Ressalta-se que a decomposição é aplicada em uma única direção, onde os coeficientes aproximação é que são sempre decompostos nos diferentes níveis. A Figura 15 ilustra um processo de decomposição sucessivo de um sinal em 3 níveis.

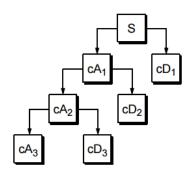


Figura 15 - Processo de decomposição de um sinal em 3 níveis (Multiresolução)

A Figura 16 apresenta um exemplo com sinal real submetido a decomposição em múltiplos níveis (multiresolução). O sinal real **S** possui frequência de amostragem de 1920 Hz e 7680 amostras. Estão representadas as faixas de frequências para cada nível de decomposição.

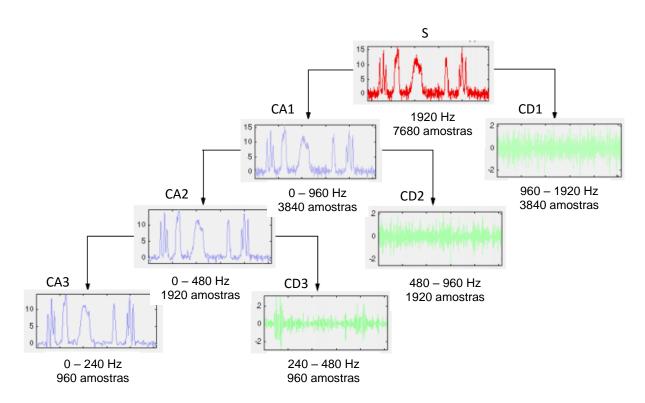


Figura 16 - Processo de decomposição de um sinal real em 3 níveis (Multiresolução) (MISITI, MISITI, et al., 2015)

Graficamente, o processo de decomposição em múltiplos níveis é representado numa região de tempo-escala, conforme Figura 17, sendo que, a escala corresponde ao nível de decomposição.

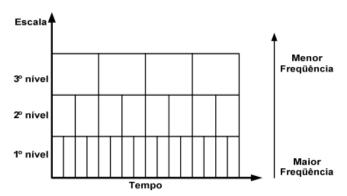


Figura 17 - Representação da Região tempo-escala

A partir da análise da Figura 16 e Figura 17, também conclui-se que, as altas frequências são melhores extraídas no primeiro nível de decomposição, quando a resolução no tempo é maior, enquanto que, as baixas frequências são melhores extraídas quanto maior for o nível de decomposição e a resolução no tempo é

menor.

Já a Figura 18 apresenta o comportamento da função wavelet em diferentes níveis de decomposição.

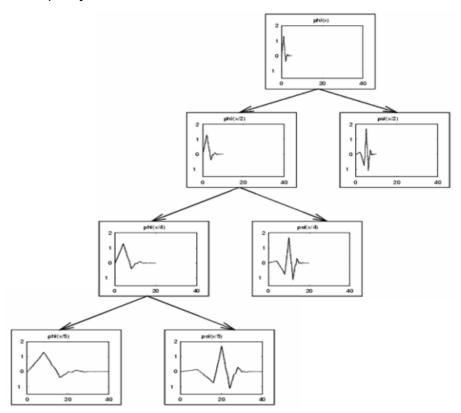


Figura 18 - Função wavelet em diferentes níveis de decomposição (RODRIGUES, 2008)

A partir da análise da Figura 18, verifica-se nitidamente o efeito do fator escala. À medida que se aumenta o nível de decomposição, o fator de escala também aumenta, tornando a função wavelet mais dilatada. Diante disso, conclui-se também que wavelet mais dilatadas são melhores para extrair características de baixas frequências, enquanto que, wavelets contraídas representam melhor os sinais de altas frequências.

## 3.1.6 TRANSFORMADA WAVELET ESTACIONÁRIA (TWE)

A TWE é também utilizada para analisar dados discretos. De forma similar ao que é realizado na TWD, o método consiste na decomposição de um sinal discreto **S** por meio da convolução desse sinal **S** e filtros passa-baixa e passa-alta, gerando dois novos conjuntos de sinais, um de baixas frequências, denominado coeficientes

de aproximação **cA**<sub>1</sub> e outro de altas frequências, denominado coeficientes detalhe **cD**<sub>1</sub>. No entanto, na TWE não ocorre a subamostragem de 2 fazendo com que cada conjunto de coeficientes possui a mesma quantidade de amostras **n** do sinal discreto **S** (MISITI, MISITI, *et al.*, 2015).A Figura 19 mostra a aplicação TWE a um sinal discreto **S**.

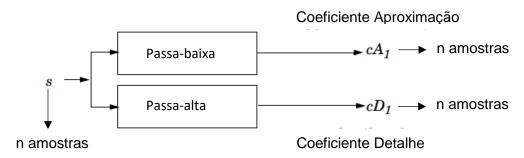


Figura 19 - TWE: Processo de filtragem ao primeiro nível de decomposição

Na TWE a decomposição em múltiplos níveis é semelhante ao realizado por TWD, ou seja, a partir da segunda decomposição, os coeficientes aproximação **cA**J+1 e os coeficientes detalhe **cD**J+1 são obtidos dos coeficientes aproximação **cA**J, sendo **J** o nível de decomposição. No entanto, os filtros passa-baixa **F**J e passa-alta **G**J são modificados a cada nível de decomposição pela inserção de zeros intercalados (upsample). A Figura 20 apresenta o processo descrito.

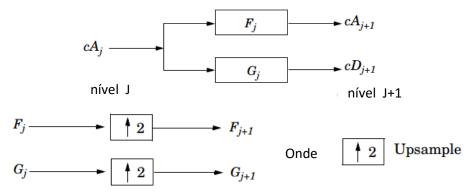


Figura 20 - Transformada wavelet estacionária: Decomposição em múltiplos níveis e upsample de filtros (MISITI, MISITI, et al., 2015)

Vale destacar que quando se compara TWE em relação a TWD, o número de amostras, após a primeira decomposição por exemplo, é maior e consequentemente o intervalo entre amostras no tempo é menor, porque não há subamostragem. Essa característica é determinante para adotar a TWE neste trabalho. A extração dos coeficientes detalhe via TWE, possibilitará, de forma mais rápida, a detecção de

altas frequências, essas que são características registradas em momentos de anormalidades, como faltas.

#### 3.1.7 TEOREMA DE PARSEVAL

A TWE apresenta uma propriedade que é a conservação de energia; assim, a energia do sinal transformado é igual a energia do sinal original. Essa energia pode ser quantificada de acordo com o teorema de Parseval (RODRIGUES, 2008), que relaciona a energia do sinal original **S** com a energia dos coeficientes aproximação **cAj** e detalhe **cDj** nos diferentes níveis de decomposição **j**, a partir da equação (2):

$$\sum_{n=1}^{N} S^{2}(n) = \sum_{n=1}^{N} cAj^{2}(n) + \sum_{n=1}^{j} \sum_{n=1}^{N} cDj^{2}(n)$$
 (2)

Onde:

S(n) – corresponde ao sinal original f(t) amostrado.

n – corresponde ao número de amostras do sinal.

$$\sum_{n=1}^{n} S^{2}(n) - corresponde a energia do sinal original$$

$$\sum_{n=1}^{n} cAj^{2}(n) - \text{ corresponde a energia do coeficiente aproximação decomposto}$$

a nível j

$$\sum_{n=1}^{j} \sum_{n=1}^{n} cDj^2(n) - \text{ corresponde a soma das energias dos coeficientes detalhe}$$

contidas do nível 1 ao j

Neste trabalho, o teorema de Parseval será aplicado aos coeficientes detalhe, obtidos via TWE, no primeiro nível de decomposição **cD**1. Como será mostrado no capítulo 4, esse processo será determinante na detecção de faltas ocorridas em linhas de transmissão. A Figura 21 contém um sinal **S**, os **cD**1 obtidos via TWE, e a energia de Parseval associada a **cD**1.

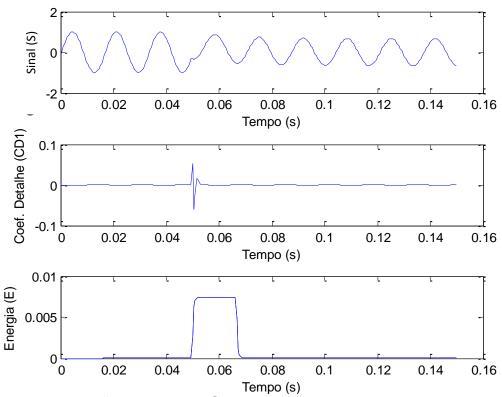


Figura 21 – Evolução de um sinal **S** ao ser submetido a TWE e energia de Parserval

#### 3.2 REDES NEURAIS ARTIFICIAIS (RNAs)

Nessa segunda parte estão apresentados os conceitos referentes a redes neurais artificiais, que também estão organizados em tópicos, nomeados da seguinte forma: Neurônio Biológico, Neurônio Artificial, Arquitetura de Redes Neurais Artificiais, e Multilayer Perceptron (MLP) com aprendizado supervisionado Backpropagation e Algoritmo de Treinamento Levenberg-Marquardt

#### 3.2.1 NEURÔNIO BIOLÓGICO

Um neurônio biológico é composto por um corpo celular (ou soma), um axônio tubular e várias ramificações arbóreas conhecidas como dendritos. A Figura 22 mostra o esboço de um neurônio biológico.

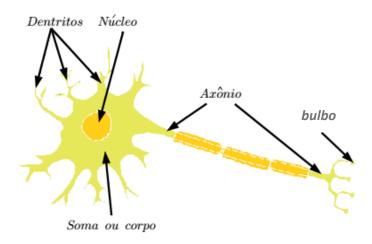


Figura 22 - Neurônio biológico (MATSUNAGA, 2012).

Os dendritos (zonas receptivas) formam uma malha de filamentos finíssimos ao redor do corpo celular. Já o axônio consta de um tubo longo e fino e é responsável pela transferência de informação entre pontos distantes do sistema nervoso (linhas de transmissão). Ele se divide em ramificações, que terminam em pequenos bulbos que quase tocam os dendritos dos outros neurônios. Há um pequeno espaço entre o fim do bulbo e o dendrito, conhecido como sinapse que tem como papel fundamental a transmissão da informação. A Figura 23 mostra a conexão (sinapse) entre dois neurônios.

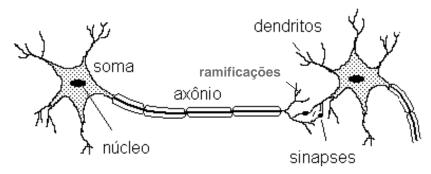


Figura 23 - Conexão entre dois neurônios (MENEZES, 2008)

Estima-se que há aproximadamente 10 bilhões de neurônios no córtex humano e 60 trilhões de sinapses (MENEZES, 2008). A interação entre os neurônios é responsável pelo armazenamento e tomada de decisões adequadas a partir de informações recebidas.

#### 3.2.2 NEURÔNIO ARTIFICIAL

Já um neurônio artificial é um modelo matemático que simula o comportamento de um neurônio biológico. Na Figura 24 está representada uma configuração genérica de um neurônio artificial.

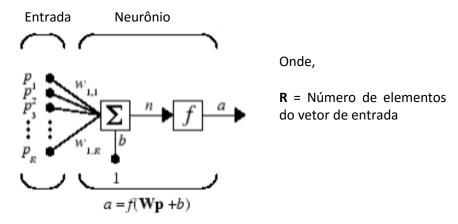


Figura 24 - Configuração neurônio artificial (DEMUTH e BEALE, 2015)

Esse neurônio artificial possui um vetor de entradas **P** com **R** elementos, que correspondem às conexões sinápticas ocorridas no neurônio biológico.

$$P_1, P_2, P_3, ... P_R$$

O processo inicia-se com a amplificação de cada elemento individual do vetor de entrada, onde cada entrada  $P_R$  é multiplicada por um peso  $W_{1,R}$ .

$$W_{1,1}, W_{1,2}, W_{1,3}, ... W_{1,R}$$

Então, os valores ponderados, com representação simplificada por **WP**, são somados. Ao resultado dessa soma, deve ser adicionado o sinal denominado bias **b**, com valor constante igual a 1, para formar o argumento **n** da função de ativação **f(n)**.

$$n = W_{1,1}P_1 + W_{1,2}P_2 + W_{1,3}P_3 + \dots + W_{1,R}P_R + b$$
(3)

A função de ativação **f(n)** modela a forma como o neurônio responde ao vetor de entrada definindo a saída da rede neural.

