



Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciências

Faculdade de Engenharia

Tiago Fernandes Moraes

Localização de faltas de curta duração em redes de distribuição

Rio de Janeiro

2014

Tiago Fernandes Moraes

Localização de faltas de curta duração em redes de distribuição



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Controle e Automação.

Orientadores:

Prof. Dr. Lisandro Lovisolo

Prof. Dr. Luis Fernando C. Monteiro

Rio de Janeiro

2014

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

M828 Moraes, Tiago Fernandes.

Localização de faltas de curta duração em redes de distribuição / Tiago Fernandes Moraes. - 2014.

114 f.

Orientador: Lisandro Lovisolo, Luis Fernando C. Monteiro.
Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.

1. Engenharia Eletrônica. 2. Energia elétrica - Distribuição - Dissertações. I. Lovisolo, Lisandro. II. Monteiro, Luis Fernando C. III. Universidade do Estado do Rio de Janeiro. IV. Título.

CDU 621.316

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta dissertação, desde que citada a fonte.

Assinatura

Data

Tiago Fernandes Moraes

Localização de faltas de curta duração em redes de distribuição

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de concentração: Controle e Automação.

Aprovado em: 30 de abril de 2014

Banca Examinadora:

Prof. Dr. Lisandro Lovisolo (Orientador)

Faculdade de Engenharia - UERJ

Prof. Dr. Luis Fernando C. Monteiro (Orientador)

Faculdade de Engenharia - UERJ

Profa. Dra. Marley Vellasco

Pontifícia Universidade Católica do Rio de Janeiro

Prof. Dr. Guilherme Rolim

Universidade Federal do Rio de Janeiro

Rio de Janeiro

2014

AGRADECIMENTO

A Deus, em primeiro lugar, por todas as ricas oportunidades que me concedeu ao longo desta caminhada e sem Ele não seria possível cumprir mais uma etapa na minha vida.

À minha noiva Tarcila, por sempre estar ao meu lado me apoiando e incentivando ao longo desta jornada.

Aos meus amados pais, que sempre me incentivaram e me apoiaram, nunca medindo esforços para que este trabalho fosse concretizado.

Ao meu querido irmão Lucas, pelo carinho que sempre recebi dele.

Aos familiares e amigos, que de uma forma ou de outra me apoiaram nesta jornada. Em especial, aos meus primos Elber e Valquíria, pelo carinho e incentivo.

Aos orientadores, professor Lisandro Lovisolo e Luis Fernando, pela dedicação em suas orientações durante o transcorrer desta pesquisa. Não se esquecendo dos imperdíveis momentos de descontração no “PROSAICO ostentação”.

Aos amigos e professores do PEL que, de algum modo, colaboraram, direta ou indiretamente, com esta pesquisa e pelas intermináveis conversas político-filosóficas.

À UERJ, à Faculdade de Engenharia, ao departamento de pós-graduação em engenharia eletrônica e aos seus funcionários por garantirem uma infra-estrutura adequada para realizar esse trabalho.

À CAPES por subsidiar esta pesquisa e acreditar que a base para o desenvolvimento do país é a formação dentro das universidades.

“O temor ao Senhor é o princípio da sabedoria”

BÍBLIA. A.T. Provérbios de Salomão. Mundo Bíblico.

Versão 1, Cap. 1, v. 7.

RESUMO

MORAES, Tiago Fernandes. *Localização de Falhas de Curta Duração em Redes de Distribuição*. 2014. 114 f. Dissertação (Mestrado em Engenharia Eletrônica) - Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro, 2014.

O objetivo deste trabalho é contribuir com o desenvolvimento de uma técnica baseada em sistemas inteligentes que possibilite a localização exata ou aproximada do ponto de origem de uma Variação de Tensão de Curta Duração (VTCD)(gerada por uma falta) em um sistema de distribuição de energia elétrica. Este trabalho utiliza um Phase-Locked Loop (PLL) com o intuito de detectar as faltas. Uma vez que a falta é detectada, os sinais de tensão obtidos durante a falta são decompostos em componentes simétricas instantâneas por meio do método proposto. Em seguida, as energias das componentes simétricas são calculadas e utilizadas para estimar a localização da falta. Nesta pesquisa, são avaliadas duas estruturas baseadas em Redes Neurais Artificiais (RNAs). A primeira é projetada para classificar a localização da falta em um dos pontos possíveis e a segunda é projetada para estimar a distância da falta ao alimentador. A técnica aqui proposta aplica-se a alimentadores trifásicos com cargas equilibradas. No desenvolvimento da mesma, considera-se que há disponibilidade de medições de tensões no nó inicial do alimentador e também em pontos esparsos ao longo da rede de distribuição. O banco de dados empregado foi obtido através de simulações de um modelo de alimentador radial usando o programa PSCAD/EMTDC. Testes de sensibilidade empregando validação-cruzada são realizados em ambas as arquiteturas de redes neurais com o intuito de verificar a confiabilidade dos resultados obtidos. Adicionalmente foram realizados testes com faltas não inicialmente contidas no banco de dados a fim de se verificar a capacidade de generalização das redes. Os desempenhos de ambas as arquiteturas de redes neurais foram satisfatórios e demonstram a viabilidade das técnicas propostas para realizar a localização de faltas em redes de distribuição.

Palavras-chave: Redes Neurais Artificiais. Variação de Tensão de Curta Duração. VTCD. Phase-Locked Loop. PLL. Sistema de Distribuição de Energia Elétrica. PSCAD/EMTDC.

ABSTRACT

MORAES, Tiago Fernandes. *Location of the Short Duration Fault in a Distribution Power Grid*. 2014. 114 f. Dissertação (Mestrado em Engenharia Eletrônica) - Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro, 2014.

The aim of this work is to contribute to the development of a technique based on intelligent systems that allows the accurate location of the Short Duration Voltage Variations (SDVV) origin in an electrical power distribution grid. Once the fault is detected via a Phase-Locked Loop (PLL), voltage signals acquired during the fault are decomposed into instantaneous symmetrical components by the proposed method. Then, the energies of the symmetrical components are calculated and used to estimate the fault location. In this work, two systems based on Artificial Neural Networks (ANN) are evaluated. The first one is designed to classify the fault location into one of predefined possible points and the second is designed to estimate the fault distance from the feeder. The technique herein proposed is applied to three-phase feeders with balanced loads. In addition, it is considered that there is availability of voltage measurements in the initial node of the feeder and also in sparse points along the distribution power grid. The employed database was made using simulations of a model of radial feeder using the PSCAD / EMTDC program. Sensitivity tests employing cross-validation are performed for both approaches in order to verify the reliability of the results. Furthermore, in order to check the generalization capability, tests with faults not originally contained in the database were performed. The performances of both architectures of neural networks were satisfactory and they demonstrate the feasibility of the proposed techniques to perform fault location on distribution grids.

Key-Words: Artificial neural network. Short Duration Voltage Variations (SDVV). phase-locked loop. PLL. Electrical Power Distribution System. PSCAD/EMTDC.

LISTA DE FIGURAS

Figura 1 - Estatísticas de ocorrência dos tipos de VTCD.....	19
Figura 2 - Sinais de tensão e corrente referente a falta do tipo AB de 10Ω com 25ms de duração e origem no ponto 01.	31
Figura 3 - Diagrama unifilar da rede de distribuição piloto elaborada no PSCAD....	32
Figura 4 - Arquitetura do sistema de detecção e localização de faltas.	33
Figura 5 - Janelamento do sinais de tensão para o cálculo de $v_{0a}(wt)$	38
Figura 6 - A Equação (4) foi aplicada à falta do tipo AG de 10Ω com 25ms de duração e origem no ponto 5.....	40
Figura 7 - Efeito de borda gerado pela janela retangular e a janela gaussiana como alternativa para filtrar este efeito.....	43
Figura 8 - A Equação 19 foi aplicada à falta do tipo AB de 10Ω com 25ms de duração e origem no ponto 5.....	45
Figura 9 - Resultados do processamento das Faltas <i>CT</i>	47
Figura 10- Diagrama unifilar simplificado.	49
Figura 11- Interpolação exponencial entre os coeficientes <i>b</i> e as distâncias das faltas ao alimentador.	49
Figura 12- Densidades de probabilidade de $b(MI, MH)$, $b(MH, ME)$ e $b(MI, ME)$ estimadas para cada classe (ponto de localização de uma falta <i>CT</i>).	49
Figura 13- Resultados do processamento das Faltas <i>ST</i>	50
Figura 14- Densidades de probabilidade de $b(MI, MH)$, $b(MH, ME)$ e $b(MI, ME)$ estimadas para cada classe (ponto de localização de uma falta <i>ST</i>).	51
Figura 15- Resultados da aplicação da Equação (19) a uma falta do tipo <i>ABC</i> de 10Ω com 25ms de duração e origem no ponto 5.	52
Figura 16- Resultados do processamento das Faltas <i>ST</i> do tipo <i>ABC</i>	53
Figura 17- Separação dos tipos de faltas <i>AB</i> , <i>AC</i> , <i>BC</i> e <i>ABC</i> a partir da aplicação da Equação (31). Cada gráfico sob a perspectiva de um medidor.	54
Figura 18- Separação dos tipos de faltas <i>CT</i> e <i>ST</i> a partir da aplicação da Equação (34). Cada gráfico sob a perspectiva de um medidor.....	55
Figura 19- Rede <i>Multilayer Perceptron</i> (MLP).	58

Figura 20- Estrutura de um neurônio artificial.	59
Figura 21- Rede MLP.	59
Figura 22- Arquitetura neural com 17 redes neurais do tipo (<i>feed-forward backpropagation network</i>).	60
Figura 23- Resultados do treinamento da RNA 0, responsável por distinguir entre faltas do tipo CT e ST.	63
Figura 24- Resultados do treinamento da RNA 1, responsável por distinguir entre os grupos $G1_{CT}$ e $G2_{CT}$	64
Figura 25- Resultados do treinamento da RNA 411, responsável por classificar a localização das faltas CT do grupo $G1_{CT}$	64
Figura 26- Resultados do treinamento da RNA 412, responsável por classificar a localização das faltas CT do grupo $G2_{CT}$	65
Figura 27- Resultados do treinamento da RNA 2, responsável por distinguir entre os tipos de faltas AB, AC, BC e ABC.	66
Figura 28- Resultados do treinamento da RNA 31, responsável por distinguir entre os grupos $G1_{STAB}$ $G2_{STAB}$	67
Figura 29- Resultados do treinamento da RNA 421, responsável por classificar a localização das faltas ST do grupo $G1_{STAB}$	68
Figura 30- Resultados do treinamento da RNA 422, responsável por classificar a localização das faltas ST do grupo $G2_{STAB}$	68
Figura 31- Resultados do treinamento da RNA 32, responsável por distinguir entre os grupos $G1_{STAC}$ e $G2_{STAC}$	69
Figura 32- Resultados do treinamento da RNA 423, responsável por classificar a localização das faltas ST do grupo $G1_{STAC}$	69
Figura 33- Resultados do treinamento da RNA 424, responsável por classificar a localização das faltas ST do grupo $G2_{STAC}$	70
Figura 34- Resultados do treinamento da RNA 33, responsável por distinguir entre os grupos $G1_{STBC}$ e $G2_{STBC}$	70
Figura 35- Resultados do treinamento da RNA 425, responsável por classificar a localização das faltas ST do grupo $G1_{STBC}$	71
Figura 36- Resultados do treinamento da RNA 426, responsável por classificar a localização das faltas ST do grupo $G2_{STBC}$	71

Figura 37- Resultados do treinamento da RNA 34, responsável por distinguir entre os grupos $G1_{STABC}$ e $G2_{STABC}$	72
Figura 38- Resultados do treinamento da RNA 427, responsável por classificar a localização das faltas ST do grupo $G1_{STABC}$	72
Figura 39- Resultados do treinamento da RNA 428, responsável por classificar a localização das faltas ST do grupo $G2_{STABC}$	73
Figura 40- Teste de robustez com validação cruzada para RNA411.	77
Figura 41- Teste de robustez com validação cruzada para RNA421.	77
Figura 42- Teste de robustez com validação cruzada para RNA427.	78
Figura 43- Teste com faltas de alta impedância (separadas por tipo).	80
Figura 44- Teste com faltas de alta impedância (separadas por impedância).	81
Figura 45- Arquitetura neural com 3 redes neurais do tipo (<i>feed-forward backpropagation network</i>).	82
Figura 46- Teste de robustez com validação cruzada para RNA 1' utilizando informações de dois medidores.	86
Figura 47- Teste de robustez com validação cruzada para RNA 2' utilizando informações de dois medidores.	86
Figura 48- Teste de robustez com validação cruzada para RNA 1' utilizando informações de três medidores.	87
Figura 49- Teste de robustez com validação cruzada para RNA 2' utilizando informações de três medidores.	87
Figura 50- Treinamento da RNA 1' utilizando informações de dois medidores.	88
Figura 51- Treinamento da RNA 2' utilizando informações de dois medidores.	89
Figura 52- Treinamento da RNA 1' utilizando informações de três medidores.	90
Figura 53- Treinamento da RNA 2' utilizando informações de três medidores.	91
Figura 54- Teste para RNA 1' utilizando informações de dois medidores.	91
Figura 55- Teste para RNA 2' utilizando informações de dois medidores.	92
Figura 56- Teste para RNA 1' utilizando informações de três medidores.	92
Figura 57- Teste para RNA 2' utilizando informações de três medidores.	93
Figura 58- Teste de segmento (fronteira entre classes) para RNA 1' utilizando informações de dois medidores (bins=6).	93

Figura 59- Teste de segmento (fronteira entre classes) para RNA 2' utilizando informações de dois medidores (bins=6).	94
Figura 60- Teste de segmento (fronteira entre classes) para RNA 1' utilizando informações de três medidores (bins=6).	95
Figura 61- Teste de segmento (fronteira entre classes) para RNA 2' utilizando informações de três medidores (bins=6).	96
Figura 62- Teste com faltas de alta impedância alimentando as redes neurais com informações de dois medidores (bins=6).	99
Figura 63- Teste com faltas de alta impedância alimentando as redes neurais com informações de três medidores (bins=6).	100
Figura 64- Teste com faltas de alta impedância localizadas entre os pontos de faltas originais. Obs.: Utilizando informações de dois medidores (bins=6).	101
Figura 65- Teste com faltas de alta impedância localizadas entre os pontos de faltas originais. Obs.: Utilizando informações de três medidores (bins=6).	102

LISTA DE TABELAS

Tabela 1 - Tabela de denominação das classes de VTCD segundo ANEEL e ONS. ..	18
Tabela 2 - Tabela de denominação das classes de VTCD segundo IEEE 1159.	18
Tabela 3 - Características do Banco de Dados de Falhas	30
Tabela 4 - Resumo dos parâmetros utilizados na construção do conjunto de faltas de alta impedância.	30
Tabela 5 - Resumo dos parâmetros utilizados na construção do conjunto de faltas de alta impedância com origem em diferentes localizações.	31
Tabela 6 - Tabela de Relação entre Faltas e Componentes Simétricas.	34
Tabela 7 - Tabela de coeficientes das retas da Figura 9.....	48
Tabela 8 - Grupo de Localizações.....	60
Tabela 9 - Legenda.....	61
Tabela 10- Composição estrutural das 17 redes neurais.	61
Tabela 11- Resumo dos parâmetros para teste de robustez com validação cruzada da rede RNA 411.	76
Tabela 12- Resumo dos parâmetros para teste de robustez com validação cruzada das redes RNA 421 e RNA 427.....	76
Tabela 13- Resumo dos parâmetros utilizados na construção do conjunto de faltas de alta impedância.	79
Tabela 14- Nova composição estrutural de redes neurais utilizando informações de dois medidores.	82
Tabela 15- Nova composição estrutural de redes neurais utilizando informações de três medidores.	83
Tabela 16- Descrição do vetor de entrada das redes neurais utilizando informações de dois medidores.....	83
Tabela 17- Descrição do vetor de entrada das redes neurais utilizando informações de três medidores.	83
Tabela 18- Resumo dos parâmetros utilizados na construção do conjunto de faltas de alta impedância com origem em diferentes localizações.	84

Tabela 19- Proporção do banco de dados escolhida para treinamento, validação e testes para dois ou três medidores.....	88
Tabela 20- Distâncias entre classes de localização.....	90
Tabela 21- Tabela para comparação de resultados (utilizando dois medidores).....	103
Tabela 22- Tabela para comparação de resultados (utilizando três medidores).	103

LISTA DE SIGLAS

VTCD	Variação de Tensão de Curta Duração
QEE	Qualidade de Energia Elétrica
ANEEL	Agência Nacional de Energia Elétrica
RNA	Rede Neural Artificial
CA	Corrente Alternada
CC	Corrente Contínua
kV	kilovolt
kA	kiloampere
m	Metro
km	Quilômetro
s	Segundo
ms	Milissegundo
EMTP	Electro Magnetic Transient Program
CT	Falta de fase a terra
ST	Falta entre fases
STAB	Falta da fase A para a fase B
STAC	Falta da fase A para a fase C
STBC	Falta da fase B para a fase C
STABC	Falta trifásica
$v_{0a}(t)$	Sequência zero instantânea
$v_{1a}(t)$	Sequência positiva instantânea
$v_{2a}(t)$	Sequência negativa instantânea

SUMÁRIO

	INTRODUÇÃO	16
1	ESTADO DA ARTE	22
2	BANCO DE DADOS DE FALTAS	29
3	METODOLOGIA	33
3.1	Detecção de Faltas	35
3.2	Descrição do Método de Estimação das Componentes Simétricas Instantâneas	35
3.2.1	Desenvolvimento da Componente $v_{0a}(wt)$	37
3.2.2	Desenvolvimento da Componente $v_{2a}(wt)$	40
3.3	Descrição do Método de Localização da Falta	44
3.4	Caracterização da Localização de Faltas CT	46
3.5	Caracterização da Localização de Faltas ST	50
3.5.1	Método de Caracterização dos Tipos de Faltas ST	52
3.6	Método de Caracterização dos tipos CT e ST de Faltas	54
4	CLASSIFICAÇÃO DE FALTAS VIA REDES NEURAIS ARTIFICIAIS	56
4.1	Classificadores <i>Multilayer Perceptron</i> (MLP)	57
4.2	Projeto dos Classificadores Via Redes Neurais Artificiais	58
4.3	Distinção Entre Faltas dos Tipos CT e ST.	62
4.4	Localização De Faltas CT.	62
4.5	Distinção Entre Os Tipos De Faltas AB, AC, BC e ABC.	65
4.6	Localização De Faltas $STAB$, $STAC$, $STBC$ e $STABC$	66
4.7	Conclusões Parciais	74
4.8	Análise De Desempenho Dos Classificadores	75
4.8.1	Testes de Robustez com Validação Cruzada	75
4.8.2	Conclusões Parciais	76
4.8.3	Teste Com Faltas Não Inicialmente Contidas No Banco De Dados	79
4.8.4	Conclusões Parciais	80

4.8.5	Conclusões Parciais Acerca Da Análise de Desempenho Dos Classificadores	80
5	ESTIMAÇÃO DE LOCALIZAÇÃO DE FALTAS VIA REDES NEURAIS ARTIFICIAIS	
	NEURAIS ARTIFICIAIS	82
5.1	Análise de Desempenho	83
5.2	Teste de Robustez com Validação Cruzada	85
5.3	Teste Com Faltas Não Inicialmente Contidas No Banco De Dados	97
5.3.1	Teste com faltas de alta impedância simuladas nos pontos de falta originais	97
5.3.2	Teste com faltas de alta impedância simuladas entre os pontos de falta originais.....	98
	CONCLUSÃO	105
	REFERÊNCIAS	110

INTRODUÇÃO

Nos últimos anos, devido ao desenvolvimento do País, houve um grande aumento na demanda por energia elétrica por parte do setor industrial e por consumidores de um modo geral. A finalidade de um sistema de potência é gerar, transmitir e distribuir energia elétrica para uma multiplicidade de pontos, para diversas aplicações.

Tal sistema deve ser projetado e operado para entregar esta energia obedecendo a dois requisitos básicos: qualidade e economia. Tais requisitos são conciliados utilizando conhecimentos técnicos e bom senso. Neste contexto, tecnologias vem sendo desenvolvidas com o objetivo de monitorar o sistema de potência de forma a garantir a Qualidade da Energia Elétrica (QEE) que é entregue ao consumidor. Esse monitoramento permite que os distúrbios que prejudicam a QEE sejam identificados e muitas das vezes localizados.

Uma das ocorrências com maior impacto no fornecimento da energia elétrica consiste em curto-circuitos (ou falta) em um dos componentes do sistema de potência, que resulta em contingências severas à rede elétrica. Essas faltas são algumas das possíveis causas das VTCDs (Variações de Tensão de Curta Duração).

Neste sentido o presente trabalho contribui a partir da concepção e implementação de ferramentas inteligentes para estimar a localização do ponto da rede onde ocorreu determinada falta e assim possibilitar uma rápida intervenção, visando a correção das anomalias e a aplicação das medidas de correções cabíveis.

Qualidade de Energia Elétrica (QEE)

A Qualidade de Energia Elétrica (QEE) está relacionada a uma ampla variedade de fenômenos eletromagnéticos que caracterizam a tensão, corrente e frequência no sistema elétrico de potência (IEEE Std 1159, 2009; ANEEL, 2009). Além disso, esses fenômenos podem causar deterioração, falhas ou má operação tanto de equipamentos eletro-eletrônicos quanto de dispositivos de proteção (DUGAN; GRANAGHAM, 2002). Geralmente o termo QEE é sinônimo de qualidade de tensão, isto se deve ao fato de que os sistemas de geração estão projetados para operar em tensão com baixa distorção harmônica e, além disso, com suas frequências e amplitudes mantidas dentro de faixas de valores nominais. No entanto, existe uma interação entre corrente e tensão, dado que uma variação considerável de corrente pode causar deformações na onda da tensão afetando sua qualidade (IEEE Std

1159, 2009; ANEEL, 2009). Esse aspecto é evidente em redes elétricas de distribuição que apresentam baixa potência de curto-circuito. Dentre os eventos que prejudicam a QEE, nos Procedimentos para Distribuição da Energia Elétrica (PRODIST), Módulo 8 (ANEEL, 2009) são mencionados os seguintes:

- 1 Correntes resultantes de curtos-circuitos produzem Variações de Tensão de Curta Duração (VTCDs);
- 2 Correntes elevadas, como as produzidas por descargas atmosféricas, podem gerar impulsos na forma de onda da tensão, além de causarem rompimento no isolamento elétrico entre os condutores;
- 3 Correntes com componentes harmônicas consumidas por cargas não lineares distorcem as tensões devido a tensão produzida por estas correntes harmônicas que fluem pela impedância da rede.

Com a finalidade de padronizar os diferentes eventos indesejáveis que alteram o estado de regime permanente da tensão ou da corrente, o IEEE estabeleceu um delineamento das definições e procedimentos, que permitem observar, de modo detalhado, os conceitos e as abordagens referentes à QEE (IEEE Std 1159, 2009). Nessa norma, pode-se encontrar uma classificação dos diferentes tipos de eventos tais como *notches*, harmônicos, transitórios, interrupções, elevações, afundamentos e flutuações de tensão, entre outros.

Por sua vez, no Brasil, estipularam-se padrões relacionados à QEE que podem ser encontrados no PRODIST, especificados em seu módulo 8 (ANEEL, 2009).

Nesse módulo são detalhadas as definições, terminologias, parâmetros e valores de referência relativos à tensão. Deste modo, o PRODIST visa estabelecer os procedimentos relativos a QEE. Os aspectos da QEE em regime permanente ou transitório, considerados pelo PRODIST são: tensão em regime permanente, distorções harmônicas, desequilíbrio de tensão, oscilações de tensão, variação de tensão de curta duração (VTCD) e variação da frequência.

Definição do Problema

Dentre os distúrbios observados na rede elétrica, a variação de tensão de curta duração (VTCD) corresponde a mais de 90% das ocorrências (LOPE, 2005).

São definidos como VTCDs, os eventos aleatórios caracterizados por uma variação da amplitude da tensão maior do que 10% em relação ao valor nominal e com duração entre um ciclo da fundamental e 1 minuto (ONS, 2011). Eventos com durações superiores são considerados como de longa duração. Suas principais causas são: curtos-circuitos, manobras de rede, atuação indevida da proteção e instabilidade ambiental (USIDA et al., 2009). Uma vez que a tensão pode variar significativamente durante o evento, é usual definir a magnitude da VTCD com base no valor extremo (máximo ou mínimo) da tensão eficaz remanescente, enquanto perdurar o evento. A recomendação IEEE 1159 (IEEE Std 1159, 2009) bem como a ANEEL (ANEEL, 2009) e o ONS (ONS, 2011) possuem classificações em função da magnitude e da duração dos eventos de curta duração (IEEE Std 1159, 2009, 1995; ANEEL, 2009; ONS, 2011). A Tabela 1 apresenta tais classificações segundo a ANEEL e o ONS. A Tabela 2 apresenta as classificações segundo a recomendação IEEE 1159. A letra *c* na Tabela 1 e na Tabela 2 representa um período de tempo igual a um ciclo da frequência fundamental (60Hz).

Tabela 1 - Tabela de denominação das classes de VTCD segundo ANEEL e ONS.

Sigla	Denominação	Duração da variação	Amplitude da Tensão (valor eficaz) em relação à tensão nominal
IMT	Interrupção Momentânea de Tensão	$\leq 3s$	inferior a 0,1 pu
AMT	Afundamento Momentâneo de Tensão	$\geq 1c, \leq 3s$	superior ou igual a 0,1 e inferior a 0,9 pu
EMT	Elevação Momentânea de Tensão	$\geq 1c, \leq 3s$	superior a 1,1 pu
ITT	Interrupção Temporária de Tensão	$> 3s, \leq 1m$	inferior a 0,1 pu
ATT	Afundamento Temporário de Tensão	$> 3s, \leq 1m$	superior ou igual a 0,1 e inferior a 0,9 pu
ETT	Elevação Temporária de Tensão	$> 3s, \leq 1m$	superior a 1,1 pu

Tabela 2 - Tabela de denominação das classes de VTCD segundo IEEE 1159.

Short-duration root-mean-square (rms) variations			
Denominação		Duração da variação	Amplitude da tensão (valor eficaz) em relação a tensão nominal
Variação Instantânea	Afundamento	0,5 - 30 c	0,1 - 0,9 pu
	Elevação	0,5 - 30 c	1,1 - 1,8 pu
Variação Momentânea	Interrupção	0,5 c - 3 s	< 0,1 pu
	Afundamento	30 c - 3 s	0,1 - 0,9 pu
	Elevação	30 c - 3 s	1,1 - 1,4 pu
Variação Temporária	Interrupção	>3 s - 1 min	< 0,1 pu
	Afundamento	>3 s - 1 min	0,1 - 0,9 pu
	Elevação	>3 s - 1 min	1,1 - 1,2 pu

distribuiçãoDentre os fenômenos de VTCD, pesquisas a partir do monitoramento de uma determinada indústria, num período de 27 meses, revelaram que a maior incidência é de Afundamentos Momentâneos de Tensão (AMT) (MAIA, 2011), compreendendo mais de 75% dos casos de VTCD. A Figura 1 ilustra os resultados estatísticos dessa pesquisa.

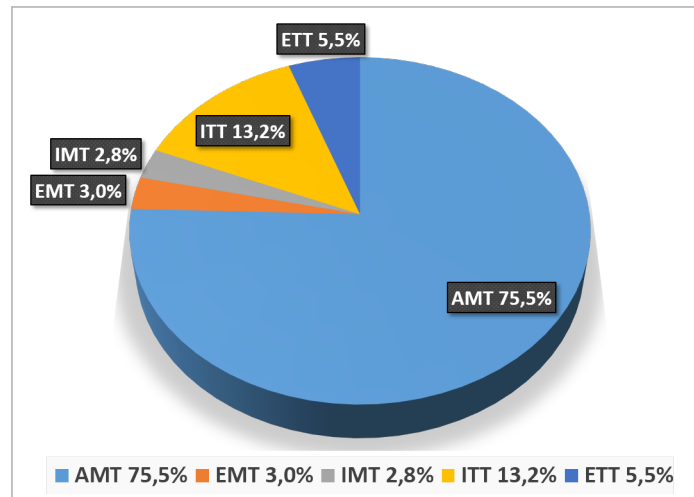


Figura 1 - Estatísticas de ocorrência dos tipos de VTCD.

O evento de uma VTCD possui grande relevância, pois sua ocorrência pode levar à interrupção de processos industriais resultando em perdas econômicas. Os aparelhos que utilizam controle digital em geral são sensíveis a variações de tensão na rede elétrica e dependem de suprimento de energia elétrica de boa qualidade para operarem adequadamente.

Neste cenário, é indispensável o acompanhamento e gerenciamento de indicadores de qualidade e a identificação do tipo e da localização de eventuais violações dos padrões estabelecidos, visando a correção das anomalias e a aplicação das medidas de correções cabíveis. Neste sentido o presente trabalho contribui a partir da concepção e implementação de ferramentas inteligentes para localizar o ponto da rede onde ocorreu determinada falta e assim possibilitar uma rápida intervenção.

