**UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS**

André Luís da Silva Pessoa

**A localização de faltas em um sistema de distribuição
radial baseada na aplicação de árvores de decisão e redes
neurais artificiais**

São Carlos

2017

André Luís da Silva Pessoa

A localização de faltas em um sistema de distribuição radial baseada na aplicação de árvores de decisão e redes neurais artificiais

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, para obtenção do título de Mestre em Ciências - Programa de Pós-Graduação em Engenharia Elétrica.

Área de concentração: Sistemas Elétricos de Potência

Orientador: Prof. Dr. Mário Oleskovicz

Trata-se da versão corrigida da dissertação. A versão original se encontra disponível na EESC/USP que aloja o programa de Pós-Graduação de Engenharia Elétrica.

**São Carlos
2017**

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

P475a Pessoa, André Luís da Silva
A localização de faltas em um sistema de
distribuição radial baseada na aplicação de árvores de
decisão e redes neurais artificiais / André Luís da
Silva Pessoa; orientador Mário Oleskovicz. São Carlos,
2017.

Dissertação (Mestrado) - Programa de Pós-Graduação
em Engenharia Elétrica e Área de Concentração em
Sistemas Elétricos de Potência -- Escola de Engenharia
de São Carlos da Universidade de São Paulo, 2017.

1. Árvores de decisão. 2. Alocação otimizada de
medidores de qualidade da energia elétrica. 3.
Monitoramento e localização de faltas. 4. Redes
elétricas inteligentes. 5. Redes neurais artificiais.
6. Sistema de distribuição aéreo. I. Título.

FOLHA DE JULGAMENTO

Candidato: Bacharel **ANDRÉ LUIS DA SILVA PESSOA.**

Título da dissertação: "A localização de faltas em um sistema de distribuição radial baseada na aplicação de árvores de decisão e redes neurais artificiais".

Data da defesa: 02/08/2017.

Comissão Julgadora:

Resultado:

Prof. Associado **Mário Oleskovicz**
(Orientador)
(Escola de Engenharia de São Carlos/EESC)

APROVADO

Prof. Dr. **Murilo da Silva**
(Universidade Tecnológica Federal do Paraná/UTFPR)

APROVADO

Prof. Dr. **Ricardo Caneloi dos Santos**
(Universidade Federal do ABC/UFABC)

APROVADO

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica:
Prof. Associado **Luis Fernando Costa Alberto**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Luis Fernando Costa Alberto**

Agradecimentos

Agradeço a toda minha família pelo amor tenro e infindável.

Agradeço aos amigos mais antigos e aos mais recentes por todo o apoio e presença.

Agradeço ao meu orientador, o Prof. Associado Mário Oleskovicz, pela dedicação e atenção em todos os momentos desta pesquisa. Pelas conversas salutaras e todo o encaminhamento que foi dado.

Agradeço a todos os funcionários da USP.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte financeiro.

Agradeço também a todos os amigos que pude conhecer no Laboratório de Sistemas de Energia Elétrica - LSEE, pelos cafés que sempre foram cheios de boa companhia.

“Aquilo que se faz por amor está sempre além do bem e do mal ”
(Friedrich Nietzsche)

RESUMO

PESSOA, A. L. S. **A localização de faltas em um sistema de distribuição radial baseada na aplicação de árvores de decisão e redes neurais artificiais.** 2017. 200p. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2017.

Os Sistemas de Distribuição (SDs), devido as suas topologias e configurações, dentre outros fatores, apresentam um desafio para a localização física das situações de faltas passíveis de ocorrência. Como fato, tem-se que uma localização de faltas, rápida e precisa, possibilita atenuar os transtornos que os usuários finais dos SDs viriam a ter em relação à qualidade do serviço prestado pelas distribuidoras. No contexto das redes elétricas inteligentes, e considerando medidores de qualidade da energia elétrica previamente alocados de forma otimizada, esta pesquisa propõe uma metodologia baseada em árvores de decisão e redes neurais artificiais para a localização de faltas em SDs radiais e aéreos. Foram realizados testes da metodologia proposta considerando variações no tipo, na impedância e no ângulo de incidência da falta aplicadas sobre o SD de 34 barras do IEEE (Institute of Electrical and Electronics Engineers). Para os testes de sensibilidade da metodologia desenvolvida, foram consideradas variações no carregamento do sistema, os erros inerentes ao sistema de medição, a variação no número de medidores disponível, o impacto de uma alocação não otimizada dos medidores e uma redução na taxa amostral. Os resultados encontrados foram promissores e indicam que a metodologia como desenvolvida poderá ser aplicada para SDs diferentes do caso teste utilizado.

Palavras-chave: Árvores de decisão. Alocação otimizada de medidores de qualidade da energia elétrica. Monitoramento e localização de faltas. Redes elétricas inteligentes. Redes neurais artificiais. Sistema de distribuição aéreo.

ABSTRACT

PESSOA, A. L. S. **Fault location in a radial distribution system based on the application of decision trees and artificial neural networks.** 2017. 200p.

Dissertation (Master Degree) - Engineering School of São Carlos, University of São Paulo, São Carlos, 2017.

Due to the distribution systems (DS) topologies, configurations and among other factors, it is a challenge to physically locate situations of faults. As a matter of fact, a fast and accurate fault location will make it possible to mitigate the inconvenience that the end users of DS would have due to the quality of the service provided by the distributors. In the context of intelligent electric grids, and considering the electric power quality meters optimally allocated, this research proposes a methodology based in decision trees and artificial neural networks for a fault location in radial and aerial DS. The proposed methodology was tested considering variations on the type, impedance and angle of incidence of the fault applied on the DS of 34 bars of the IEEE (Institute of Electrical and Electronic Engineers). For a sensitivity test of the developed methodology, it were considered the variations in system loading, the errors inherent to the measurement system, a variation in number of meters available, the impact of the non-optimized allocation of the meters and a reduction on the sampling rate. The results were promising and indicated that the methodology developed can be applied to different DS from the test case used.