Existem diversos tipos de funções de ativação, como degrau, linear, rampa, sigmoide e tangente hiperbólica, sendo as mais utilizadas, as funções de ativação linear, sigmoide e tangente hiperbólica, que estão apresentadas na Figura 25.

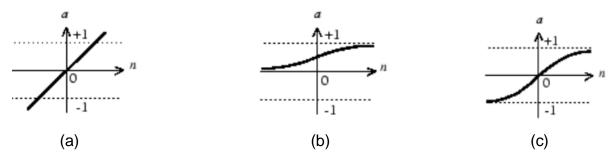


Figura 25 - Funções de ativação: a) Linear; b) Sigmoide; c) Tangente hiperbólica

A função de ativação linear é utilizada em situações que se deseja que o neurônio retorne um valor aproximado. Já a função de ativação sigmoide limita a resposta do neurônio entre os valores 0 e 1. Alternativamente pode ser usada função de ativação tangente hiperbólica, que gera resposta entre os valores -1 e 1. Essas duas últimas funções são frequentemente utilizadas em problemas de reconhecimento de padrões.

É comum na literatura referir aos neurônios artificiais como perceptron, nome dado ao primeiro modelo de neurônio artificial criado por Rosenblatt (ROSENBLATT, 1957). Vale destacar também que redes neurais complexas podem ser formadas pela interconexão de vários neurônios individuais, como será mostrado a seguir.

#### 3.2.3 ARQUITETURA DE REDES NEURAIS ARTIFICIAIS

A arquitetura de uma rede neural artificial é estruturada de acordo com o problema a ser resolvido, sendo que, quatro temas devem ser avaliados nesse processo: Número de camadas, número de neurônios, método de aprendizagem e função de ativação. A seguir será apresentada breve discussão sobre esses temas, com exceção do tema referente a função de ativação que já foi abordado no item 3.2.2.

#### 3.2.3.1 Número de camadas

Segue na Figura 26 uma rede neural com uma única camada, com R elementos no vetor de entrada P e com uma quantidade S de neurônios.

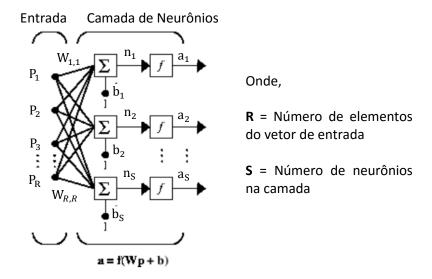


Figura 26 - Rede Neural com uma camada (DEMUTH e BEALE, 2015)

Nessa rede, todos os elementos  $\mathbf{R}$ , do vetor de entrada  $\mathbf{P}$ , são conectados a todos neurônios por meio da matriz de pesos  $\mathbf{W}$ . Em uma expansão matricial, o argumento  $\mathbf{n}_s$ , de cada neurônio, é obtido da seguinte forma:

$$\begin{bmatrix} n_1 \\ n_2 \\ \vdots \\ n_s \end{bmatrix} = \begin{bmatrix} w_{1,1} & w_{1,2} & w_{1,R} \\ w_{2,1} & w_{2,2} & w_{2,R} \\ \vdots & \vdots & \vdots \\ w_{s,1} & w_{s,2} & w_{s,R} \end{bmatrix} \cdot \begin{bmatrix} P_1 \\ P_2 \\ \vdots \\ P_R \end{bmatrix} + \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_s \end{bmatrix}$$
(4)

Nota-se que os índices de linha sobre os elementos da matriz **W** indicam o neurônio de destino do peso, enquanto que, os índices de coluna indicam à qual elemento **R** do vetor de entrada **P** está relacionada a origem do peso.

Finalmente, as saídas de todos os neurônios formam um vetor coluna **a.** A expressão para **a** é mostrada na parte inferior da Figura 26 e é dada por:

$$a = f(n) = f(wp + b) \tag{5}$$

Já a Figura 27 apresenta uma rede neural com múltiplas camadas de neurônios. Esse tipo de rede é uma expansão da rede neural com camada única, onde cada camada tem uma matriz de peso **W**, um vetor bias **b** e um vetor de saída **a.** Nota-se que as saídas de cada camada intermediária são as entradas para a camada seguinte. Analisando a rede neural da Figura 27 nota-se que a rede possui

 ${\bf R^1}$  entradas,  ${\bf S^1}$  neurônios na primeira camada (por isso o subscrito 1),  ${\bf S^2}$  neurônios na segunda camada e  ${\bf S^3}$  neurônios na terceira camada. É comum que as diferentes camadas possuam diferentes números de neurônios.

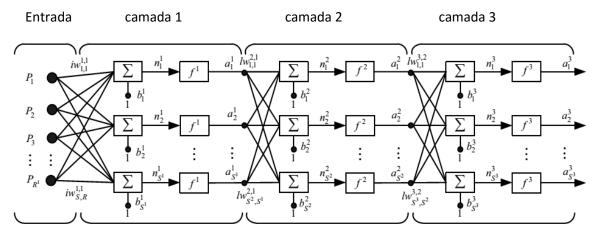


Figura 27 - Rede neural de múltiplas camadas (DEMUTH e BEALE, 2015)

As diferentes camadas da rede mostrada anteriormente são designadas como camada de saída (camada 3) e camadas ocultas (camada 1 e da camada 2) e a estrutura da rede pode ser referida como R-S<sup>1</sup>-S<sup>2</sup>-S<sup>3</sup>.

De forma geral, redes neurais com configurações simples com duas camadas, por exemplo, onde a primeira camada possui função de ativação sigmoide e a segunda camada possui função de ativação linear, pode ser treinada e proporcionar boa aproximação para qualquer função.

#### 3.2.3.2 Número de Neurônios

Não há uma regra exclusiva que possibilita determinar o número de neurônios de cada camada. Alguns autores afirmam que com apenas uma camada oculta na rede neural já é possível calcular uma função arbitrária qualquer a partir de dados fornecidos, e que a camada oculta deve ter por volta de (2i+1) neurônios, onde i é o número de elementos do vetor de entrada (HECHT-NIELSEN, 1989).

Já LIPPMANN em 1987, apresentou que, havendo uma segunda camada oculta na rede neural, esta deve ter o dobro de neurônios da camada de saída e no caso de uma rede neural com apenas uma camada, ela deverá ter **s(i+1)** neurônios, onde **s** é o número de neurônios de saída e **i**, o número de elementos do vetor de entrada.

No entanto, uma prática comum adotada por pesquisadores, é determinar o número de neurônios e de camadas ocultas de forma experimental. O processo adotado neste trabalho consiste em começar com números menores de neurônios por camada e ir aumentando até que a rede neural apresente bons resultados. Quando foi necessário um número de neurônio na camada oculta muito maior que o dobro de dados de entrada, optou por dividir esses neurônios em duas camadas, o que ajudou a melhorar na precisão da rede neural.

#### 3.2.3.3 Métodos de Aprendizagem

O aprendizado das redes neurais pode ser na forma supervisionada ou não supervisionada (MENEZES, 2008).

No aprendizado supervisionado, na fase de treinamento é apresentado à rede um conjunto de padrões que contém os elementos do vetor de entrada e um conjunto de padrões que contém os elementos do vetor de saída desejado. A cada iteração na fase de treinamento, há uma conferência entre a saída desejada e a saída obtida pela rede. Nessa conferência gera-se um erro que é retornado ao sistema de aprendizagem, adaptando os pesos entre os neurônios, de modo a prover uma menor diferença entre o alvo obtido e o alvo desejado.

Já no aprendizado não supervisionado o conjunto de padrões de alvos desejados não é conhecido. A rede é ajustada de acordo com regularidades estatísticas dos dados de entrada. Isso significa que a rede deverá ser capaz de ajustar os pesos entre as camadas de neurônios, através do mapeamento dos padrões apresentados na sua entrada, sem possiblidade de confrontar os resultados gerados por ela.

# 3.2.4 MULTILAYER PERCEPTRON (MLP) COM APRENDIZADO SUPERVISIONADO BACKPROPAGATION E ALGORITMO DE TREINAMENTO LEVENBERG-MARQUARDT

A rede neural com múltiplas camadas, apresentada na Figura 27, é também conhecida como Multilayer Perceptron (MLP). Uma característica desse tipo de rede é definida como feedforward, o que significa que as saídas dos neurônios em qualquer camada se conectam unicamente às entradas dos neurônios da camada

seguinte, sem presença de laços de realimentação. Além da MLP, existem outras topologias de redes neurais, dentre as quais destacam-se as apresentadas na Tabela 1.

Tabela 1 - Topologias de redes neurais

RBF – Radial Basis Function (Função de Base Radial)
PNN – Probabilistic Neural Network (Rede Neural Probabilística)
SOM – Self-Organizing Map (Mapa Auto-Organizável) de Kohonen
LVQ – Learning Vector Quantization (Quantização Vetorial por Aprendizagem)

Entre essas topologias, a MLP foi escolhida neste trabalho por ter capacidade de resolver problemas de reconhecimento de padrões (Classificação de falta), problemas do tipo em que se deseja estimar valores (determinar locais de falta e resistências de falta) e por ser amplamente contemplada pelo software Matlab.

No que refere aos métodos de aprendizagem, as MLP utilizam o método de aprendizagem supervisionado denominado backpropagation (DEMUTH e BEALE, 2015). Nesse algoritmo, inicialmente os pesos **W** são inicializados de forma aleatória. Em seguida, um padrão de entrada **P** é aplicado aos neurônios da primeira camada da rede que é propagado adiante por cada uma das outras camadas intermediárias até que seja gerado o vetor de saída **a**. Então o vetor de saída **a** é comparado com o conjunto de padrão de saída desejado **d**, gerando um sinal de erro para cada elemento do vetor de saída. O sinal de erro é propagado para trás, da camada de saída em direção a camada de entrada, ajustando os pesos **W**, para que o erro seja mínimo entre as saídas desejadas **d** e o vetor de saída obtido **a**. A Figura 28 mostra a arquitetura da rede MLP com algoritmo de aprendizagem supervisionado backpropagation.

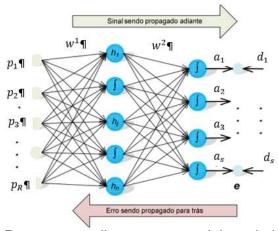


Figura 28 - Rede MLP com aprendizagem supervisionada backpropagation (MENEZES, 2008)

Definida a topologia, resta estabelecer o algoritmo de treinamento da rede. Existem diversos algoritmos de treinamentos que estão apresentados na Tabela 2. Esses algoritmos possuem técnicas baseadas nos métodos do gradiente e Jacobiano (HAGAN, DEMUTH e BEALE, 1996).

Tabela 2 - Algoritmos de treinamento

Levenberg-Marquardt
Bayesian Regularization
BFGS Quasi-Newton
Resilient Backpropagation
Scaled Conjugate Gradient
Conjugate Gradientwith Powell / Beale Restarts
Fletcher-Powell Conjugate Gradient
Polak-Ribiére Conjugate Gradient
One Step Secant
Variable Learning Rate Gradient Descent
Gradient Descentwith Momentum
Gradient Descent

Como as redes neurais desenvolvidas neste trabalho são pequenas (matriz de pesos com quantidade muito inferior a mil), foi adotado algoritmo de treinamento Levenberg-Marquardt por ser eficiente e rápido para essas dimensões de rede.

## 3.3 CONSIDERAÇÕES FINAIS

Neste capítulo foram apresentados alguns conceitos referentes a transformada wavelet e redes neurais artificiais. O objetivo principal foi apresentar os fundamentos básicos necessários para aplicação dessas ferramentas no software Matlab.

Dentro desse contexto, destacam-se a TWE e o Teorema de Parseval, que serão utilizados no processo de detecção de falta. Também se destacam os conceitos referente as RNAs com topologia MLP, método de aprendizagem supervisionado backpropagation e algoritmo de treinamento Levenberg-Marquardt, que serão utilizadas nos processos de classificação e localização de falta, e para determinar resistência de falta.