Organização do trabalho

No **capítulo 1** são apresentadas algumas bibliografias referente ao tema: Localização e classificação de faltas em sistemas de transmissão e distribuição. Na literatura, encontra-se uma grande variedade de trabalhos, dessa forma, apenas alguns trabalhos relacionados a esse tema são apresentados nessa seção.

No **capítulo 2** é descrito o banco de dados de faltas utilizado neste trabalho bem como sua origem e formato de armazenamento. Também são descritos mais dois bancos de dados que foram gerados para complementar testes adicionais.

O **capítulo 3** apresenta a metodologia proposta nesta dissertação para localizar faltas VTCD geradas por curtos circuitos. Na sequência, é descrita a forma de detecção da faltas por meio de um circuito de sincronismo (*Phase Locked Loop*). A decomposição dos sinais de tensão durante a falta em componentes simétricas e a utilização dessas componentes na extração de características que permitem localizar a falta em um sistema de distribuição também são explorados nesse capítulo.

No **capítulo 4** é proposto um classificador de localização de faltas cuja arquitetura é composta por 17 redes neurais artificiais do tipo MLP (*Multilayer Perceptron*). Cada uma dessas redes possui um papel particular no sistema de localização de falta. Neste capítulo são discutidas, também, as vantagens e desvantagens dessa abordagem. São apresentados os parâmetros de treinamento, bem como os resultados de treinamento, validação e testes. Ainda nesse capítulo é realizada uma análise de desempenho do classificador proposto. Basicamente são realizados dois tipos de testes. O primeiro teste tem o propósito de analisar a sensibilidade das redes neurais a diferentes partições do banco de dados (Validação cruzada) e analisar a sensibilidade a diferentes proporções para o conjunto de treinamento, validação e testes (Teste de Robustez). No segundo teste, basicamente é avaliado o poder de generalização das redes neurais. Neste teste são apresentadas às redes neurais, faltas não inicialmente contidas no banco de dados original, a saber, são apresentadas faltas de alta impedância. Essas faltas fazem parte do banco de dados gerado para complementar os testes adicionais. Ao final do capítulo são apresentadas algumas conclusões parciais.

No **capítulo 5** é proposto um estimador de localização de falta via redes neurais MLP. Nesse sistema, as redes MLP são utilizadas para aproximar uma função que fornece, como saída, a distância da falta ao alimentador do sistema de distribuição. Ainda neste capítulo é feita a análise de desempenho do sistema. Os mesmos testes descritos no capítulo anterior são feitos aqui. Adicionalmente é feito outro teste com faltas não inicialmente contidas no banco de dados, a saber, é feito um teste com faltas de alta impedância simuladas entre os pontos originais de faltas. Além disso, também é feita uma comparação para o desempenho do estimador quando são utilizadas informações de dois

e três medidores da rede. Ao final deste capítulo são apresentadas algumas conclusões parciais.

Ao final do trabalho são apresentadas as conclusões gerais sobre os resultados obtidos nos testes realizados bem como recomendações e sugestões para trabalhos futuros.

1 ESTADO DA ARTE

Nos últimos anos, a necessidade de identificar e caracterizar os problemas relacionados à QEE tem levado ao desenvolvimento e aplicação de diversas metodologias que permitam de forma confiável a identificação e o reconhecimento automático dos diferentes distúrbios. Dentre os apontamentos encontrados, pode-se observar o uso de metodologias que envolvem ou compreendem duas áreas, sendo uma encarregada de abstrair informações importantes que definem um problema em particular e, a segunda, de processar tal informação para definir, de forma automática, a classe ou tipo de distúrbio ao qual pertencem (GRANADOS-LIEBERMAN et al., 2011).

Com objetivo de extrair informações de sinais que representem algum fenômeno físico, diferentes abordagens são empregadas. Basicamente estes sinais são analisados com base em ferramentas definidas no domínio do tempo ou no domínio da frequência (CHUI, 1992). A técnica mais conhecida na análise no domínio da frequência é a Transformada de Fourier que permite conhecer os componentes em frequência de um sinal (OPPENHEIM; WILLSKY; NAWAB, 2010).

Atualmente, existem diferentes métodos para análise tempo-frequência como espectrogramas, distribuição de *Wigner-Ville*, *Cho-William* entre outras (COHEN, 1995). O objetivo principal do uso da análise tempo-frequência é conhecer como o espectro de frequência de um sinal não estacionário se comporta com o passar do tempo.

Para obter uma classificação confiável, diferentes técnicas são empregadas com a finalidade de determinar as características que definem cada um dos eventos. Na análise de distúrbios de QEE, dentre os classificadores encontrados na literatura e que se destacam, podem ser mencionadas as Redes Neurais Artificiais (RNAs) (KEYHANI; DERICHE; PALMER, 2001; MORETO, 2005; THUKARAM; KHINCHA; VIJAYNARASIMHA, 2005) e *Support Vector Machine* (SVM) (THUKARAM; KHINCHA; VIJAYNARASIMHA, 2005). Contudo, estes classificadores, mesmo robustos, dependem dos dados fornecidos pela etapa anterior, representada pela extração de características particulares, para assim conseguir um desempenho satisfatório.

Em Takagi et al. (1981), o método de localização de faltas consiste em tentar determinar a impedância vista de um dos terminais da linha de transmissão a partir dos fasores de tensão e corrente medidos no mesmo terminal nas condições de pré-falta e pós-

falta e, a partir dessa informação, estimar a localização da falta. Os autores de (TAKAGI et al., 1981) possuem uma patente de um sistema localizador de faltas disponível em Takagi e Yamakoshi (1982) bem como um artigo sobre a aplicação em campo do mesmo disponível em Takagi et al. (1982).

Em Kezunovic, Mrkic e Perunicic (1994) são introduzidos novos algoritmos de localização de faltas com base em amostragem sincronizada. Um modelo no domínio do tempo de uma linha de transmissão é utilizado como base para o desenvolvimento dos algoritmos. As amostras de tensão e corrente nas extremidades de uma linha de transmissão são tomadas de forma síncrona e usadas para estimar a localização da falta. O artigo discute duas formas diferentes de algoritmos utilizando dois modelos de linhas, linhas de transmissão curtas e linhas de transmissão longas. Um conjunto de testes são realizados por meio de simulações de faltas no EMTP (*Electro Magnetic Transient Program*). Os resultados permitem concluir que o método proposto é promissor.

Em Huang e Hsieh (1999) é apresentada uma proposta para discriminar as faltas de alta impedância das comutações regulares (manobras de rede). O método utiliza aplicação da transformada *wavelets Morlet* para a análise tempo-frequência de sinais de falta gerados por altas impedâncias. Os resultados dos testes demonstraram viabilidade e vantagens do método para a aplicação proposta.

Como descrito em Welfonder et al. (2000), a compensação das redes de distribuição de média tensão melhora por um lado a qualidade do fornecimento de energia e impõe, por outro lado, restrições maiores sobre estratégias de detecção e localização de faltas. Nesse trabalho são discutidos três novos algoritmos para a detecção das faltas resistivas monofásicas com terra. Depois da primeira implementação em campo, os problemas encontrados foram solucionados e levaram à concepção de uma nova estratégia para localização de faltas para redes de distribuição radiais complexas e compensadas.

Em Gaouda et al. (2000), a técnica *Multiresolution Analysis* (MRA) de um sinal é apresentada como uma ferramenta poderosa para detectar, classificar e quantificar as VTCDs em um sistema de distribuição elétrica. Usando a técnica proposta, é possível medir a magnitude e a duração do sinal durante eventos de VTCD. Além disso, a distorção harmônica total e o nível DC também podem ser medidos. As informações obtidas em diferentes níveis de resolução e os valores medidos pela técnica proposta podem ser usados para distinguir entre fenômenos semelhantes de qualidade de energia e podem ajudar a

encontrar a fonte da perturbação.

Em IEEE Std C37.114 (2005) são descritas as técnicas e as considerações de aplicação para determinar a localização de uma falta em linhas de transmissão e distribuição AC. Este documento analisa as abordagens tradicionais como métodos baseados na impedância e em ondas viajantes. São feitas, também, considerações de aplicação para linhas de dois e de três terminais.

Em Thukaram, Khincha e Vijaynarasimha (2005), o método de ondas viajantes é aplicado a um sistema de transmissão de $330kV$. Este baseia-se na transformada *Wavelet*. As polaridades dos coeficientes resultantes são utilizadas para inferir a natureza e a localização da falta.

Em Ruiz-Reyes, Vera-Candeas e Jurado (2005) é apresentada uma técnica para a discriminação exata entre transitório de tensão estável e afundamento de tensão combinando modelagem de transitórios baseada em senoides amortecidas com redes neurais. A modelagem do transitório é realizada por um algoritmo específico que se utiliza de um dicionário de senoides amortecidas para obtenção de um modelo esparso do sinal. Na etapa seguinte, informações fornecidas pelas senoides amortecidas tornam-se os parâmetros de entrada de uma rede neural, que determina de forma rápida e precisa a classe a que a forma de onda pertence.

Em Mora-Florez, Barrera-Nuez e Carrillo-Caicedo (2007) é proposta uma alternativa para localizar faltas em sistemas de distribuição de energia usando o algoritmo de aprendizagem para análise de dados multivariável LAMDA (*Learning Algorithm For Multivariable Data Analysis*). Neste trabalho, as formas de onda de tensão e corrente medidas durante eventos de faltas são analisadas para se obter um conjunto de métricas (média, RMS, desvio padrão, entre outros). A partir do conjunto obtido, é feita uma análise exploratória para obter a melhor projeção em uma base ortonormal denominada α - β . Em seguida, essas projeções são usadas como dados de entrada de cinco redes LAMDAs para localizar a falta em uma rede de distribuição. A metodologia proposta exige um mínimo de investimento das concessionárias uma vez que só exige medidores na subestação.

Em Borghetti et al. (2008) é apresentado um procedimento de localização de faltas para redes de distribuição com base na análise da transformada *Wavelet* do sinal de falta gerado utilizando o método de ondas viajantes. Em particular, o procedimento proposto

implementa a análise *wavelet* contínua aplicada às formas de onda da tensão gravadas durante eventos de falta. A fim de melhorar a análise *Wavelet*, o algoritmo propõe a construção de *mother wavelets* específicas. O desempenho do algoritmo proposto é testado na rede de distribuição teste IEEE 34-bus e comparado com os obtidos usando a *mother wavelets* mais tradicional, a *Morlet*.

Em Mora-Florez, Melendez e Carrillo-Caicedo (2008) são comparados 10 métodos de localização de falta para sistemas de distribuição de energia. Os métodos analisados usam apenas medições de tensão e corrente na subestação. Componente fundamental de tensão e corrente durante a falta e antes da falta são usados para estimar a impedância aparente vista a partir do ponto de medição. A comparação entre a impedância antes da falta e durante a falta juntamente com os parâmetros do sistema, são utilizadas para estimar a distância até ao ponto de falta. Os 10 métodos selecionados foram implementados, testados e comparados em uma rede simulada. O método baseado em impedância foi originalmente desenvolvido por (TAKAGI et al., 1981) para localizar faltas em linhas de transmissão.

Em Pourahmadi-Nakhli e Safavi (2011) é proposto um novo algoritmo para a localização de faltas fase para a terra em um sistema de distribuição de energia elétrica, utilizando o método de ondas viajantes e filtros *Wavelet*. O sinal transitório é decomposto por um filtro *Wavelet* e seu espectro de energia é decomposto em diferentes níveis. Em seguida, uma rede neural é responsável por classificar os dados. O Percentual de energia em cada nível é utilizado para treinamento da rede neural artificial. Os sinais transitórios são simulados usando o programa ATP/EMTP e o programa MATLAB é utilizado para projeto e treinamento das redes neurais.

Na trabalho descrito em Antunes (2012) é utilizado um PLL (*Phase-Locked-Loop*) com o objetivo de extrair informações como amplitude, frequência e fase da componente fundamental das tensões e correntes durante a falta. A partir dessas informações é possível detectar, identificar o tipo e a localização da falta em uma extensa rede de distribuição de energia elétrica através da utilização de RNAs (Redes Neurais Artificiais) como classificadores.

Em Lovisolo et al. (2012) é proposto um método de detecção e localização de VTCDs baseado na decomposição dos sinais de tensão e corrente em somatórios de senoides amortecidas. Os sinais de tensão e corrente são medidos em apenas um ponto

na subestação. Após a detecção da falta através de um PLL (*Phase-Locked-Loop*), os sinais de tensão e corrente passam pela decomposição usando senoides amortecidas. Os parâmetros que definem as senoides amortecidas são utilizados para classificar o tipo de falta e sua localização. O classificador utilizado para determinar o tipo de falta é baseado em SVM (*Support Vector Machine*) enquanto que para classificar a localização da falta são utilizadas RNAs (Redes Neurais Artificiais). As faltas foram simuladas no programa PSCAD através da modelagem de uma pequena rede de distribuição de energia elétrica. Os resultados permitem concluir que com esta metodologia é possível a extração de informações relevantes para classificação do tipo e da localização da falta. No entanto, é necessário estender essa aplicação para sistemas de distribuição maiores com o objetivo de confirmar a eficácia do método.

Em Lout e Aggarwal (2013) é investigado o uso de sinais de corrente para estimar as fases envolvidas durante uma determinada falta e sua distância à subestação. Ambos através da utilização Redes Neurais Artificiais (RNA). Tanto as RNAs responsáveis por classificar o tipo de falta quanto para localizar a falta são alimentadas por coeficientes gerados pela decomposição *Wavelet* dos sinais de correntes. Testes de sensibilidade também foram realizados para demonstrar a robustez do método proposto. As simulações das faltas foram realizadas no programa ATP/EMTP com base na modelagem a partir de um sistema de distribuição de 33kV.

Em Gazzana et al. (2013) é proposta uma metodologia híbrida integrando o método baseado em impedância com o método baseado em ondas viajantes para localizar faltas em sistemas de distribuição. Com esses dois métodos em conjunto, os erros referentes à estimação da localização da falta são minimizados. Com o objetivo de verificar a aplicação da metodologia proposta, simulações foram realizadas no programa ATP com base na modelagem de um sistema real de distribuição de energia elétrica.

Como descrito em Dashti e Sadeh (2013), a modelagem precisa da carga total e da carga em cada nó em sistemas de distribuição de energia é muito importante para determinar a localização exata da falta quando se utiliza algoritmos de localização baseados em impedância. Neste artigo, é proposto um algoritmo modificado de localização de faltas baseado em impedância capaz de estimar a carga dinâmica e os parâmetros distribuídos do modelo da linha de distribuição. A partir destas informações, a falta é localizada juntamente com a análise dos equipamentos de proteção, ou seja, fusíveis, indicadores

de falta e religadores. O desempenho do método proposto é avaliado com base em um alimentador real de uma rede de distribuição no Irã sob diferentes condições de falta. Os resultados obtidos mostram a eficiência e a precisão do método proposto.

Em Awalín et al. (2013) é apresentado um método de localização de faltas com base em perfis de queda de tensão para as redes de distribuição. Em outros métodos anteriores, era utilizada apenas uma única medição. Este método pode ser usado com qualquer número de medições efetuadas na rede, tornando-o mais geral. Para validar o método, diferentes estudos de caso com vários números de medições foram realizadas em uma grande rede consistindo de 42 barramentos e com o alimentador de 11 kV. Os resultados do teste mostram que existe uma melhoria em termos de precisão na detecção do ponto de falta para cada medição adicional. Portanto, utilizando o valor médio de cada medição, uma melhor precisão de localização de faltas pode ser obtida.

Em Ye et al. (2014) são utilizados a transformada *wavelet* e a *Support Vector Regression* (SVR) para estimar a localização da falta em sistemas radiais de distribuição de energia. O método utiliza dados gravados apenas na subestação. Após a transformação modal dos sinais medidos, o tempo de chegada e a informação de amplitude dos componentes modais são extraídos usando transformada *wavelet* discreta (DWT). Em particular, o tempo de atraso e a primeira Transformada *Wavelet Modulus Maxima* (WTMM) dos componentes em cada uma das escalas modais são as características utilizadas para criar a SVR que é utilizado para estimar a localização da falta. O processo de simulação das faltas e o projeto da SVR são realizadas, respectivamente, por meio dos programas PSCAD/EMTDC e MATLAB. Os resultados mostram que o método é promissor.

Em Zhai et al. (2014) é apresentada uma metodologia para detectar faltas em redes de distribuição por meio de transformada *Wavelet* e um algoritmo de detecção de energia. A técnica proposta consiste em extrair características da falta a partir do coeficiente D5 da decomposição *Wavelet* da tensão residual e da corrente residual. Comparando a energia dos coeficientes obtidos com a energia na situação normal de operação (utilizando um algoritmo de detecção de energia), as faltas podem ser detectadas. A técnica proposta é investigada com os recursos do programa ATP/EMTP. Os resultados das simulações mostram que esta técnica é eficaz e robusta e o método proposto tem o potencial de ser utilizado em campo para aplicações com monitoramento em tempo real.

Em Popovic, Kezunovic e Krstajic (2014) são discutidos os requisitos de imple-

mentação para a integração dos dados de uma subestação automatizada com a análise de faltas em linhas de transmissão de energia elétrica. A abordagem é baseada em medições na subestação através de dispositivos eletrônicos inteligentes. A arquitetura proposta oferece uma abordagem transparente para o gerenciamento de dados nas subestações, as funções de análise, bem como a visualização dos dados integrados e análise de resultados. Os resultados de análise de faltas, tradicionalmente obtidos através de intervenção humana direta, agora podem ser usados de forma automatizada para apoiar as decisões durante a operação ou a restauração do sistema de energia. A solução é aberta a novas expansões e interfaces com sistemas de terceiros. O artigo ilustra exemplos de implementação e fornece resultados iniciais obtidos em laboratório e em campo. O método de localização de faltas abordado é o mesmo apresentado por Takagi et al. (1981).

Nesta dissertação é proposta uma nova metodologia de localização de faltas baseada na dissipação da energia do sinal de falta ao longo da linha. Esta metodologia é testada em uma extensa rede de distribuição de energia elétrica alimentada à quatro fios, da qual apenas os sinais de tensão são utilizados. Após o processo de extração de características dos sinais de tensão, são utilizadas redes neurais para estimar a localização da falta. Nessa etapa são utilizadas duas abordagens. Na primeira, as redes neurais são utilizadas para classificar o local da falta em um dos possíveis pontos da rede preestabelecidos. Assume-se que esses pontos sejam consumidores e que deseja-se saber qual dos consumidores é o responsável por afetar a QEE. Na segunda abordagem, as redes neurais são utilizadas para estimar o local da falta fornecendo, como saída, a distância entre o alimentador principal da rede e a possível localização da falta. Ou seja, assume-se que o agente causador da falta possa estar em qualquer ponto da rede. No decorrer do trabalho, o desempenho desta metodologia é testada por meio de diversos testes.

2 BANCO DE DADOS DE FALTAS

Este trabalho foi realizado com base em um banco de dados de faltas disponibilizado por Antunes (2012). Esse banco de dados foi construído a partir de uma série de simulações realizadas através do programa PSCAD/EMTDC. Para tais simulações foi proposta a rede de distribuição de energia piloto ilustrada na Figura 3.

O sistema piloto analisado foi modelado como um sistema trifásico com um alimentador cuja tensão de despacho e corrente de carregamento são, respectivamente, 24,3kV e 246A. As cargas (equilibradas e conectadas em estrela com neutro aterrado) foram distribuídas em 13 (treze) pontos distintos. Nesses pontos foram aplicadas dez diferentes tipos de falhas (curto-circuito da fase A para o terra (AG), da fase B para o terra (BG) e assim por diante conforme ilustra a Tabela 3). Também foi definido que as faltas ocorreriam com três diferentes intervalos de tempo e três diferentes valores de impedâncias. As medições utilizadas para analisar os resultados consistiram de um Registrador Digital de Perturbação (RDP) no início, outro no meio, e um no final da linha de distribuição, conforme mostrado na Figura 3. As faltas foram modeladas como simples resistências e a frequência de amostragem utilizada para captura foi de 24.390 amostras por segundo, resultando em aproximadamente 406 amostras por ciclo de 60Hz. A escolha dessa frequência de amostragem não foi por acaso pois essa é uma frequência comum em muitos registradores hoje em dia.

O tempo total de cada simulação foi de 0,3s. Cada matriz referente a uma característica falta é composta por três sinais de tensão e três sinais de corrente correspondendo ao sistema trifásico. A Tabela 3 resume as características do banco de dados.

Considerando os treze pontos, os dez tipos de falhas, as três impedâncias de curto circuito, os três intervalos de tempo e os três locais de medição, resulta em um total de 3510 sinais para serem analisados. A Figura 2 ilustra os sinais de tensão e corrente referente a uma determinada falta do banco de dados.

Os sinais de tensão e corrente gerados pelas faltas por meio de simulação estão gravados no banco de dados no padrão denominado por COMTRADE. O COMTRADE, como descrito em COMTRADE... (1992), foi desenvolvido pelo *IEEE PES Power System Relaying Committee*. Ele é destinado aos dispositivos digitais que geram ou coletam dados temporários de sistemas de energia elétrica. Esta padronização tem o objetivo

Tabela 3 - Características do Banco de Dados de Falhas

Ponto de Falta		Tipo de Falha		Carga (Ω)		Duração (ms)		Local de Medida
Ponto 1		AB		10		8.33		Início
Ponto 2		AC		25		16.67		Meio
Ponto 3		BC		40		25.00		Fim
Ponto 4		ABC						
Ponto 5		AG						
Ponto 6		BG						
Ponto 7	×	CG	×		×		×	
Ponto 8		ABG						
Ponto 9		ACG						
Ponto 10		BCG						
Ponto 11								
Ponto 12								
Ponto 13								

de facilitar o intercâmbio dos dados entre equipamentos ou pessoas com o propósito de realizar simulações, testes, processamento ou simplesmente armazenamento.

Toda a pesquisa desenvolvida nesta dissertação foi realizada com base no banco de dados disponibilizado por Antunes (2012). No entanto, na medida em que o trabalho foi avançando, verificou-se a necessidade de expandir o banco de dados. Com o objetivo de avaliar o trabalho desenvolvido, novas simulações de novas faltas foram realizadas para a realização de testes com dados (faltas) “desconhecidos”. Basicamente, as novas faltas foram divididas em dois tipos:

- Faltas de alta impedância
- Faltas de alta impedância com origem em localizações diferentes das contidas no banco de dados original.

A Tabela 4 e a Tabela 5 apresentam os parâmetros utilizados para a construção dos novos conjuntos de dados (faltas).

Tabela 4 - Resumo dos parâmetros utilizados na construção do conjunto de faltas de alta impedância.

Ponto de Falta		Tipo de Falha		Carga (Ω)		Período (ms)		Local de Medida
6		<i>ABG</i>		50 Ω		$\frac{3}{4}$ ciclo		Início
8	×	<i>AC</i>	×	75 Ω	×	$\frac{5}{4}$ ciclo	×	Meio
		<i>ABC</i>		100 Ω				Fim

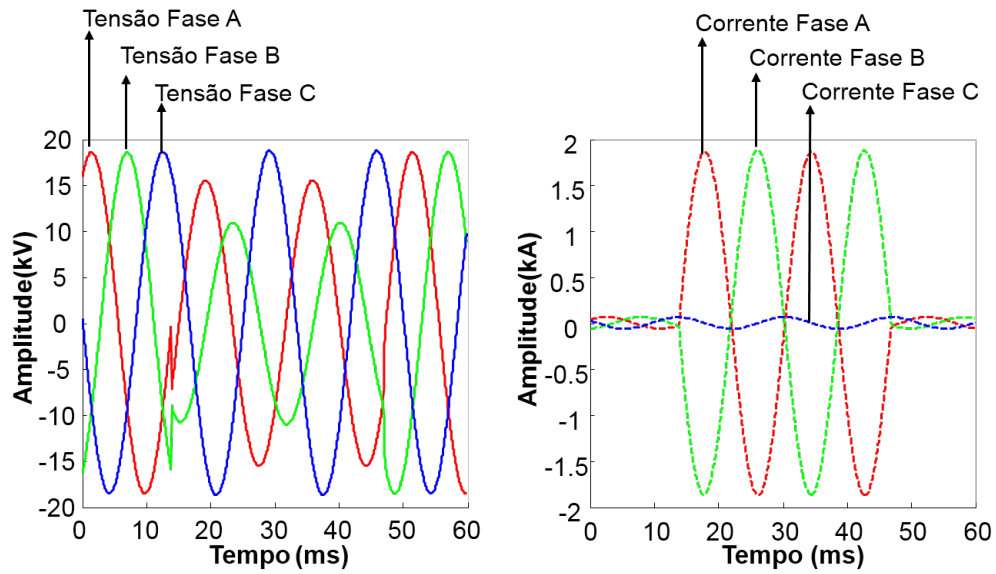


Figura 2 - Sinais de tensão e corrente referente a falta do tipo AB de 10Ω com 25ms de duração e origem no ponto 01.

Tabela 5 - Resumo dos parâmetros utilizados na construção do conjunto de faltas de alta impedância com origem em diferentes localizações.

Ponto de Falta		Tipo de Falha		Carga (Ω)		Período (ms)		Local de Medida
P3E4		ABG		75 Ω		$\frac{3}{4}$ ciclo		Início
P6E7	×	AC	×		×	$\frac{5}{4}$ ciclo	×	Meio
P12E13		ABC						Fim

Na Tabela 5, por exemplo, para o ponto de falta P3E4, entende-se que a falta foi simulada entre os pontos 3 e 4 (exatamente no meio do caminho entre os pontos 3 e 4).

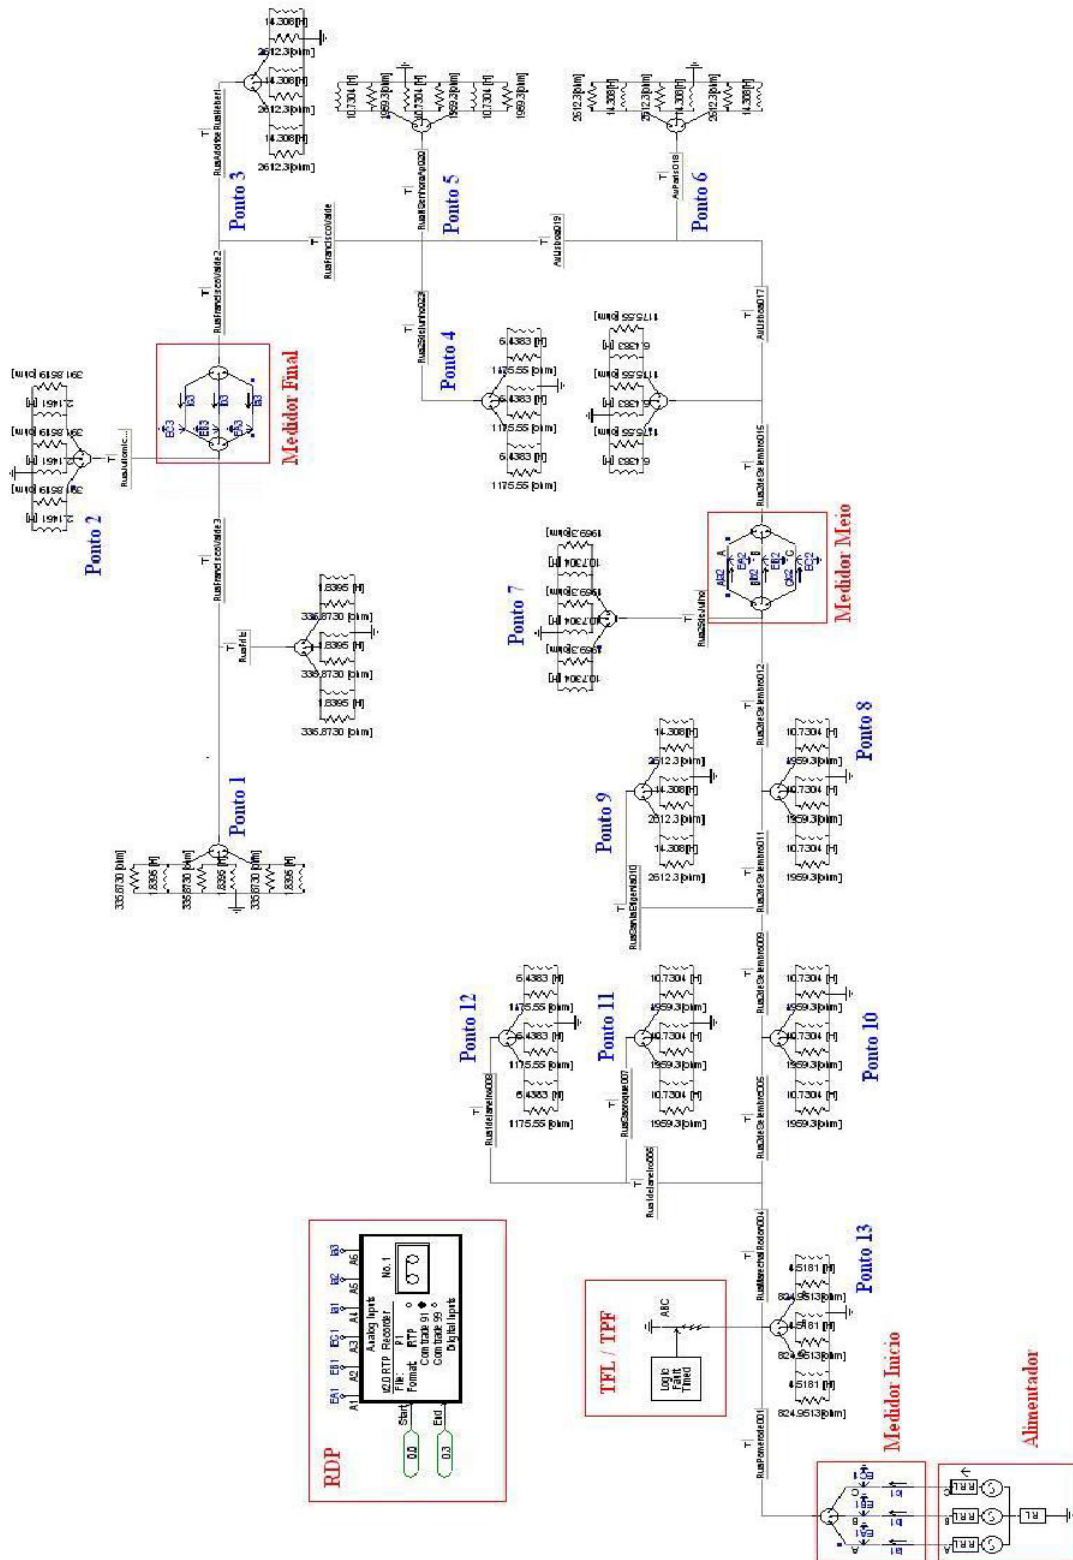


Figura 3 - Diagrama unifilar da rede de distribuição piloto elaborada no PSCAD.