Keywords: Decision trees. Optimized allocation of power quality meters. Monitoring and fault location. Smart grids. Neural networks. Aerial distribution system.

Lista de ilustrações

Figura 1 – Elementos e interfaces atreladas aos conceitos das Redes Elétricas Inteligentes (REIs).	40
Figura 2 – Configuração típica de uma rede de distribuição de média tensão (MT).	43
Figura 3 – Quadro contendo a representação linear de alguns dos tipos de faltas monofásicas, bifásicas e trifásicas usualmente empregadas.	44
Figura 4 – Modelo generalizado para uma situação de falta.	45
Figura 5 – Estratégia para a classificação e a localização de faltas através da decomposição do sinal armazenado em modelos de senoides amortecidas.	52
Figura 6 – Árvore de decomposição através da WPT.	56
Figura 7 – Fluxogramas das etapas e módulos considerados na pesquisa.	64
Figura 8 – Sistema do <i>Institute of Electrical and Electronics Engineers</i> (IEEE) de 34 barras com a representação da posição das chaves, permitindo a aplicação dos curtos-circuitos de interesse, e dos medidores de Qualidade da Energia Elétrica (QEE) (PARTE 1).	65
Figura 9 – Sistema do IEEE de 34 barras com a representação da posição das chaves, permitindo a aplicação dos curtos-circuitos de interesse, e dos medidores de QEE (PARTE 2).	66
Figura 10 – Fluxo de informações entre os medidores instalados e o sistema de localização das faltas.	70
Figura 11 – Valores <i>RMS</i> dos sinais das corrente trifásicas para as faltas <i>A</i> -terra, <i>AB</i> , <i>AB</i> -terra e <i>ABC</i>	71
Figura 12 – Algoritmo para a divisão do sistema de distribuição radial em áreas.	73
Figura 13 – Sistema ilustrativo contendo 5 medidores.	74
Figura 14 – Definição das áreas para o sistema ilustrativo de 5 barras após analisar todos os medidores.	74
Figura 15 – Definição final das áreas para o sistema ilustrativo de 5 barras após analisar todos os medidores.	75

Figura 16 – Definição de áreas para o Sistema de Distribuição (SD) do IEEE de 34 barras considerando 3 medidores otimamente alocados.	76
Figura 17 – Definição de áreas para o SD do IEEE de 34 barras considerando 4 medidores otimamente alocados.	77
Figura 18 – Definição de áreas para o SD do IEEE de 34 barras considerando 4 medidores sem adotar uma alocação otimizada.	78
Figura 19 – Ilustração do SD do IEEE de 34 barras.	79
Figura 20 – SD do IEEE de 34 barras dividido em 17 regiões iniciais.	80
Figura 21 – Fluxograma para a divisão do sistema de distribuição radial em regiões.	82
Figura 22 – Fluxograma utilizado para a definição dos agrupamentos entre regiões adjacentes.	84
Figura 23 – SD do IEEE de 34 barras dividido em 10 regiões finais.	86
Figura 24 – Exemplo de uma RNA <i>Perceptron</i> Multicamadas.	87
Figura 25 – Algoritmo para o projeto das Redes Neurais Artificiais (RNAs) para a estimação da distância da falta com relação à subestação.	89
Figura 26 – Representação genérica das RNAs utilizadas para a estimação da distância da falta.	90
Figura 27 – Ilustração do banco de dados utilizado para o treinamento e validação das RNAs.	90
Figura 28 – Algoritmo utilizado para obter a topologia adequada para a estimação da distância das faltas.	93
Figura 29 – Exemplo de árvore de decisão.	94
Figura 30 – Ilustração de uma árvore de decisão genérica para identificar a área e/ou a região de ocorrência da falta.	95
Figura 31 – Algoritmos para o treinamento das árvores de decisão utilizadas.	97
Figura 32 – Gráfico <i>bubble chart</i> dos parâmetros utilizados por algumas árvores de decisão treinadas.	98
Figura 33 – Algoritmo completo da localização de faltas.	102
Figura 34 – Ilustração da aplicação do algoritmo de localização de faltas na estimação da distância da falta.	103
Figura 35 – Ilustração do problema das múltiplas estimações na localização de faltas fase A-terra no SD do IEEE de 34 barras.	104
Figura 36 –	105
Figura 37 –	106
Figura 38 – Detalhamento das principais informações presentes em um gráfico <i>box plot</i>	108
Figura 39 – Gráficos <i>box plot</i> dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra, fase C-terra, fases AB, fases BC e fases AC.	110