## 4 METODOLOGIA: ALGORITMOS PARA DETECTAR, CLASSIFICAR, LOCALIZAR FALTAS E DETERMINAR RESISTÊNCIA DE FALTA

Este capítulo apresenta os três algoritmos desenvolvidos para detectar, classificar, localizar faltas e determinar resistências de faltas, em linhas de transmissão.

Os algoritmos se baseiam nas ferramentas já apresentadas (TWE, energia de Parseval e RNAs), mas não se restringem a estas, sendo utilizados também outros métodos para processamento de sinais, como filtragem, interpolação e minimização dos erros quadrados. Os algoritmos 1 e 2 utilizam dados de um único terminal, enquanto que, o algoritmo 3 utiliza dados registrados nos dois terminas da linha de transmissão.

A fim de descrever as características do sistema elétrico a que os algoritmos propostos são aplicáveis, e principalmente, como foram desenvolvidos, este capítulo está organizado em itens denominados: Topologia do Sistema Elétrico; Préprocessamento; Algoritmo Proposto 1: Energia dos Coeficientes Detalhe de Wavelet de Corrente e Tensão para Treinamento e Teste de RNAs. Dados de um Terminal; Algoritmo Proposto 2: Módulos Fasoriais de Corrente e Tensão para Treinamento e Teste de RNAs. Dados de um Terminal; Algoritmo Proposto 3: Módulos Fasoriais de Corrente para Treinamento e Teste de RNAs. Dados de dois Terminais e Considerações Finais.

#### 4.1 TOPOLOGIA DO SISTEMA ELÉTRICO

Os algoritmos desenvolvidos são aplicáveis a qualquer sistema elétrico modelado por uma linha de transmissão e fontes equivalentes no terminal emissor **S** e terminal receptor **R**, conforme Figura 29.

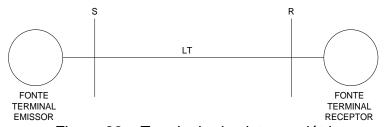


Figura 29 – Topologia do sistema elétrico

É nesse cenário que os algoritmos desenvolvidos são capazes de detectar faltas, classificá-las quanto ao tipo (fase-terra, trifásica, bifásica, bifásica-terra), localizá-las, informando em quilômetros onde a falta ocorreu e ainda determinar a resistência, em ohms, associada à falta. A Figura 30 detalha os tipos de falta aqui investigadas, por meio de uma representação trifásica do sistema elétrico da Figura 29, onde são apresentados os diferentes tipos de falta, local de ocorrência da falta **F**, distância que ocorreu a falta **DF** a partir do terminal **S** e resistências de falta **RF**.

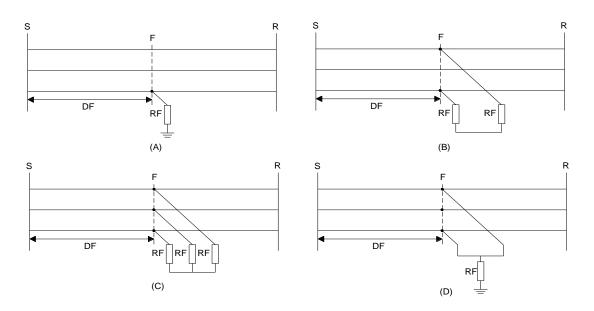


Figura 30 - Diferentes tipos de falta: A) fase-terra; B) bifásico; C) trifásica; D) bifásico-terra

Para realizar tais funções, os algoritmos 1 e 2 utilizam dados de apenas um terminal, enquanto que, algoritmo 3 utiliza dados dos dois terminais. É importante destacar, mesmo que, apresentem metodologias diferentes, uma etapa denominada pré-processamento, é comum aos 3 algoritmos e por isso será apresentada inicialmente.

#### 4.2 PRÉ-PROCESSAMENTO

A Figura 31 apresenta a estrutura do algoritmo para pré-processamento de dados. Esse algoritmo é responsável, por detectar o instante de íncio da falta, estimar os módulos e ângulos das fontes equivalentes nos dois terminais e gerar o banco de dados necessários para treinamentos das RNAs.

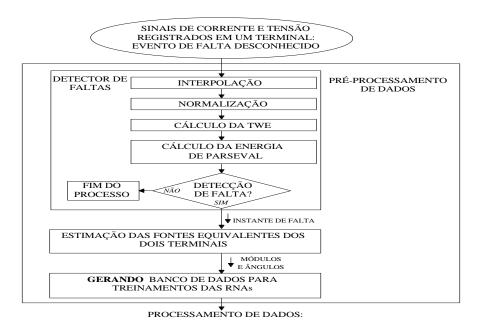


Figura 31 - Estrutura do algoritmo para pré-processamento de dados

#### 4.2.1 DETECTOR DE FALTA

O detector de falta entra em operação quando são obtidos os sinais trifásicos de corrente e tensão (sinais de entrada) registrados durante um evento de falta. Em seguida esses sinais são submetidos aos processos de interpolação, normalização, transformada wavelet estacionária, energia de Parseval e detecção de falta.

Os relés digitais e os registradores digitais de perturbações, responsáveis por gravar os eventos de faltas, geram arquivos de dados com diferentes taxas de amostragem. Assim, os sinais de entrada são submetidos ao processo de interpolação linear, que visa padronizar em 32 o número de pontos por ciclo (NPC) dos dados de entrada, o que corresponde a uma frequência de amostragem de 1920 Hz.

Depois de interpolados, os sinais são normalizados considerando o máximo valor de pico, registrado durante os dois primeiros ciclos em que o sistema elétrico está operando no período pré-falta. Esse processo estabelece que as amostras dos sinais de entrada estejam entre os valores de 1 à -1 durante o período pré-falta, padronizando assim as amostras utilizadas para treinamento e testes das RNAs.

Conforme já descrito, neste trabalho é escolhida a TWE, em seu 1º nível de decomposição, para aplicar aos sinais normalizados, por ser eficiente na extração de características de altas frequências e possibilitar a identificação da falta em menor

tempo. Para construção dos filtros foram utilizadas wavelet mãe Daubechies de quarta ordem (db4), pois apresentam bom desempenho para extração de coeficientes detalhes **cD1** na análise de sistemas elétricos (SILVA, SOUSA e BRITO, 2006; KALAM, JAMIL e ANSARI, 2010). A implementação computacional é realizada com o recurso do Toolbox wavelet no Matlab (MISITI, MISITI, et al., 2015).

Os coeficientes detalhes **cD**1, obtidos via TWE em seu primeiro de decomposição, são selecionados e então é calculada a energia do coeficiente detalhe **E**, baseando-se teorema de Parseval (COSTA, 2014; SALIM, OLIVEIRA, et al., 2008 e SILVA, SOUSA e BRITO, 2006). Como são selecionados somente **cD**1, o teorema de Parseval, apresentado no item 3.1.7, é simplificado à seguinte equação.

$$E = \sum_{n=1}^{NPC} cD1^{2}(n)$$
 (6)

O cálculo é realizado movendo uma janela, de comprimento igual a NPC, através de **cD1**, com passo de deslocamento de uma amostra.

A Figura 32 apresenta a evolução de um sinal original de corrente ao passar pelos processos descritos anteriormente.

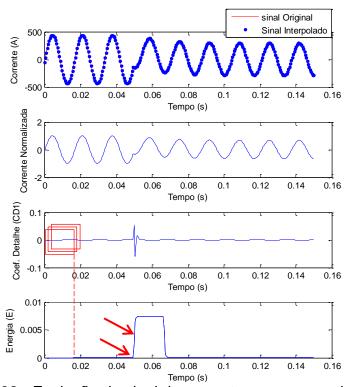


Figura 32 - Evolução do sinal de corrente ao passar pelos processos de interpolação, normalização, TWE e energia de Parserval

Para detecção da falta são selecionados os dados de energia do coeficiente detalhe **E** referente aos sinais de correntes trifásicas, e então a ocorrência da falta é identificada em qualquer uma das três fases, de acordo com a equação (7) (COSTA, 2014; SALIM, OLIVEIRA, et al., 2008 e SILVA, SOUSA e BRITO, 2006),

$$E(n+1) - E(n) > E_{\text{máx}} \tag{7}$$

sendo que, **n** corresponde à enésima amostra da energia do coeficiente detalhe  $\mathbf{E}$  e  $E_{m\acute{a}x}$  corresponde ao valor limite de energia que deve ser estabelecido pelo engenheiro de proteção, dado pela diferença entre a primeira amostra do período de falta e a ultima amostra do período pré-falta, conforme indicado na Figura 32. A Figura 33 apresenta gráficos das correntes no domínio do tempo e suas respectivas energias dos coeficientes detalhe.

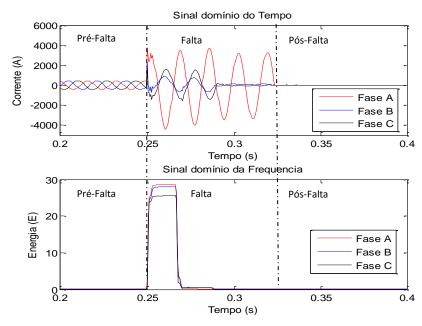


Figura 33 - Sinais de corrente no domínio do tempo e suas respectivas energias dos coeficientes detalhe

Alguns algoritmos utilizam os próprios coeficientes detalhes dos sinais de corrente **cD**1 para a Detecção Falta (MARTÍN e AGUADO, 2003; NGAOPITAKKUL e POTHISARN, 2009 e SARAVANABABU, BALAKRISHNAN e SATHIYASEKAR, 2013). No entanto, durante os testes realizados de detecção de falta, não se verificou uma mudança abrupta entre os coeficientes detalhes dos sinais de wavelet Daubechies corrente pré-falta e de falta, devido à utilização da (db4) em seu

primeiro nível de decomposição. Por essa razão, a opção por detecção de falta por energia do coeficiente detalhe **E** foi adotada. Esse método mostrou-se eficiente detectando a falta em um intervalo de tempo de 0,00052 s para todos os testes realizados.

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

### 4.2.2 ESTIMAÇÃO FASORIAL DAS FONTES EQUIVALENTES

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

Para os algoritmos 1 e 2, que utilizam dados somente de um terminal, o processo para a estimação fasorial das fontes equivalentes do terminal emissor **S** e receptor **R**, inicia-se com o cálculo dos fasores fundamentais dos sinais de corrente e tensão registrados no terminal emissor **S**, por meio de uma variação do método dos erros mínimos quadrados de Sachdev & Baribeau (PEREIRA e CRUZ, 1999). Os valores foram obtidos considerando uma janela de dados com 32 pontos por ciclo.

Em seguida foram selecionados somente os fasores pré-falta e calculou-se a média de cada conjunto (módulos e ângulos). Por meio do Teorema de Fortescue, obteve-se um fasor de corrente **IS** e um fasor de tensão **VS** de sequência positiva no terminal emissor **S**. Conhecendo-se as impedâncias das fontes equivalentes **ZS1** e **ZR1**, da linha **ZL1** e os fasores de sequência positiva de corrente e tensão no terminal emissor **S**, é necessário apenas resolver as equações 8, 9 e 10, para estimar módulo e ângulo das tensões das fontes equivalentes nos dois terminais,

conforme Figura 34. É importante destacar que, a linha de transmissão apresentada na Figura 34, modela uma linha curta, com comprimento de até 80 quilômetros. Para linhas médias (entre 80 e 240 quilômetros) e longas (acimas de 240 quilômetros), existem modelos correspondentes, que consideram correções hiperbólicas e capacitâncias paralelas (SILVEIRA, 2007).

$$ES = VS + ZS1.IS \tag{8}$$

$$VR = VS - ZL1. IS$$
 (9)

$$ER = VR - ZR1.IS (10)$$

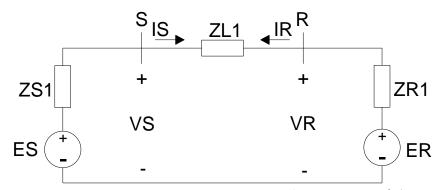


Figura 34 - Modelo linha de transmissão: circuito pré-falta

Para melhor ilustrar o processo descrito, na Tabela 3 estão apresentados os parâmetros de um sistema elétrico real, localizado no interior de Minas Gerais, Brasil, pertencente à uma concessionária de energia.