3 METODOLOGIA

Neste capítulo é apresentada a técnica utilizada para extração de características que permite a localização da falta através da análise das tensões trifásicas. Inspirada na teoria das ondas viajantes abordada em Bewley (1951), IEEE Std C37.114 (2005), Spoor e Zhu (2006), Borghetti et al. (2010, 2008), Pourahmadi-Nakhli e Safavi (2011), esta técnica considera que, durante uma falta, a energia decorrente da falta se propaga pela linha de distribuição em ambos os sentidos. Tal energia transporta consigo informações sobre o caminho percorrido, ou seja, informações sobre a localização da falta. Esta informação decorre da dissipação de energia ao longo da linha de distribuição. O presente trabalho propõe que a informação da localização da falta pode ser extraída da relação entre as energias dos sinais gerados pela falta medidos em diferentes pontos da linha. A Figura 4 ilustra a arquitetura proposta nesta dissertação para o sistema de localização de faltas.

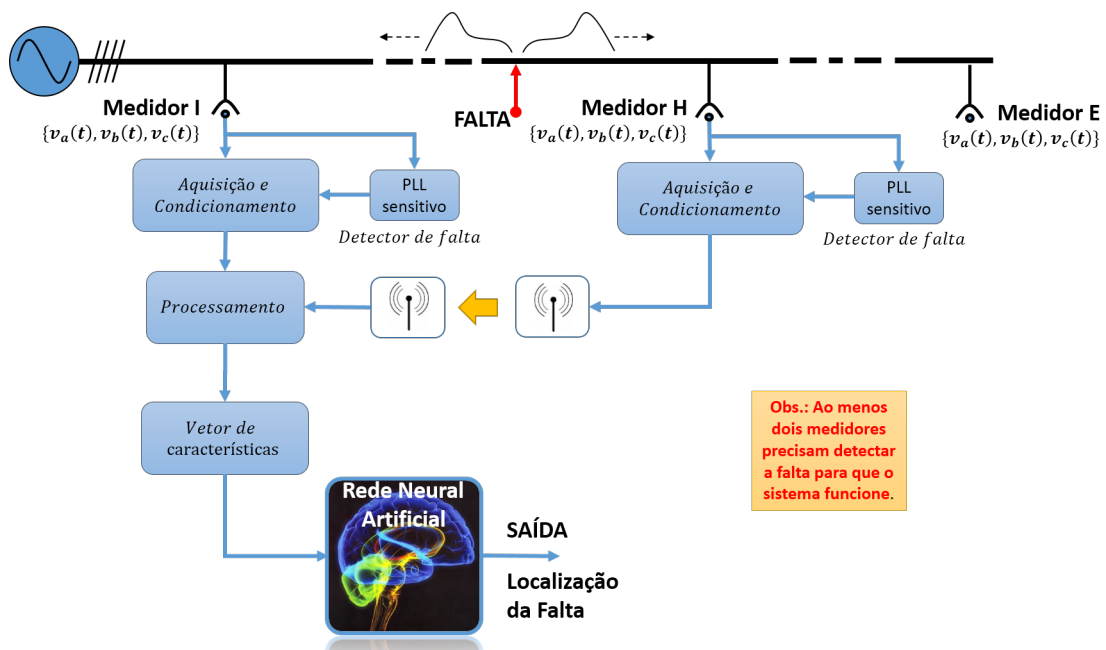


Figura 4 - Arquitetura do sistema de detecção e localização de faltas.

Como ilustra a Figura 4, o sistema pode ser composto por mais de dois sensores. No entanto, são necessários ao menos dois. Outro ponto importante é que neste trabalho é abordada uma técnica simples, porém robusta, na qual apenas os sinais de tensão são utilizados para identificar a localização da falta. Além disso, não há a necessidade dos medidores estarem sincronizados. É necessário, apenas, que o detector identifique falta e

envie os sinais de tensão, registrados durante a falta, para serem processados.

A metodologia proposta pode ser entendida como segue. Parte-se do princípio de que o sistema trifásico encontra-se equilibrado com tensões e correntes contendo somente a componente fundamental de sequência positiva. Assim, as componentes de sequência negativa e zero das tensões que surgem durante a falta podem ser utilizadas com o objetivo de definir um sinal que exista somente durante a falta. Nesse caso, sob o ponto de vista da análise de sinais e sistemas (OPPENHEIM; WILLSKY; NAWAB, 2010), as componentes de sequência negativa e zero das tensões que surgem durante a falta podem ser encaradas como sendo “sinais de energia”. Esses sinais, por sua vez, após o processo de extração de características (JENSEN; SHEN, 2008), fornecerá a entrada para o sistema que estimará a localização da falta.

Como descrito em Stevenson (1982), para um sistema com gerador conectado em estrela e neutro aterrado podemos relacionar as faltas de curto-circuito com as componentes simétricas geradas como mostra a Tabela 6 onde “+”, “-” e “0” representam a sequência positiva, negativa e zero respectivamente.

Tabela 6 - Tabela de Relação entre Faltas e Componentes Simétricas.

Faltas	Componentes Simétricas
Trifásicas	+
Bifásicas	+, -
Bifásicas com terra	+, -, 0
Monofásicas com terra	+, -, 0

O sistema de localização de faltas abordado neste trabalho possui duas etapas:

- **Etapa 1)** Faz-se a distinção entre dois tipos de faltas:
 - Faltas com caminho pelo terra (Faltas *CT*) que são as faltas do tipo *AG*, *BG*, *CG*, *ABG*, *ACG* e *BCG*.
 - Faltas sem caminho pelo terra, ou seja, entre fases somente (Faltas *ST*) que são as faltas do tipo *AB*, *AC*, *BC* e *ABC*.
- **Etapa 2)** O processo de localização estimada da falta segue de maneira diferente para cada tipo de falta acima.

Pelas razões demonstradas na Tabela 6, a etapa 1 é realizada através da análise da componente de sequência zero ao passo que, na etapa 2, as falta *CT* são localizadas por

meio da análise da componente de sequência zero e as faltas ST são localizadas através da análise da componente de sequência negativa. O processo de extração de características que permite a localização das faltas, representado pelo bloco “*processamento*” na Figura 4, é descrito na seção 3.2.

Todo o processo de localização de faltas inicia-se com a detecção da mesma. Por esse motivo a seção 3.1 é reservada para descrever, sem muito aprofundamento, como a detecção é realizada.

3.1 Detecção de Faltas

Antes do processamento dos sinais de tensão, a falta precisa ser detectada. Uma vez que a falta tenha sido detectada, o sistema prossegue com o processamento dos sinais de tensão registrados durante a falta a fim de extrair as características necessárias para estimar a localização da falta. Com o propósito de detectar a falta utilizando baixo poder computacional, um PLL (*Phase-Locked-Loop*) é empregado. O PLL aqui empregado (LOVISOLO et al., 2008) estima a frequência, ângulo e amplitude da componente fundamental. Para detectar o instante em que falta ocorre, o PLL é aplicado aos sinais de tensão a fim de monitorar e estimar suas amplitudes e frequências. Uma vez que as estimativas variam acima de uma taxa de variação predefinida, então é assumido que a falta ocorreu. Em Lovisolo et al. (2008) e Neto et al. (2009), são apresentados mais detalhes sobre esse PLL.

Um vez que a falta tenha sido identificada, o sistema retrocede dois ciclos e armazena em memória 6 ciclos de 60Hz do sinal de falta. Esta janela de 6 ciclos passa, em seguida, para a etapa de processamento. São utilizadas três janelas de dados, cada uma correspondendo à tensão de uma determinada fase (fase A, fase B e fase C). Isto é feito em cada medidor.

3.2 Descrição do Método de Estimação das Componentes Simétricas Instantâneas

Essencialmente, a partir dos sinais de tensão obtidos durante a ocorrência da falta, é feito a decomposição em componentes simétricas a partir da transformação de Fortescue (FORTESCUE, 1918). Por meio dessa transformação, um sistema trifásico deseque-

librado pode ser decomposto em três sistemas equilibrados, formado por componentes de sequencia positiva (+), negativa (-) e zero (0). Como já é sabido, durante a falta ocorre um desequilíbrio entre as fases (STEVENSON, 1982). Assim, o objetivo é estimar as componentes simétricas instantâneas geradas pelo desequilíbrio. Para tal é utilizada a transformação

$$\begin{bmatrix} v_{0a}(wt) \\ v_{1a}(wt) \\ v_{2a}(wt) \end{bmatrix} = \frac{1}{3} \text{Real} \left\{ \begin{bmatrix} 1 & 1 & 1 \\ 1 & \alpha & \alpha^2 \\ 1 & \alpha^2 & \alpha \end{bmatrix} \begin{bmatrix} A\{g_w(t)v_a(wt)\} \\ A\{g_w(t)v_b(wt)\} \\ A\{g_w(t)v_c(wt)\} \end{bmatrix} \right\}. \quad (1)$$

Nesta transformação, $A\{\}$ é o operador para cálculo do sinal analítico, $g_w(t)$ é uma função de janelamento, α representa a constante complexa $e^{j\frac{2\pi}{3}}$ e $v_a(wt)$, $v_b(wt)$ e $v_c(wt)$ são as tensões das fases a , b e c respectivamente. O sinal analítico (HAYKIN, 2004) é definido como

$$A\{s(t)\} = M(t)e^{j\phi(t)} = s(t) + jH\{s(t)\}, \quad (2)$$

onde $H\{s(t)\}$ é a Transformada de Hilbert definida por

$$H\{s(t)\} = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{s(\tau)}{\tau - t} d\tau. \quad (3)$$

A transformada de *Hilbert* possibilita a criação do sinal analítico que, por sua vez, pode ser entendido como a representação complexa de um sinal real (HAYKIN, 2004). Neste caso, uma propriedade muito interessante é o fato de que o espectro (domínio da frequência) do sinal analítico é nulo para as frequências negativas (COHEN, 1995). Um sinal periódico, desde que satisfaça as condições de *Dirichlet*, pode ser expresso como um somatório de infinitas exponenciais complexas de frequências positivas e negativas através da série exponencial de *Fourier*. Ao aplicar o operador analítico à série, obtém-se como resultado o somatório somente das exponenciais complexas positivas, cada uma referente a uma harmônica da série de *Fourier*. O equivalente analítico de um sinal periódico real pode ser entendido também como um somatório de fasores girantes de diferentes frequências. A partir desta representação é possível alterar a fase de todas as componentes de frequência presentes no sinal sob análise através da multiplicação pela constante complexa α .

A forma como é feita a decomposição das tensões trifásicas em componentes simétricas instantâneas nesta dissertação é semelhante àquela proposta por Cutri (2004), onde também são apresentadas outras abordagens com a teoria de vetores espaciais e a teoria PQ.

3.2.1 Desenvolvimento da Componente $v_{0a}(wt)$

A componente $v_{0a}(wt)$ da matriz de transformação da Equação (1) pode ser simplificada para melhor entendimento. Considerando que $v_a(wt)$, $v_b(wt)$, $v_c(wt)$ e $g_w(t)$ são funções reais podemos simplificar $v_{0a}(wt)$ da Equação (1) como

$$v_{0a}(wt) = \frac{1}{3}g_w(t)(v_a(wt) + v_b(wt) + v_c(wt)). \quad (4)$$

Alguns comentários sobre a função janela $g_w(t)$ para o cálculo de $v_{0a}(wt)$ precisam ser apresentados. Antes da ocorrência da falta os sinais de tensão possuem somente a componente de sequência positiva, pois as mesmas estão em equilíbrio. Deste modo, havendo a falta, naturalmente surgem as componentes de sequência zero e negativa como descrito em Stevenson (1982). Em outras palavras, nestas condições, o sinal $v_{0a}(wt)$ existe somente durante a ocorrência de uma falta CT . Em tal cenário é plausível usar uma função janela $g_w(t)$ retangular, desde que esta tenha suporte temporal suficiente para comportar o sinal analisado. Satisfeita esta condição de largura da janela retangular o espectro do sinal analisado não sofrerá influência do janelamento retangular (COHEN, 1995).

A Figura 5 ilustra dois casos. Nos gráficos superiores é mostrado o caso em que a função janela não comporta totalmente o sinal sob análise (à esquerda) bem como a implicação disto no domínio da frequência (à direita), ou seja, o espectro do sinal janelado carrega consigo as características do espectro da janela. Nos gráficos inferiores é mostrado o caso em que a função janela comporta totalmente o sinal sob análise (à esquerda) e a não ocorrência desse efeito no domínio da frequência (à direita). Este efeito pode ser explicado através da seguinte propriedade: o produto de duas funções no domínio do tempo se transforma na convolução destas mesmas funções no domínio da frequência (OPPENHEIM; WILLSKY; NAWAB, 2010).

Como dito anteriormente, a Equação (4) fornece a superposição dos componentes de sequência zero presentes no sistema trifásico. Provamos esse resultado a seguir.

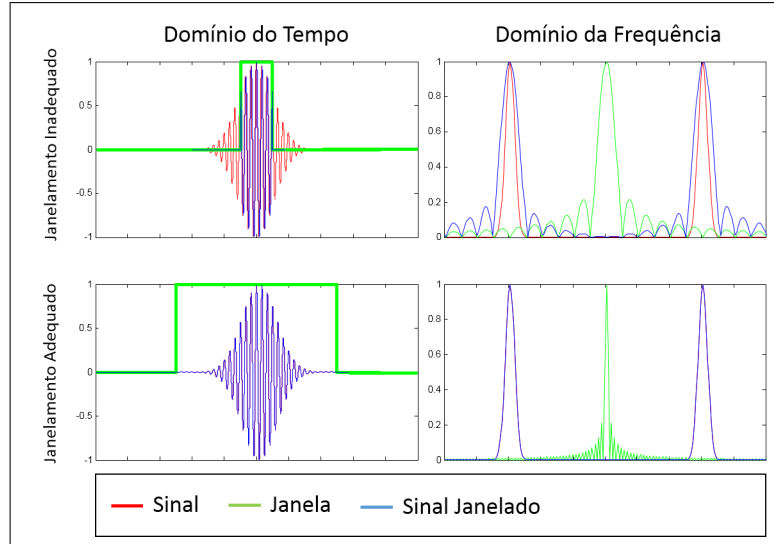


Figura 5 - Janelamento dos sinais de tensão para o cálculo de $v_{0a}(wt)$.

Considere-se o sistema de tensões $v_a(wt)$, $v_b(wt)$ e $v_c(wt)$ com sequência positiva, negativa e zero dados por

$$\left\{ \begin{array}{l}
 v_a(wt) = \sum_{n=1}^{\infty} V_{an} \cos [hwt] = \\
 = \sum_{n=1}^{\infty} V_{a(3n-2)} \cos [(3n-2)wt] + \sum_{n=1}^{\infty} V_{a(3n-1)} \cos [(3n-1)wt] + \\
 + \sum_{n=1}^{\infty} V_{a(3n)} \cos [(3n)wt], \\
 \\
 v_b(wt) = \sum_{n=1}^{\infty} V_{bn} \cos \left[h \left(wt - \frac{2\pi}{3} \right) \right] = \\
 = \sum_{n=1}^{\infty} V_{b(3n-2)} \cos \left[(3n-2) \left(wt - \frac{2\pi}{3} \right) \right] + \sum_{n=1}^{\infty} V_{b(3n-1)} \cos \left[(3n-1) \left(wt - \frac{2\pi}{3} \right) \right] + \\
 + \sum_{n=1}^{\infty} V_{b(3n)} \cos \left[(3n) \left(wt - \frac{2\pi}{3} \right) \right], \\
 \\
 v_c(wt) = \sum_{n=1}^{\infty} V_{cn} \cos \left[h \left(wt + \frac{2\pi}{3} \right) \right] = \\
 = \sum_{n=1}^{\infty} V_{c(3n-2)} \cos \left[(3n-2) \left(wt + \frac{2\pi}{3} \right) \right] + \sum_{n=1}^{\infty} V_{c(3n-1)} \cos \left[(3n-1) \left(wt + \frac{2\pi}{3} \right) \right] + \\
 + \sum_{n=1}^{\infty} V_{c(3n)} \cos \left[(3n) \left(wt + \frac{2\pi}{3} \right) \right].
 \end{array} \right. \quad (5)$$

Os termos $(3n-2)$, $(3n-1)$ e $(3n)$ para $n = 1, 2, 3, \dots, +\infty$, representam os harmônicos de sequência positiva, negativa e zero respectivamente.

Simplificando as equações em 5, as tensões $v_a(wt)$, $v_b(wt)$ e $v_c(wt)$ são dados por

$$\left\{ \begin{array}{l} v_a(wt) = \sum_{n=1}^{\infty} V_{a(3n-2)} \cos \left[(3n-2)wt \right] + \sum_{n=1}^{\infty} V_{a(3n-1)} \cos \left[(3n-1)wt \right] + \\ \quad + \sum_{n=1}^{\infty} V_{a(3n)} \cos \left[(3n)wt \right], \\ v_b(wt) = \sum_{n=1}^{\infty} V_{b(3n-2)} \cos \left[(3n-2)wt - \frac{2\pi}{3} \right] + \sum_{n=1}^{\infty} V_{b(3n-1)} \cos \left[(3n-1)wt + \frac{2\pi}{3} \right] + \\ \quad + \sum_{n=1}^{\infty} V_{b(3n)} \cos \left[(3n)wt \right], \\ v_c(wt) = \sum_{n=1}^{\infty} V_{c(3n-2)} \cos \left[(3n-2)wt + \frac{2\pi}{3} \right] + \sum_{n=1}^{\infty} V_{c(3n-1)} \cos \left[(3n-1)wt - \frac{2\pi}{3} \right] + \\ \quad + \sum_{n=1}^{\infty} V_{c(3n)} \cos \left[(3n)wt \right]. \end{array} \right. \quad (6)$$

Se aplicarmos as tensões trifásicas descritas acima à Equação (4), pode ser observado que, se o sistema estiver equilibrado, ou seja, se as amplitudes $V_a = V_b = V_c = V$ para todas as componentes simétricas, então as únicas componentes que não se anulam são as de sequência zero. Assim,

$$\begin{aligned} v_{0a}(wt) &= \frac{1}{3}g_w(t)(v_a(t) + v_b(t) + v_c(t)) \\ v_{0a}(wt) &= \frac{1}{3}g_w(t) \left(\sum_{n=1}^{\infty} V_{a(3n)} \cos [(3n)wt] + \sum_{n=1}^{\infty} V_{b(3n)} \cos [(3n)wt] + \right. \\ &\quad \left. + \sum_{n=1}^{\infty} V_{c(3n)} \cos [(3n)wt] \right) \\ v_{0a}(wt) &= g_w(t) \left(\sum_{n=1}^{\infty} V_{(3n)} \cos [(3n)wt] \right) \end{aligned} \quad (7)$$

Como o sistema de distribuição que originou o banco de dados sob análise é composto por tensões contendo somente a componente fundamental, de acordo com a Tabela 6, o desequilíbrio gerado por uma falta CT resulta no surgimento de uma componente de sequência zero. A Figura 6 exemplifica este caso onde é apresentado um exemplo da aplicação da Equação (4) em uma das faltas contidas no banco de dados. A Figura 6.a apresenta as tensões $v_a(wt)$, $v_b(wt)$ e $v_c(wt)$ durante uma falta. A Figura 6.b representa o sinal $v_{0a}(wt)$ interpretado neste trabalho como sendo uma estimativa da sequência zero

instantânea. E a Figura 6.c representa a densidade de energia instantânea (OPPENHEIM; WILLSKY; NAWAB, 2010).

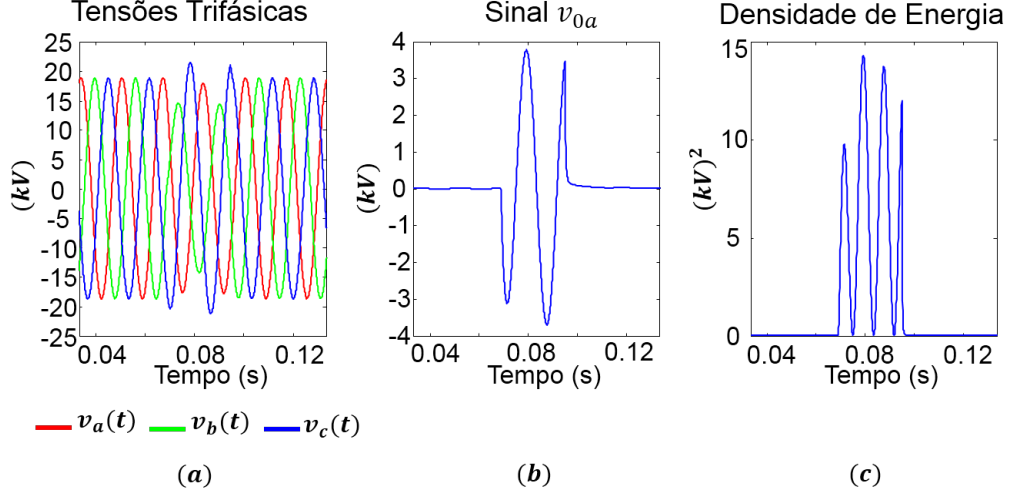


Figura 6 - A Equação (4) foi aplicada à falta do tipo AG de 10Ω com 25ms de duração e origem no ponto 5.

3.2.2 Desenvolvimento da Componente $v_{2a}(wt)$

A componente de sequência negativa, $v_{2a}(wt)$, da matriz de transformação da Equação (1) também pode ser simplificada. Considerando que $v_a(wt)$, $v_b(wt)$, $v_c(wt)$ e $g_w(t)$ são funções reais, $v_{2a}(wt)$ da Equação (1) é dada por:

$$\begin{aligned}
 v_{2a}(wt) &= \frac{1}{3}\text{Real}\{A\{g_w(t)v_a(wt)\} + A\{g_w(t)v_b(wt)\}e^{-j\frac{2\pi}{3}} + A\{g_w(t)v_c(wt)\}e^{j\frac{2\pi}{3}}\} \\
 v_{2a}(wt) &= \frac{1}{3}\text{Real}\{A\{g_w(t)v_a(wt)\}\} + \text{Real}\{A\{g_w(t)v_b(wt)\}e^{-j\frac{2\pi}{3}}\} + \text{Real}\{A\{g_w(t)v_c(wt)\}e^{j\frac{2\pi}{3}}\} \\
 v_{2a}(wt) &= \frac{1}{3}\left(g_w(t)v_a(wt) + \text{Real}\left\{(g_w(t)v_b(wt) + jH\{g_w(t)v_b(wt)\})\left(-\frac{1}{2} - j\frac{\sqrt{3}}{2}\right)\right\} + \right. \\
 &\quad \left. + \text{Real}\left\{(g_w(t)v_c(wt) + jH\{g_w(t)v_c(wt)\})\left(-\frac{1}{2} + j\frac{\sqrt{3}}{2}\right)\right\}\right),
 \end{aligned} \tag{8}$$

que matricialmente é descrita da seguinte forma:

$$v_{2a}(wt) = \frac{1}{3} \begin{bmatrix} 1 & -\frac{1}{2} & -\frac{1}{2} \end{bmatrix} \begin{bmatrix} g_w(t)v_a(wt) \\ g_w(t)v_b(wt) \\ g_w(t)v_c(wt) \end{bmatrix} + \frac{1}{3} \begin{bmatrix} 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} H\{g_w(t)v_a(wt)\} \\ H\{g_w(t)v_b(wt)\} \\ H\{g_w(t)v_c(wt)\} \end{bmatrix}. \tag{9}$$

Os coeficientes da Equação (9) são relacionados com os coeficientes da transformação de Clarke (CLARKE, 1950)(Equação (10)) resultando na mudança do sistema $a - b - c$ para o sistema $\alpha - \beta - 0$.

$$\begin{bmatrix} v_0(wt) \\ v_\alpha(wt) \\ v_\beta(wt) \end{bmatrix} = \sqrt{\frac{2}{3}} \begin{bmatrix} 1 & 1 & 1 \\ 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} v_a(wt) \\ v_b(wt) \\ v_c(wt) \end{bmatrix}. \quad (10)$$

Supondo que

$$\begin{aligned} G_W(\omega) &= 0 \quad \text{para } |\omega| > \Omega \\ V_N(\omega) &= 0 \quad \text{para } |\omega| \leq \Omega \quad ; N = \{a, b, c\}, \end{aligned} \quad (11)$$

onde $G_W(\omega)$ e $V_N(\omega)$ são as transformadas de *Fourier* da função janela e dos sinais de tensão respectivamente. E Ω é um limite que separa as bandas de $G_W(w)$ e $V_N(w)$.