Figura 40 – Gráficos <i>box plot</i> dos erros de estimação da distância da falta para os tipos de falta fases AB-terra, fases BC-terra, fases AC-terra, fases ABC e fases ABC-terra.	111
Figura 41 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra, fase C-terra, fases AB, fases BC e fases AC.	112
Figura 42 – Histograma dos erros de estimação da distância da falta para os tipos de falta fases AB-terra, fases BC-terra, fases AC-terra, fases ABC e fases ABC-terra.	113
Figura 43 – Distribuição dos erros de estimação da distância da falta para a impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra.	114
Figura 44 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fases AB-terra, fases BC-terra, fases AC-terra e fases ABC-terra.	115
Figura 45 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra, fase C-terra, fases AB, fases BC e fases AC.	116
Figura 46 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 15° , 45° e 75° , e para os tipos de falta fases AB-terra, fases BC-terra, fases AC-terra, fases ABC e fases ABC-terra.	117
Figura 47 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra, fase C-terra, fases AB, fases BC e fases AC.	120
Figura 48 – Matrizes de confusão para os tipos de falta fases AB-terra, fases BC-terra, fases AC-terra, fases ABC e fases ABC-terra.	121
Figura 49 – Amplitudes das correntes trifásicas em situações de falta fase A-terra aplicadas no sistema com carregamento reduzido para 80% do seu valor nominal.	124
Figura 50 – Amplitudes das correntes trifásicas em situações de falta fase A-terra aplicadas no sistema com carregamento normal.	125
Figura 51 – Comparativo entre os valores das amplitudes das fases trifásicas do sistema com carregamento normal, e do sistema com carregamento reduzido para 80% do seu valor nominal, considerando a aplicação de faltas fase A-terra.	126
Figura 52 – Impacto do erro de medição em $En12_{IB}$	134
Figura 53 – Árvore de decisão para a identificação das regiões de ocorrência das faltas fase A-terra para os dados do medidor M01.	148
Figura 54 – Árvore de decisão para a identificação das áreas de ocorrência das faltas fase A-terra.	149

Figura 55 – Gráficos <i>box plot</i> dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando redução da impedância das cargas em 80%.	151
Figura 56 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando redução da impedância das cargas em 80%.	152
Figura 57 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma redução da impedância das cargas em 80%.	153
Figura 58 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma redução da impedância das cargas em 80%.	154
Figura 59 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma redução da impedância das cargas em 80%.	155
Figura 60 – Gráficos <i>box plot</i> dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma redução aleatória da impedância das cargas entre 95% e 105% do valor nominal.	157
Figura 61 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma impedância das cargas aleatória entre 95% e 105% do valor nominal.	158
Figura 62 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 95% e 105% do valor nominal.	159
Figura 63 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 95% e 105% do valor nominal.	160
Figura 64 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 95% e 105% do valor nominal.	161
Figura 65 – Gráficos <i>box plot</i> dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma redução aleatória da impedância das cargas entre 90% e 110% do valor nominal.	163

Figura 66 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 90% e 110% do valor nominal.	164
Figura 67 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 90% e 110% do valor nominal.	165
Figura 68 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 90% e 110% do valor nominal.	166
Figura 69 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 90% e 110% do valor nominal.	167
Figura 70 – Gráficos <i>box plot</i> dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando redução aleatória da impedância das cargas em 120% do valor nominal.	169
Figura 71 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas em 120% do valor nominal.	170
Figura 72 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas em 120% do valor nominal.	171
Figura 73 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas em 120% do valor nominal.	172
Figura 74 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas em 120% do valor nominal.	173
Figura 75 – Gráficos <i>box plot</i> dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a presença de erro na medição.	175
Figura 76 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a presença de erro na medição.	176

Figura 77 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a presença de erro na medição. . . .	177
Figura 78 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a presença de erro na medição.	178
Figura 79 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a presença de erro na medição.	179
Figura 80 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando 4 medidores otimamente alocados.	182
Figura 81 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando 4 medidores não otimamente alocados.	184
Figura 82 – Gráficos <i>box plot</i> dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 128 amostras/ciclo.	185
Figura 83 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 128 amostras/ciclo.	186
Figura 84 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 128 amostras/ciclo.	187
Figura 85 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 128 amostras/ciclo.	188
Figura 86 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 128 amostras/ciclo. . . .	189
Figura 87 – Gráficos <i>box plot</i> dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 64 amostras/ciclo.	191
Figura 88 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 64 amostras/ciclo.	192
Figura 89 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 64 amostras/ciclo.	193

Figura 90 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 64 amostras/ciclo.	194
Figura 91 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 64 amostras/ciclo. . .	195

Lista de tabelas

Tabela 1 – Similaridades entre os métodos levantados na revisão bibliográfica com os objetivos desta pesquisa.	60
Tabela 2 – Possibilidades para a alocação dos medidores de QEE conforme os limiares de tensão desejados.	67
Tabela 3 – Número de simulações realizadas para cada tipo de falta.	69
Tabela 4 – Regiões relacionadas à cada tipo de falta passível de ocorrência sobre o SD do IEEE de 34 barras.	79
Tabela 5 – Distância média das regiões consideradas para a falta fase A-terra. . .	81
Tabela 6 – Distâncias (km) entre a média das estimações das distâncias das estimações das falta fase A-terra de cada uma das regiões consideradas com relação às demais regiões.	83
Tabela 7 – Agrupamentos de regiões adjacentes obtidos para as faltas fase A-terra, fase B-terra e fase C-terra.	85
Tabela 8 – Regiões finais relacionadas a cada tipo de falta.	85
Tabela 9 – Melhor topologia obtida para cada um dos tipos de falta.	92
Tabela 10 – Resultados gerais apresentados com base nos gráficos <i>box plot</i> referentes à estimação da distância da falta.	118
Tabela 11 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário padrão de testes.	119
Tabela 12 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta.	122
Tabela 13 – Resultados gerais observados nas matrizes de confusão referentes ao cenário padrão de testes.	122
Tabela 14 – Resultados gerais da estimação da distância da falta para o cenário com carregamento reduzido para 80% da carga instalada.	123
Tabela 15 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta considerando o carregamento reduzido para 80% do seu valor nominal.	127