Tabela 3 - Parâmetros sistema elétrico real

DADOS DAS FONTES EQUIVALENTES - FORNECIDA PELA CONCESSIONÁRIA									
IMPEDÂNCIA DA FONTE (Ω/km)									
TERMINA	L EMISSOR	TERMINAL RECEPTOR							
ZS0	ZS1	ZR0	ZR1						
4,0692+j33,6032	4,00077+j34,1103	2,73069+j39,3637	6,33183+ j53,845						
DADOS LINHA DE TRANSMISSÃO - FORNECIDA PELA CONCESSIONÁRIA									
COMP	RIMENTO (km)		74,4						
TE	ENSÃO (kV)	345							
IMPEDÂNCIA DA LINHA (Ω/km)									
ZL0 ZL1									
0,362191	+ j1,432507	0,036102	+j 0,375919						

Estão apresentados na Figura 35 sinais reais registrados no terminal emissor **S** durante uma falta.

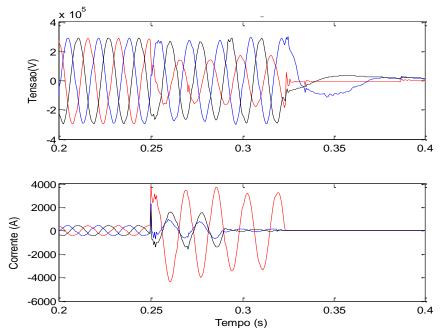


Figura 35 - Sinais reais registrados no terminal S

Já na Tabela 4, estão os resultados estimados das fontes equivalentes, obtidos a partir das equações 8,9 e 10, das informações da Tabela 3 e dos dados registrados terminal **S**, representado na Figura 35.

Tabela 4 - Fontes equivalentes: Valores estimados para terminais emissor **S** e receptor **R** considerando dados de um terminal

Ī	TERMINAL EN	/ISSOR (ES)	TERMINAL RECEPTOR (ER)					
Ī	MÓDULO (kV)	ÂNGULO (°)	MÓDULO (kV)	ÂNGULO (°)				
Ī	292,059	24	290,158	13,9				

Uma ressalva deve ser feita com relação ao algoritmo 3, que utiliza dados dos dois terminais. O processo é semelhante, no entanto, como são conhecidas as medições no terminal receptor **R**, deve-se determinar os fasores de sequência positiva de corrente **IR** e tensão **VR**, seguindo o mesmo procedimento que foi utilizado para determinar **IS** e **VS**. Assim, a solução das equações 8 e 11 seria suficiente para estimar o módulo e ângulo das tensões das fontes equivalentes nos dois terminais.

$$ER = VR + ZR1.IR (11)$$

### 4.2.3 SIMULAÇÃO: GERANDO BANCO DE DADOS

Para o bom desempenho das RNAs é necessário um conjunto de cenários, que contemplam diversas possibilidades de falta no sistema elétrico. Dessa forma, as seguintes variáveis foram consideradas para estabelecimento dos padrões necessários para treinamento das RNAs, conforme Tabela 5

Tabela 5 - Conjunto de variáveis para gerar padrões de treinamento

VARIÁVEIS	TREINAMENTO					
Locais de falta (km)	Locais de falta estão entre 10% e 90% do comprimento da linha, com incremento de 10%, totalizando 9 diferentes locais de falta.					
Resistência de Falta Fase-terra $(\Omega)$	0-7-14-21-28-35-42-49					
Resistência de Falta Fase-Fase $(\Omega)$	0-5					
Tipos de Falta	$ \begin{vmatrix} AT - BT - CT - AB - AC - BC - ABT - ACT - \\ BCT - ABC \end{vmatrix} $					
Fluxo de Potência	*Determinado na etapa de Estimação Fasorial: Fontes Equivalentes					
Ângulo de Incidência de Falta	*Determinado pelo Detector de Falta					

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

As combinações das variáveis citadas na Tabela 5 geram 504 cenários de faltas diferentes. Como não existem registros reais de todas essas situações, tais condições são simuladas nessa etapa. O método consiste no uso de arquivos com extensão .bat, utilizado para automatizar tarefas e permite a simulação em batelada através do software ATP (SU, X.DUAN e ZENG., 2008 e JÚNIO, 2009).

Após gerado o conjunto de cenários para treinamento das RNAs, esses dados devem ser tratados conforme etapa de processamento de dados, correspondente ao algoritmo que será utilizado.

# 4.3 ALGORITMO PROPOSTO 1: ENERGIA DOS COEFICIENTES DETALHE DE WAVELET DE CORRENTE E TENSÃO PARA TREINAMENTO E TESTE DE RNAS. DADOS DE UM TERMINAL

O algoritmo 1 propõe nova metodologia, que seleciona as energias dos coeficientes detalhe de wavelet, extraídos dos sinais de tensões e correntes trifásicos, registrados em um único terminal nos primeiros 1/8 de ciclo do período de

falta, para treinamentos e testes das RNAs.

#### 4.3.1 PROCESSAMENTO DE DADOS:

Na Figura 36 está apresentada a estrutura do algoritmo de processamento de dados. Nessa etapa ocorre a extração das características dos sinais de entrada, tensões e correntes de fase e neutro (A, B, C e N), e seleção dos dados de falta para testes e treinamentos das RNAs.

Para extração das características, os dados de entrada devem ser submetidos aos processos de interpolação, normalização, cálculo da TWE e energia de Parseval.

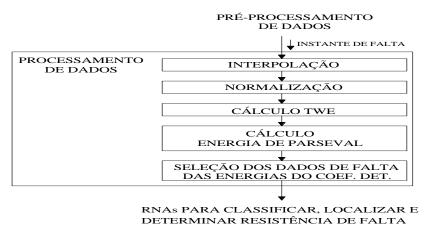


Figura 36 - Estrutura do algoritmo para processamento de dados

Em seguida ocorre a seleção dos dados para treinamento e teste das RNAs. Nessa etapa, de acordo com o instante de falta informado pelo detector de falta, são escolhidos os dados correspondentes a energia do coeficiente detalhe dos sinais de corrente EI e tensão EV registrados nos primeiros 1/8 de ciclo do período de falta. É considerada uma janela fixa com 4 amostras, totalizando 32 amostras para cada cenário de falta. Para melhor visualização, na Figura 37 está ilustrado a seleção dos dados de energia do coeficiente detalhe do sinal de corrente da fase B EIBx, mas essa análise deve ser estendida a todos dados de energias dos coeficientes detalhe EIAx, EIBx, EICx, EINx, EVAx, EVBx, EVCx, EVNx, sendo x=1, ..., 4.

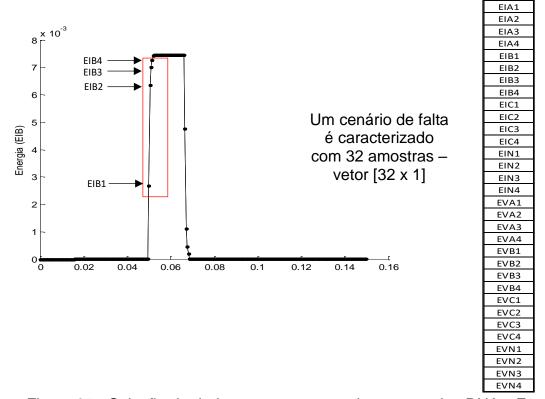


Figura 37 - Seleção de dados para testes e treinamentos das RNAs. Energia do coeficiente detalhe da corrente e tensão

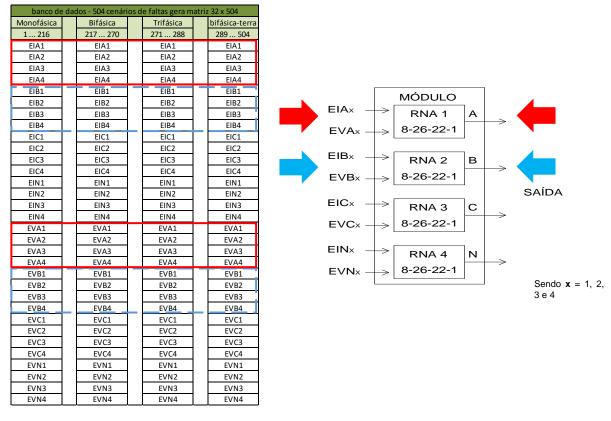
# 4.3.2 APLICAÇÃO DE RNAS PARA CLASSIFICAR, LOCALIZAR FALTA E DETERMINAR RESISTÊNCIAS DE FALTA

As RNA's foram implementadas utilizando o Toolbox Neural Network do Matlab (DEMUTH e BEALE, 2015). Possuem método de aprendizagem supervisionado backpropagation com algoritmo de treinamento Levenberg Marquardt. O treinamento é encerrado quando o erro médio quadrático (MSE) atingir um valor inferior a  $1 \times 10^{-10}$  ou quando forem realizadas 1000 iterações. Deve-se destacar que essas características, referentes as RNAs, também se aplicam aos algoritmos 2 e 3.

Neste algoritmo é proposto o emprego de RNAs modulares. Nesse processo, existem várias RNAs independentes dentro de um único módulo, em que cada RNA realiza uma sub tarefa e a solução geral é dada pela combinação de resultados de cada RNA que estruturam o módulo. Essa metodologia ajuda na precisão dos resultados (PRADHAN, MOHANTY e ROUTRAY., 2006; SAHOO, RAY e PANIGRAHI, 2010 e LOUT e AGGARWAL, 2012).

#### 4.3.2.1 RNAS Modulares Para Classificar Faltas

Conforme Figura 38, o módulo para classificar falta é composto por 4 RNAs. Cada RNA recebe os dados de energia do coeficiente detalhe de uma única fase ou neutro, sendo 4 amostras por tipo de sinal. Os alvos de saída são 1 para condições de falta e 0 para não falta. As RNAs trabalham em paralelo. Todas RNAs possuem arquiteturas iguais e foram determinadas de forma experimental, sendo 8 dados de entrada, 26 neurônios na primeira camada oculta, 22 neurônios na segunda camada oculta e um neurônio na camada de saída. Foi utilizada a função de ativação logsigmóide para todos os neurônios.



	Tipos de falta - Matriz 4 x 504																												
Α	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	
В	1	1	1	1	1	_1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	
С	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	0	
Т	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	

Figura 38 - RNAs modulares para classificação de falta. Cada RNA recebe os dados de uma única fase ou neutro (A, B, C e N)

# 4.3.2.2 RNAS modulares para localizar falta e RNAS modulares para determinar resistências de falta

Os módulos para localização de falta e determinação das resistências de falta também são compostos por 4 RNAs cada, conforme pode ser verificado na Figura

39. Cada RNA recebe os dados de energia do coeficiente detalhe dos sinais de corrente **El** e tensão **EV** de fase e neutro (A, B, C e N), de acordo com o tipo de falta (monofásica, bifásica, trifásica, bifásica-terra).

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

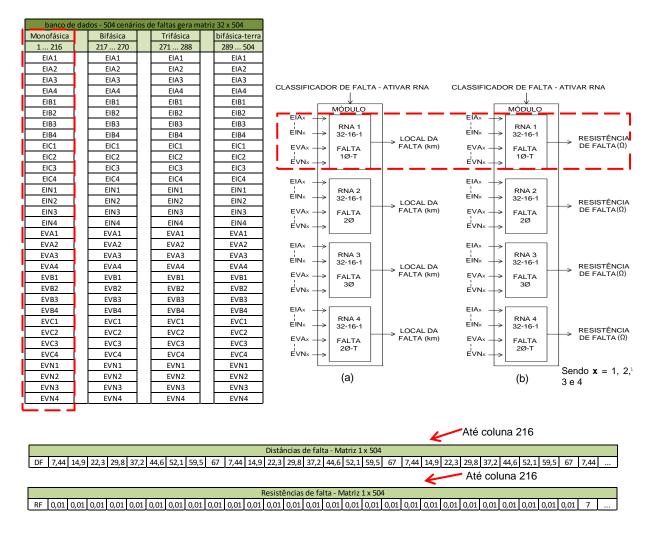


Figura 39 - (a) RNAs modulares para localizar falta; (b) RNAs modulares para determinar resistências de falta. Cada RNA recebe os dados de acordo com o tipo de falta.

# 4.4 ALGORITMO PROPOSTO 2: MÓDULOS FASORIAIS DE CORRENTE E TENSÃO PARA TREINAMENTO E TESTE DE RNAS. DADOS DE UM TERMINAL

Neste item, propõe-se um segundo algoritmo, que seleciona os módulos fasoriais dos sinais de tensão e corrente, registrados em um único terminal nos primeiros 1/4 de ciclo do período de falta, para treinamentos e testes das RNAs.