Pode-se utilizar a identidade

$$H\{g_w(t)v_n(wt)\} = g_w(t)H\{v_n(wt)\}, \quad n = \{a, b, c\}, \quad (12)$$

chamada identidade de Bedrosian (BEDROSIAN, 1963) para obter a seguinte simplificação:

$$v_{2a}(wt) = \frac{1}{3} \sqrt{\frac{3}{2}} g_w(t) (v_\alpha(wt) + H\{v_\beta(wt)\}). \quad (13)$$

A Equação (13) fornece a superposição dos componentes de sequência negativa presentes no sistema trifásico. A prova deste resultado é apresentada em seguida. Considerando as tensões trifásicas na Equação (6) e supondo que o sistema esteja em equilíbrio, ou seja, que $V_a = V_b = V_c = V$, as tensões $v_\alpha(wt)$ e $v_\beta(wt)$ são dadas por:

$$\left\{ \begin{array}{l}
v_\alpha(wt) = \sqrt{\frac{2}{3}} \left(\sum_{n=1}^{\infty} V_{(3n-2)} \cos \left[(3n-2)wt \right] - \frac{1}{2} \sum_{n=1}^{\infty} V_{(3n-2)} \cos \left[(3n-2)wt - \frac{2\pi}{3} \right] + \right. \\
\left. - \frac{1}{2} \sum_{n=1}^{\infty} V_{(3n-2)} \cos \left[(3n-2)wt + \frac{2\pi}{3} \right] + \right. \\
\left. + \sum_{n=1}^{\infty} V_{(3n-1)} \cos \left[(3n-1)wt \right] - \frac{1}{2} \sum_{n=1}^{\infty} V_{(3n-1)} \cos \left[(3n-1)wt + \frac{2\pi}{3} \right] + \right. \\
\left. - \frac{1}{2} \sum_{n=1}^{\infty} V_{(3n-1)} \cos \left[(3n-1)wt - \frac{2\pi}{3} \right] + \right. \\
\left. + \sum_{n=1}^{\infty} V_{(3n)} \cos \left[(3n)wt \right] - \frac{1}{2} \sum_{n=1}^{\infty} V_{(3n)} \cos \left[(3n)wt \right] - \frac{1}{2} \sum_{n=1}^{\infty} V_{(3n)} \cos \left[(3n)wt \right] \right), \quad (14) \\
H\{v_\beta(wt)\} = \sqrt{\frac{2}{3}} \left(\frac{\sqrt{3}}{2} \sum_{n=1}^{\infty} V_{(3n-2)} \sin \left[(3n-2)wt - \frac{2\pi}{3} \right] - \frac{\sqrt{3}}{2} \sum_{n=1}^{\infty} V_{(3n-2)} \sin \left[(3n-2)wt + \frac{2\pi}{3} \right] + \right. \\
\left. + \frac{\sqrt{3}}{2} \sum_{n=1}^{\infty} V_{(3n-1)} \sin \left[(3n-1)wt + \frac{2\pi}{3} \right] - \frac{\sqrt{3}}{2} \sum_{n=1}^{\infty} V_{(3n-1)} \sin \left[(3n-1)wt - \frac{2\pi}{3} \right] + \right. \\
\left. + \frac{\sqrt{3}}{2} \sum_{n=1}^{\infty} V_{(3n)} \sin \left[(3n)wt \right] - \frac{\sqrt{3}}{2} \sum_{n=1}^{\infty} V_{(3n)} \sin \left[(3n)wt \right] \right).
\end{array} \right.$$

Utilizando-se as identidades trigonométricas:

$$\cos \left(a - \frac{2\pi}{3} \right) + \cos \left(a + \frac{2\pi}{3} \right) = -\cos(a), \quad (15)$$

e

$$\sin \left(a - \frac{2\pi}{3} \right) - \sin \left(a + \frac{2\pi}{3} \right) = -\sqrt{3} \cos(a), \quad (16)$$

$v_\alpha(wt)$ e $v_\beta(wt)$ são reescritas da seguinte forma:

$$\left\{ \begin{array}{l}
v_\alpha(wt) = \sqrt{\frac{2}{3}} \left(\sum_{n=1}^{\infty} V_{(3n-2)} \cos [(3n-2)wt] + \frac{1}{2} \sum_{n=1}^{\infty} V_{(3n-2)} \cos [(3n-2)wt] + \right. \\
\left. + \sum_{n=1}^{\infty} V_{(3n-1)} \cos [(3n-1)wt] + \frac{1}{2} \sum_{n=1}^{\infty} V_{(3n-1)} \cos [(3n-1)wt] + \right. \\
\left. + \sum_{n=1}^{\infty} V_{(3n)} \cos [(3n)wt] - \sum_{n=1}^{\infty} V_{(3n)} \cos [(3n)wt] \right) \quad ; \quad (17) \\
H\{v_\beta(wt)\} = \sqrt{\frac{2}{3}} \left(-\frac{\sqrt{3}}{2} \sqrt{3} \sum_{n=1}^{\infty} V_{(3n-2)} \cos [(3n-2)wt] + \right. \\
\left. + \frac{\sqrt{3}}{2} \sqrt{3} \sum_{n=1}^{\infty} V_{(3n-1)} \cos [(3n-1)wt] + 0 \right)
\end{array} \right.$$

e simplificadas para:

$$\left\{ \begin{array}{l}
v_\alpha(wt) = \sqrt{\frac{2}{3}} \left(+\frac{3}{2} \sum_{n=1}^{\infty} V_{(3n-2)} \cos [(3n-2)wt] + \frac{3}{2} \sum_{n=1}^{\infty} V_{(3n-1)} \cos [(3n-1)wt] \right) \\
H\{v_\beta(wt)\} = \sqrt{\frac{2}{3}} \left(-\frac{3}{2} \sum_{n=1}^{\infty} V_{(3n-2)} \cos [(3n-2)wt] + \frac{3}{2} \sum_{n=1}^{\infty} V_{(3n-1)} \cos [(3n-1)wt] \right)
\end{array} \right. \quad (18)$$

A partir dos cálculos e simplificações feitas a tensão $v_{2a}(wt)$ é descrita da seguinte forma:

$$v_{2a}(wt) = \frac{1}{3}\sqrt{\frac{3}{2}}g_w(t)(v_\alpha(wt) + H\{v_\beta(wt)\}) = \sum_{n=1}^{\infty} V_{(3n-1)} \cos [(3n-1)wt]. \quad (19)$$

Alguns comentários sobre a função janela $g_w(t)$ para o cálculo de $v_{2a}(wt)$ precisam ser apresentados. A transformada de Hilbert do sinal janelado por uma função retangular gera um efeito de borda indesejável (COHEN, 1995). Tal efeito de borda impede o cancelamento completo das funções $v_\alpha(wt)$ e $H\{v_\beta(wt)\}$ para as componente de sequência positiva e zero. Uma forma de contornar este problema é utilizar uma função janela que satisfaça as condições apresentadas na Equação (11). A Figura 7 mostra o caso em que um sinal $s(t)$ é janelado por uma função retangular e por uma Gaussiana. Observa-se que quando o sinal janelado por uma função retangular passa pela transformada de *Hilbert* aparece o efeito de borda diferentemente do que ocorre para a janela Gaussiana, onde este efeito não é visível.

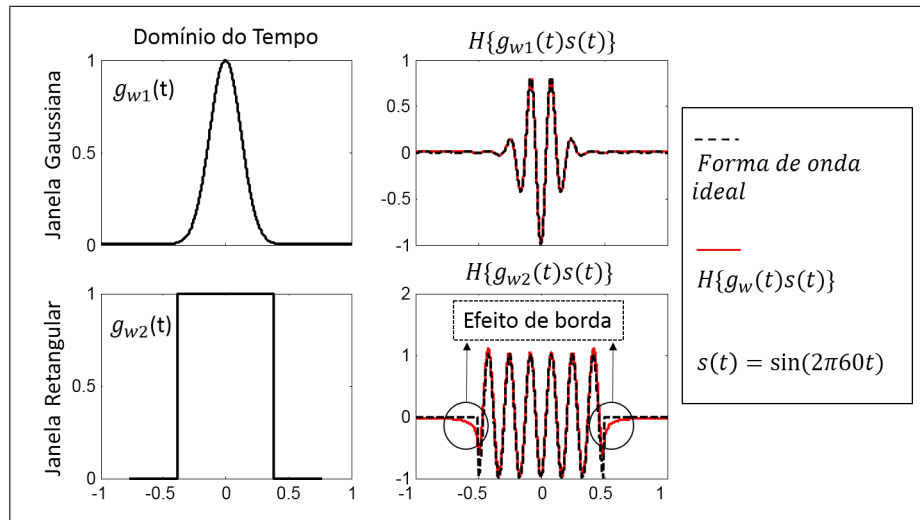


Figura 7 - Efeito de borda gerado pela janela retangular e a janela gaussiana como alternativa para filtrar este efeito.

Assim, uma função janela que atende às condições apresentadas na Equação (11) é a função Gaussiana. Considere a função janela $g_w(t)$ e sua transformada de *Fourier*

$$g_w(t) = \frac{1}{\sqrt{2\pi\sigma_t^2}} e^{-\frac{t^2}{2\sigma_t^2}}, \quad (20)$$

$$G_W(\omega) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(\sigma_t\omega)^2}{2}}. \quad (21)$$

A relação entre as variâncias é dada por:

$$\sigma_t = \frac{1}{\sigma_w}. \quad (22)$$

Uma forma de estimar a banda da função Gaussiana é pelo método da energia no domínio da frequência. Em uma banda de $3\sigma_w \text{ rad/s}$ tem-se aproximadamente 99,7% da energia total do sinal (COHEN, 1995). Desta forma pode-se projetar uma janela Gaussiana de forma a atender as condições apresentadas na Equação (11).

Neste trabalho optou-se por uma abordagem alternativa mais simples, que consiste em aumentar o suporte temporal da janela de captura ($g_{w_1}(t)$), aplicar a transformada de *Hilbert* e, posteriormente, eliminar os efeitos de borda por truncamento. Isto é feito a partir de uma outra janela ($g_{w_2}(t)$) de menor suporte temporal conforme:

$$v_{2a}(wt) = \frac{1}{3} \sqrt{\frac{3}{2}} g_{w_2}(t) \left(g_{w_1}(t) v_\alpha(wt) + H\{g_{w_1}(t) v_\beta(wt)\} \right). \quad (23)$$

Assumindo que o sistema de distribuição que originou o banco de dados sob análise é composto por tensões contendo somente a componente fundamental, de acordo com a Tabela 6 o desequilíbrio gerado por uma falta *ST* (com exceção da faltas do tipo *ABC* que são tratadas mais adiante) resulta em uma componente de sequência negativa. A Figura 8 exemplifica este caso onde é apresentado um exemplo da aplicação da Equação (13) em uma das faltas contidas no banco de dados. A Figura 8.a apresenta as tensões $v_a(wt)$, $v_b(wt)$ e $v_c(wt)$ durante uma falta. A Figura 8.b apresenta a decomposição das tensões $v_a(wt)$, $v_b(wt)$ e $v_c(wt)$ nos sistema $\alpha - \beta$. A Figura 8.c representa o sinal $v_{2a}(wt)$ interpretado neste trabalho como sendo uma estimativa da sequência negativa instantânea. E a Figura 8.d representa a densidade de energia instantânea do sinal $v_{2a}(wt)$ (OPPENHEIM; WILLSKY; NAWAB, 2010).

3.3 Descrição do Método de Localização da Falta

Nesta seção é descrita a técnica proposta para caracterizar a localização da falta. Como discutido no início desse capítulo, o objetivo é estimar a localização da falta a partir da dissipação dos sinais de energia que se propagam pela linha de distribuição. Os sinais $v_{0a}(t)$ e $v_{2a}(t)$ representam o evento da falta. Assim, calcula-se a energia total desses sinais em medidores que estejam à direita e à esquerda da falta e relaciona-se os dois conforme




Figura 8 - A Equação 19 foi aplicada à falta do tipo AB de 10Ω com 25ms de duração e origem no ponto 5.

ilustra a Equação (24). Como, a princípio, não se sabe a localização da falta, o ideal é utilizar medidores que estejam situados nos extremos da linha de distribuição, ou seja, o medidor do início (MI) e o medidor do final da linha de distribuição (ME). Dessa forma é assegurado que a falta ocorreu entre estes dois medidores.

$$b(s(t), ME, MI) = \ln \left(\frac{\varepsilon\{s_{ME}(t)\}}{\varepsilon\{s_{MI}(t)\}} \right), \quad (24)$$

no qual, $\varepsilon\{*\}$ é o operador que calcula a energia total do sinal, b é o coeficiente linear e os índices MI e ME no sinal $s(t)$ referem-se aos medidores do início e do final da linha de distribuição, respectivamente. A energia total é calculada da seguinte forma:

$$\varepsilon\{s_k(t)\} = \int_{-\infty}^{\infty} |s_k(t)|^2 dt, \quad (25)$$

onde k refere-se ao medidor, $k=ME,MI$.

O sinal de análise $s_k(t)$ é alterado (com base na Tabela 6) de acordo com cada caso:

- 1) Para distinguir os tipos CT e ST de faltas, o sinal de análise $s_k(t)$ é $v_{0a}(t)$;
- 2) Para caracterizar a localização de faltas CT , o sinal de análise $s_k(t)$ é $v_{0a}(t)$;
- 3) Para caracterizar a localização de faltas ST , o sinal de análise $s_k(t)$ é $v_{2a}(t)$.

3.4 Caracterização da Localização de Faltas CT

Nesta seção são apresentados os testes da aplicação da Equação (24) em faltas CT , com os resultados apresentados na Figura 9. Cada ponto $p(x, y)$ neste gráfico foi calculado usando o mapeamento

$$\begin{cases} x = \ln(\varepsilon\{v_{0a_{MI}}(t)\}) \\ y = \ln(\varepsilon\{v_{0a_{ME}}(t)\}) \end{cases}, \quad (26)$$

a partir do qual pode-se extrair

$$\ln(\varepsilon\{v_{0a_{ME}}(t)\}) = \ln(\varepsilon\{v_{0a_{MI}}(t)\}) + b(v_{0a}(t), ME, MI). \quad (27)$$

A Figura 9 mostra os resultados do processamento das faltas CT contidas no banco de dados, ou seja, que contemplam os tipos: AG , BG , CG , ABG , ACG , e BCG , com resistências de 10Ω , 25Ω e 40Ω e durações de $8,33ms$, $16,67ms$ e $25ms$. Na realidade a Equação (24) deriva da Equação (27) que foi deduzida experimentalmente com base nos resultados ilustrados na Figura 9.

As retas na Figura 9 possuem coeficientes angulares praticamente iguais e unitários. Além disso, elas sugerem que seus coeficientes lineares estão associados à localização da falta no ramo de distribuição principal (ramo entre os medidores mais externos - medidores I e E). Tal conclusão pode ser confirmada ao observar a Tabela 7 onde os coeficientes angulares e lineares foram obtidos por meio de uma regressão linear dessas retas.

Analisando os dados da Tabela 7 com a ajuda do diagrama unifilar apresentado

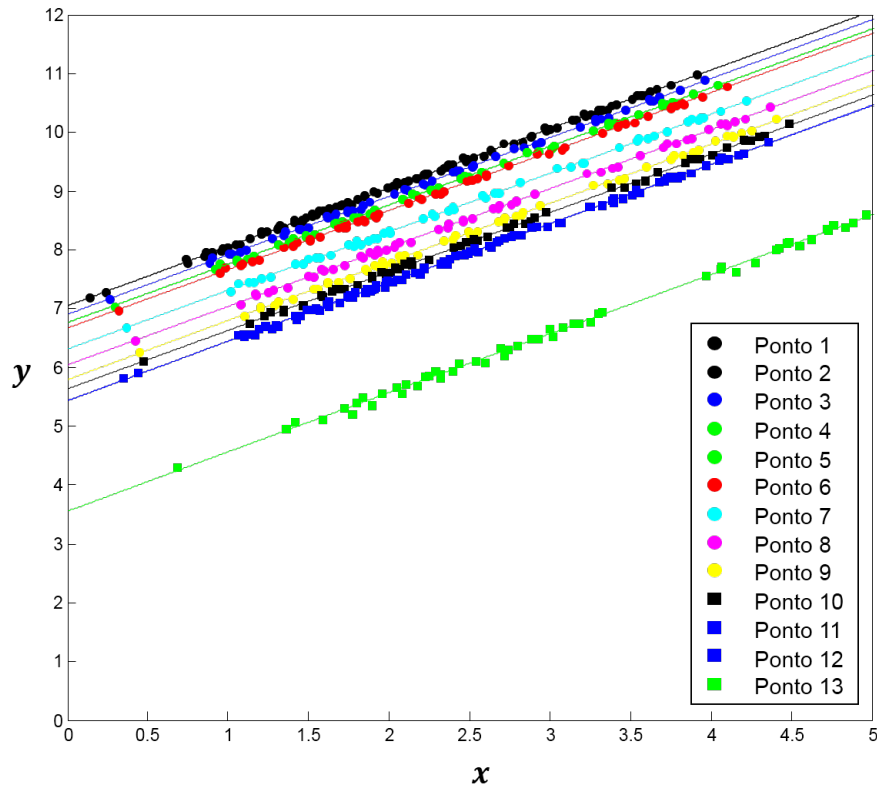


Figura 9 - Resultados do processamento das Falhas *CT*.

na Figura 10, são observados que alguns pontos de faltas não são distinguíveis. Este fato sugere que, por este método, para as faltas ocorridas fora do trecho que interliga dois medidores, somente a localização do ramal sob falta é identificada. No diagrama da Figura 10 os pontos que compartilham a mesma região em vermelho não são distinguíveis.

A Figura 11 apresenta a regressão exponencial obtida relacionando-se os coeficientes $b(v_{0a}(t), ME, MI)$ com as distâncias das faltas ao alimentador apresentados na Tabela 7. Esse resultado mostra que existe uma relação não linear entre o coeficiente $b(v_{0a}(t), ME, MI)$ e a distância da falta ao alimentador. Com efeito, o coeficiente linear $b(v_{0a}(t), ME, MI)$ possui potencial para estimar a localização das faltas.

A Figura 12 mostra três gráficos com as densidades de probabilidade estimadas para cada classe (ponto de localização de uma falta) em função do coeficiente linear $b(M1, M2)$. Essas densidades foram obtidas a partir de todas as faltas *CT* contidas no banco de dados. A Figura 12.a está em função de $b(MI, MH)$. A Figura 12.b está em função de $b(MH, ME)$. A Figura 12.c está em função de $b(MI, ME)$. As funções densidade foram obtidas pelo método de estimação não paramétrico. O estimador para uma variável contínua z com base em um conjunto de dados (amostras) $\{z_1, z_2, z_3, \dots, z_n\}$

avaliadas no ponto z pode ser definido como

$$f(z) = \frac{1}{n} \sum_{i=1}^n \phi(z - z_i, h), \quad (28)$$

onde ϕ é uma função gaussiana de média z_i e desvio padrão h . Pode-se observar, com base na Figura 12, que é possível separar a maioria das classes (cada classe representa uma localização de falta) com certo grau de separação quando são utilizados os medidores que estão mais distantes. Por outro lado quando são utilizado medidores mais próximos, as faltas que estão fora do intervalo desses medidores não podem ser separadas. Entretanto, as classes que aparecem dentro do intervalo desses medidores possuem uma separação maior. Em outras palavras, a distância entre os medidores influencia na precisão da localização da falta. Quanto menor o intervalo entre os medidores, melhor é a estimativa da localização da falta.

Tabela 7 - Tabela de coeficientes das retas da Figura 9

Ponto	Coeficientes		Distância do Ramal ao Alimentador (km)
	Angular	Linear	
1	1,00107	7,05133	6,755
2	1,00087	7,05257	6,325
3	1,00029	6,90758	5,895
4	0,99974	6,75337	5,465
5	0,99973	6,75337	5,465
6	0,99975	6,66362	5,395
7	0,99976	6,3029	4,515
8	0,99915	6,03509	3,945
9	1,00055	5,79012	3,495
10	1,00037	5,62532	3,225
11	1,0026	5,43574	2,98
12	1,00345	5,43574	2,98
13	1,00714	3,55424	1,12

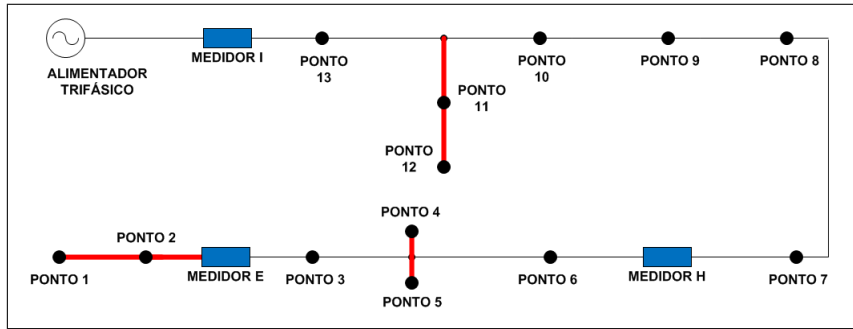


Figura 10 - Diagrama unifilar simplificado.




Figura 11 - Interpolação exponencial entre os coeficientes b e as distâncias das faltas ao alimentador.




Figura 12 - Densidades de probabilidade de $b(MI, MH)$, $b(MH, ME)$ e $b(MI, ME)$ estimadas para cada classe (ponto de localização de uma falta CT).

3.5 Caracterização da Localização de Falhas ST

Nesta seção são apresentados os testes da aplicação da Equação (24) em faltas ST , com os resultados apresentados na Figura 13. Cada ponto $p(x, y)$ neste gráfico foi calculado usando o mapeamento

$$\begin{cases} x = \ln(\varepsilon\{v_{2a_{MI}}(t)\}) \\ y = \ln(\varepsilon\{v_{2a_{ME}}(t)\}) \end{cases}, \quad (29)$$

a partir do qual pode-se extrair

$$\ln(\varepsilon\{v_{2a_{ME}}(t)\}) = \ln(\varepsilon\{v_{2a_{MI}}(t)\}) + b(v_{2a}(t), ME, MI). \quad (30)$$

Os dados mostrados nesse gráfico referem-se a todas as faltas ST contidas no banco de dados, ou seja, contemplam os tipos: AB, AC, BC e ABC para resistências de 10Ω , 25Ω e 40Ω e durações de $8, 33ms$, $16, 67ms$ e $25ms$.

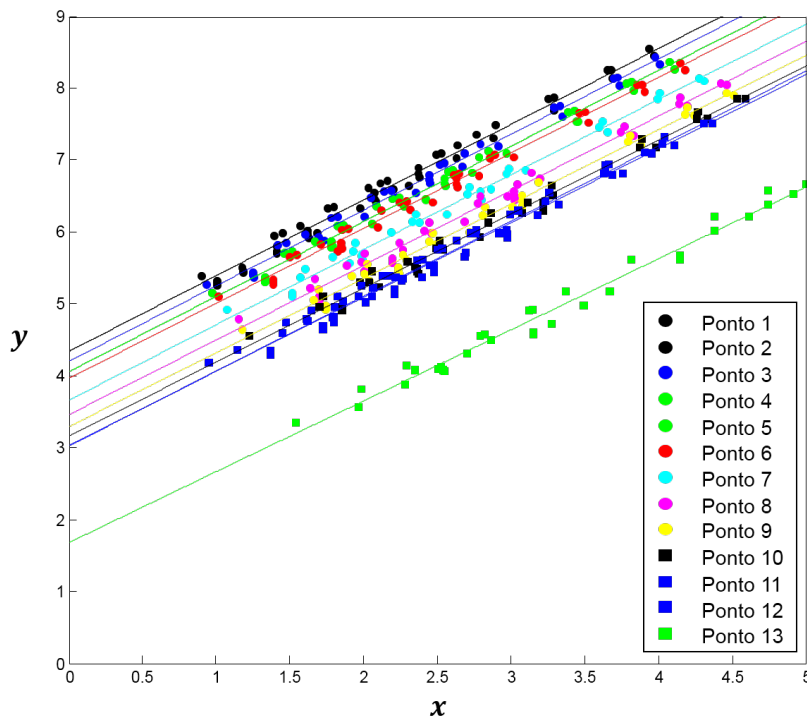


Figura 13 - Resultados do processamento das Falhas ST .

Observa-se, com base na Figura 13, que a dispersão dos dados é maior se comparado com os dados referentes às Falhas CT apresentados na Figura 9. Em outras palavras, existe uma interseção entre classes mais visível. Essas interseções podem ser confirmadas

na Figura 14 onde são apresentados três gráficos com as densidades de probabilidade estimadas para cada classe (ponto de localização de uma falta) em função do coeficiente linear $b(v_{2a}(t), M1, M2)$. Pode-se então observar, por essas densidades de probabilidade, como a dispersão dos dados reflete diretamente na interseção entre classes.




Figura 14 - Densidades de probabilidade de $b(MI, MH)$, $b(MH, ME)$ e $b(MI, ME)$ estimadas para cada classe (ponto de localização de uma falta ST).

As faltas do tipo *ABC* por serem simétricas (equilibradas), possuem apenas componente de sequência positiva (conforme apresentado na Tabela 6). No entanto, ainda assim o evento da falta pode ser observada no sinal $v_{2a}(t)$ que representa a sequência negativa instantânea. Na verdade, somente os transitórios ocorridos devido ao aparecimento e desaparecimento da falta podem ser observados. A Figura 15 mostra, para um exemplo de falta do tipo *ABC* contida no banco de dados, os transitórios representando o fenômeno do aparecimento e desaparecimento da falta. A Figura 15.a apresenta as tensões $v_a(t)$, $v_b(t)$ e $v_c(t)$ durante uma falta. A Figura 15.b apresenta a decomposição das tensões $v_a(t)$, $v_b(t)$ e $v_c(t)$ nos sistema $\alpha - \beta$. A Figura 15.c representa o sinal $v_{2a}(t)$ interpretado neste trabalho como sendo uma estimativa da sequência negativa instantânea. E a Figura 15.d representa a densidade de energia instantânea do sinal $v_{2a}(t)$ (OPPENHEIM; WILLSKY; NAWAB, 2010). Para esses tipos de faltas utiliza-se o mesmo tratamento utilizado no tipos de faltas *AB*, *AC* e *BC*. A Figura 16 apresenta os resultados do processamento das faltas *ST* do tipo *ABC* utilizando o sinal $v_{2a}(t)$. Pode ser observado nesse gráfico que as faltas

do tipo ABC seguem um padrão bem comportado assim como as faltas CT .

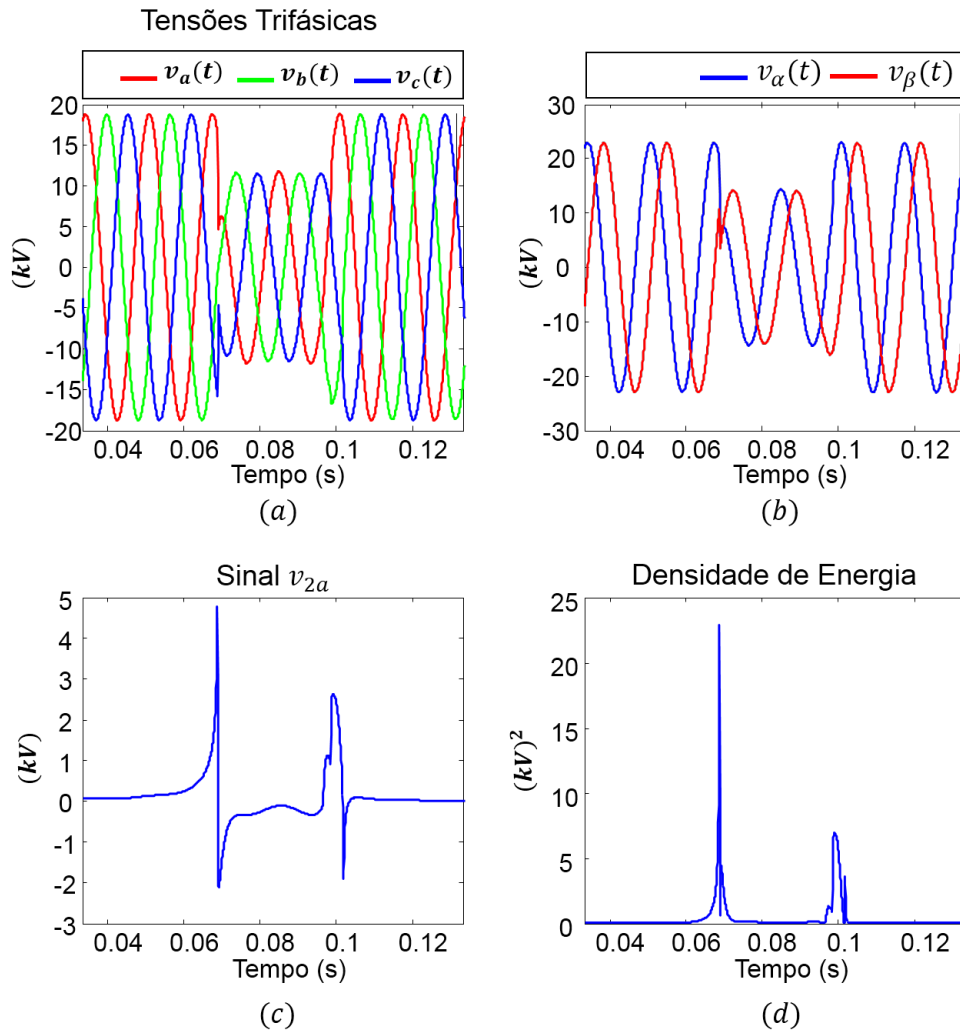


Figura 15 - Resultados da aplicação da Equação (19) a uma falta do tipo ABC de 10Ω com 25ms de duração e origem no ponto 5.

Considerando o caso especial que são as faltas do tipo ABC e a grande interseção de classes observada nos resultados apresentados na Figura 13, a próxima seção descreve um método para extrair mais informações das faltas ST , objetivando a melhora da caracterização desse tipo de falta. Na próxima seção é apresentada a metodologia para caracterizar os tipos de faltas AB , AC , BC e ABC .

3.5.1 Método de Caracterização dos Tipos de Faltas ST

Nesta seção é apresentado o método utilizado para distinguir entre os tipos de faltas AB , AC , BC e ABC . Este método se baseia na variação da amplitude das tensões




Figura 16 - Resultados do processamento das Falhas *ST* do tipo *ABC*.

durante a falta. Durante uma falta do tipo *AB*, somente as amplitudes das tensões das fase *A* e *B* sofrem variações significativas, o que se repete em outros tipos de faltas. O cálculo das variações de amplitude das tensões é dado por:

$$\begin{cases} \delta_{v_{a_k}} = \ln(\text{var}\{|A\{v_{a_k}(t)\}|^2\}) \\ \delta_{v_{b_k}} = \ln(\text{var}\{|A\{v_{b_k}(t)\}|^2\}) \\ \delta_{v_{c_k}} = \ln(\text{var}\{|A\{v_{c_k}(t)\}|^2\}), \end{cases} \quad (31)$$

onde $\text{var}\{*\}$ representa o operador para cálculo da variância amostral definido por

$$\text{var}\{x[T_s n]\} = \frac{1}{N} \sum_{n=1}^N (x[T_s n] - \mu)^2, \quad (32)$$

onde $x[T_s n]$ representa um sinal janelado de tamanho N e amostrado a intervalos T_s . O índice k representa o medidor sob análise ($k = \{MI, MH, ME\}$) e μ é a média do sinal $x[T_s n]$ definida por

$$\mu = \frac{1}{N} \sum_{n=1}^N x[T_s n]. \quad (33)$$

O cálculo do módulo do sinal analítico equivale a extrair a envoltória do sinal. No entanto, o módulo ao quadrado faz referência à energia do sinal analítico. Sendo assim, a equação (31) corresponde à variância da energia da envoltória dos sinais de tensão. O objetivo da função logarítmica é normalizar os dados de forma que as baixas oscilações no sinal tendam a $-\infty$, enquanto que as oscilações de interesse mantenham-se significativas. A Figura 17 apresenta os resultados obtidos a partir da aplicação da Equação (31). Os dados mostrados nesse gráfico referem-se a todas as faltas *ST* contidas no banco de dados.