Tabela 16 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta considerando as cargas com carregamento reduzido para 80% do seu valor nominal.	127
Tabela 17 – Resultados gerais para a estimação da distância da falta para o cenário considerando uma variação aleatória em cada uma das cargas entre 95% e 105% do seu valor nominal.	128
Tabela 18 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta considerando uma variação aleatória em cada uma das cargas entre 95% e 105% do seu valor nominal.	128
Tabela 19 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta considerando as cargas com carregamento aleatório entre 95% e 105% do seu valor nominal.	128
Tabela 20 – Resultados gerais para a estimação da distância da falta considerando uma variação aleatória em cada uma das cargas entre 90% e 110% do seu valor nominal.	129
Tabela 21 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta considerando uma variação aleatória em cada uma das cargas entre 90% e 110% do seu valor nominal.	129
Tabela 22 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta considerando as cargas com carregamento aleatório entre 90% e 110% do valor nominal.	130
Tabela 23 – Resultados gerais referentes à estimação da distância da falta para o cenário com o carregamento aumentado para 120% da carga instalada.	130
Tabela 24 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta considerando uma variação aleatória em cada uma das cargas com o carregamento aumentado para 120% da carga instalada.	130
Tabela 25 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta, considerando as cargas com carregamento 120% do valor nominal.	131
Tabela 26 – Erros gerais referentes à estimação da distância da falta para o cenário contendo erros de medição.	131
Tabela 27 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário contendo erros de medição. . .	132
Tabela 28 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta considerando a presença de erros de medição.	133
Tabela 29 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário com 4 medidores otimamente alocados.	133

Tabela 30 – Taxa de acerto para a identificação da região de ocorrência das faltas considerando 4 medidores otimamente alocados.	135
Tabela 31 – Resultados gerais observados nas matrizes de confusão referentes ao contexto padrão de testes na presença de 4 medidores instalados. . . .	135
Tabela 32 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário com 4 medidores não otimamente alocados.	135
Tabela 33 – Taxa de acerto para a identificação da região de ocorrência das faltas considerando 4 medidores não otimamente alocados.	136
Tabela 34 – Resultados gerais observados nas matrizes de confusão referentes ao contexto padrão de testes.	136
Tabela 35 – Resultados gerais referentes à estimação da distância da falta considerando uma taxa amostral de 128 amostras/ciclo.	137
Tabela 36 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário com taxa amostral de 128 amostras/ciclo.	138
Tabela 37 – Taxa de acerto para a identificação da região de ocorrência das faltas considerando uma taxa amostral de 128 amostras/ciclo.	138
Tabela 38 – Resultados gerais referentes à estimação da distância da falta considerando uma taxa amostral de 64 amostras/ciclo.	138
Tabela 39 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário com taxa amostral de 64 amostras/ciclo.	139
Tabela 40 – Taxa de acerto para a identificação da região de ocorrência das faltas considerando uma taxa amostral de 64 amostras/ciclo.	139

Lista de Siglas

ANEEL	Agência Nacional de Energia Elétrica
CWT	<i>Continuous Wavelet Transform</i>
DIC	Duração de Interrupção Individual por Unidade Consumidora ou por Ponto de Conexão
DMIC	Duração Máxima de Interrupção Conta por Unidade Consumidora ou por Ponto de Conexão
DICRI	Duração da Interrupção Individual Ocorrida em Dia Crítico por Unidade Consumidora ou Ponto de Conexão
DEC	Duração Equivalente de Interrupção por Unidade Consumidora
DTFT	<i>Discrete-Time Fourier Transform</i>
DFT	<i>Discrete Fourier Transform</i>
DWT	<i>Discrete Wavelet Transform</i>
FIC	Frequência de Interrupção por Unidade Consumidora ou por Ponto de Conexão
FEC	Frequência Equivalente de Interrupção por Unidade Consumidora
IED	<i>Intelligent Electronic Device</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
PAC	Ponto de Acoplamento Comum
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional

PNIE	Percentual do Número de Emergências com Interrupções de Energia
PSO	Particle Swarm Optimization
QEE	Qualidade da Energia Elétrica
QS	Qualidade do Serviço
REIs	Redes Elétricas Inteligentes
RSSF	Redes de Sensores Sem Fio
RNAs	Redes Neurais Artificiais
RBFNN	<i>Radial Basis Function Neural Network</i>
RBFNN-OSD	<i>Radial Basis Function Neural Network with Optimum Steepest Descent</i>
SD	Sistema de Distribuição
SEP	Sistema Elétrico de Potência
SVM	<i>Support Vector Machine</i>
SMA	Sistema Multiagente
TMP	Tempo Médio de Preparação
TMD	Tempo Médio de Deslocamento
TME	Tempo Médio de Execução
TMAE	Tempo Médio de Atendimento a Emergências
TP	Transformador de Potencial
TC	Transformador de Corrente
TPC	Transformador de Potencial Capacitivo
TW	Transformada Wavelet
TWD	Transformada Wavelet Discreta
WPT	<i>Wavelet Packet Transform</i>