#### 4.4.1 PROCESSAMENTO DE DADOS:

Na Figura 40 está apresentada a estrutura do algoritmo de processamento de dados.

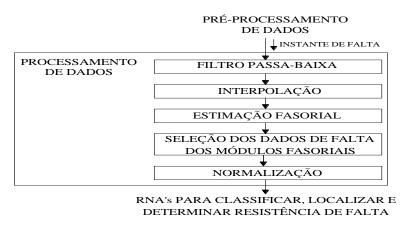


Figura 40 - Estrutura do algoritmo para processamento de dados

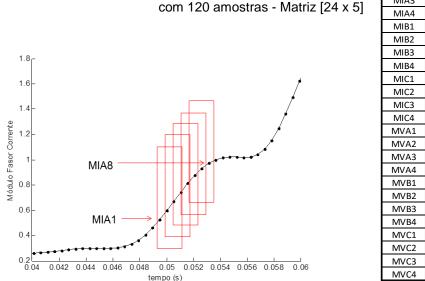
Para extração das características é utilizado um filtro passa-baixa para eliminar os transitórios de altas frequências. O filtro é do tipo Butterworth de 6<sup>a</sup> ordem e frequência de corte de 80 Hz. Como será detalhado a seguir, os parâmetros do filtro foram determinados de forma experimental.

Após a filtragem, os sinais são interpolados e então é realizado o cálculo dos fasores fundamentais, por meio de uma variação do método dos erros mínimos quadrados de Sachdev & Baribeau.

Para treinamento e testes das RNAs foram selecionados no período de falta, amostras referentes aos módulos fasoriais das tensões e correntes nas fases (A, B e C), em janelas com 4 amostras, com passo de deslocamento de 1 amostra durante 1/4 de ciclo. Assim, um cenário de falta é caracterizado com 120 amostras. Antes do

Um cenário de falta é caracterizado

envio das amostras para treinamento e testes das RNAs, elas foram normalizadas considerando o maior valor registrado durante 1/4 de ciclo após o início da falta. Na Figura 41 está ilustrado a seleção módulos fasoriais de corrente da fase A MIAx, mas essa análise deve ser estendida a todos módulos fasoriais de tensão e corrente MIAx, MIBx, MICx, MVAx, MVBx, MVCx, sendo x = 1, ..., 8.



MIA1	MIA2	MIA3	MIA4	MIA5
MIA2	MIA3	MIA4	MIA5	MIA6
MIA3	MIA4	MIA5	MIA6	MIA7
MIA4	MIA5	MIA6	MIA7	MIA8
MIB1	MIB2	MIB3	MIB4	MIB5
MIB2	MIB3	MIB4	MIB5	MIB6
MIB3	MIB4	MIB5	MIB6	MIB7
MIB4	MIB5	MIB6	MIB7	MIB8
MIC1	MIC2	MIC3	MIC4	MIC5
MIC2	MIC3	MIC4	MIC5	MIC6
MIC3	MIC4	MIC5	MIC6	MIC7
MIC4	MIC5	MIC6	MIC7	MIC8
MVA1	MVA2	MVA3	MVA4	MVA5
MVA2	MVA3	MVA4	MVA5	MVA6
MVA3	MVA4	MVA5	MVA6	MVA7
MVA4	MVA5	MVA6	MVA7	MVA8
MVB1	MVB2	MVB3	MVB4	MVB5
MVB2	MVB3	MVB4	MVB5	MVB6
MVB3	MVB4	MVB5	MVB6	MVB7
MVB4	MVB5	MVB6	MVB7	MVB8
MVC1	MVC2	MVC3	MVC4	MVC5
MVC2	MVC3	MVC4	MVC5	MVC6
MVC3	MVC4	MVC5	MVC6	MVC7
MVC4	MVC5	MVC6	MVC7	MVC8

Figura 41 - Seleção de dados para testes e treinamentos das RNAs. Módulos fasoriais de corrente e tensão

Uma vez apresentada a etapa de processamento de dados, vale destacar os critérios adotados para determinar os parâmetros do filtro. A partir dos fasores fundamentais estimados, recuperaram-se as formas de onda no domínio do tempo, e comparou sinais reais com sinais simulados no software ATP, que tentam reproduzir esse sinal real. Conforme Figura 42 e Figura 43, observa-se, que através do filtro de 6ª ordem, obtém-se maior aproximação de comportamento entre sinais reais e sinais simulados, principalmente no período transitório de falta. Foram realizadas as correções de ganho e atraso de fase introduzida pelo filtro.

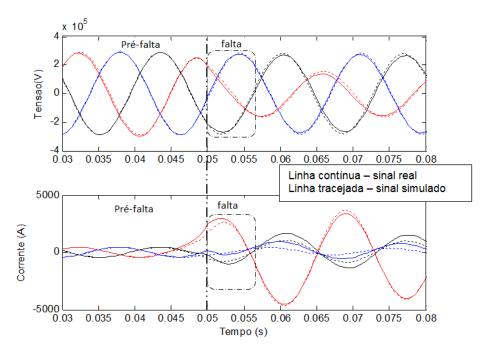


Figura 42 - Sinais recuperados no tempo. Filtro de 2ª ordem e frequência de corte de 100 Hz

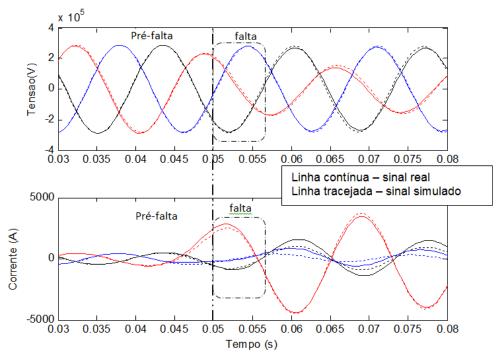


Figura 43 - Sinais recuperados no tempo. Filtro de 6ª ordem e frequência de corte de 80 Hz

# 4.4.2 RNAS PARA CLASSIFICAR, LOCALIZAR FALTA E DETERMINAR RESISTÊNCIAS DE FALTA

Para classificação de falta é utilizada apenas uma RNA com estrutura

convencional, com 24 dados de entrada, 8 neurônios na camada oculta e 4 neurônios na camada de saída. A função de ativação sigmoide é adotada para todos os neurônios.

Essa RNA recebe dados de todos os cenários de falta para treinamento, que estão organizados em uma matriz [24 x 2520], uma vez que, cada cenário é caracterizado por uma matriz [24 x 5] e existem no total 504 cenários de falta. Os alvos de saída são 1 para condições de falta e 0 para não falta. A Figura 44 está apresentada a RNA para classificação de falta.

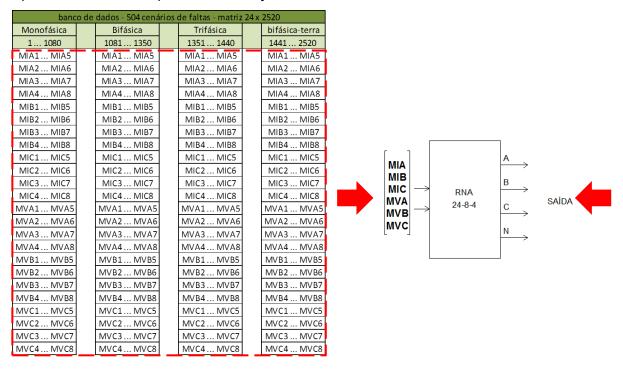


Figura 44 - RNA convencional para classificação de falta. A RNA recebe os dados de todos os cenários de falta.

B 1 1 1 1 1 C 0 0 0 0 0

Tipo de falta - matriz 4 x 2520
A 0 0 0 0 0

A opção por uma RNA convencional para classificação se deve a não utilização do sinal de neutro nesse algoritmo. O sinal de neutro é uma combinação dos sinais trifásicos de fase. Como já discutido através da Figura 42 e Figura 43, o software ATP consegue reproduzir de forma aproximada o comportamento de sinais reais. Assim, a utilização do sinal de neutro é descartada, pois seria mais uma informação, aproximada, o que poderia diminuir na precisão do algoritmo, principalmente na análise de sinais reais.

Já para localização de faltas e determinação da resistência de falta, utilizamse RNAs modulares, que devem ser ativadas de acordo com a saída do módulo de classificação de falta. As RNAs possuem função de ativação sigmoide para os neurônios pertencentes à camada oculta e função de ativação linear para o neurônio da camada de saída. As arquiteturas das RNAs foram determinadas de forma experimental. Na Figura 45 estão apresentadas as RNAS modulares já descritas.

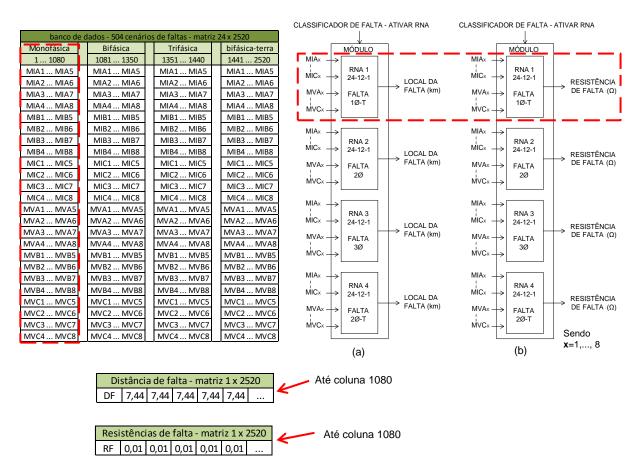


Figura 45 - (a) RNAs modulares para localizar falta; (b) RNAs modulares para determinar resistências de falta. Cada RNA recebe os dados de acordo com o tipo de falta.

# 4.5 ALGORITMO PROPOSTO 3: MÓDULOS FASORIAIS DE CORRENTE PARA TREINAMENTO E TESTE DE RNAS. DADOS DE DOIS TERMINAIS.

Após ser apresentada duas propostas baseadas em algoritmos que utilizam dados de um terminal, implementou-se um novo algoritmo que utiliza dados de dois terminais. Diante disso, propõe-se o algoritmo 3, que utiliza módulos fasoriais somente dos sinais de corrente de fase (A, B e C), registrados nos dois terminais,

nos primeiros 1/4 de ciclo do período de falta, para treinamentos e testes das RNAs.

### 4.5.1 SINCRONIZAÇÃO DOS DADOS

Para o bom desempenho de métodos que usam dados de dois terminais, é necessário que os dados dos dois terminais estejam sincronizados no tempo, pois, isso aumenta a precisão nos processos de localização de falta (SILVEIRA, 2007).

No entanto, pode ocorrer que os dados obtidos em cada terminal, através dos registradores digitais de perturbações, não estejam sincronizados por GPS. Diante disso, é preciso que se tenha um procedimento de sincronização para estabelecer que a variação dos sinais nos dois terminais ocorra ao mesmo tempo.

Vale ressaltar que, o processo de sincronização é necessário somente quando são analisados sinais reais, pelos motivos já citados. Os dados de dois terminais obtidos via ATP já são sincronizados.

A seguir será apresentada a inserção do método de sincronização nas etapas denominadas Pré-processamento e Processamento de Dados, já descritas nos itens 4.2 e 4.4.1 respectivamente.

#### 4.5.1.1 Pré-processamento

A Figura 46 apresenta a etapa de pré-processamento descrito no item 4.2, porém com a inserção do processo de sincronização.

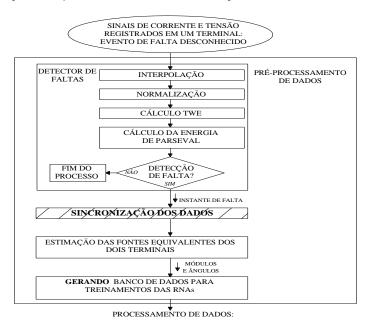


Figura 46 - Pré-processamento de dados: inserção processo de sincronização

O pré-processamento inicia-se com os dados dos dois terminais **S** e **R** sendo submetidos ao detector de falta. Após a detecção da falta são selecionados três ciclos do período pré-falta e seis ciclos do período de falta dos sinais de tensão e corrente, na base de tempo registrado no terminal **S**, sendo rearranjados num único arquivo, formando uma matriz **M** com dimensões [288 x 13]

Em seguida, na etapa de sincronização de dados são extraídos os fasores fundamentais dos sinais de corrente e tensão registrados no período pré-falta, por meio do método dos erros mínimos quadrado.