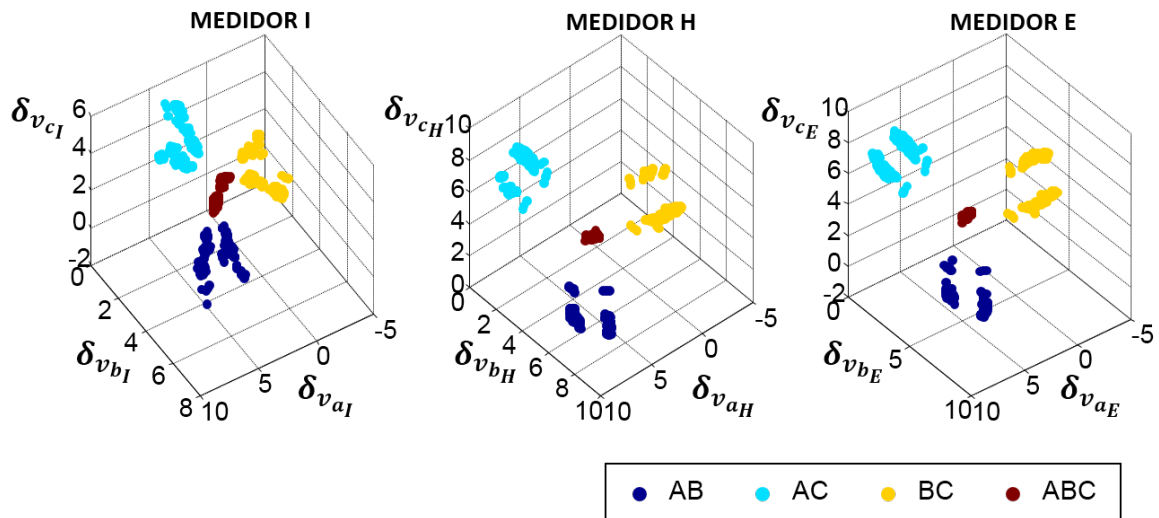


Figura 17 - Separação dos tipos de faltas *AB*, *AC*, *BC* e *ABC* a partir da aplicação da Equação (31). Cada gráfico sob a perspectiva de um medidor.

Com base nos gráficos da Figura 17, é observado que, independentemente do medidor em análise, os tipos de faltas *AB*, *AC*, *BC* e *ABC* podem ser separados sem nenhuma interseção entre classes.

3.6 Método de Caracterização dos tipos *CT* e *ST* de Faltas

Como já descrito em outras seções deste trabalho o algoritmo aqui desenvolvido divide o problema de localização de faltas em dois casos principais e trata de cada um de forma diferente. Em vista disto, nesta seção é apresentada a metodologia utilizada para caracterizar estes dois casos principais que são os tipos *CT* e *ST* de faltas.

Para caracterizar os tipos *CT* e *ST* de faltas, é utilizado o sinal de análise v_{0a} pois sabe-se que as faltas entre fases somente (faltas *ST*) não produzem componentes de sequência zero. A Figura 18 apresenta os histogramas de:

$$M_k = \ln(\varepsilon\{v_{0a_k}(t)\}), \quad (34)$$

onde k representa o medidor em análise ($k = \{MI, MH, ME\}$).

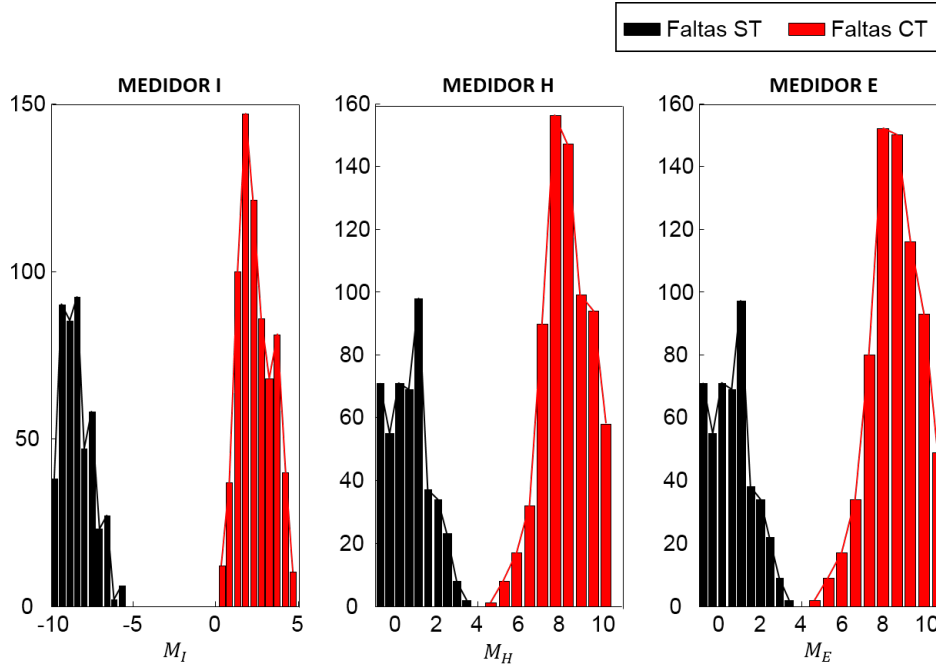


Figura 18 - Separação dos tipos de faltas CT e ST a partir da aplicação da Equação (34). Cada gráfico sob a perspectiva de um medidor.

Os dados mostrados nos histogramas da Figura 18 possuem como fonte todas as faltas contidas no banco de dados. Com base nesses gráficos, pode-se observar que os histogramas cujos dados referem-se ao medidor I (medidor mais próximo do alimentador) possuem um espaçamento entre classes maior se comparado aos outros medidores. No entanto, independentemente do medidor sob análise, os tipos de faltas CT e ST podem ser separados sem nenhuma interseção entre classes. Apesar das classes estarem bem próximas para os medidores H e E , ainda assim não há interseção.

Neste capítulo foram descritas as métricas utilizadas para extração de características que definem o problema da localização de faltas. Observou-se que, a partir dessas métricas, foi possível identificar com certo grau de separação, as localizações das faltas bem como os tipos de faltas. No próximo capítulo, tais métricas são utilizadas como vetores de entrada para os classificadores via redes neurais artificiais. Esses classificadores têm por objetivo, fornecer a localização das faltas no sistema de distribuição com base nas métricas apresentadas neste capítulo.

4 CLASSIFICAÇÃO DE FALTAS VIA REDES NEURAIS ARTIFICIAIS

Este capítulo trata da implementação dos classificadores via redes neurais, responsáveis por estimar a localização das faltas na rede de distribuição de energia elétrica. As redes neurais artificiais (RNAs) são sistemas de computação adaptativos inspirados nas características de processamento de informação encontradas nos neurônios biológicos e em suas características de interconexões (BISHOP, 2006).

O cérebro humano possui uma enorme capacidade de processamento de informações, como por exemplo, o reconhecimento da fala e a segmentação de imagens. E, a partir desta constatação, pesquisas têm sido realizadas com o intuito de reproduzir algumas das funções do cérebro em máquinas (Rede Neural Artificial), obtendo-se resultados promissores (apesar do pouco conhecimento que se tem sobre o funcionamento total do cérebro humano). As RNAs são formadas por um conjunto de neurônios artificiais que interagem entre si, semelhantemente ao funcionamento de neurônios biológicos. Basicamente, são sistemas paralelos de computação e suas implementações podem ser em software (HAYKIN, 2001) (simulações por programação em um computador digital) ou em *hardware* (KOVACS, 2002; GRANADO et al., 2006) (realiza uma determinada tarefa a partir de componentes eletrônicos).

As redes neurais têm a capacidade de coletar, utilizar e armazenar informações baseadas em experimentos (treinamentos). Redes neurais bem treinadas podem generalizar o conhecimento contido nos dados de treinamento, de forma a responder de forma adequada quando entradas desconhecidas no treinamento são apresentadas à rede (HAYKIN, 2001).

Algumas características importantes de uma rede neural artificial são (HAYKIN, 2001):

- Capacidade de generalização;
- Tolerância a falhas: A eliminação de alguns neurônios não afeta substancialmente o desempenho global;
- Tolerância a informações incompletas ou afetadas por ruído;
- Capacidade de realizar mapeamentos não-lineares entre entrada e saída;

- Adaptabilidade, mediante algoritmo de aprendizado.

4.1 Classificadores *Multilayer Perceptron* (MLP)

Uma MLP é uma rede neural do tipo *feed-forward* consistindo de uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída, como mostra a Figura 19. Cada camada da MLP possui vários neurônios. Como apresentado na Figura 20, cada neurônio possui várias entradas. À soma das entradas ponderadas (por pesos sinápticos) de um neurônio é aplicada uma função de ativação gerando a saída de cada neurônio. Esta por sua vez é repassada às entradas dos neurônios da camada seguinte até que a informação chegue aos neurônios da última camada. Para um problema de classificação de L-classes são necessários L neurônios na camada de saída para representar todas as possíveis classes de decisões. A quantidade de entradas da primeira camada é usualmente igual ao número de elementos do vetor de características que representa o sinal de entrada. A quantidade de neurônios da camada escondida bem como a quantidade total de camadas escondidas são determinadas de acordo com a aplicação e ficam a cargo do projetista da MLP. Quanto às funções de ativação, existem várias, a Figura 21 apresenta algumas delas.

Para que se possa aplicar uma rede neural em um problema de classificação, primeiro é necessário submeter a rede a um processo de aprendizagem ou treinamento realizado por técnicas recursivas conhecidas em estatística genericamente por aproximação estocástica (HAYKIN, 2001; KOVACS, 2002). O uso do algoritmo *backpropagation* é a abordagem de treinamento supervisionado mais utilizado em redes MLP (HAYKIN, 2001; KOVACS, 2002). Cada iteração no processo de treinamento consiste de dois passos:

- Passo 1: *Feed forward*: Neste passo uma amostra do conjunto de treinamento é passada adiante no sentido da camada de entrada para a camada de saída. Na camada de saída o erro entre a saída atual e a saída desejada é então calculado.
- Passo 2: *Feed Backward*: Neste passo o erro é propagado no sentido inverso, ou seja, no sentido da camada de saída para a camada de entrada. Neste processo os pesos sinápticos são atualizados a partir do gradiente do erro.

Antes do Passo 1, os pesos sinápticos já foram previamente inicializados aleatoriamente. A iteração dos Passos 1 e 2 continua até que um critério de parada seja




Figura 19 - Rede *Multilayer Perceptron* (MLP).

atingido (HAYKIN, 2001; KOVACS, 2002), como:

- Número fixo de épocas de treinamento (cada época de treinamento se completa após a apresentação de todos os padrões de entrada);
- Busca do erro médio quadrático mínimo para o conjunto de validação (conjunto de dados utilizados para analisar o desempenho do treinamento).

4.2 Projeto dos Classificadores Via Redes Neurais Artificiais

A escolha por redes neurais como ferramenta de classificação se justifica pelas interseções entre classes observadas para as faltas *ST* em função do coeficiente b (Figura 14, capítulo 3). Essas interseções constituem um problema para a classificação. Por ser uma ferramenta robusta e relativamente simples de se implementar, a rede neural foi a ferramenta escolhida. Para que fosse mantido o mesmo tipo de classificador, também foram utilizadas redes neurais para a localização das faltas *CT*.

Como primeira abordagem (abordagem teste), foram projetadas 17 redes MLP com

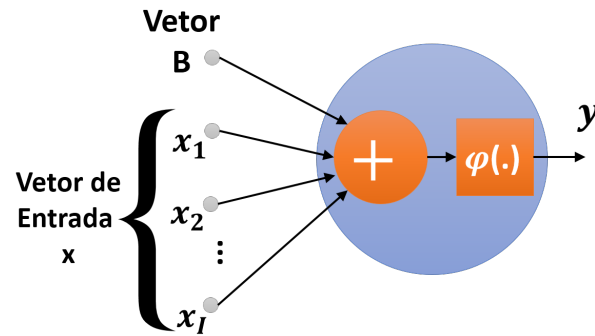


Figura 20 - Estrutura de um neurônio artificial.

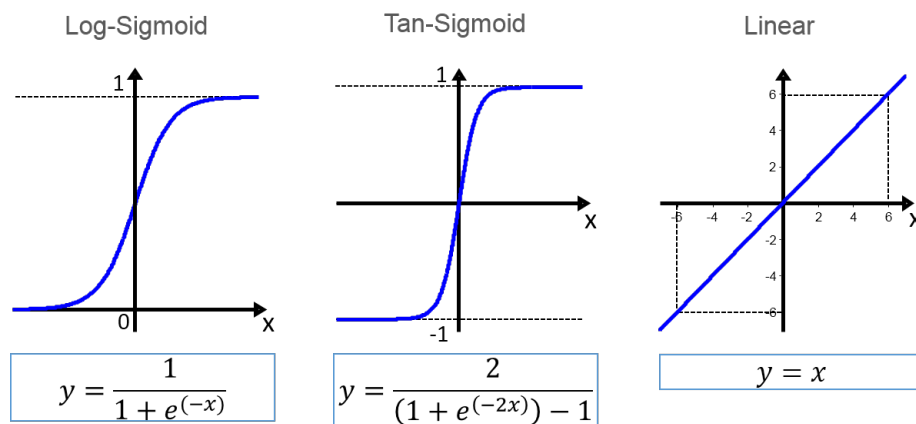


Figura 21 - Rede MLP.

algoritmo de otimização *Levenberg – Marquardt* (LM) (HAYKIN, 2001) que se encontra implementado no *Neural Network Toolbox* do software MATLAB. Cada rede neural é responsável por uma etapa em um processo gradual de localização das faltas. A Figura 22 apresenta a arquitetura de redes neurais adotada.

O processo de classificação começa com a distinção entre faltas *CT* e *ST* através da *RNA 0*. Em seguida, as faltas *ST* são separadas por tipo de falta *AB*, *AC*, *BC* e *ABC* através da *RNA 2*. Com o objetivo de minimizar a dimensão das redes neurais, tornando o processo de treinamento mais rápido, uma etapa de separação de grupos de classes foi incluída e constituem as redes neurais: *RNA 1*, *RNA 31*, *RNA 32*, *RNA 33* e *RNA 34*. Cada uma destas redes neurais é responsável por classificar uma falta entre dois grupos. O grupo $G1_{TIPO}$ contempla as classes de localização que vão do ponto 01 ao 07 e o grupo $G2_{TIPO}$ contempla as classes de localização que vão do ponto 08 ao 13. A Tabela 8 apresenta a distinção entre os grupos $G1$ e $G2$ bem a nova nomenclatura atribuída

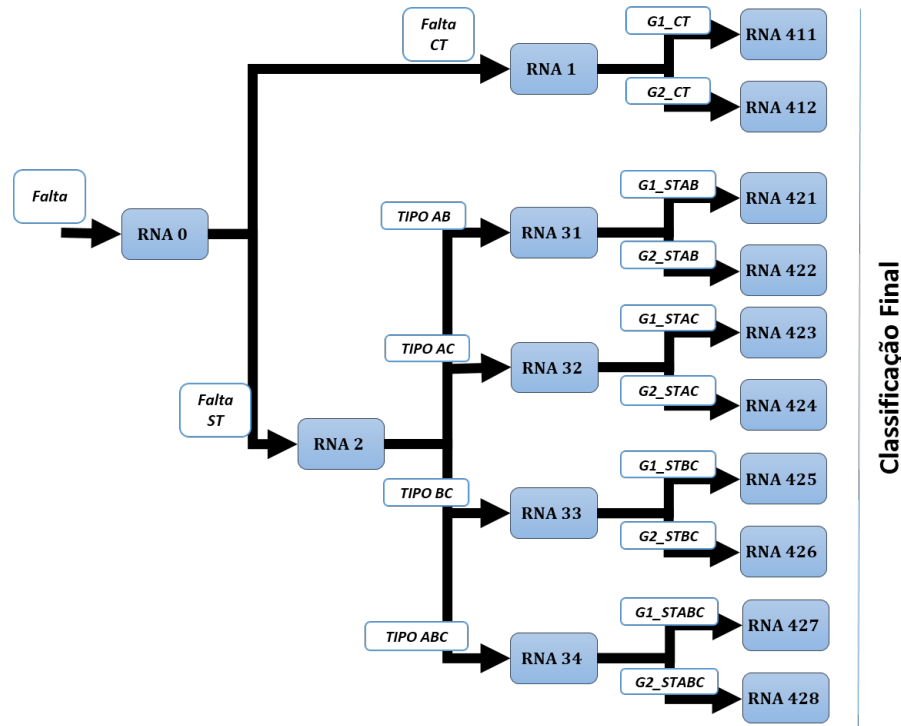


Figura 22 - Arquitetura neural com 17 redes neurais do tipo (*feed-forward backpropagation network*).

aos pontos de localização de falta. O índice *TIPO* é dado de acordo com a Tabela 9. Na Tabela 8 pode ser observado que os Pontos 1 e 2 foram incluídos na mesma classe assim como os Pontos 4 e 5 e os Pontos 11 e 12. Estes agrupamentos se devem ao fato de que estes pares de pontos de localizações de faltas não são distinguíveis, como foi apresentado no capítulo anterior.

As *RNAs* 411 e 412 são responsáveis por estimar a localização das faltas pertencentes ao grupo $G1_{CT}$ e $G2_{CT}$ respectivamente. As *RNAs* 421 e 422 são responsáveis por estimar a localização das faltas pertencentes ao grupo $G1_{STAB}$ e $G2_{STAB}$ respectivamente. As *RNAs* 423 e 424 são responsáveis por estimar a localização das faltas pertencentes ao grupo $G1_{STAC}$ e $G2_{STAC}$ respectivamente e assim por diante. A composição estrutural de cada rede neural pode ser vista na Tabela 10.

Tabela 8 - Grupo de Localizações.

Grupo $G1$		Grupo $G2$	
Classe 1	Ponto 1 e 2	Classe 6	Ponto 8
Classe 2	Ponto 3	Classe 7	Ponto 9
Classe 3	Ponto 4 e 5	Classe 8	Ponto 10
Classe 4	Ponto 6	Classe 9	Ponto 11 e 12
Classe 5	Ponto 7	Classe 10	Ponto 13

O banco de dados foi dividido em três conjuntos, um para treinamento (contendo

Tabela 9 - Legenda.

Índice	Significado
<i>CT</i>	Faltas com caminho para o terra
<i>STAB</i>	Faltas do tipo AB sem caminho para o terra
<i>STAC</i>	Faltas do tipo AC sem caminho para o terra
<i>STBC</i>	Faltas do tipo BC sem caminho para o terra
<i>STABC</i>	Faltas do tipo ABC sem caminho para o terra

Tabela 10 - Composição estrutural das 17 redes neurais.

	Nº de Entradas	Nº de Neurônios da Camada Escondida	Nº de Neurônios da Camada de Saída
<i>RNA 0</i>	1	3	2
<i>RNA 1</i>	3	3	2
<i>RNA 2</i>	3	7	4
<i>RNA 31 – RNA 34</i>	3	3	2
<i>RNA 411 – RNA 412</i>	3	9	5
<i>RNA 421 – RNA 428</i>	3	9	5
Função de Ativação da Camada		Tangente Sigmoid	Log Sigmoid

70% do banco de dados), um para validação (contendo 20% do banco de dados) e outro para testes das redes neurais (contendo 10% do banco de dados). O conjunto de treinamento é utilizado no processo de aprendizagem da rede neural. O conjunto de validação é utilizado para supervisionar o poder de generalização da rede neural durante o processo de aprendizagem, é uma avaliação feita de “n épocas” em “n épocas” durante o treinamento. O conjunto de teste é um terceiro conjunto de dados utilizado para testar definitivamente a rede neural ao final do treinamento.

O treinamento dessas redes neurais é supervisionado, ou seja, a cada época de treinamento, o erro entre a saída estimada e a saída alvo é calculado e repassado à rede no sentido contrário. A minimização da função custo (Erro Médio Quadrático - EMQ) definida por

$$EMQ = \frac{1}{n} \sum_{i=1}^n (y_{Estimada_i} - y_{Alvo_i})^2, \quad (35)$$

é o que permite à rede neural supervisionar a convergência do treinamento.

A condição adotada para marcar o fim de um treinamento foi a busca da máxima taxa de acertos para o grupo de validação. Desta forma é possível garantir que a rede possui o nível de generalização máximo, já que a generalização é a capacidade da rede de responder adequadamente a entradas não utilizadas no treinamento.

A matriz de confusão é a ferramenta aqui adotada para avaliar o grau de generalização das redes neurais. Por meio desta matriz é possível relacionar a saída predita pelo classificador com a saída esperada (saída alvo) e, deste modo, se pode avaliar o grau de

acerto do classificador para o grupo de testes.

A configuração de saída desejada para as redes neurais é binária, ou seja, quando uma classe é marcada pelo *bit* 1 as outras devem ser marcadas pelo *bit* 0. No entanto, a função de transferência escolhida para a camada de saída é uma função matemática *Log-Sigmoid* que varia entre 0 e 1. Isto implica que a saída das redes neurais têm, na verdade, uma medida de pertinência em cada classe. Assim, para completar o processo de classificação é necessário avaliar qual o maior grau de pertinência.

4.3 Distinção Entre Faltas dos Tipos *CT* e *ST*.

A RNA 0 é a responsável por esta etapa. A entrada desta rede neural é o vetor V_{in} composto por uma das métricas apresentadas no Capítulo 3, Seção 3.6, M_I , M_H , M_E .

$$V_{in} = [M_I \text{ ou } M_H \text{ ou } M_E], \quad (36)$$

no qual

$$M_k = \ln(\varepsilon\{v_{0a_k}(t)\}), \quad (37)$$

onde k representa o medidor em análise ($k = \{MI, MH, ME\}$).

Como foi apresentado no Capítulo 3, Seção 3.6, através da métrica M_I obtém-se um grau de separação maior entre as faltas *CT* e *ST*. Por isso, optou-se pela escolha da métrica M_I . Os resultados do treinamento da RNA 0 são apresentados na Figura 23 na qual a classe 1 representa as falta *CT* e a classe 2 representa as faltas *ST*. As conclusões referentes ao treinamento e teste da RNA 0 bem como das demais RNAs avaliadas são apresentadas na Seção 4.7.

4.4 Localização De Faltas *CT*.

As redes neurais RNA 1, RNA 411 E RNA 412 pertencem à última etapa do processo de classificação. São responsáveis por estimar a localização das faltas *CT*. Essas redes neurais possuem como entrada o vetor V_{in} composto pelas métricas apresentadas no Capítulo 3, Seção 3.3.

$$V_{in} = [\ln(\varepsilon\{v_{0a_{MI}}(t)\}); \ln(\varepsilon\{v_{0a_{ME}}(t)\}); b(v_{0a}(t), MI, ME)], \quad (38)$$




Figura 23 - Resultados do treinamento da RNA 0, responsável por distinguir entre faltas do tipo CT e ST.

em que

$$b(v_{0a}(t), ME, MI) = \ln \left(\frac{\varepsilon\{v_{0a_{ME}}(t)\}}{\varepsilon\{v_{0a_{MI}}(t)\}} \right). \quad (39)$$

Os resultados do treinamento para a RNA 1, RNA 411 e RNA 412 são apresentados na Figura 24, Figura 25 e Figura 26 respectivamente. Na Figura 24, a classe 1 representa as faltas $G1_{CT}$ e a classe 2 representa as faltas $G2_{CT}$. Na Figura 25 e na Figura 26, as classes correspondem àquelas da Tabela 8.

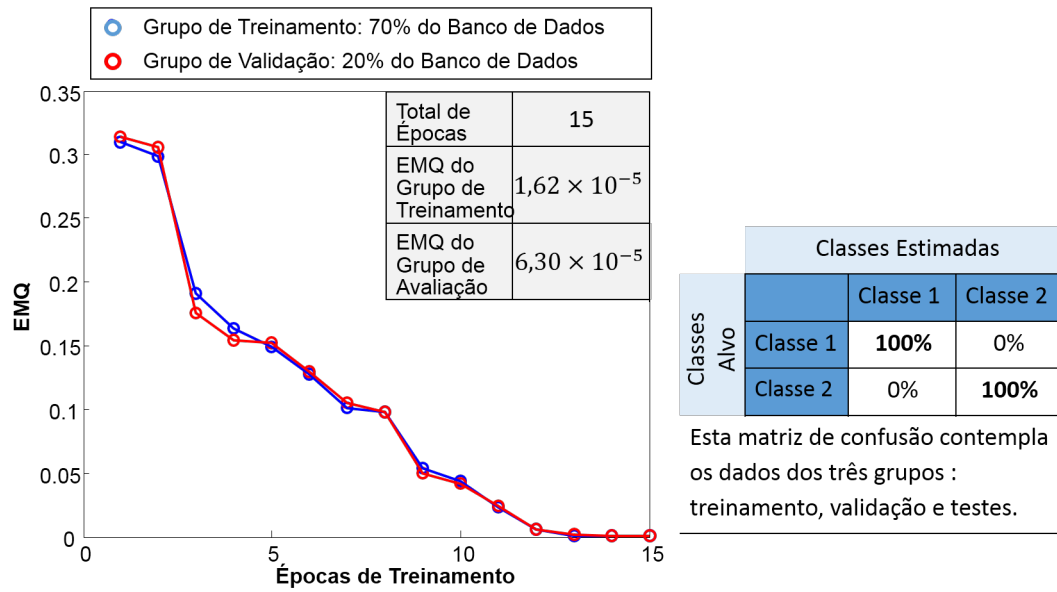


Figura 24 - Resultados do treinamento da RNA 1, responsável por distinguir entre os grupos $G1_{CT}$ e $G2_{CT}$.




Figura 25 - Resultados do treinamento da RNA 411, responsável por classificar a localização das faltas CT do grupo $G1_{CT}$.




Figura 26 - Resultados do treinamento da RNA 412, responsável por classificar a localização das faltas CT do grupo $G2_{CT}$.

4.5 Distinção Entre Os Tipos De Faltas AB , AC , BC e ABC .

A RNA 2 é a responsável por esta etapa. A entrada desta rede neural é o vetor V_{in} composto pelas métricas apresentadas no Capítulo 3, Seção 3.5.1.

$$V_{in} = [\delta_{v_{a_{MI}}}; \delta_{v_{b_{MI}}}; \delta_{v_{c_{MI}}}], \quad (40)$$

em que

$$\begin{cases} \delta_{v_{a_{MI}}} = \ln(\text{var}\{|A\{v_{a_{MI}}(t)\}|^2\}) \\ \delta_{v_{b_{MI}}} = \ln(\text{var}\{|A\{v_{b_{MI}}(t)\}|^2\}) \\ \delta_{v_{c_{MI}}} = \ln(\text{var}\{|A\{v_{c_{MI}}(t)\}|^2\}). \end{cases} \quad (41)$$

O medidor I foi escolhido arbitrariamente pois, pelos resultados apresentados no Capítulo 3 Seção 3.5.1, não há diferenças significativas que indiquem a escolha preferível de um medidor. Os resultados do treinamento da RNA 2 são apresentados na Figura 27 onde as classes 1, 2, 3 e 4 representam os tipos de faltas AB , AC , BC e ABC respectivamente.