Sumário

1	INTRODUÇÃO	33
1.1	Objetivos da pesquisa	34
1.2	Contribuições da pesquisa	35
1.3	Estrutura do documento	35
2	CONTEXTO E DEFINIÇÃO DO PROBLEMA	37
2.1	Uma visão geral das redes elétricas inteligentes	37
2.2	O sistema de distribuição	42
2.2.1	A representação das faltas em um SD	43
2.3	A qualidade do serviço prestado pelas concessionárias	45
2.3.1	A QEE e a qualidade do serviço	45
2.3.2	A localização dos curtos-circuitos e a qualidade do serviço	46
2.4	Considerações finais	47
3	O ESTADO DA ARTE	49
3.1	Métodos baseados na estimação de fasores na frequência fundamental	49
3.2	Métodos baseados em técnicas de inteligência computacional e aprendizagem de máquina	52
3.3	Principais aspectos metodológicos observados nesta revisão bibliográfica	57
3.4	Considerações finais	61
4	METODOLOGIA	63
4.1	Etapa offline	63
4.1.1	Modelagem do sistema teste	63
4.1.2	Alocação otimizada dos medidores de qualidade da energia elétrica	67
4.1.2.1	Simulações dos curtos-circuitos	67

4.1.3	Processamento dos sinais de pós-falta	69
4.1.4	Divisão do sistema de distribuição radial em áreas	71
4.1.5	Divisão do sistema de distribuição radial em regiões	75
4.1.6	Treinamento das RNAs para a estimação da distância da falta	85
4.1.6.1	Parâmetros de entrada e de saída das RNAs	88
4.1.6.2	Normalização dos parâmetros de entrada e de saída das RNAs	89
4.1.6.3	Busca da melhor topologia	91
4.1.7	Treinamento das árvores de decisão para identificar a área e a região do sistema nas quais a falta ocorreu	92
4.2	Etapas de operação	98
4.2.1	Aquisição dos dados dos medidores de QEE	98
4.2.2	Deteção da ocorrência da falta	99
4.2.3	Classificação do tipo da falta	99
4.2.4	Algoritmo para a localização da falta	99
4.3	Testes de sensibilidade realizados para a avaliação do algoritmo de localização de faltas proposto	103
4.3.1	Variação do carregamento do sistema	104
4.3.2	Impacto de erros de medição na localização da falta	104
4.3.3	Variação do número de medidores	105
4.3.4	Variação do número de medidores e considerando uma alocação não otimizada	105
4.3.5	Variação da taxa amostral utilizada	105
4.4	Considerações finais	106
5	RESULTADOS E DISCUSSÕES	107
5.1	O desempenho do algoritmo para o cenário padrão	107
5.1.1	Resultados para a estimação da distância da falta	109
5.1.2	Resultados para a identificação da área de ocorrência da falta	118
5.1.3	Resultados para a identificação da região de ocorrência da falta	119
5.2	Desempenho do algoritmo considerando a variação no carregamento do sistema	123
5.2.1	Cargas com carregamento em 80% do valor nominal	123
5.2.1.1	Resultados para a estimação da distância da falta	123
5.2.1.2	Resultados para a identificação da área de ocorrência da falta	126

5.2.1.3	Resultados para a identificação da região de ocorrência da falta	127
5.2.2	Cargas com carregamento aleatório entre 95% e 105% do valor nominal . .	127
5.2.2.1	Resultados para a estimação da distância da falta	127
5.2.2.2	Resultados para a identificação da área de ocorrência da falta	128
5.2.2.3	Resultados para a identificação da região de ocorrência da falta	128
5.2.3	Cargas com carregamento aleatório entre 90% e 110% do valor nominal . .	129
5.2.3.1	Resultados para a estimação da distância da falta	129
5.2.3.2	Resultados para a identificação da área de ocorrência da falta	129
5.2.3.3	Resultados para a identificação da região de ocorrência da falta	129
5.2.4	Cargas com carregamento em 120% do valor nominal	130
5.2.4.1	Resultados para a estimação da distância da falta	130
5.2.4.2	Resultados para a identificação da área de ocorrência da falta	130
5.2.4.3	Resultados para a identificação da região de ocorrência da falta	131
5.3	Desempenho do algoritmo considerando erros na medição	131
5.3.1	Resultados para a estimação da distância da falta	131
5.3.2	Resultados para a identificação da área de ocorrência da falta	132
5.3.3	Resultados para a identificação da região de ocorrência da falta	132
5.4	Desempenho do algoritmo considerando 4 medidores otimamente posicionados	133
5.4.1	Resultados para a identificação da área de ocorrência da falta	133
5.4.2	Resultados para a identificação da região de ocorrência da falta	134
5.5	Desempenho do algoritmo considerando 4 medidores não otimamente posicionados	135
5.5.1	Resultados para a identificação da área de ocorrência da falta	135
5.5.2	Resultados para a identificação da região de ocorrência da falta	135
5.6	Desempenho do algoritmo considerando uma redução na taxa amostral	137
5.6.1	Resultados considerando uma taxa amostral de 128 amostras/ciclo	137
5.6.1.1	Resultados para a estimação da distância da falta	137
5.6.1.2	Resultados para a identificação da área de ocorrência da falta	137
5.6.1.3	Resultados para a identificação da região de ocorrência da falta	138
5.6.2	Resultados considerando uma taxa amostral de 64 amostras/ciclo	138
5.6.2.1	Resultados para a estimação da distância da falta	138

5.6.2.2	Resultados para a identificação da área de ocorrência da falta	139
5.6.2.3	Resultados para a identificação da região de ocorrência da falta	139
5.7	Considerações finais	140
6	CONCLUSÕES E TRABALHOS FUTUROS	141
6.1	Trabalhos futuros	143