Ainda nesta etapa, Utilizam-se as tensões VR e correntes IR trifásicas registradas no terminal R, no período pré-falta, para determinar os dados calculados de tensão Vsc e correntes Isc no terminal S, utilizando a teoria de quadripolos, conforme equação (12), onde A, B, C e D parâmetros de sequência positiva da linha de transmissão;

$$\begin{bmatrix} V_{SC} \\ I_{SC} \end{bmatrix} = \begin{bmatrix} A & B \\ C & D \end{bmatrix} \cdot \begin{bmatrix} V_R \\ I_R \end{bmatrix}$$
 (12)

A correção necessária dos ângulos de tensão  $\delta_V$  e corrente  $\delta_I$  no terminal emissor **S** será dada mediante a comparação entre os dados calculados de tensão **Vsc** e correntes **Isc** com os respectivos sinais de tensão **Vs** e corrente **Is** registradas no terminal **S**, dado pela equação (13) e (14):

$$\delta_{\rm V} = {\rm \hat{a}ngulo}\left(\frac{{\rm V}_{\rm SC}}{{\rm V}_{\rm S}}\right)$$
 (13)

$$\delta_{\rm I} = {\rm \hat{a}ngulo}\left(\frac{{\rm I}_{\rm SC}}{{\rm I}_{\rm S}}\right)$$
 (14)

Então os dados corrigidos de tensão **Vc** e corrente **Ic** do terminal **S**, são obtidos de acordo com as equações (15) e (16):

$$V_{C} = V_{S}e^{j\delta_{V}}$$
 (15)

$$I_{C} = I_{S}e^{j\delta_{I}} \tag{16}$$

Esses dados devem ser utilizados para estimar as fontes equivalentes e consequentemente gerar o banco de dados.

#### 4.5.1.2 Processamento de Dados

O algoritmo proposto 3, no que refere a etapa de processamentos de dados, possui método semelhante ao utilizado pelo algoritmo 2, conforme pode-se verificar comparando a Figura 47 e Figura 40. A única divergência, é que os dados dos dois terminais devem ser sincronizados, conforme método descrito no item anterior, e que, são submetidos a esse processo, somente os sinais de corrente, registrados nos terminais **S** e **R**.

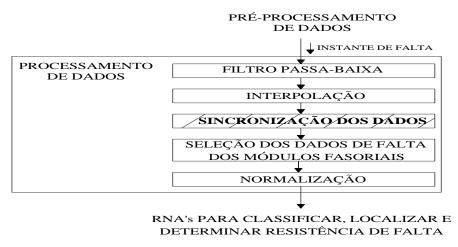


Figura 47 - Estrutura do algoritmo para processamento de dados: Inserção processo sincronização

Assim, são selecionados para testes das RNAs, amostras referentes aos módulos fasoriais das correntes nas fases (A, B e C) nos dois terminais, em janelas com 4 amostras, com passo de deslocamento de 1 amostra durante 1/4 de ciclo, caracterizando um cenário de falta com 120 amostras. Antes do envio das amostras para testes das RNAs, elas foram normalizadas considerando o maior valor registrado durante 1/4 de ciclo após o início da falta.

# 4.5.2 RNAS PARA CLASSIFICAR, LOCALIZAR FALTA E DETERMINAR RESISTÊNCIAS DE FALTA

Para classificação de falta é utilizada apenas uma RNA com estrutura convencional, sendo a função de ativação sigmoide adotada para todos neurônios.

Já para localização de faltas e determinação da resistência de falta, utilizam RNAs Modulares, que possuem função de ativação sigmoide para os neurônios pertencentes a camada oculta e função de ativação linear para o neurônio da camada de saída.

As arquiteturas das RNAs foram determinadas de forma experimental e estão apresentadas na Tabela 6.

Tabela 6 - Arquitetura das RNAs para classificar, localizar falta e determinar resistência de falta: algoritmo proposto 3

Função	Estrutura	Redes	Topologia
Classificação de Faltas:	Convencional	RNA	24-8-4
		RNA 1	24-16-1
I goalização do Foltas:	Modular	RNA 2	24-16-1
Localização de Faltas:	Modulai	RNA 3	24-16-1
		RNA 4	24-16-1
		RNA 1	24-16-1
Resistência de falta:	Modular	RNA 2	24-16-1
Resistencia de faita.	Modulai	RNA 3	24-16-1
		RNA 4	24-16-1

# 4.6 CONSIDERAÇÕES FINAIS

Neste capítulo foram apresentadas três propostas de algoritmos, capazes de detectar, classificar e localizar faltas e determinar resistência de falta, sendo que, os algoritmos 1 e 2 utilizam dados processados obtidos a partir das medições realizadas em um único terminal, enquanto que o algoritmo 3 utiliza dados dos dois terminais.

O algoritmo proposto 1 se baseia na energia dos coeficientes detalhe, extraídos dos sinais de corrente e tensão, para treinamento e testes das RNAs. Nesse método os sinais foram processados considerando transformada wavelet estacionária e energia de Parseval. Já o algoritmo proposto 2 baseia-se nos módulos fasoriais extraídos dos sinais de corrente e tensão a partir do método dos erros mínimos quadrados, enquanto que, o algoritmo 3 utiliza somente módulos fasoriais dos sinais de corrente, obtidos também via método dos erros mínimos quadrados. No algoritmo 3, destacou-se a necessidade de sincronização de dados quando são analisados sinais reais.

### 5 RESULTADOS

Uma vez conhecidos os três algoritmos desenvolvidos, este capítulo é destinado a apresentação dos resultados obtidos.

Para os testes foram considerados sinais reais obtidos por meio registradores de perturbações e sinais simulados obtidos via ATP, sendo que, os sinais simulados consideram as características do sistema elétrico, informadas na Tabela 3.

Os resultados estão apresentados em três itens principais, denominados: resultados do algoritmo proposto 1, resultados do algoritmo proposto 2 e resultados do algoritmo proposto 3.

### 5.1 RESULTADOS DO ALGORITMO PROPOSTO 1

### 5.1.1 SINAIS SIMULADOS

Foram avaliados diferentes cenários de falta obtidos via simulação no software ATP. O módulo para classificação de falta apresentou exatidão para os testes realizados. Na Tabela 7 estão apresentados os resultados. São consideradas condições de falta caso a RNA retorne valor maior ou igual a 0,7. Se a RNA retornar valor menor ou igual a 0,3 não se indica falta.

Tabela 7 - Classificação de faltas

Tipo de	Local da	Local da Resistência falta (km) de falta (Ω)	Saídas Estimadas				
Falta	falta (km)		A	В	С	T	
	6,00	3,00	0,99999	9,273E-13	0,025215	0,99999	
AT	6,00	45,00	0,99999	6,590E-13	0,023777	0,99999	
AI	68,40	3,00	0,99999	3,842E-4	0,088325	0,99999	
	68,40	45,00	0,99999	8,267E-6	0,058539	0,99999	
AB	6,00	3,00	0,99999	0,999999	0,020679	0,00230	
	68,40	3,00	0,99999	1	0,020679	0,00230	
ABC	6,00	3,00	0,99999	1	0,999999	0,00230	
ADC	68,40	3,00	0,99999	1	0,999976	0,00230	
	6,00	3,00	0,99999	1	0,022744	0,99999	
ABT	6,00	45,00	0,99999	1	0,021763	0,99999	
	68,40	3,00	0,99999	1	0,039764	0,99999	
	68,40	45,00	0,99999	1	0,0294971	0,99999	

Os módulos para localizar falta e determinar resistência de falta também foram testados, considerando os mesmos cenários de faltas aplicados ao módulo de classificação. Os resultados estão na Tabela 8, sendo que, apresentam erros inferiores a 3% para o módulo de localização de falta e inferiores a 4 % para o módulo de determinação de resistência de falta.

Tabela 8 - Localização de falta e determinação da resistência de falta: algoritmo proposto 1

Tipo	Local da	Local	Erro	Resistência	Resistência	Erro
de	falta	Estimado(	Relativo	de falta $(\Omega)$	Estimada	Relativo
Falta	(km)	km)	(%)		$(\Omega)$	(%)
	6,00	6,17	2,83	3,00	3,05	1,67
AT	6,00	6,16	2,67	45,00	44,98	0,04
	68,40	68,30	0,15	3,00	2,99	0,33
	68,40	68,35	0,07	45,00	44,98	0,04
AB	6,00	6,02	0,33	3,00	3,03	1,00
Ab	68,40	68,36	0,06	3,00	3,01	0,33
ABC	6,00	6,02	0,33	3,00	2,92	2,67
ABC	68,40	68,35	0,07	3,00	3,04	1,33
	6,00	6,01	0,17	3,00	2,89	3,67
ABT -	6,00	6,01	0,17	45,00	45,07	0,16
	68,40	68,40	0,00	3,00	2,98	0,67
	68,40	68,40	0,00	45,00	45,00	0,00

Para o erro relativo considerou a seguinte formulação:

$$erro relativo = \frac{|valor exato - valor aproximado|}{valor exato}$$
(17)

## **5.1.2 SINAIS REAIS E DISCUSSÕES**

As RNAs Modulares não convergiram quando foram testados sinais reais. As possíveis causas de divergências nos resultados podem ser explicadas a partir da Figura 48, onde estão representados um sinal real e um sinal simulado no software ATP que tenta reproduzir o sinal real. Foram considerados os parâmetros informados pela concessionária, como local de falta, resistência de falta, parâmetros de linha e impedâncias das fontes equivalentes. O fluxo de potência foi estimado a partir do sinal real, considerando o período pré-falta.

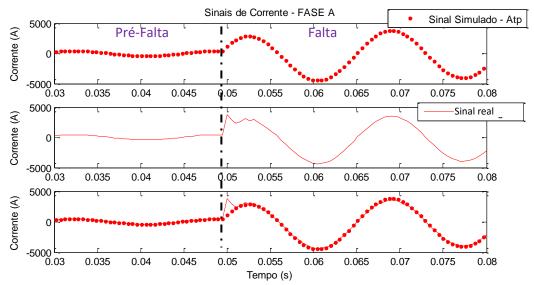


Figura 48 - a) Sinal simulado (ATP); b) Sinal real; c) Sobreposição dos sinais.

Na Figura 48-C, verifica-se que no período de falta o sinal simulado não possui a mesma forma de onda do sinal real, possivelmente por não contemplar no ATP, algumas influências, como, resistência variável durante o curto-circuito e erros percentuais de transformadores de corrente e potencial.

Essa diferença de comportamento é também verificada nas energias dos coeficientes detalhe dos sinais. A Figura 49, apresenta os coeficientes detalhe correspondentes aos sinais de corrente representados na Figura 48.

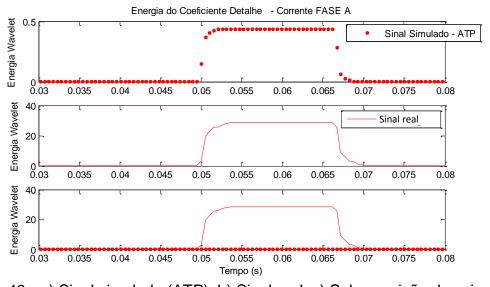


Figura 49 - a) Sinal simulado (ATP); b) Sinal real; c) Sobreposição dos sinais.

No entanto, pode-se verificar através da Figura 49-A e B, que a energia dos coeficientes detalhe do sinal simulado e do sinal real possuem a mesma forma de

onda (aproximadamente retangular) e apenas amplitudes diferentes. Então, investigou-se qual efeito causaria, se essas ondas fossem normalizadas, considerando o máximo valor registrado durante os 1/4 do período de falta.

Diante disso, foram normalizadas as energias dos coeficientes detalhe dos sinais de correntes e tensões trifásicas, apresentadas respectivamente na Figura 50 e Figura 51. Para melhor visualização, as figuras apresentam os comportamentos da onda somente durante o período de falta (a partir de 0,05 s).

Conforme Figura 50, verificou-se que formas de onda das energias dos coeficientes detalhe dos sinais de corrente alcançaram proximidade de valores depois da normalização.