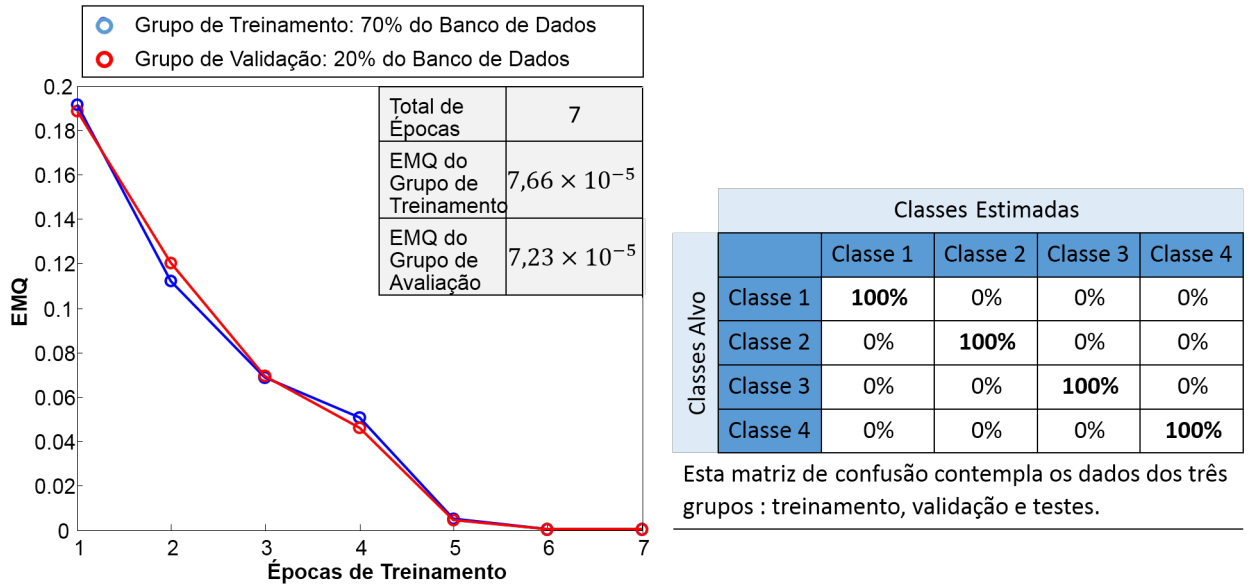


Figura 27 - Resultados do treinamento da RNA 2, responsável por distinguir entre os tipos de faltas AB , AC , BC e ABC .

4.6 Localização De Faltas $STAB$, $STAC$, $STBC$ e $STABC$

As redes neurais RNA 31 à 34 e RNA 421 à 428 pertencem à última etapa do processo de classificação. São responsáveis por estimar a localização de faltas ST . A entrada destas redes neurais é o vetor V_{in} composto pelas métricas apresentadas no Capítulo 3, Seção 3.5.

$$V_{in} = [\ln E\{v_{2a_{MI}}(t)\}; \ln E\{v_{2a_{ME}}(t)\}; b(v_{2a_{ME}}(t), MI, ME)], \quad (42)$$

em que

$$b(v_{2a}(t), ME, MI) = \ln \left(\frac{\varepsilon\{v_{2a_{ME}}(t)\}}{\varepsilon\{v_{2a_{MI}}(t)\}} \right). \quad (43)$$

Os resultados do treinamento para a RNA 31 ,RNA 421 e RNA 422, responsáveis por classificar as faltas do tipo $STAB$, são apresentados na Figura 28, Figura 29 e Figura 30 respectivamente. Na Figura 28, a classe 1 representa as faltas $G1_{STAB}$ e a classe 2 representa as faltas $G2_{STAB}$. Na Figura 29 e na Figura 30, as classes correspondem àquelas da Tabela 8.

Os resultados do treinamento para a RNA 32 ,RNA 423 e RNA 424, responsáveis

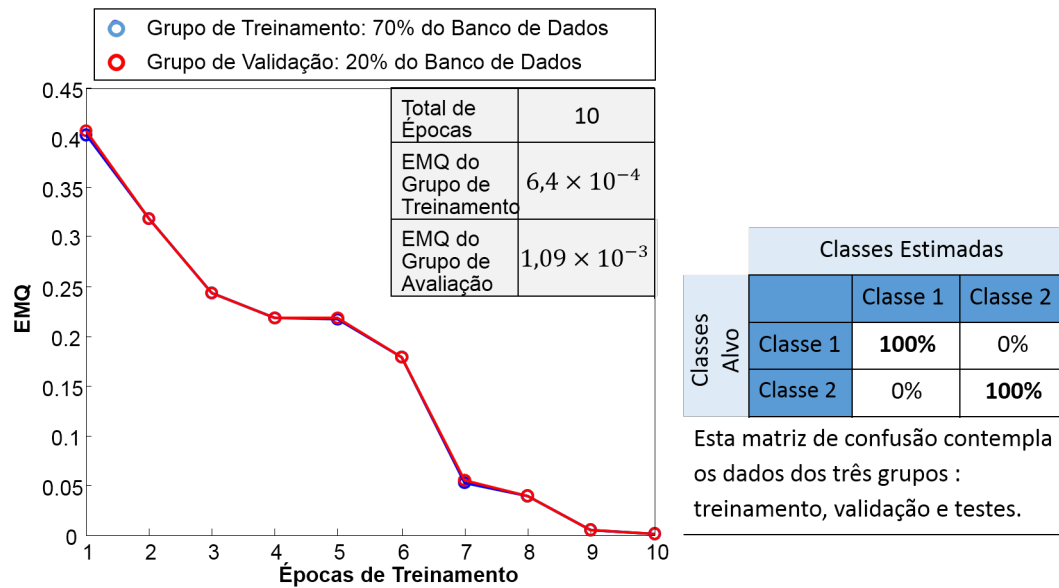


Figura 28 - Resultados do treinamento da RNA 31, responsável por distinguir entre os grupos $G1_{STAB}$ e $G2_{STAB}$.

por faltas do tipo $STAC$, são apresentados na Figura 31, Figura 32 e Figura 33 respectivamente. Na Figura 31, a classe 1 representa as faltas $G1_{STAC}$ e a classe 2 representa as faltas $G2_{STAC}$. Na Figura 32 e na Figura 33, as classes correspondem àquelas da Tabela 8.

Os resultados do treinamento para a RNA 33, RNA 425 e RNA 426, responsáveis pelas faltas do tipo $STBC$, são apresentados na Figura 34, Figura 35 e Figura 36 respectivamente. Na Figura 34, a classe 1 representa as faltas $G1_{STBC}$ e a classe 2 representa as faltas $G2_{STBC}$. Na Figura 35 e na Figura 36, as classes correspondem àquelas da Tabela 8.

Os resultados do treinamento para a RNA 34, RNA 427 e RNA 428, responsáveis por faltas do tipo $STABC$, são apresentados na Figura 37, Figura 38 e Figura 39 respectivamente. Na Figura 37, a classe 1 representa as faltas $G1_{STABC}$ e a classe 2 representa as faltas $G2_{STABC}$. Na Figura 38 e na Figura 39, as classes correspondem àquelas da Tabela 8.




Figura 29 - Resultados do treinamento da RNA 421, responsável por classificar a localização das faltas ST do grupo $G1_{STAB}$.




Figura 30 - Resultados do treinamento da RNA 422, responsável por classificar a localização das faltas ST do grupo $G2_{STAB}$.

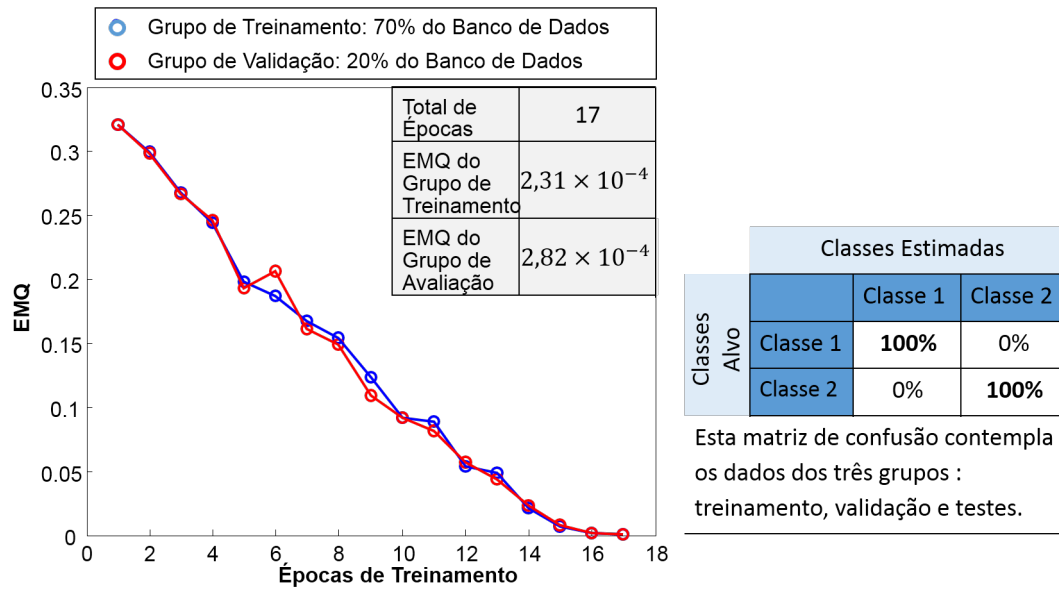


Figura 31 - Resultados do treinamento da RNA 32, responsável por distinguir entre os grupos $G1_{STAC}$ e $G2_{STAC}$.

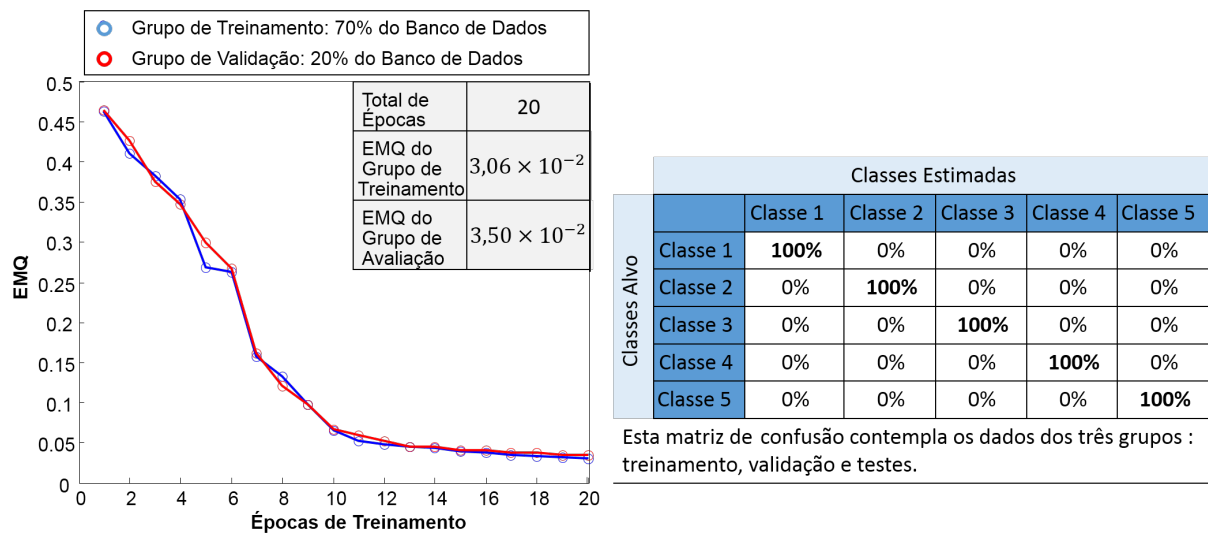


Figura 32 - Resultados do treinamento da RNA 423, responsável por classificar a localização das faltas ST do grupo $G1_{STAC}$.




Figura 33 - Resultados do treinamento da RNA 424, responsável por classificar a localização das faltas ST do grupo $G2_{STAC}$.




Figura 34 - Resultados do treinamento da RNA 33, responsável por distinguir entre os grupos $G1_{STBC}$ e $G2_{STBC}$.




Figura 35 - Resultados do treinamento da RNA 425, responsável por classificar a localização das faltas ST do grupo $G1_{STBC}$.




Figura 36 - Resultados do treinamento da RNA 426, responsável por classificar a localização das faltas ST do grupo $G2_{STBC}$.




Figura 37 - Resultados do treinamento da RNA 34, responsável por distinguir entre os grupos $G1_{STABC}$ e $G2_{STABC}$.




Figura 38 - Resultados do treinamento da RNA 427, responsável por classificar a localização das faltas ST do grupo $G1_{STABC}$.




Figura 39 - Resultados do treinamento da RNA 428, responsável por classificar a localização das faltas ST do grupo $G2_{STABC}$.

4.7 Conclusões Parciais

Nesta primeira abordagem foram utilizados sinais de tensão provenientes apenas dos medidores I e E. Esta escolha se deveu ao fato de que apenas esses medidores são suficientes para classificar a maioria dos pontos de faltas (conforme apresentado no Capítulo 3).

Quanto ao processo de treinamento das redes neurais, pode-se observar que as primeiras redes neurais (RNA 0, RNA 1, RNA 2, RNA 31 - 34) convergiram rapidamente com menos de 20 épocas de treinamento e obtendo EMQ em torno de 10^{-4} . Entretanto, para as últimas redes neurais (RNA 411, RNA 412, RNA 421 - 428), responsáveis por classificar a localização da falta, os processos só convergiram com mais de 20 épocas de treinamento. Isso era esperado, pois essas redes são responsáveis por uma quantidade maior de classes.

Pode-se observar que o treinamento das redes responsáveis por classificar faltas *CT* convergiu mais rapidamente com o número de épocas de treinamento variando de 21 a 84 e com EMQ em torno de 10^{-3} . O treinamento das redes responsáveis por classificar faltas *ST* bifásicas convergiu com o número de épocas de treinamento variando de 20 a 111 e com EMQ em torno de 10^{-2} . Já o treinamento das redes responsáveis por classificar as Faltas *ST* trifásicas convergiu com o número de épocas de treinamento variando de 129 a 168 e com EMQ em torno de 10^{-3} . Embora o treinamento das redes responsáveis pelas faltas *ST* trifásicas tenha demorado mais a convergir, estas obtiveram um EMQ menor se comparado ao obtido para as redes responsáveis pelas faltas *ST* bifásicas. Pode-se concluir que, mesmo que as redes responsáveis pelas faltas *ST* bifásicas tenham alcançado um nível de EMQ pobre (se comparado com as demais redes), ainda assim o treinamento pode ser considerado satisfatório, uma vez que os testes apresentaram uma taxa de acerto de 100%.

4.8 Análise De Desempenho Dos Classificadores

Neste capítulo são descritos os testes complementares. Com eles pretende-se analisar a sensibilidade e a capacidade de generalização dos classificadores propostos. Basicamente, dois tipos de testes complementares foram realizados:

- Testes de Robustez com Validação Cruzada;
- Teste com faltas não inicialmente contidas no banco de dados.

Os procedimentos realizados nesses testes são descritos nas próximas seções.

4.8.1 Testes de Robustez com Validação Cruzada

No teste de validação cruzada, pretende-se avaliar a sensibilidade das redes neurais aos conjuntos de treinamento, validação e teste para diferentes partições do banco de dados. Em outras palavras, para cada treinamento são sorteados os dados que compõem os conjuntos de treinamento, validação e teste (tal sorteio é realizado de forma que cada classe tenha sempre o mesmo número de representantes). Como resultado, pode-se extrair métricas estatísticas como a Taxa de Acerto Médio (TAM) definida por

$$TAM = \frac{1}{10} \sum_{i=1}^{10} tx_i, \quad (44)$$

onde tx_i é a taxa de acerto para um determinado treinamento i .

No teste de Robustez, deseja-se analisar a sensibilidade das redes neurais a diferentes proporções de conjuntos de treinamento, validação e teste. Para isso, são empregadas configurações diferentes de tamanhos dos conjuntos de treinamento, validação e teste para o treinamento de uma determinada rede neural. Para cada configuração do teste de robustez é realizado um teste de validação cruzada. Pretende-se, nestes testes, responder às seguintes perguntas:

- Qual o impacto da separação do conjunto de dados conhecido no desempenho da rede? Por exemplo, são realmente necessários 70% do banco de dados para treinamento ou pode-se utilizar uma porcentagem menor?
- Normalmente o treinamento pode ser sensível a sub-grupos específicos do banco de

dados. Então, na média, qual é a real taxa de acerto se forem consideradas várias configurações do conjunto de treinamento?

Para este teste foram escolhidas três redes neurais: A RNA 411, RNA 421 e RNA 427. Cada uma representando um tipo de falta diferente: faltas CT, faltas ST bifásicas e faltas ST trifásicas respectivamente. A Tabela 11 resume os parâmetros deste teste para a RNA 411, enquanto a Tabela 12 resume os parâmetros deste teste para a RNA 421 e RNA 427. Os valores apresentados nessas tabelas indicam as porcentagens utilizadas do banco de dados em cada configuração. Como pode ser observado, a Tabela 11 apresenta cinco configurações enquanto a Tabela 12 apresenta três configurações. Isso decorre do fato de que há muito mais dados de faltas *CT* que dados de faltas *ST* bifásicas e trifásicas, permitindo assim uma maior liberdade na divisão dos dados para testes.

Tabela 11 - Resumo dos parâmetros para teste de robustez com validação cruzada da rede RNA 411.

Configuração	Grupo de Treinamento	Grupo de Validação	Grupo de Teste
1	70,37%	14,81%	14,81%
2	62,96%	18,52%	18,52%
3	59,26%	20,37%	20,37%
4	55,56%	22,22%	22,22%
5	51,85%	24,07%	24,07%

Tabela 12 - Resumo dos parâmetros para teste de robustez com validação cruzada das redes RNA 421 e RNA 427.

Configuração	Grupo de Treinamento	Grupo de Validação	Grupo de Teste
1	77,77%	11,11%	11,11%
2	55,55%	22,22%	22,22%
3	33,33%	33,33%	33,33%

Os resultados do teste de robustez com validação cruzada para as redes *RNA411*, *RNA421* e *RNA427* são apresentados na Figura 40, Figura 41 e Figura 42 respectivamente.

4.8.2 Conclusões Parciais

No teste de robustez com validação cruzada para a RNA 411, apresentado na Figura 40 e que representa as faltas *CT*, pode ser observado que a taxa média de acerto se manteve em torno de 98% para configurações que contemplam de 50 à 70% das faltas do banco de dados no treinamento. Pode-se concluir que a quantidade de dados utilizada para treinamento da RNA 411 pouco influencia no desempenho final da rede. Em outras




Figura 40 - Teste de robustez com validação cruzada para RNA411.




Figura 41 - Teste de robustez com validação cruzada para RNA421.

palavras, a rede é pouco sensível à quantidade de dados utilizada para treinamento. As curvas de máximo e de mínimo permitem concluir que esta rede neural é pouco sensível às diferentes partições do banco de dados, haja em vista que a maior diferença entre as curvas de máximo e mínimo é menor que 4%, o que aumenta a confiabilidade dos resultados. Para a configuração que utiliza 70% do banco de dados, a taxa de acerto médio é de $\approx 98\%$.

No teste de robustez com validação cruzada para a RNA 421, apresentado na Figura 41 e que localiza faltas *ST* bifásicas, pode ser observado uma variação significativa na taxa média de acerto que vai de ≈ 77 à $\approx 85\%$ para as configurações que contemplam de 50 à 70% das faltas do banco de dados. Podemos concluir que a quantidade de dados utilizada para treinamento da RNA 421 influencia o desempenho final da rede neural. Em outras palavras, a taxa média de acerto foi reduzida conforme reduziu-se a quantidade de dados




Figura 42 - Teste de robustez com validação cruzada para RNA427.

utilizada no treinamento. Uma das causas prováveis é que a redução da quantidade de dados de treinamento implica na redução das informações de caracterização da falta. Com respeito à sensibilidade a diferentes partições do banco de dados, pode-se observar que existe uma diferença em torno de 10% entre as curvas de mínimo e máximo em todas as configurações. Isso permite concluir que esta rede neural também é sensível a diferentes partições do banco de dados. Para a configuração que utiliza 70% do banco de dados, a taxa de acerto médio é de $\approx 85\%$.

No teste de robustez com validação cruzada para a RNA 427, apresentado na Figura 42 e que representa as faltas *ST* trifásicas, pode ser observada uma variação na taxa média de acerto que vai de ≈ 82 a $\approx 89\%$ para as configurações que contemplam de 50 à 70% das faltas do banco de dados no treinamento. Podemos concluir que a quantidade de dados utilizado para treinamento da RNA 427 também influencia no desempenho final da rede neural. Porém com impacto menor do que o observado para RNA 421. Com respeito à sensibilidade a diferentes partições do banco de dados, pode-se observar que existe uma diferença em torno de 15% entre as curvas de mínimo e máximo para todas as configurações. Isso permite concluir que esta rede neural também é sensível a diferentes partições do banco de dados. Para a configuração que utiliza 70% do banco de dados, a taxa de acerto médio é de $\approx 90\%$.

Estes testes são utilizados para responder as perguntas propostas anteriormente:

- Qual o impacto da separação do conjunto de dados conhecido no desempenho da rede? Por exemplo, são realmente necessários 70% do banco de dados para treinamento ou pode-se utilizar uma porcentagem menor?

- Normalmente, o treinamento pode ser sensível a sub-grupos específicos do banco de dados. Então, na média, qual seria a real taxa de acerto se considerarmos várias configurações para o grupo de treinamento?

Mas para responder essas perguntas é necessário primeiro responder outra pergunta:

- O quanto é permitido errar no processo de localização de faltas?

A partir da resposta a esta questão, pode-se, então, dar prosseguimento à realização do classificador neural estabelecendo uma relação de compromisso entre a porcentagem do banco de dados utilizado para treinamento, validação e testes e a taxa de acerto médio apresentado para conjunto de testes (tendo em vista que quanto mais dados estiverem disponíveis para testes, maior será a confiabilidade dos resultados). O banco de dados raramente contemplará o universo de possibilidades, assim, quanto maior for o banco de dados, melhor ou mais real será a estimativa de desempenho do classificador.

4.8.3 Teste Com Faltas Não Inicialmente Contidas No Banco De Dados

Neste teste, são apresentados às redes neurais dados nunca antes vistos, ou seja, novos tipos de faltas foram simulados no *software* PSCAD. Essas novas faltas foram modeladas com impedâncias maiores que as usadas na construção do banco de dados. Isso permite saber se o classificador neural é capaz de generalizar o conhecimento adquirido a fim de responder adequadamente a essas novas faltas. A Tabela 13 resume os parâmetros das faltas utilizadas neste teste.

Tabela 13 - Resumo dos parâmetros utilizados na construção do conjunto de faltas de alta impedância.

Ponto de Falta		Tipo de Falha		Carga (Ω)		Período (ms)		Local de Medida
6		ABG		50 Ω		$\frac{3}{4}$ ciclo		Início
8	×	AC	×	75 Ω	×	$\frac{5}{4}$ ciclo	×	Meio
		ABC		100 Ω				Fim

Os resultados para os testes com faltas de alta impedância são apresentados na Figura 43 e na Figura 44.




Figura 43 - Teste com faltas de alta impedância (separadas por tipo).

4.8.4 Conclusões Parciais

Os resultados apresentados para os testes com faltas de alta impedância obtiveram como origem uma realização cujo treinamento contemplava 70% das faltas do banco de dados. Para esta configuração, os erros de classificação se concentraram nas faltas de alta impedância do tipo *ST* de 75Ω e de 100Ω . Para as faltas *CT* de alta impedância a taxa de acerto foi de 100%. Da mesma forma, para as faltas de 50Ω de todos os tipos, a taxa de acerto também foi de 100%. A taxa de acerto para as faltas *ST* de alta impedância foi de 80%. Esses resultados demonstram uma excelente capacidade de generalização para faltas de alta impedância.

4.8.5 Conclusões Parciais Acerca Da Análise de Desempenho Dos Classificadores

A utilização do classificador composto por 17 redes MLP, apesar dos bons resultados apresentados, possui o seguinte ponto negativo: Dada a grande quantidade de redes neurais para classificar as faltas *ST*, as últimas redes acabam por dispor de uma parcela pequena do banco de dados. Isto reduz a quantidade de dados disponíveis para treinamento, validação e testes dessas redes, o que sempre leva a questionamentos sobre a




Figura 44 - Teste com faltas de alta impedância (separadas por impedância).

confiabilidade dos resultados. O teste de validação cruzada pode ser utilizado pra resolver esse problema fornecendo resultados estatísticos sobre o desempenho de uma rede.

Outro aspecto também importante está na forma como o problema é abordado nesta primeira etapa, ou seja, a proposta resume-se em localizar faltas em um sistema de distribuição no qual os consumidores são os possíveis causadores das faltas. Por isso, o sistema possui saída binária que informa ao usuário se uma falta pertence ou não a uma posição específica no sistema de distribuição. Na próxima etapa é proposta uma outra abordagem na qual é possível estimar a localização da falta em metros ou quilômetros com um faixa de erro bem definida. Em vista disso, uma nova estrutura de classificadores é proposta no próximo capítulo.

5 ESTIMAÇÃO DE LOCALIZAÇÃO DE FALTAS VIA REDES NEURAIS ARTIFICIAIS

Nesta abordagem, as redes MLP são utilizadas como aproximador de funções (MARTINEZ; FERRARA; MARIO, 2012; CORRÊA; VELLASCO, 2008). O objetivo é construir redes neurais que forneçam como saída uma estimativa da distância entre a falta e o alimentador do sistema de distribuição. A Figura 45 ilustra a nova estrutura. Nesta estrutura, as redes neurais RNA 2, RNA 31-34 e RNA 421-428 que antes eram utilizadas para classificar a localização das faltas *ST*, agora são incorporadas à nova rede neural RNA 2'. As redes neurais RNA 1 e RNA 411-412 que antes eram utilizadas para classificar a localização das faltas *CT*, agora são incorporadas à nova rede neural RNA 1'. A RNA 0 foi mantida.

As distâncias dos pontos de faltas ao alimentador foram normalizadas para corresponder à saída das redes RNA 1' e RNA 2' que possuem a função matemática *Log-Sigmoid* como função de ativação .




Figura 45 - Arquitetura neural com 3 redes neurais do tipo (*feed-forward backpropagation network*).

Tabela 14 - Nova composição estrutural de redes neurais utilizando informações de dois medidores.

	Nº de Entradas	Nº de Neurônios da Camada Escondida	Nº de Neurônios da Camada de Saída
<i>RNA 1'</i>	2	2	1
<i>RNA 2'</i>	5	3	1
Função de Ativação		Tangente Sigmoid	Log Sigmoid

A Tabela 14 e a Tabela 15 apresentam as estruturas das redes neurais *RNA 1'* e *RNA 2'* respectivamente, para os casos em que se utilizam informações de dois e três medidores. A saída dessas novas redes neurais é projetada para responder fornecendo a distância normalizada entre o alimentador e o ponto onde ocorreu a falta. A Tabela 16

Tabela 15 - Nova composição estrutural de redes neurais utilizando informações de três medidores.

	Nº de Entradas	Nº de Neurônios da Camada Escondida	Nº de Neurônios da Camada de Saída
<i>RNA 1'</i>	3	2	1
<i>RNA 2'</i>	6	4	1
Função de Ativação		Tangente Sigmoid	Log Sigmoid

e a Tabela 17 apresentam as variáveis utilizadas como entradas de cada rede neural, já apresentadas no Capítulo 3. Essas redes foram treinadas utilizando o algoritmo *backpropagation* otimizado por *Levenberg – Marquardt* (LM) (HAYKIN, 2001) que se encontra implementado no *Neural Network Toolbox* do programa MATLAB.

Tabela 16 - Descrição do vetor de entrada das redes neurais utilizando informações de dois medidores.

	Vetor de Entrada
<i>RNA 1'</i>	$[\ln E\{v_{0a_{MI}}(t)\}; \ln E\{v_{0a_{ME}}(t)\}]$
<i>RNA 2'</i>	$[\ln E\{v_{2a_{MI}}(t)\}; \ln E\{v_{2a_{ME}}(t)\}; \delta_{v_{a_I}}; \delta_{v_{b_I}}; \delta_{v_{c_I}}]$.

Tabela 17 - Descrição do vetor de entrada das redes neurais utilizando informações de três medidores.

	Vetor de Entrada
<i>RNA 1'</i>	$[\ln E\{v_{0a_{MI}}(t)\}; \ln E\{v_{0a_{MH}}(t)\}; \ln E\{v_{0a_{ME}}(t)\}]$
<i>RNA 2'</i>	$[\ln E\{v_{2a_{MI}}(t)\}; \ln E\{v_{2a_{MH}}(t)\}; \ln E\{v_{2a_{ME}}(t)\}; \delta_{v_{a_I}}; \delta_{v_{b_I}}; \delta_{v_{c_I}}]$.

5.1 Análise de Desempenho

Os testes de desempenho realizados são os mesmos:

- Teste de Robustez com Validação Cruzada;
- Teste com faltas não inicialmente contidas no banco de dados;

Entretanto, os teste com faltas não inicialmente contidas no banco de dados são ainda divididos em dois:

- Testes com faltas de alta impedância simuladas nos pontos de falta originais
- Testes com faltas de alta impedância simuladas em pontos distintos dos pontos de falta originais, entre eles.

Tabela 18 - Resumo dos parâmetros utilizados na construção do conjunto de faltas de alta impedância com origem em diferentes localizações.