APÊNDICES	145
------------------	------------

APÊNDICE A	–	EXEMPLOS DE ÁRVORES DE DECISÃO TREINADAS	147
APÊNDICE B	–	GRÁFICOS DOS TESTES CONSIDERANDO CAR- GAS COM CARREGAMENTO EM 80% DO VALOR NOMINAL	151
APÊNDICE C	–	GRÁFICOS DOS TESTES CONSIDERANDO CAR- GAS COM CARREGAMENTO ENTRE 95% E 105% DO VALOR NOMINAL	157
APÊNDICE D	–	GRÁFICOS DOS TESTES CONSIDERANDO CAR- GAS COM CARREGAMENTO ALEATÓRIO ENTRE 90% E 110% DO VALOR NOMINAL	163
APÊNDICE E	–	GRÁFICOS DOS TESTES CONSIDERANDO CAR- GAS COM CARREGAMENTO EM 120% DO VALOR NOMINAL	169
APÊNDICE F	–	GRÁFICOS DOS TESTES CONSIDERANDO A PRE- SENÇA DE ERROS NA MEDIÇÃO	175
APÊNDICE G	–	GRÁFICOS DO TESTE CONSIDERANDO 4 MEDI- DORES OTIMAMENTE POSICIONADOS	181
APÊNDICE H	–	GRÁFICOS DO TESTE CONSIDERANDO 4 MEDI- DORES NÃO OTIMAMENTE POSICIONADOS . . .	183

APÊNDICE I	–	GRÁFICOS DO TESTE CONSIDERANDO UMA TAXA AMOSTRAL DE 128 AMOSTRAS/CICLO	185
APÊNDICE J	–	GRÁFICOS DO TESTE CONSIDERANDO UMA TAXA AMOSTRAL DE 64 AMOSTRAS/CICLO	191
REFERÊNCIAS			197

Introdução

A filosofia de operação do sistema elétrico de potência tradicional possui sérias dificuldades para atender as necessidades atuais dos consumidores finais da energia elétrica, e, neste cenário, as Redes Elétricas Inteligentes (REIs) são apresentadas como parte da solução.

Dentre os ideais das REIs, tem-se a perspectiva de se ter um sistema elétrico totalmente automatizado. Dos possíveis benefícios que as REIs possibilitarão está a capacidade de operar melhor o Sistema Elétrico de Potência (SEP) com um fluxo de potência bidirecional (devido a presença de geração distribuída), tornar o sistema capaz de favorecer de forma sustentável o uso dos carros elétricos, tornar a atuação do sistema mais inteligente diante da ocorrência de faltas (curtos-circuitos), possibilitar o uso da energia elétrica mais eficiente, e também tornar a comunicação do sistema elétrico bidirecional.

As REIs englobam os sistemas de geração, transmissão e distribuição e, conforme o exposto, tornam o SEP muito mais confiável. Além do aumento da confiabilidade do sistema, também podem possibilitar uma melhor regulamentação do serviço prestado pelas concessionárias de forma mais precisa, o que acaba repercutindo em um aumento da Qualidade do Serviço (QS) que os consumidores do sistema elétrico recebem.

No contexto delineado, as REIs criam um ambiente favorável ao desenvolvimento de diversas ferramentas que venham a aperfeiçoar a operação do sistema elétrico como um todo. Dentre estas ferramentas estão os algoritmos voltados para a localização precisa (física) das situações de faltas. Estando a Qualidade da Energia Elétrica (QEE) intimamente ligada à qualidade do produto e do serviço, uma precisa localização dos defeitos (os quais podem resultar deste afundamentos menos ou mais severos, a depender do ponto de ocorrência e de medição, até interrupções no fornecimento) poderá vir a garantir e a satisfatoriamente refletir a qualidade do serviço prestado a todos os usuários do SEP.

A localização das faltas desempenha uma etapa suplementar ao sistema de proteção. Os localizadores de falta devem propiciar uma localização (física) da falta que seja rápida e precisa. Outros elementos que balizam o uso deste tipo de ferramenta é a necessidade,

diante de uma situação de falta, de se ter um sistema que tenha uma interoperabilidade, que favoreça a continuidade da operação e do fornecimento de energia, e uma confiabilidade do sistema elétrico. Além destes pontos mencionados, o localizador de faltas também deve sanar fontes espúrias (ou incipientes) de falhas no sistema elétrico.

Diversas pesquisas foram publicadas na temática da localização de faltas em sistemas de distribuição. Trindade, Freitas e Vieira (2014), Naidu, George e Ashok (2015), Iurinic et al. (2015), Souto, Manassero e Santo (2016) e Vianna, Araujo e Penido (2016) apresentam metodologias para a localização de faltas baseados nos fasores das componentes de frequência fundamental de tensão e/ou de corrente. Lovisolo et al. (2012), Dehghani e Nezami (2013), Zayandehroodi et al. (2013), Lout e Aggarwal (2013), Ray, Mishra e Panda (2015), Tong et al. (2015) e Festa (2015) desenvolveram metodologias baseadas em Redes Neurais Artificiais (RNAs). Bunjongjit, Ngaopitakkul e Pothisarn (2013) aplicaram lógica fuzzy e a transformada *wavelet* discreta. Já Ghorbani, Choudhry e Feliachi (2013) utilizaram sistemas multiagentes, e Zapata-Tapasco, Mora-Flórez e Almeida (2014) usaram árvores de decisão.

1.1 Objetivos da pesquisa

A metodologia desenvolvida visa aproveitar o cenário que as redes elétricas inteligentes oferecem, do ponto de vista da centralização do processamento das informações coletadas dos medidores de Qualidade da Energia Elétrica (QEE) que já estejam instalados de forma otimizada no sistema, para localizar fisicamente a região do sistema em que ocorreu a falta.