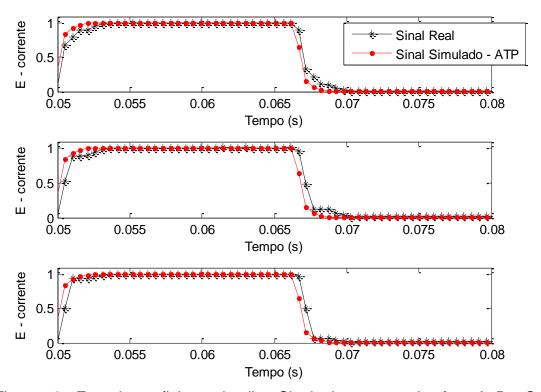


Figura 50 - Energia coeficiente detalhe: Sinais de corrente das fase A, B e C

No entanto, quando são analisados os sinais de tensão, os comportamentos são muito diferentes, principalmente fases A e C, conforme pode-se verificar na Figura 51.

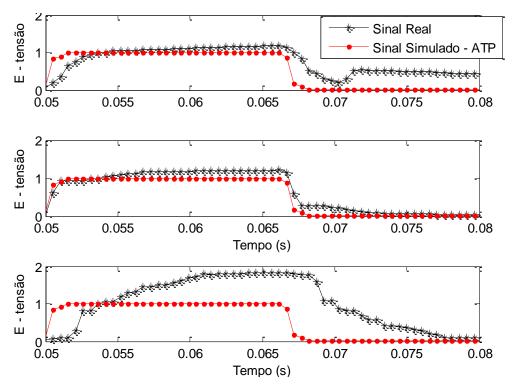


Figura 51 - Energia coeficiente detalhe: Sinais de tensão das fases A, B e C

Dessa forma, conclui-se que os padrões gerados pelo software ATP, mesmo após a etapa de processamento de dados, não possuem a mesma dinâmica dos sinais reais. Isso pode explicar a não convergência para metodologia desenvolvida quando são testados sinais reais. Como ficará evidente no capítulo 6, uma das propostas de continuidade é verificar a possibilidade de uma modelagem mais robusta do sistema elétrico, de forma a permite que os resultados simulados busquem representar com maior precisão sinais reais.

### 5.2 RESULTADOS DO ALGORITMO PROPOSTO 2

## 5.2.1 SINAIS SIMULADOS

As RNAs foram testadas considerando os mesmos cenários de falta apresentados na Tabela 7 e Tabela 8, obtidos através do software ATP. O módulo para classificar faltas identificou os diferentes tipos de falta com 100% de acerto. Os módulos para localizar apresentaram erros relativos inferiores a 4%, enquanto que, os módulos para determinar resistência de falta apresentaram erros relativos inferiores a 5%, com exceção de uma falta  $\bf AT$ , ocorrida a 68,4 km do termina  $\bf S$  e com resistência de falta de 3  $\bf \Omega$ , que apresentou erro relativo de 19%, o que em

valores absolutos corresponde uma diferença de 0,58  $\Omega$ , já que o módulo apresentou resultado de 2,42  $\Omega$ .

## **5.2.2 SINAIS REAIS E DISCUSSÕES**

Para sinais reais as RNAs também convergiram. Os resultados estão apresentados na Tabela 9. Vale ressaltar que, as RNAs apresentaram resultados precisos, testadas diante de sinais reais mesmo sendo treinadas com sinais simulados. Para alcançar esses resultados foi um processo lento e somente atingido após várias tentativas.

Tabela 9 - Sinais reais: algoritmo proposto 2

Tipo de Falta	Fluxo de Potência			Local da falta (km)		Resistência de falta (Ω)	
	Terminal Emissor	Terminal Receptor	Real	Estimado	Real	Estimado	
AT	292,059 ∠ 23,9° kV	290,158 ∠ 13,9° kV	60	60,95	4,24	4,93	
BT	291,447 ∠ -197,6° kV	289,815 ∠ -203,6° kV	54	54,92	3,75	5,66	

Apesar da convergência do algoritmo 2, neste ponto cabe uma discussão a seu respeito, cujo objetivo é explicar porque esse algoritmo convergiu diante de sinais reais.

Quando essa discussão foi realizada referente ao algoritmo 1, mostrou que, a não convergência aconteceu, porque os padrões gerados pelo ATP, mesmo após a etapa de processamento não conseguiam reproduzir sinais reais de forma adequada para treinamentos das RNAs.

Já através do algoritmo 2, verificou-se que após a etapa de processamento de dados, no período mais próximo de início da falta, os módulos fasoriais obtidos de um sinal simulado no software ATP tendem a ter o mesmo comportamento do seu respectivo sinal real, ou seja, há a sobreposição das formas de onda, quando são comparados os módulos fasorias de um sinal real e de um sinal simulado que tenta reproduzir esse sinal real, o que explica a convergência desse método.

Para ilustrar, na Figura 52 e na Figura 53, estão apresentados respectivamente os módulos fasoriais de tensão e corrente, de um sinal real e de um sinal simulado. Esses módulos fasoriais foram extraídos dos sinais apresentados na Figura 48. Para melhor visualização estão apresentados somente os módulos obtidos do período de falta (a partir de 0,05 s).

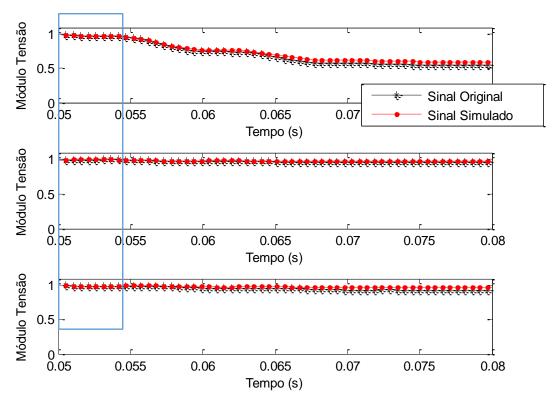


Figura 52 - Módulos Fasoriais sinais de tensão: Fases A, B e C

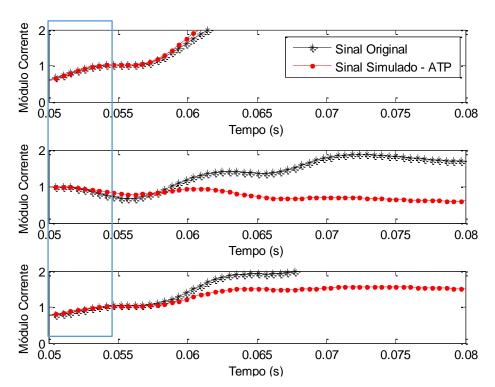


Figura 53 - Módulos Fasoriais sinais de corrente: Fases A, B e C. Comportamento semelhante principalmente no período de início da falta

Cabe salientar que a mesma análise deve ser realizada em outros sinais reais para verificar se os módulos fasoriais de sinais reais e simulados terão

comportamentos semelhantes em outros registros. O que há de claro é que se o ATP conseguir reproduzir o comportamento do sinal real, as RNAs apresentarão bons resultados.

### 5.3 RESULTADOS DO ALGORITMO PROPOSTO 3

#### 5.3.1 SINAIS SIMULADOS E SINAIS REAIS

O algoritmo 3 também foi testado diante de diferentes cenários de falta obtidos via simulação no software ATP e também através de sinais reais.

Para o processo de classificação o método identificou os diferentes tipos de faltas com 100% de acerto.

Já os módulos de localização de falta apresentaram resultados com erros relativos inferiores a 6%, enquanto que, os módulos para determinar resistência de falta apresentaram erros relativos inferiores a 17%, o que corresponde uma diferença de  $0.5~\Omega$  entre o valor desejado e o obtido pela RNA. A Tabela 10 contém os resultados para a localização e determinação de resistência de falta.

Tabela 10 - Localização de falta e determinação da resistência de falta: algoritmo proposto 3

Tipo de Falta	Local da falta (km)	Local Estimado (km)	Erro Relativo (%)	Resistência de falta (Ω)	Resistência Estimada (Ω)	Erro Relativo (%)
	6,00	5,73	4,50	3,00	2,70	10,00
AT	6,00	6,36	6,00	45,00	46,44	3,20
Ai	68,40	68,54	0,20	3,00	3,50	16,67
	68,40	68,35	0,07	45,00	45,83	1,84
AB	6,00	6,24	4,00	3,00	3,32	10,67
Ab	68,40	68,96	0,82	3,00	2,63	12,33
ABC	6,00	6,13	2,17	3,00	3,23	7,67
ABC	68,40	68,07	0,48	3,00	3,11	3,67
	6,00	5,90	1,67	3,00	3,05	1,67
ABT	6,00	6,08	1,33	45,00	45,02	0,04
	68,40	68,29	0,16	3,00	2,69	10,33
	68,40	68,44	0,06	45,00	45,34	0,76

Para sinais reais as RNAs também convergiram. Os resultados estão apresentados na Tabela 11.

Tabela 11 - Sinais reais: algoritmo proposto 3

Tipo de Falta	Fluxo de Potência			Local da falta (km)		Resistência de falta (Ω)	
	Terminal Emissor	Terminal Receptor	Real	Estimado	Real	Estimado	
AT	292,059 ∠ 21,9° kV	286,036∠ 13,3° kV	60	58,12	4,24	5,65	
BT	291,447 ∠ -195,3° kV	285,155∠ -200° kV	54	55,31	3,75	18,05	

Novamente, é importante destacar que, os ajustes de bias e pesos definidos nos treinamentos das RNAs, atenderam simultaneamente as situações de falta reais e simuladas. Os motivos para a convergência desse algoritmo são os mesmos apresentados referentes ao algoritmo 2, pois esse algoritmo também utiliza módulos fasoriais para treinamentos das RNAs.

# 5.4 CONSIDERAÇÕES FINAIS

Neste capítulo foram apresentados os resultados obtidos através dos três algoritmos desenvolvidos.

Todos os algoritmos apresentaram bons resultados quando foram testados considerando cenários de faltas obtidos a partir do software ATP, sendo que, o algoritmo proposto 1 apresentou menores erros relativos entre os três métodos.

Quando os algoritmos foram testados considerando sinais reais, apenas os algoritmos propostos 2 e 3 apresentaram convergência nos resultados, sendo que, as RNAs para classificação de indicaram corretamente os diferentes tipos de faltas analisados. No que refere a localização e a resistência de falta, o algoritmo proposto 2, obteve respostas mais próximas dos valores desejados, com diferenças inferiores a 950 m na localização de falta e 1,91 Ω na determinação da resistência de falta.

É importante destacar que, para os algoritmos 2 e 3, os ajustes de bias e pesos, definidos nos treinamentos das RNAs, atenderam simultaneamente duas condições diferentes, que são situações de falta reais e faltas simuladas via ATP, e conforme descrito, apresentando convergência em ambas. Esse processo foi lento e alcançado após várias tentativas.

Já o algoritmo proposto 1, teve os ajustes de bias e pesos para atender somente a condições de faltas simuladas, uma vez que não apresentou convergência para sinais reais. Esse processo foi mais simples e alcançado após poucas tentativas.

Também foi realizada uma discussão a fim de elucidar os motivos pelos quais o algoritmo 1 não convergiu e os algoritmos 2 e 3 convergiram, diante de sinais reais. Para isso, foi reproduzido no ATP uma situação de falta, com as mesmas características de um sinal real registrado. Sucintamente, conseguiu-se através dos algoritmos 2 e 3, mostrar que os módulos fasoriais extraídos, do sinal simulado, tinham proximidade de valores, do sinal real, o que explica a convergência já que as RNAs foram treinadas com sinais mais próximos da realidade. No entanto, o algoritmo 1 não conseguiu que os valores de energia dos coeficientes detalhe do sinal real e simulado, tivessem o mesmo comportamento.

# 6 CONCLUSÃO

Neste trabalho procurou-se descrever sobre algumas técnicas de processamento de dados e inteligência computacional, assim como, aplicação dessas técnicas em algoritmos capazes de realizar funções de detecção, classificação e localização de falta, e determinar a resistência de falta em linhas de transmissão.

Diante disso, são propostos três algoritmos aplicáveis à qualquer sistema elétrico modelado por duas fontes equivalentes interligadas por uma linha de transmissão, que a partir dos dados registrados em um ou dois terminais, devem detectar o instante do início da falta, classificá-la quanto ao tipo (fase-terra, trifásica, bifásica, bifásica-terra), localizá-la, informando a que distância em quilômetros a falta ocorre e qual o valor da resistência associada a falta.