Ponto de Falta		Tipo de Falha		Carga (Ω)		Período (ms)		Local de Medida
P3E4		<i>ABG</i>		75 Ω		$\frac{3}{4}$ ciclo		Início
P6E7	×	<i>AC</i>	×		×	$\frac{5}{4}$ ciclo	×	Meio
P12E13		<i>ABC</i>						Fim

Para o teste com faltas de alta impedância simuladas entre os pontos de falta originais, foram simuladas novas faltas com características apresentadas na Tabela 18.

Para esta abordagem de localização de faltas foram comparados ainda dois casos:

- Caso 1: Utilizando informações das tensões $v_a(t)$, $v_b(t)$ e $v_c(t)$ de dois medidores (*MI* e *ME*);
- Caso 2: Utilizando informações das tensões $v_a(t)$, $v_b(t)$ e $v_c(t)$ de três medidores (*MI*, *MH* e *ME*);

Pretende-se, com estes testes, analisar o desempenho do estimador de localização de faltas quando são utilizadas informações de dois ou três medidores. Todas as simulações dos testes de robustez com validação cruzada tiveram um número limite fixo de épocas de treinamento (200) e dentro desse total de épocas buscou-se a época na qual o *EMQ* para o grupo de validação fosse o mínimo. Esta estratégia garante certa capacidade de generalização da rede neural (HAYKIN, 2001). Além disso, a porcentagem do banco de dados utilizada para treinamento foi avaliada para uma faixa entre 30% e 70%.

Nesta abordagem, métricas como taxa de acerto não fazem mais sentido, agora devemos avaliar o erro entre a posição real da falta e a posição estimada pelo sistema (em metros e em percentual do comprimento da linha de distribuição). Assim, algumas estatísticas foram avaliadas, e essas estatísticas são:

- Erro Médio

$$\overline{Erro} = \frac{1}{n} \sum_{i=1}^n Erro_i. \quad (45)$$

onde

$$Erro_i = Y_{alvo_i} - Y_{estimada_i}. \quad (46)$$

- Raiz Quadrada do Erro Médio Quadrático

$$\sqrt{EMQ} = \sqrt{\frac{1}{n} \sum_{i=1}^n Erro_i^2}. \quad (47)$$

- Desvio Padrão do Erro

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (Erro_i - \overline{Erro})^2}. \quad (48)$$

- Máximo (Erro máximo positivo)

$$Max = \max_{i=1}^n (Erro_i). \quad (49)$$

- Mínimo (Erro máximo negativo)

$$Min = \min_{i=1}^n (Erro_i). \quad (50)$$

As métricas em valores percentuais são obtidas dividindo-se as métricas acima pelo comprimento da linha (6,755km). Adicionalmente, também são realizados testes de segmento. Nesses testes pretende-se avaliar o quanto a estimativa de localização de falta para um determinado ponto de falta invade as fronteiras dos pontos de faltas vizinhos. Para isso arbitrou-se que a metade da distância entre dois pontos de falta consecutivos seria a fronteira entre esses mesmos pontos de falta.

5.2 Teste de Robustez com Validação Cruzada

Nesta seção são apresentados os resultados do teste de robustez com validação cruzada. A Figura 46 e a Figura 47 apresentam os testes de robustez/validação cruzada para a *RNA 1'* e *RNA 2'* respectivamente, utilizando informações de dois medidores.

A Figura 48 e a Figura 49 apresentam os testes para a *RNA 1'* e *RNA 2'* respectivamente, utilizando informações de três medidores.

Com base nos gráficos dos testes de sensibilidade apresentados, pode-se escolher a proporção do banco de dados mais conveniente para treinamento. Ou seja, tal escolha pode ser norteadada com base nas métricas apresentadas nesses gráficos. A Tabela 19 apresenta as configurações escolhidas para dar seguimento à análise de desempenho. A




Figura 46 - Teste de robustez com validação cruzada para RNA 1' utilizando informações de dois medidores.




Figura 47 - Teste de robustez com validação cruzada para RNA 2' utilizando informações de dois medidores.

escolha dessas configurações foi feita na tentativa de se minimizar os erros de estimação apresentados e, ao mesmo tempo, maximizar o tamanho dos conjuntos de validação e




Figura 48 - Teste de robustez com validação cruzada para RNA 1' utilizando informações de três medidores.




Figura 49 - Teste de robustez com validação cruzada para RNA 2' utilizando informações de três medidores.

teste. Contudo, como pode ser observado, as únicas métricas que apresentaram variações significativas são os erros máximos positivos e negativos. Ou seja, as proporções foram

arbitradas predominantemente com base no tamanho do conjunto de treinamento.

Tabela 19 - Proporção do banco de dados escolhida para treinamento, validação e testes para dois ou três medidores.

	Treinamento	Validação	Teste
<i>RNA 1'</i>	51,85%	24,07%	24,07%
<i>RNA 2'</i>	55%	22,5%	22,5%

Na sequência, a partir das proporções apresentados na Tabela 19, foram escolhidas quatro realizações de redes neurais, uma *RNA 1'* e uma *RNA 2'* treinadas com dados de faltas de dois e de três medidores. Tais redes foram treinadas até duas mil épocas na tentativa de minimizar o EMQ dos grupos de treinamento e validação ou até que fosse encontrado um EMQ mínimo para o grupo de validação. Estas abordagens foram realizadas na tentativa de aumentar o poder de generalização das redes neurais. Na etapa seguinte, o conjunto de testes é então apresentado às redes neurais.

A Figura 50, Figura 51, Figura 52 e a Figura 53 apresentam os resultados dos treinamentos das redes. Vale relembrar que a *RNA 1'* é responsável pelas faltas *CT* enquanto que a *RNA 2'* é responsável pelas faltas *ST*.




Figura 50 - Treinamento da *RNA 1'* utilizando informações de dois medidores.

A Figura 54, Figura 55, Figura 56 e a Figura 57 apresentam os resultados em forma de histogramas dos erros para o conjunto de testes. Os erros são apresentados em

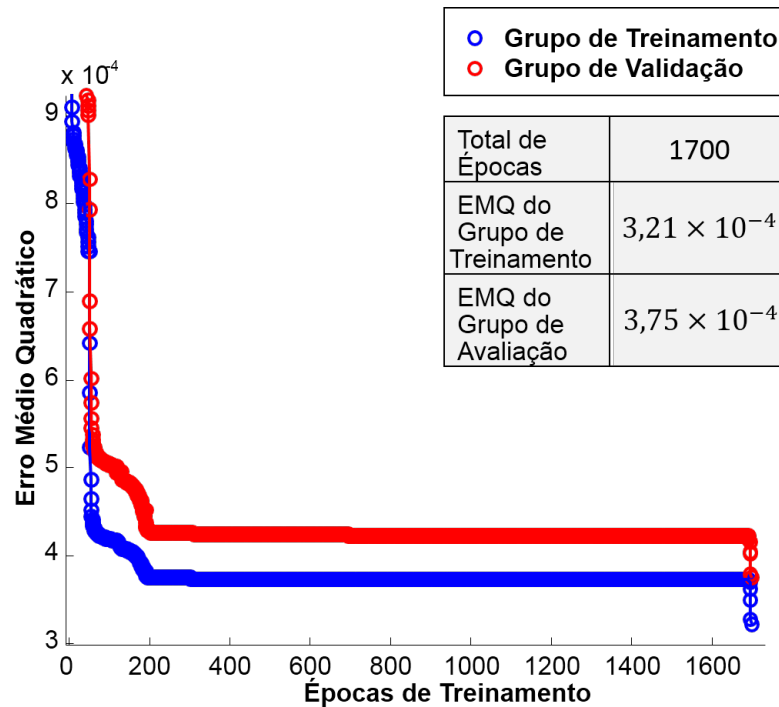


Figura 51 - Treinamento da *RNA 2'* utilizando informações de dois medidores.

metros e são calculados pela diferença entre a posição da falta e a posição estimada tendo como marco zero, a localização do alimentador.

A Figura 58, Figura 59, Figura 60 e Figura 61 apresentam o teste de segmento onde é avaliado o quanto a estimativa de localização de falta de um determinado ponto de falta invade a fronteira do ponto de falta vizinho. Nesses gráficos são apresentados os histogramas de:

$$\frac{erro}{\Delta}, \quad (51)$$

onde Δ representa a distância entre ponto de falta avaliado e o ponto de falta vizinho. Dessa forma, Δ pode assumir dois valores, um valor caso o erro estimado esteja à direita (erro positivo) do ponto de falta e outro valor caso o erro estimado esteja à esquerda do ponto de falta (erro negativo). A Tabela 20 apresenta as distâncias entre os pontos de faltas. Por exemplo, à esquerda do ponto 8 existe um Δ de $0,57km$, o que significa que os pontos 7 e 8 estão distantes entre si de $0,57km$. À direita do ponto 8 existe um Δ de $0,45km$, o que significa que os pontos 8 e 9 estão distantes entre si de $0,45km$.

Por meio desses gráficos pode-se observar que na maioria dos pontos de falta, a relação $\frac{erro}{\Delta}$ é menor ou igual a 0,5 o que significa que os erros não chegam a exceder suas fronteiras (supondo um $\frac{erro}{\Delta}$ máximo satisfatório de 0,5), com exceção para o intervalo do




Figura 52 - Treinamento da *RNA 1'* utilizando informações de três medidores.

Tabela 20 - Distâncias entre classes de localização.

Δ (km) à esquerda	Localização	Δ (km) à direita
0,43	Ponto 1 e 2	0,43
0,43	Ponto 3	0,43
0,43	Ponto 4 e 5	0,07
0,07	Ponto 6	0,88
0,88	Ponto 7	0,57
0,57	Ponto 8	0,45
0,45	Ponto 9	0,27
0,27	Ponto 10	0,245
0,245	Ponto 11 e 12	1,86
1,86	Ponto 13	1,12

“pontos 4 e 5” para o “ponto 6”, onde a relação $\frac{\text{erro}}{\Delta}$ excede o valor de 0,5. Isto se deve ao fato de que o intervalo entre esses pontos é de apenas 70m como apresenta a Tabela 20. Pode observar-se também que obtém-se melhores resultados quando são utilizadas informações de três medidores.




Figura 53 - Treinamento da RNA 2' utilizando informações de três medidores.




Figura 54 - Teste para RNA 1' utilizando informações de dois medidores.




Figura 55 - Teste para RNA 2' utilizando informações de dois medidores.




Figura 56 - Teste para RNA 1' utilizando informações de três medidores.




Figura 57 - Teste para RNA 2' utilizando informações de três medidores.

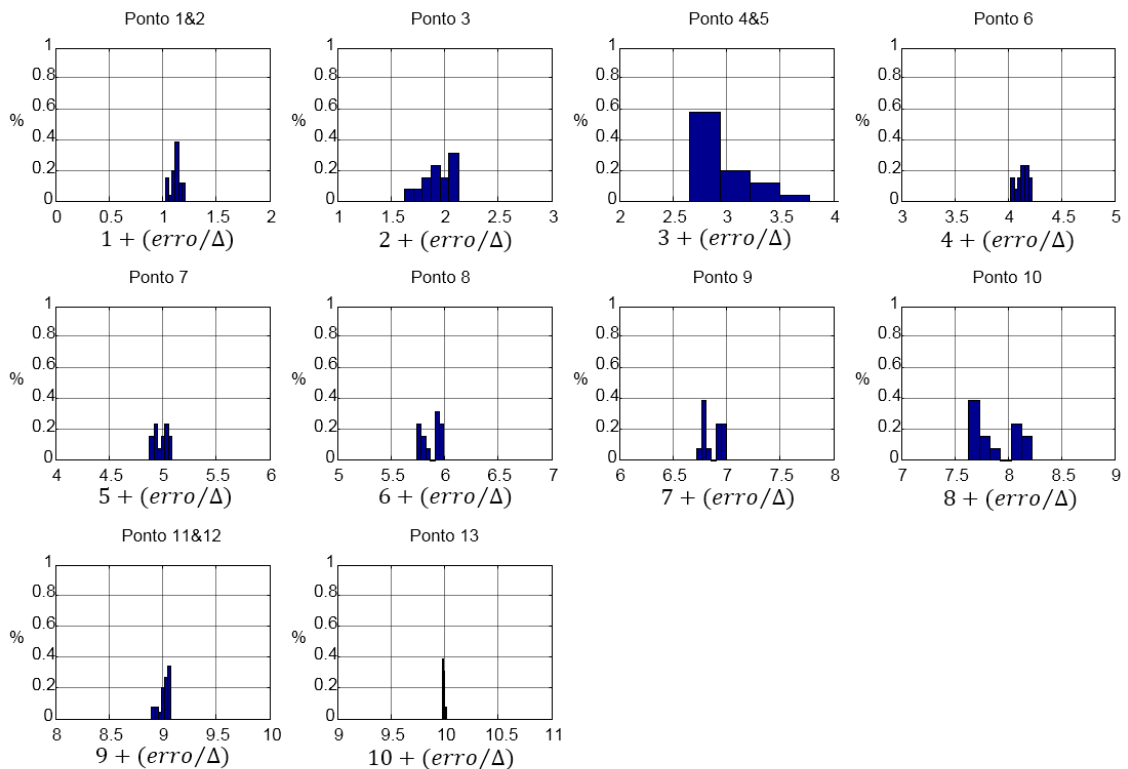


Figura 58 - Teste de segmento (fronteira entre classes) para RNA 1' utilizando informações de dois medidores (bins=6).

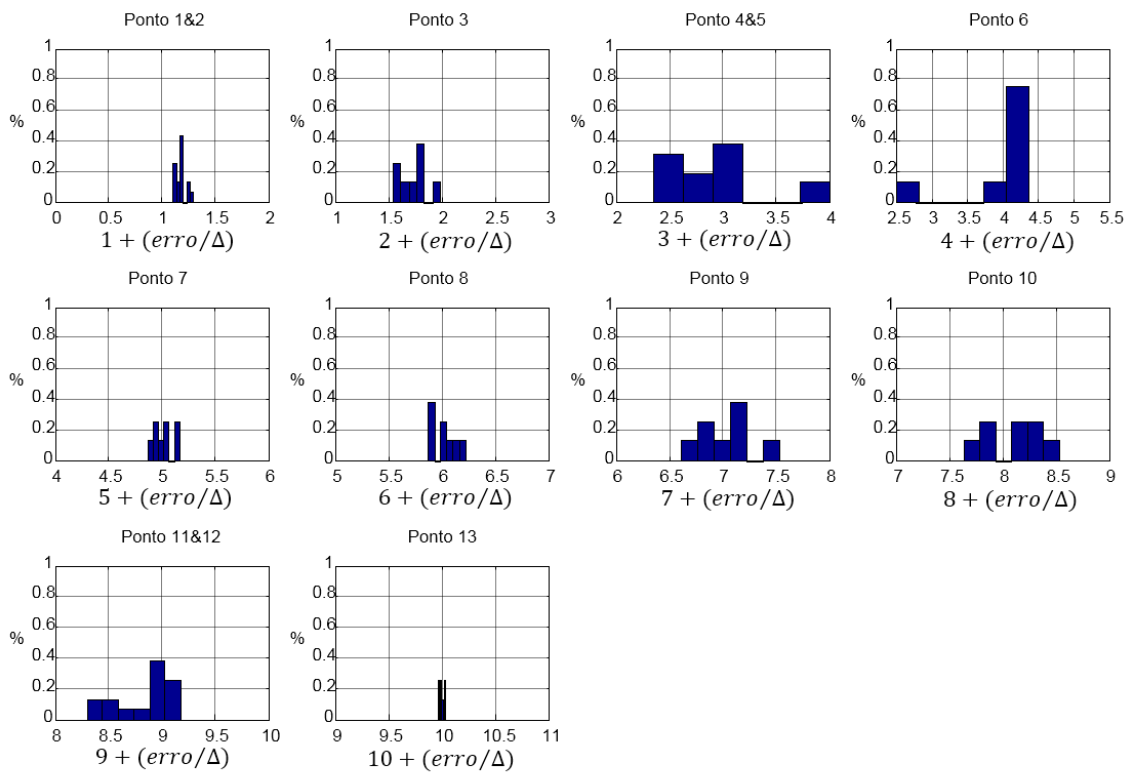


Figura 59 - Teste de segmento (fronteira entre classes) para RNA 2' utilizando informações de dois medidores (bins=6).

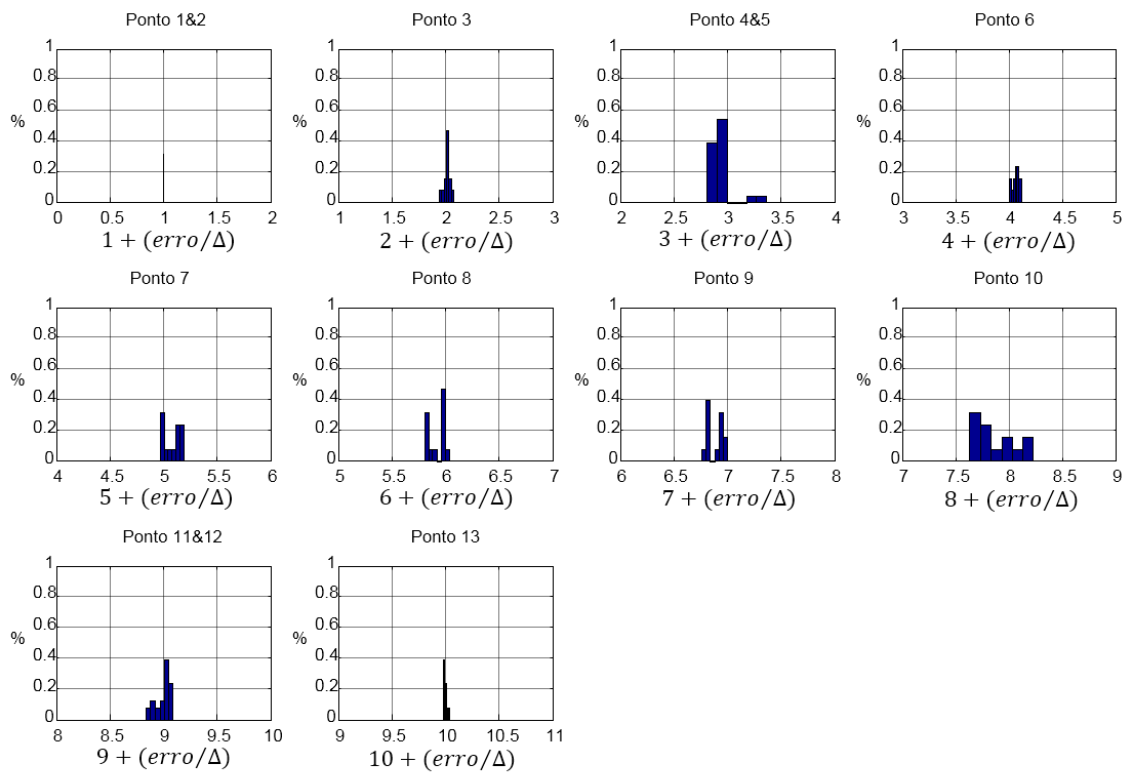


Figura 60 - Teste de segmento (fronteira entre classes) para RNA 1' utilizando informações de três medidores (bins=6).

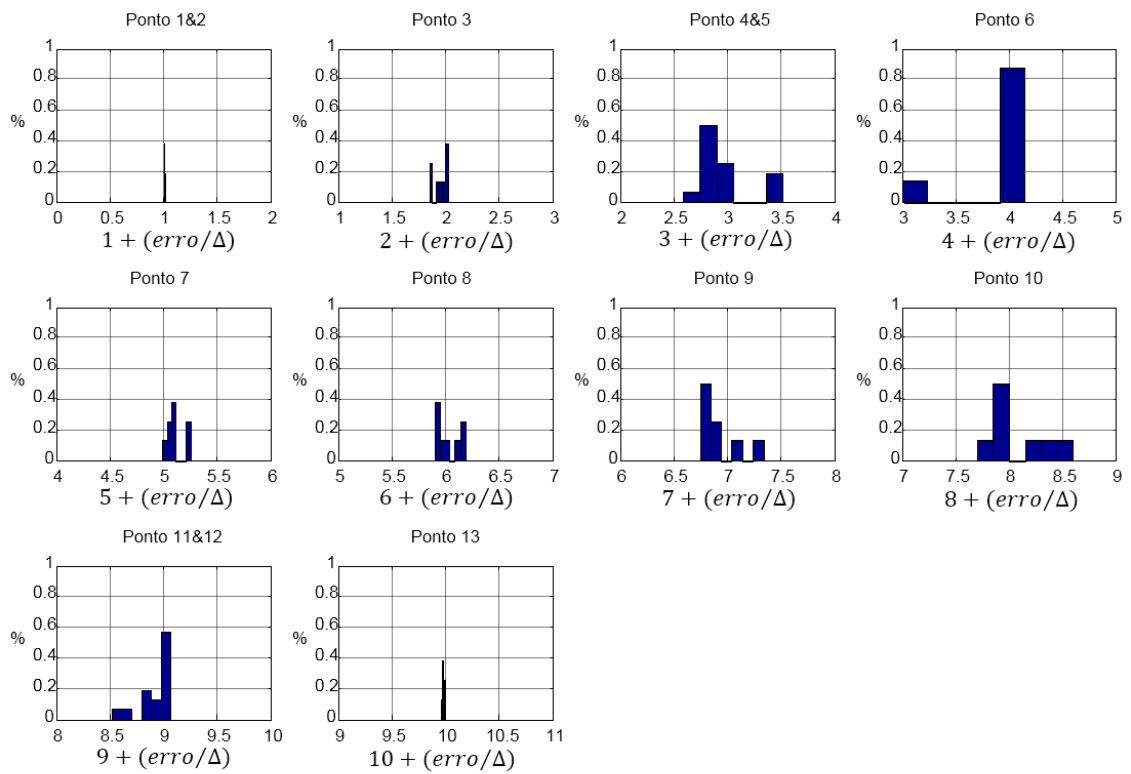


Figura 61 - Teste de segmento (fronteira entre classes) para RNA 2' utilizando informações de três medidores (bins=6).

A partir dos resultados apresentados na Figura 54, Figura 55, Figura 56 e Figura 57, pode-se observar que os erros médios para os tipos de faltas *CT* e *ST*, utilizando dois e três medidores estão bem próximo de zero, o que mostra boa acurácia do estimador de localização de faltas. Além disso, o erro máximo para as faltas *CT* foi de 200m com desvio padrão de 74,1m quando se utilizam dois medidores. No entanto, quando se utilizam três medidores, o erro máximo passa para 145m com desvio padrão de 46,8m. Para as faltas do tipo *ST* o erro máximo foi de 337,6m com desvio padrão de 110,3m quando se utilizam dois medidores, enquanto que quando se utilizam três medidores o erro máximo passa para 176,2m com desvio padrão de 62,8m. Esses valores representam erros de estimação muito pequenos considerando a dimensão do sistema de distribuição, que é maior que 6,755km. Ou seja, o maior erro máximo foi de 337,6m e representa apenas 5% da dimensão do sistema de distribuição enquanto que o menor erro máximo que foi de 145m representa apenas 2,14% da dimensão do sistema de distribuição. Os baixos valores para o desvio padrão demonstram boa precisão do estimador de localização de faltas. Outra conclusão importante é que quanto mais medidores (informações) são utilizados, melhor é a acurácia e a precisão na estimação (Média mais próxima de zero e desvio padrão menor).

5.3 Teste Com Faltas Não Inicialmente Contidas No Banco De Dados

5.3.1 Teste com faltas de alta impedância simuladas nos pontos de falta originais

Nesta seção, o desempenho das redes *RNA 1'* e *RNA 2'* é avaliado para as faltas de alta impedância. Na Figura 62, e na Figura 63, são apresentados os resultados com as faltas de alta impedância. A Figura 62 apresenta os resultados para as redes neurais alimentadas com informações de apenas dois medidores *MI* e *ME* e a Figura 63 apresenta os resultados para as redes neurais alimentadas com informações dos três medidores *MI*, *MH* e *ME*.

Para os testes com faltas de alta impedância utilizando informações de dois medidores, cujos resultados são apresentados na Figura 62, pode-se destacar que os menores erros são obtidos para as faltas *CT* com média de 32m, máximo de 159m e desvio padrão de 94m. Para as faltas *ST* bifásicas foi obtido uma média de -5m com máximo de 96m e desvio padrão de 68m. Os maiores erros foram obtidos para as faltas *ST* trifásicas com média de 200m, máximo de 344m e desvio padrão de 94m. Pode-se observar, a partir dos

erros médios, que a acurácia neste teste teve desempenho inferior se comparado com o obtido para o conjunto de testes originais. Entretanto, observando os valores de desvio padrão, pode-se notar que a precisão de estimação não apresentou variações significativas. Do ponto de vista das impedâncias, pode-se observar, a partir dos erros médios, que a acurácia diminui quando se aumenta o valor da impedância. Ou seja, o erro de estimação da localização da falta tende a aumentar com valores altos de impedância de falta.

A Figura 63 apresenta os resultados dos testes com faltas de alta impedância utilizando informações de três medidores. Pode-se observar uma melhora na acurácia e na precisão quando se utilizam informações de mais medidores. Em outras palavras, neste cenário, erro médio e desvio padrão são reduzidos. Mas uma exceção é observada para as faltas *ST*, pode-se notar que o desempenho foi reduzido ao se utilizar três medidores. A inclusão da informação de mais um medidor beneficiou mais a classe de faltas *ST* trifásicas que as bifásicas. Isso ocorreu, talvez, porque na metodologia proposta neste trabalho, foi disponibilizado apenas uma rede neural para localizar faltas *ST* bifásicas e *ST* trifásicas. Uma abordagem na qual se tenha uma RNA para as faltas *ST* bifásicas e outra para faltas *ST* trifásicas poderia sanar essa deficiência.

5.3.2 Teste com faltas de alta impedância simuladas entre os pontos de falta originais

Na Figura 64 e na Figura 65 são apresentados os resultados dos testes com faltas de alta impedância e origem entre pontos de faltas originais. A Figura 64 apresenta os resultados do classificador neural cuja entrada é alimentada com informações dos medidores *MI* e *ME*. A Figura 65 apresenta os resultados do classificador neural cuja entrada é alimentada com informações dos medidores *MI*, *MH* e *ME*.




Figura 62 - Teste com faltas de alta impedância alimentando as redes neurais com informações de dois medidores (bins=6).