Para desenvolver, testar e validar a metodologia proposta, será utilizado o sistema de distribuição aéreo do IEEE de 34 barras para correlacionar parâmetros que servirão para avaliar o local físico em que as faltas ocorreram. Para fazer esta correlação entre estes parâmetros e o local no qual houve uma falta será utilizada uma técnica de inteligência computacional conhecida por redes neurais artificiais e uma técnica de aprendizagem de máquina conhecida como árvores de decisão. Inicialmente será estimada a distância da falta com relação à subestação. Outro ponto a se observar é que o SD (Sistema de Distribuição) supracitado será dividido em regiões, permitindo identificar em qual destas regiões a falta ocorreu. Após desenvolver os algoritmos que estimam o local das faltas, serão considerados também testes de sensibilidade que incluirão variações no carregamento do sistema, o impacto de erros nas medições, a variação no número de medidores, a avaliação do uso de uma alocação não otimizada de medidores de QEE nesta metodologia de localização de faltas, e a redução na taxa amostral.

1.2 Contribuições da pesquisa

Esta pesquisa oferece algumas contribuições na área de localização de faltas por meio de técnicas de aprendizagem de máquina nos seguintes pontos:

- utiliza uma metodologia multiestágio que mescla tanto as RNAs quanto as árvores de decisão para a estimação da distância da falta e da região de ocorrência da falta no sistema de distribuição radial;
- extrai diversos parâmetros dos sinais de pós-falta de modo a melhor caracterizar estas mesmas faltas; e
- realiza testes de sensibilidade avaliando o desempenho da metodologia proposta diante de mudanças no carregamento do sistema, na presença de erros na medição, variação do número de medidores considerando a alocação otimizada dos medidores de QEE, variação do número de medidores sem considerar uma alocação otimizada dos medidores de QEE, e variação da taxa amostral.

1.3 Estrutura do documento

Além desta introdução, este documento está dividido em mais cinco capítulos. Abaixo segue o descritivo destes capítulos.

Capítulo 2: Neste capítulo é discorrido sobre o contexto geral das REIs. As dificuldades dos sistemas elétricos tradicionais e os benefícios das REIs são abordados de modo a levar o leitor a entender como é imprescindível que ocorram mudanças no paradigma atual do SEP. São apresentadas algumas características do sistema de distribuição que venham a ser necessárias no desenvolvimento de um algoritmo de localização de faltas. Após isso, é apresentado como será realizada a modelagem dos diversos tipos de falta. Tendo sido apresentados estes elementos iniciais, serão discorridos alguns pontos que levem a compreender a função de uma localização de faltas efetiva para a garantia de uma qualidade do serviço adequada.

Capítulo 3: Neste capítulo são apresentados alguns algoritmos para a localização de faltas em sistemas de distribuição encontrados na literatura correlata. Estes métodos (algoritmos) foram divididos em dois grupos: métodos baseados na estimação dos fasores na frequência fundamental, e métodos baseados em técnicas de inteligência computacional e aprendizagem de máquina.

Capítulo 4: Neste capítulo é apresentada a metodologia desenvolvida nesta dissertação. Esta metodologia está dividida em duas etapas, uma é a *offline*, e a outra é a fase de *operação*. A etapa *offline* engloba a modelagem do SD do IEEE de 34 barras

utilizando o *software* ATP (*Alternative Transients Program*), a alocação otimizada dos monitores (ou medidores) de QEE, a simulação de curtos-circuitos, o processamento dos sinais obtidos, a divisão do sistema de distribuição em áreas e em regiões, o treinamento das RNAs para a estimação da distância da falta, o treinamento das árvores de decisão para a identificação da área de ocorrência da falta, e o treinamento das árvores de decisão para a identificação da região de ocorrência da falta. A etapa de *operação* corresponde à aquisição de dados dos medidores de QEE alocados, detecção do instante de ocorrência da falta, a classificação do tipo da falta e a aplicação do algoritmo de localização de faltas. Por último, é apresentado neste capítulo a metodologia utilizada nos testes de sensibilidade que foram aplicados no algoritmo proposto.

Capítulo 5: São apresentados e discutidos os resultados obtidos. Neste capítulo são apresentados inicialmente os resultados para a situação padrão de teste, e em seguida são apresentados os resultados referentes aos testes de sensibilidade.

Capítulo 6: São discutidas as conclusões observadas pela realização desta pesquisa, alguns pontos que podem nortear à continuidade da pesquisa iniciada, e as publicações obtidas até o momento.

Contexto e definição do problema

A aplicação e o completo desenvolvimento das REIs proporcionarão uma mudança para o paradigma do SEP tradicional, pois abrirão possibilidades para uma geração de energia mais sustentável e também um controle mais inteligente, repercutindo desta forma em um aumento na confiabilidade do sistema de potência como um todo. Além disso, a possibilidade de ter acesso a informações de pontos de medição instalados no sistema, e de usar estas informações para sanar distúrbios que venham a ocorrer na rede elétrica, como, por exemplo, situações de faltas, possibilitam o emprego de algoritmos que façam a localização destas mesmas faltas.

Além do entendimento das REIs, é importante compreender sobre a complexidade atual dos sistemas de distribuição, e como uma localização de faltas rápida e precisa é importante para garantir uma boa qualidade do serviço prestado pelas concessionárias para os usuários finais do produto energia elétrica.