Para alcançar esse objetivo, iniciou-se um estudo que buscou encontrar na literatura, as principais publicações que cercavam o problema, em que ficou constatado que a transformada wavelet e redes neurais artificias são ferramentas amplamente utilizadas para detecção, classificação e localização de faltas e determinação de resistências de falta em linhas de transmissão.

Assim, neste trabalho a transformada wavelet estacionária em seu primeiro nível de decomposição, em conjunto com a energia de Parseval, é utilizada no processo de detecção de falta, enquanto que as redes neurais artificiais com topologia Multilayer Perceptron (MLP), método de aprendizagem supervisionado backpropagation e algoritmo de treinamento Levenberg Marquardt, é utilizada nos processos de classificação e localização de faltas, e determinação de resistências de falta.

Apesar de basear-se nessas ferramentas, outras técnicas de processamento de dados, como filtragem, interpolação e o método dos erros mínimos quadrados são também utilizados nos algoritmos. Dentro desses métodos, destaca-se o método dos erros mínimos quadrados, que é utilizado para extrair os fasores fundamentais de tensão e corrente dos sinais registrados.

Com relação a parte computacional, os algoritmos foram implementados no software Matlab. Uma prática computacional adotada foi a opção por redes neurais modulares.

Os três algoritmos implementados possuem uma etapa em comum,

denominada pré-processamento. Essa etapa é responsável por identificar o instante de início da falta, por determinar módulos e ângulos das fontes equivalentes e por gerar os cenários de falta através do software ATP, necessários para treinamento das redes neurais artificiais.

Após detectada a falta e gerado o banco de dados para treinamento das RNAs, os dados a serem analisados podem ser enviados para as RNAs dos algoritmos propostos, sendo que, para treinamento e teste das RNAs, o algoritmo 1 propõe nova metodologia, que seleciona as energias dos coeficientes detalhe de wavelet, extraídos dos sinais de tensões e correntes trifásicos, registrados em um único terminal nos primeiros 1/8 de ciclo do período de falta. Já o algoritmo 2 seleciona os módulos fasoriais dos sinais de tensão e corrente, registrados também em um único terminal nos primeiros 1/4 de ciclo do período de falta. E por fim, propõe-se o algoritmo 3, que utiliza módulos fasoriais somente dos sinais de corrente, registrados nos dois terminais, nos primeiros 1/4 de ciclo do período de falta, para treinamentos e testes das RNAs.

Destacam-se os resultados alcançados por esses algoritmos. Quando os três algoritmos foram testados considerando cenários de faltas obtidos a partir do software ATP, as RNAs para classificação de falta apresentaram resultados com 100% de acerto. As RNAs para localização de faltas e determinar resistência de falta dos três algoritmos também apresentaram resultados precisos, sendo que o algoritmo 1 apresentou menores erros relativos.

No entanto, quando os algoritmos foram testados considerando sinais reais, apenas os algoritmos propostos 2 e 3 apresentaram convergência nos resultados para as RNAs de classificação e localização de falta, e determinação resistência de falta, sendo que, o algoritmo proposto 2, obteve melhores resultados.

Nesse ponto é importante destacar que, para os algoritmos 2 e 3, que convergiram diante de sinais reais e sinais simulados, há um único ajuste de bias e pesos, definidos para atender simultaneamente as duas condições. Outro ponto que deve ser enfatizado em relação aos algoritmos, é que o algoritmo 1 é um novo método, que utiliza dados processados de altas frequências, uma vez que os dados enviados para testes e treinamentos das RNAs, são as energias associadas aos coeficientes detalhes obtidos via TWE, enquanto que, os algoritmos 2 e 3 utilizam dados de baixa frequência para testes e treinamentos das RNAs, uma vez que são

selecionados os módulos fasorias fundamentais dos sinais obtidos a partir do método dos erros mínimos quadrados.

Também foi realizada uma discussão a respeito da convergência ou não dos algoritmos, comparando gráficos de dados processados, de um sinal real e de um simulado no ATP com mesmas características. Verificou-se que a não convergência do algoritmo 1 se deve à diferença de comportamento, quando são comparadas as energias dos coeficientes wavelet dos sinais reais e sinais simulados. Para o algoritmo 2 e 3, quando comparados os módulos fasoriais de sinais reais e sinais simulados, verificou que nos primeiros 1/4 ciclo do período de falta, as duas ondas tendem a ter os mesmos valores, o que explica a convergência desses algoritmos.

### 6.1 PROPOSTAS PARA TRABALHOS FUTUROS

Nesse trabalhou mostrou-se que as RNAs são ferramentas que podem ser aplicadas em diferentes funções e que o seu bom desempenho está ligado a qualidade de seu banco de dados, que deve comtemplar as mais diversas condições de falta, e também ao método de processamento de dados, que tratam os sinais registrados, adequando-os para treinamentos das RNAs.

Dessa maneira, os trabalhos futuros devem buscar contemplar no software de simulação, simulações mais robustas que busquem reproduzir com proximidade eventos reais de falta e também investigar novos métodos de processamento de dados que busquem aproximar os dados de situações de faltas reais de faltas simuladas.

De forma pontual:

- É conhecido que, resistência variável durante a falta, capacitâncias shunt das linhas de transmissão, erros percentuais de transformadores de correntes e tensão e resistência do solo são alguns fatores que influenciam nos processos de localização de falta. Uma investigação para verificar a possibilidade de contemplar esses fatores em simulações deve ser realizada.
- Os algoritmos que melhor responderam diante de sinais reais utilizam dados de baixas frequências por meio de módulos fasoriais fundamentais. Assim, deve ser investigado a utilização de dados de baixas frequências, porém, obtidos via TWE, conhecidos como coeficientes aproximação, para treinamentos e testes de RNAs.

#### 7 BIBLIOGRAFIA

AMORIM, H. P.; HUAIS, L. Faults Location in Transmission lines through Neural Networks. IEEE/PES Transmission e Distribuition Conference e Exposition: Latin America. [S.I.]: [s.n.]. October 2004.

CHEN, Z.; MAUN, J.-C. Artificial Neural Network Approach to Single-Ended Fault Locator for Transmission Lines. IEEE Transactions on Power Systems, v. 15, february 2000.

COSTA, F. B. Fault-Induced Transient Detection Based on Real-Time Analysis of the Wavelet Coefficient Energy. IEEE Transactions on Power Delivery, v. 29, n. 1, february 2014.

DEMUTH, H.; BEALE, M. Neural Network Toolbox User'S Guide, The Math Work. [S.I.]: [s.n.], 2015.

FILHO, O. D. Um algoritmo para Detecção, Localização e Classificação de Distúrbios na Qualidade de Energia Elétrica Utilizando a Transformada wavelet. Tese apresentada a escola de engenharia de São Carlos, da universidade de São Paulo. [S.I.]. Maio, 2007.

GRACIA, J.; MAZÓN, A. J.; ZAMORA, I. Best ANN Strutuctures for Fault Location in Single and Double-Circuit Transmission Lines. IEEE Transactions on Power System, v. 20, n. 4, October 2005.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H. Neural Network Design. BOSTON: [s.n.], 1996. Cap. 11 E 12.

HECHT-NIELSEN, R. Neurocomputing, University of California, San Diego., 1989.

JIANG, 1. J.-A. et al. A Hybrid Framework for Fault Detection, Classification and Location - Part 1: Concept, Structure and Methodology. IEEE Transactions on Power Delivery, v. 26, July 2011.

JÚNIO, G. R. G. Detecção e Classificação Automática de Faltas a partir de Registros Oscilográficos. Projeto fim de curso II, Universidade Federal de Minas Gerais. [S.I.]. 2009.

KALAM, M. A.; JAMIL, M.; ANSARI, A. Q. Wavelet based ANN Approach for Fault Location on a Transmission Line. IEEE, New Delhi Conference. [S.I.]: [s.n.]. 2010.

LIPPMANN, R. An Introduction to computin with neural nets. IEEE, v. 4, n. 2, p. 4-22, 1987.

LOUT, K.; AGGARWAL, R. K. A Feedforward Artificial Neural Network Approach to Fault Classification and Location on a 132 kV Transmission Line Using Current Signals Only. IEEE, Universities Power Engineering Conference (UPEC). [S.I.]: [s.n.]. 2012.

MARTÍN, F.; AGUADO, J. A. Wavelet-Based ANN Approach for Transmission Line Protection. IEEE Transactions on Power Delivery, v. 18, n. 4, October 2003.

MATSUNAGA, V. Y. Curso de Redes Neurais Utilizando o Matlab. Belém, Brasil. 2012.

MENEZES, M. P. Classificação E Localização de Faltas em Linha de Transmissão Usando Diferentes Arquiteturas de Redes Neurais Artificiais. Dissertação de mestrado submetido a Escola Politécnica da Universidade de São Paulo. São Paulo. 2008.

MISITI, M. et al. Wavelet Toolbox User'S Guide, The Math Work. [S.I.]: [s.n.], 2015.

NGAOPITAKKUL, A.; POTHISARN, C. Discrete Wavelet Transform and Backpropagation neural network algorithm for fault location on single-circuit Transmission Line. Proceedings of the 2008 IEEE Internacional Conference on Robotics and Biomimetics Bangkok. Thailand: [s.n.]. February, 2009.

PANIGRAHI, B. K.; MAHESHWARI, R. P. Transmission Line Fault Detection and Classification. IEEE, Proceedings of Icetect. [S.I.]: [s.n.]. 2011.

PEREIRA, C.; CRUZ, F. D. Análise do Comportamento Estático e Dinâmico dos Filtros Digitais de

Mínimos Quadrados na Proteção de Linhas de Transmissão. XV SNPTEE, Foz do Iguaçu, 1999.

PRADHAN, A. K.; MOHANTY, S. R.; ROUTRAY., A. Neural Fault Classifier for Transmission Line Protection - A Modular Approach. IEEE, Department of Electrical Engineering. Kharagpur, Indian: [s.n.]. 2006.

RODRIGUES, L. C. P. Técnicas para a Detecção, Classificação e Localização no Tempo das Variações de Tensão de Curta e Longa Duração. Dissertação submetida à Escola de Engenharia de São Carlos, da Universidade de São Paulo. São Carlos. 2008.

ROSENBLATT, F. The perceptron: A perceiving and recognizing automaton. Report 85-460-1, Project PARA, Cornell Aeronautical Lab. Ithaca, NY. 1957.

SAHOO, S.; RAY, P.; PANIGRAHI, B. K. A Computational Intelligence Approach for Fault Location in Transmission Lines. IEEE, Power Electronics, Drives and Energy Systems (PEDES) & Power India, 2010 Joint International Conference on. [S.I.]: [s.n.]. 2010.

SALIM, R. H. et al. Hybrid Fault Diagnosis Scheme Implementation for Power Distribution Systems Automation. IEEE Transactions on Power Delivery, v. 23, n. 4, October 2008.

SARAVANABABU, K.; BALAKRISHNAN, P.; SATHIYASEKAR, K. Transmission Line Faults Detection, Classification, and Location Using Discrete Wavelet Transform. IEEE International Conference on Power, Energy and Control (ICPEC). [S.I.]: [s.n.]. 2013.

SILVA, K. M.; SOUSA, B. A.; BRITO, N. S. D. Fault Detection and Classification in Transmission Lines Based on Wavelet Transform an ANN. IEEE, Transactions on Power Delivery, v. 21, October 2006.

SILVEIRA, E. G. D. Localização de Faltas em Linhas de Transmissão: Desenvolvimento de novos Algoritmos e Implementação de Sistema Computacional para Aplicações Práticas. Tese de Doutorado, Universidade Federal de Minas Gerais. [S.I.]. 2007.

SOUZA, S. M. D.; SILVA, A. P. A. D.; A.C.S.LIMA. Voltage and Current Patterns for Fault Location in Transmission Lines. IEEE, Proceedings of International Joint Conference on Neural Networks. Orlando, Florida, USA: [s.n.]. August, 2007.

SU, S.; X.DUAN; ZENG., X. Atp-based automated fault simulation.. IEEE Transactions on Power Delivery, v. 23, n. 3, 2008.

TEKLIC, L.; FILIPOVIC-GRCIC, B.; I.PAVICIC. Artificial Neural Network Approach for Locating Faults in Power Transmission System. IEEE, EuroCon. [S.I.]: [s.n.]. july, 2013.