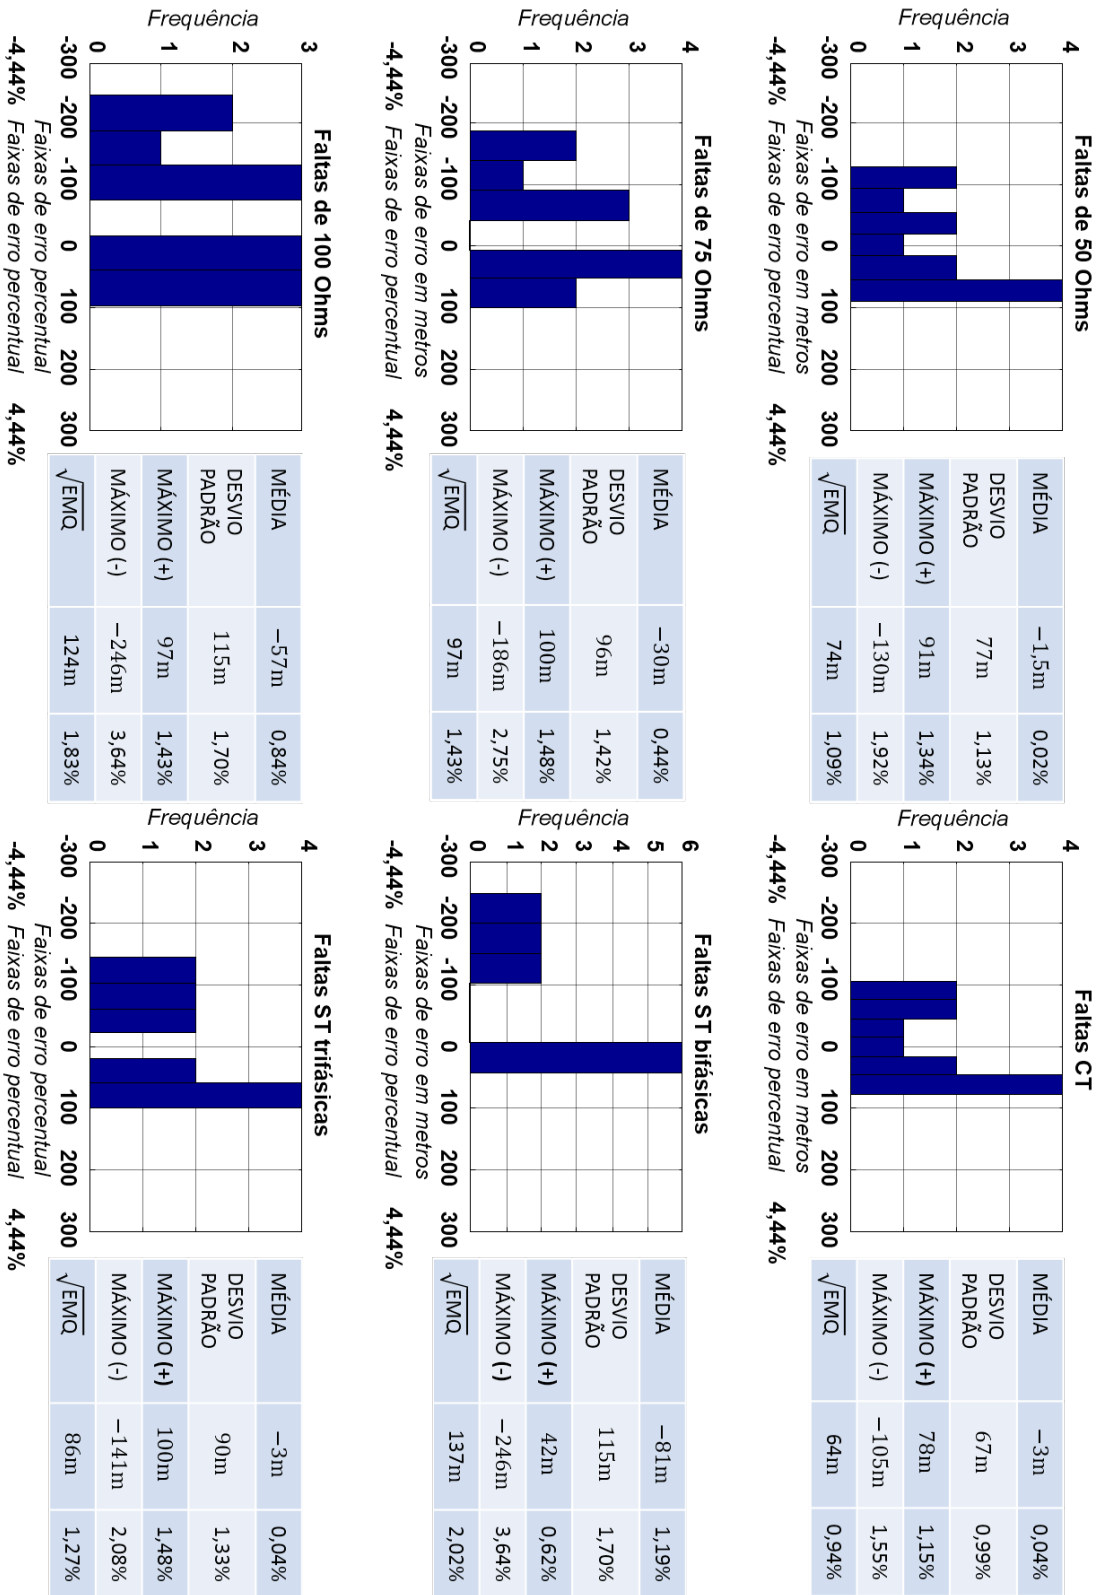


Figura 63 - Teste com faltas de alta impedância alimentando as redes neurais com informações de três medidores (bins=6).




Figura 64 - Teste com faltas de alta impedância localizadas entre os pontos de faltas originais. Obs.: Utilizando informações de dois medidores (bins=6).




Figura 65 - Teste com faltas de alta impedância localizadas entre os pontos de faltas originais. Obs.: Utilizando informações de três medidores (bins=6).

Uma forma de avaliar esses resultados é a partir da comparação com os resultados apresentados na Figura 62. Espera-se que, nessa comparação, os erros médios bem como as variâncias não sejam tão discrepantes. Em outras palavras, espera-se que o sistema localizador de falta mantenha a mesma tendência ao estimar a localização de faltas com origem nos pontos originais de localização e entre esses pontos.

Assim, na Figura 64, pode-se observar, para as faltas *CT*, um erro médio de 36m com desvio padrão de 121m, enquanto que para as faltas *ST* bifásicas é encontrado um erro médio de -89m e um desvio padrão de 164m. Para as faltas *ST* trifásicas é encontrado um erro médio de 171m com desvio padrão de 106m. Os erros médios bem como os desvios padrões não sofreram grandes alterações se comparados com os resultados apresentados na Figura 62 exceto para a classe de faltas *ST* bifásica. Pode-se notar que para essa classe o erro médio passou de -5m para -89m. Esta discordância pode ser atribuída a dois resultados presentes no histograma que estão muito mais afastadas dos demais. Os outros resultados que compõe o histograma estão situados entre -26m e 30m. Entretanto, tal discrepância torna-se amena quando se faz uso de três medidores ao invés de dois. Estes resultados são sintetizados na Tabela 21 para uma melhor comparação.

Tabela 21 - Tabela para comparação de resultados (utilizando dois medidores).

Tipo de Falta	Resultados da Figura 62		Resultados da Figura 64	
	Média	Desvio Padrão	Média	Desvio Padrão
CT	32m	94m	36m	121m
ST Bifásicas	-5m	68m	-89m	164m
ST Trifásicas	202m	94m	171m	106m

Na Figura 65, pode-se notar que as médias e os desvios padrões foram reduzidos. Por outro lado, os erros médios estão um pouco maiores se comparado com os resultados apresentados na Figura 63, o que resulta numa pequena redução na acurácia do estimador. Em contrapartida, pode-se notar uma melhora na precisão por meio da redução dos desvios padrões. O maior erro médio obtido correspondeu a 38m, o que equivale a 0,5% da extensão da rede de distribuição. Deste modo, o incremento nos valores dos erros médios é aceitável. Estes resultados são sintetizados na Tabela 22 para uma melhor comparação.

Tabela 22 - Tabela para comparação de resultados (utilizando três medidores).

Tipo de Falta	Resultados da Figura 63		Resultados da Figura 65	
	Média	Desvio Padrão	Média	Desvio Padrão
CT	-3m	67m	38m	84m
ST Bifásicas	-81m	115m	-29m	53m
ST Trifásicas	-3m	90m	21m	39m

Em suma, os resultados apresentados demonstram boa generalização do estimador de localização de faltas para as faltas localizadas entre os pontos originais. Adicionalmente, a utilização de informações de mais medidores pode melhorar a estimativa da localização da falta.

CONCLUSÕES E PROPOSTAS PARA TRABALHOS FUTUROS

Conclusão

Nesta dissertação, buscou-se, no âmbito dos sistemas de localização de faltas em sistemas de distribuição de energia elétrica, agregar conhecimento e experiência através do desenvolvimento de uma nova abordagem. No capítulo 3 foi apresentada essa nova abordagem, que consiste em uma metodologia baseada na dissipação da energia da falta. Para tal, as componentes simétricas instantâneas dos sinais de tensão medidos em dois e três medidores são entendidas como sinais de energia.

Tal metodologia é analisada em uma rede elétrica de distribuição equilibrada e sem harmônicos. Esta condição inicialmente parece inadequada pois não condiz com os cenários reais. No entanto, levando em consideração que a tensão na rede é projetada para estar equilibrada, e com baixa distorção harmônica, o fato desta metodologia utilizar somente os sinais de tensão pode se tornar uma vantagem.

Contudo, é imprescindível levar a metodologia proposta neste trabalho a um nível de testes mais elaborados, onde a rede de distribuição tenha características mais próximas das reais. Através dos resultados apresentados no Capítulo 3, percebe-se que tal metodologia tem potencial para estimar a localização de faltas. Principalmente as faltas do tipo fase-terra(*CT*).

O problema das faltas cujas localizações não são diferenciadas, como os pontos 1 e 2, 11 e 12, talvez possam ser solucionados com a inserção de medidores de tensão ao final de cada ramal. Com o advento do conceito *Smart Grids*, futuramente isto não será um problema de implementação pois haverá a possibilidade de inúmeros medidores de tensões espalhados pelo sistema de distribuição. Já para os pontos 4 e 5, o possível problema é que seus respectivos ramais derivam do mesmo ponto do sistema. No entanto, tais conclusões são intuitivas e necessitam de mais resultados experimentais para comprovação.

No capítulo 4, foi proposto um classificador via Redes Neurais Artificiais. Esse classificador, composto por dezessete redes MLP, foi projetado para classificar uma determinada falta em uma das treze possíveis localizações de falta. Essas dezessete redes MLP tinham o propósito de resolver o complexo problema de localização de faltas dividindo-o em problemas mais simples. Primeiro, as faltas eram classificadas em faltas fase-terra(*CT*)

ou entre-fases(*ST*). Na sequência, as faltas *CT* eram passadas diretamente para as redes responsáveis por classificar a localização. Já as faltas *ST* passavam, primeiro, por uma rede responsável por classificá-las por tipo *AB*, *AC*, *BC* ou *ABC*. A partir de então, essas faltas eram passadas para outras redes responsáveis por classificar a localização. Este método, apesar de ter apresentados bons resultados, classificando o conjunto de faltas reservado para teste com 100% de acerto, possui baixa confiabilidade (no caso das faltas *ST*), visto que para as últimas redes neurais temos uma pequena parcela do banco de dados. Com poucos dados disponíveis para treinamento, avaliação e testes, a confiabilidade dos resultados obtidos é questionável.

Assim, na Seção 4.8 foram descritas algumas formas de avaliar o desempenho dos classificadores. A primeira forma, avaliou a sensibilidade da rede neural para os conjuntos de treinamento, validação e testes com diferentes proporções do banco de dados (Teste de Robustez). Ao mesmo tempo foi avaliada a sensibilidade para diferentes partições do banco de dados (Validação Cruzada). A partir desses testes foi estabelecida uma relação de compromisso entre a taxa de acerto médio para o conjunto de testes e a proporção utilizada para treinamento. Observou-se que, para a configuração que utiliza 70% do banco de dados para treinamento, obtém-se uma taxa de acerto médio de $\approx 98\%$, $\approx 85\%$ e $\approx 90\%$, para classificação de localização de faltas *CT*, *ST* bifásicas e *ST* trifásicas, respectivamente. A classificação de faltas *CT* apresentou resultados satisfatórios haja em vista que a taxa de acerto médio se manteve em $\approx 98\%$ para todas as configurações. Já a classificação de faltas *ST* bifásicas e trifásicas, apesar dos bons resultados, necessitam de um banco de dados maior para confirmar os resultados e garantir a confiabilidade dos mesmos.

A segunda forma da análise de desempenho avaliou a capacidade de generalização do classificador. Nesse teste foram utilizadas faltas com características diferentes das conhecidas nos treinamentos das redes. Basicamente foram utilizadas faltas de alta impedância com valores de 50Ω , 75Ω e 100Ω . Nesses testes, verificou-se que o classificador generalizou corretamente as faltas *CT* de alta impedância, obtendo uma taxa de acerto de 100%. A menor taxa de acerto obtida foi de 75% para as faltas *ST* trifásicas. Para as faltas *ST* bifásicas foi obtido uma taxa de acerto de 83,3%. Esses resultados mostram uma boa capacidade de generalização.

No capítulo 5, é proposto um estimador de localização de faltas via redes neurais.

Nesta abordagem as redes MLP são utilizadas como aproximadores de funções. Foram projetadas duas redes neurais, uma responsável por estimar a localização de faltas *CT* e outra para faltas *ST*.

Para essa abordagem, primeiro, realizou-se a análise de desempenho utilizando os mesmos testes de robustez com validação cruzada. Adicionalmente, realizou-se um teste com faltas de alta impedância simuladas entre os pontos de faltas originais. Além disso, foram comparados os casos em que se utilizam dois e três medidores. Não observou-se variações significativas nos erros médios nem nos desvios padrões para os dois casos em função da proporção de separação do banco de dados utilizada para treinamento. Assim, arbitrou-se a proporção de 51,85% para o conjunto de treinamento da RNA 1' e de 55% para a RNA 2' observando apenas os erros máximos positivos e negativos do teste da RNA 2' para três medidores.

Essas proporções disponibilizam uma quantidade grande de dados para os conjuntos de validação e testes possibilitando uma confiabilidade aceitável nos resultados dos testes. Na sequência, foi treinado um estimador de localização de faltas utilizando essas proporções com resultados satisfatórios para o conjunto de testes. A partir dos resultados apresentados, pode-se observar que os erros médios para os tipos de faltas *CT* e *ST*, utilizando dois e três medidores estão próximos de zero. Em outras palavras, pode-se afirmar que o estimador tem boa acurácia. Além disso, os desvios padrões são de 74m e 110m para as faltas *CT* e *ST* quando se utilizam dois medidores e de 46m e 62m para as faltas *CT* e *ST* quando se utilizam três medidores. Esses valores revelam boa precisão do estimador. Pode-se notar, também, que a utilização de três medidores melhorou significativamente a precisão do estimador. Esses resultados apresentam boa confiabilidade pois os erros médios e os desvios padrões estão próximos dos testes de validação cruzada apresentados, cujos resultados foram obtidos estatisticamente com base em dez possíveis realizações.

Na sequência, foi analisada a capacidade das redes neurais (RNA 1' e RNA 2') de generalizar o conhecimento adquirido para as faltas de alta impedância. Neste teste também foram utilizadas faltas de alta impedância com valores de 50Ω , 75Ω e 100Ω . Para o caso em que se utilizou dois medidores, verificou-se que o estimador generalizou de forma satisfatória as faltas *CT* de alta impedância, obtendo um erro médio de 32m com desvio padrão de 94m. O maior erro foi obtido para as faltas *ST* trifásicas com erro médio de 202m e desvio padrão de 94m. Para as faltas *ST* bifásicas foi obtido um erro

médio de -5m com desvio padrão de 68m. Esses resultados demonstram a capacidade de generalização para as faltas *CT* e *ST* bifásica de alta impedância demonstrando boa acurácia. No entanto, a capacidade de generalização para as faltas *ST* trifásicas, nesse caso, foi comprometida.

Com a utilização de três medidores, verificou-se que o estimador generalizou satisfatoriamente as faltas *CT* de alta impedância, com erro médio de -3m e desvio padrão de 67m. O maior erro foi obtido para as faltas *ST* bifásicas com erro médio de -81m e desvio padrão de 115m. Para as faltas *ST* trifásicas foi obtido um erro médio de -3m com desvio padrão de 90m. Esses resultados mostram uma boa capacidade de generalização para as faltas *CT* e *ST* trifásica de alta impedância demonstrando boa acurácia e precisão. No entanto, a capacidade de generalização para as faltas *ST* bifásicas, nesse caso, foi comprometida.

Com isso, nessas condições, pode ser verificado que o estimador não conseguiu responder adequadamente ao mesmo tempo para as faltas *ST* bifásicas e trifásicas. Uma solução possível consiste em separar a rede RNA 2' em duas redes, uma responsável pelas faltas *ST* bifásicas e outra responsável pela faltas *ST* trifásicas. No entanto, isto reduziria consideravelmente a quantidade de dados para treinamento, validação e testes para a rede responsável pelas faltas *ST* trifásicas. Para que isso pudesse ser realizado, o banco de dados precisaria ser expandido. Mas ainda assim, os resultados são satisfatórios tendo em vista que em um sistema de distribuição com mais de 6,755km, um erro médio de 202m representa menos que 3%.

Na sequência, foi analisada a capacidade das redes neurais (RNA 1' e RNA 2') de generalizar seu conhecimento adquirido para as faltas de alta impedância ocorridas entre os pontos originais de falta. Nesse teste foram utilizadas faltas de alta impedância de 75Ω . Esperava-se que os erros médios bem como os desvios padrões não fossem tão discordantes dos resultados observados para o teste anterior. Assim, para o caso em que se utilizou dois medidores, verificou-se um erro médio de 36m com desvio padrão de 121m para as faltas *CT* de alta impedância. Um erro médio de 171m com desvio padrão de 106m para as faltas *ST* trifásicas. E, para as faltas *ST* bifásicas, foi obtido um erro médio de -89m com desvio padrão de 164m. Desta forma, pode-se notar que não houve variações significativas com exceção dos resultados para as faltas *ST* bifásicas no qual o erro médio avançou de -5m para -89m. Entretanto, foram alcançados excelentes resultados quando

se fez uso de três medidores. Pode-se observar um erro médio de 38m com desvio padrão de 84m para as faltas *CT*, um erro médio de -29m com desvio padrão de 53m para as faltas *ST* bifásicas e um erro médio de 21m com desvio padrão de 39m para as faltas *ST* trifásicas.

Em suma, a confiabilidade e a disponibilidade no fornecimento de energia elétrica são necessárias para a vida contemporânea. Distúrbios no fornecimento de energia elétrica devem ser evitados e, quando isto não for possível, deve-se buscar a rápida recuperação do fornecimento. A detecção e a localização do distúrbio em um sistema de distribuição de energia elétrica é muito importante para a manutenção da confiabilidade e disponibilidade do sistema, permitindo providenciar o reparo do fornecimento de energia já quando os primeiros sinais de distúrbios sejam detectados. Assim, o presente trabalho contribuiu com uma metodologia alternativa, simples e eficaz para esse propósito.

Propostas Para Trabalhos Futuros

De modo a aperfeiçoar a metodologia proposta, tornando-a mais abrangente e confiável, propõem-se algumas sugestões de trabalhos a serem realizados futuramente:

- Utilizar uma quantidade maior de medidores no sistema de distribuição com o objetivo de melhorar a generalização das RNAs bem como distinguir os pontos de faltas 1 e 2, 4 e 5, 11 e 12 no sistema estudado;
- Testar outros classificadores como SVM e RBF;
- Expandir o banco de dados com mais faltas do tipo *ST* para disponibilizar mais dados para treinamento, validação e testes;
- Testar outras técnicas de decomposição dos sinais correspondentes às tensões e correntes para extração de dados;
- Testar a aplicação desta metodologia em linhas de transmissão.

REFERÊNCIAS

- ANEEL. *PRODIST - Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional*. 2009.
- ANTUNES, R. H. R. *Detecção e classificação de VTCDs em sistemas de distribuição de energia elétrica usando redes neurais artificiais*. Dissertação (Dissertação de Mestrado) — Universidade do Estado do Rio de Janeiro (UERJ), 2012.
- AWALIN, L. J. et al. A generalized fault location method based on voltage sags for distribution network. *IEEEJ Transactions on Electrical and Electronic Engineering*, Wiley Subscription Services, Inc., A Wiley Company, v. 8, n. S1, p. S38–S46, 2013.
- BEDROSIAN, E. A product theorem for hilbert transforms. *Proceedings of the IEEE*, v. 51, n. 5, p. 868–869, May 1963. ISSN 0018-9219.
- BEWLEY, L. *Traveling Waves on Transmission Systems*. [S.l.]: John Wiley & Sons, 1951. (General Electric Series).
- BISHOP, C. *Pattern Recognition and Machine Learning*. [S.l.]: Springer, 2006. (Information Science and Statistics). ISBN 9780387310732.
- BORGHETTI, A. et al. Integrated use of time-frequency wavelet decompositions for fault location in distribution networks: Theory and experimental validation. *Power Delivery, IEEE Transactions on*, v. 25, n. 4, p. 3139–3146, 2010. ISSN 0885-8977.
- BORGHETTI, A. et al. Continuous-wavelet transform for fault location in distribution power networks: Definition of mother wavelets inferred from fault originated transients. *Power Systems, IEEE Transactions on*, v. 23, n. 2, p. 380–388, 2008.
- CHUI, C. K. An introduction to wavelets. *Boston: Academic Press*, p. 264, 1992.
- CLARKE, E. *Circuit Analysis of A-C Power Systems...* [S.l.]: Wiley, 1950. (General Electric series).
- COHEN, L. *Time-frequency Analysis*. [S.l.]: Prentice Hall PTR, 1995. (Electrical engineering signal processing). ISBN 9780135945322.
- COMTRADE: a new standard for common format for transient data exchange. *Power Delivery, IEEE Transactions on*, v. 7, n. 4, p. 1920–1926, Oct 1992.
- CORRÊA, M. F.; VELLASCO, M. Análise de risco de crédito em correspondentes bancários através de redes neurais. *Revista Inteligência Computacional Aplicada*, v. 1, n. 1, p. 23–37, 2008.
- CUTRI, R. *Compensação de desequilíbrios de carga empregando conversor estático operando com modulação em largura de pulso*. Dissertação (Dissertação (Mestrado em Sistemas de Potência)) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2004 2004.

- DASHTI, R.; SADEH, J. Applying dynamic load estimation and distributed-parameter line model to enhance the accuracy of impedance-based fault-location methods for power distribution networks. *Electric Power Components and Systems*, v. 41, n. 14, p. 1334–1362, 2013.
- DUGAN; GRANAGHAM. Electrical power systems quality. *New York: Mc Graw - Hill*, p. 521, 2002.
- FORTEESCUE, C. L. Method of symmetrical co-ordinates applied to the solution of polyphase networks. *American Institute of Electrical Engineers, Transactions of the, IEEE*, v. 37, n. 2, p. 1027–1140, 1918.
- GAOUDA, A. et al. Application of multiresolution signal decomposition for monitoring short-duration variations in distribution systems. *Power Delivery, IEEE Transactions on*, v. 15, n. 2, p. 478–485, Apr 2000.
- GAZZANA, D. et al. An integrated technique for fault location and section identification in distribution systems. 2013.
- GRANADO, J. et al. Using fpgas to implement artificial neural networks. In: IEEE. *Electronics, Circuits and Systems, 2006. ICECS'06. 13th IEEE International Conference on*. [S.l.], 2006. p. 934–937.
- GRANADOS-LIEBERMAN, D. et al. Techniques and methodologies for power quality analysis and disturbances classification in power systems: a review. *IET Generation, Transmission e Distribution*, p. 519–529, 2011.
- HAYKIN, S. *Redes Neurais: princípios e prática*. [S.l.]: Porto Alegre: Bookman, 2001.
- HAYKIN, S. *Sistemas de Comunicações: Analógicos e Digitais. 4ª Edição*. [S.l.]: Editora Bookman, 2004.
- HUANG, S.-J.; HSIEH, C.-T. High-impedance fault detection utilizing a morlet wavelet transform approach. *Power Delivery, IEEE Transactions on*, v. 14, n. 4, p. 1401–1410, Oct 1999.
- IEEE Std 1159. *IEEE Recommended Practice for Monitoring Electric Power Quality*. 1995.
- IEEE Std 1159. Ieee recommended practice for monitoring electric power quality. *IEEE Std 1159-2009 (Revision of IEEE Std 1159-1995)*, p. c1–81, June 2009.
- IEEE Std C37.114. *IEEE Guide for Determining Fault Location on AC Transmission and Distribution Lines*. 2005. 1-36 p.
- JENSEN, R.; SHEN, Q. *Computational Intelligence and Feature Selection: Rough and Fuzzy Approaches*. [S.l.]: Wiley-IEEE Press, 2008. ISBN 0470229756, 9780470229750.
- KEYHANI, R.; DERICHE, M.; PALMER, E. A high impedance fault detector using a neural network and subband decomposition. 6th international. *Symposium on Signal Processing and its Applications, Malaysia 2*, p. 458–461, August 2001.

KEZUNOVIC, M.; MRKIC, J.; PERUNICIC, B. An accurate fault location algorithm using synchronized sampling. *Electric Power Systems Research*, v. 29, n. 3, p. 161 – 169, 1994.

KOVACS, Z. *Redes Neurais Artificiais*. [S.l.]: LIVRARIA DA FISICA, 2002. ISBN 9788588325142.

LOPE, M. D. C. *Análise Probabilística de Variações de Tensão de Curta Duração em Redes de Distribuição*. Dissertação (Mestrado) — UFMA, 2005.

LOUT, K.; AGGARWAL, R. Current transients based phase selection and fault location in active distribution networks with spurs using artificial intelligence. In: *Power and Energy Society General Meeting (PES), 2013 IEEE*. [S.l.: s.n.], 2013. p. 1–5.

LOVISOLO, L. et al. Análise comparativa do desempenho de algoritmos de sistemas de sincronismos (pll - phase lock loop). *Revista EletroEvolução - Sistema de Potência, Cigré-Brasil*, 10, p. 37–43., Junho 2008.

LOVISOLO, L. et al. Location of faults generating short-duration voltage variations in distribution systems regions from records captured at one point and decomposed into damped sinusoids. *Generation, Transmission Distribution, IET*, v. 6, n. 12, p. 1225–1234, December 2012.

MAIA, R. M. *Caracterização das variações de tensão de curta duração e seus impactos em uma planta da indústria alimentícia*. Dissertação (Mestrado) — UFMG, 2011.

MARTINEZ, S. de C.; FERRARA, L. F. P.; MARIO, M. C. Análise de um aproximador funcional utilizando as redes neurais artificiais mlp treinadas com o algoritmo backpropagation. *1º EPG*, p. 21, 2012.

MORA-FLOREZ, J.; BARRERA-NUEZ, V.; CARRILLO-CAICEDO, G. Fault location in power distribution systems using a learning algorithm for multivariable data analysis. *Power Delivery, IEEE Transactions on*, v. 22, n. 3, p. 1715–1721, July 2007. ISSN 0885-8977.

MORA-FLOREZ, J.; MELENDEZ, J.; CARRILLO-CAICEDO, G. Comparison of impedance based fault location methods for power distribution systems. *Electric Power Systems Research*, v. 78, n. 4, p. 657 – 666, 2008. ISSN 0378-7796. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S037877960700123X>>.

MORETO, M. Localização de faltas de alta impedância em sistemas de distribuição de energia: Uma metodologia baseada em redes neurais artificiais. *Master's thesis, Universidade Federal do Rio Grande do Sul*, 2005.

NETO, J. A. M. et al. Robust positive-sequence detector algorithm. In: *Industrial Electronics, 2009. IECON 09. 35th Annual Conference of IEEE*. [S.l.: s.n.], 2009. p. 788–793.

Procedimentos de Rede - Submódulo 2.8. Disponível em: <<http://www.ons.org.br>>.

OPPENHEIM, A.; WILLSKY, A.; NAWAB, S. *Sinais e sistemas*. Prentice-Hall, 2010. ISBN 9788576055044. Disponível em: <<http://books.google.com.br/books?id=ZOg9bwAACAAJ>>.

- POPOVIC, T.; KEZUNOVIC, M.; KRSTAJIC, B. Implementation requirements for automated fault data analytics in power systems. *International Transactions on Electrical Energy Systems*, p. n/a–n/a, 2014.
- POURAHMADI-NAKHLI, M.; SAFAVI, A. Path characteristic frequency-based fault locating in radial distribution systems using wavelets and neural networks. *Power Delivery, IEEE Transactions on*, v. 26, n. 2, p. 772–781, 2011. ISSN 0885-8977.
- RUIZ-REYES, N.; VERA-CANDEAS, P.; JURADO, F. Discrimination between transient voltage stability and voltage sag using damped sinusoids-based transient modeling. *Power Delivery, IEEE Transactions on*, v. 20, n. 4, p. 2644–2650, 2005. ISSN 0885-8977.
- SPOOR, D.; ZHU, J. G. Improved single-ended traveling-wave fault-location algorithm based on experience with conventional substation transducers. *Power Delivery, IEEE Transactions on*, v. 21, n. 3, p. 1714–1720, 2006. ISSN 0885-8977.
- STEVENSON, W. *Elements of power system analysis*. [S.l.]: McGraw-Hill, 1982. (McGraw-Hill series in electrical engineering: Power and energy). ISBN 9780070612792.
- TAKAGI, T.; YAMAKOSHI, Y. *Fault detecting system for locating a fault point with a fault resistance separately measured*. Google Patents, jan. 26 1982. US Patent 4,313,169. Disponível em: <<http://www.google.com/patents/US4313169>>.
- TAKAGI, T. et al. A new algorithm of an accurate fault location for ehv/uhv transmission lines: Part i - fourier transformation method. *Power Apparatus and Systems, IEEE Transactions on*, PAS-100, n. 3, p. 1316–1323, March 1981. ISSN 0018-9510.
- TAKAGI, T. et al. Development of a new type fault locator using the one-terminal voltage and current data. *Power Apparatus and Systems, IEEE Transactions on*, PAS-101, n. 8, p. 2892–2898, April 1982. ISSN 0018-9510.
- THUKARAM, D.; KHINCHA, H. P.; VIJAYNARASIMHA, H. P. Artificial neural network and support vector machine (svm) approach for locating faults in radial distribution systems. *IEEE Transactions on Power Delivery* 20, p. 710–721, 2005.
- USIDA, W. F. et al. Análise qualitativa no monitoramento automático dos eventos de tensão de curta duração. *Revista Controle & Automação* 20, v. 3, p. 323–334, Agosto 2009.
- WELFONDER, T. et al. Location strategies and evaluation of detection algorithms for earth faults in compensated mv distribution systems. *Power Delivery, IEEE Transactions on*, v. 15, n. 4, p. 1121–1128, Oct 2000.
- YE, L. et al. An improved fault-location method for distribution system using wavelets and support vector regression. *International Journal of Electrical Power & Energy Systems*, v. 55, n. 0, p. 467 – 472, 2014.
- ZHAI, J. et al. Early fault detection of distribution network based on high-frequency component of residual current. In: WONG, W. E.; ZHU, T. (Ed.). *Computer Engineering and Networking*. [S.l.]: Springer International Publishing, 2014, (Lecture Notes in Electrical Engineering, v. 277). p. 1083–1090.