2.1 Uma visão geral das redes elétricas inteligentes

Como fato, tem-se que o consumo global de energia elétrica vem crescendo continuamente, o que já pode caracterizar inúmeros e novos desafios. Por outro lado, o setor de energia pode vir a passar por dificuldades na geração, transmissão e distribuição da energia elétrica necessária para este atendimento do aumento na demanda. Deste modo o desencontro entre a geração e o consumo pode causar falhas parciais ou totais no sistema. Por conta destas dificuldades o sistema de potência atual vem mostrando sinais de operação ineficiente e tendo dificuldades para satisfazer plenamente os avanços tecnológicos do século XXI. O impacto negativo do crescimento do consumo vem se agravando cada vez mais com a diminuição dos combustíveis fósseis e com o aumento das emissões de gases causadores do efeito estufa. Além destes pontos, espera-se para os próximos anos um aumento da presença de veículos elétricos, algo que também implicará em aumento da demanda no sistema (GOEL; AGARWAL, 2015).

Como fato, tem-se que a infraestrutura do setor elétrico atual, em geral, foi

projetada há meio século atrás, a demanda de carga vem crescendo continuamente e o sistema elétrico está se tornando cada vez mais desatualizado frente às atuais necessidades dos consumidores (KHAN et al., 2009). Com a crescente demanda por energia elétrica, e o aumento do uso de fontes de energia renováveis, as redes tradicionais de transmissão e de distribuição necessitam ser atualizadas para um modelo de rede que seja mais interativo e/ou inteligente (GAO; REDFERN, 2011).

Como também é de conhecimento, nas primeiras redes elétricas projetadas, o fluxo de potência era unidirecional, pois a geração de energia elétrica era realizada basicamente por meio de grandes centrais geradoras, e os usuários finais possuíam fácil previsibilidade de carga, algo que é essencial para a indústria de energia elétrica por garantir uma devida operação e planejamento do sistema. Nas redes tradicionais, com fluxo de potência com características *top-down*, a geração pode suprir flexivelmente as cargas do sistema (HAMIDI; SMITH; WILSON, 2010).

Entretanto, as mudanças atuais no sistema devido, por exemplo, à introdução de fontes de geração distribuída e de veículos elétricos, vem trazendo novos desafios para o modelo tradicional do SEP. Esta mudança no cenário elétrico vem surgindo devido às necessidades por fontes mais sustentáveis de energia elétrica, transporte (e utilização final) da energia elétrica mais eficiente e pela própria necessidade de modernizar a infraestrutura do setor elétrico (FALVO et al., 2013). Para prevenir que ocorram falhas no sistema, alguns países vêm investindo largamente em uma renovação das redes elétricas. Assim cresce o interesse em melhorar as redes elétricas atuais através da incorporação de inteligência para cada pequeno componente do sistema e também no projeto do sistema elétrico como um todo. A indústria de potência busca para os sistemas elétricos uma infraestrutura que possibilite tanto um fluxo de potência, quanto um fluxo de informação, bidirecionais (GOEL; AGARWAL, 2015).

Neste contexto, o conceito das REIs está sendo introduzido como um conjunto de tecnologias que venham a garantir uma automatização de processos pertinentes aos sistemas de transmissão e de distribuição, incorporando benefícios a estes sistemas (HAMIDI; SMITH; WILSON, 2010). Nos sistemas elétricos de potência as REIs são reconhecidas como uma nova solução que garantirá uma melhor administração também dos sistemas de distribuição, garantido um melhor aproveitamento das fontes de energia renováveis (FALVO et al., 2013).

Na sequência, apresentam-se alguns apontamentos que denotarão os conceitos, dificuldades e benefícios decorrentes das REIs.

• Conceitos relacionados às REIs

O termo REIs abrange uma variedade de tecnologias que foram e estão sendo desenvolvidas como alternativas aos métodos tradicionais de operação do sistema elétrico

de potência (HAMIDI; SMITH; WILSON, 2010). As REIs são uma combinação de vários dos principais campos da tecnologia e sua implementação requer um ajuste na regulamentação atual do sistema de energia como um todo. A aplicação das REIs irá requerer uma integração com o atual *Supervisory Control and Data Acquisition* (SCADA) (KHAN et al., 2009).

O conceito básico das REIs engloba a capacidade de monitoração do sistema com a integração dos processos, análises avançadas para suportar o controle, a segurança e a comunicação do sistema, bem como a redução do consumo e custos. Neste sentido, considerando o cenário no qual os usuários finais serão cada vez mais relevantes nos estudos de controle de tensão das REIs, os sistemas de comunicação e de transmissão de dados serão necessários e indispensáveis (GAO; REDFERN, 2011).

Sendo assim, cada vez mais vem sendo recomendada a instalação de medidores de QEE próximos de subestações, em pontos de média tensão e próximos ao final dos alimentadores, bem como de qualquer carga sensível (ou perturbadora) do sistema de distribuição. Esta intensa monitoração das REIs tem a função de prover uma boa QEE aos consumidores de energia elétrica, bem como possibilitar um controle em tempo real e, conseqüentemente, permitir uma maior segurança e eficiência do sistema. Contudo, conforme colocado por Gao e Redfern (2011), a habilidade de coletar dados precisos de pontos chaves do sistema e de aglomerados de consumidores, somente será alcançada utilizando medidores inteligentes, sistemas de comunicação sem fio e sistemas apropriados de gestão do sistema. Sendo assim, o projeto de comunicação da rede irá envolver uma análise detalhada dos requerimentos de comunicação, arquitetura de protocolos apropriados, escolha das mais adequadas tecnologias, e um sistema de gestão para uma rede heterogênea. Neste sentido, para se obter vantagens significativas sobre as tecnologias de comunicação tradicionais, as REIs devem envolver, por exemplo, o uso de Redes de Sensores Sem Fio (RSSF). Recentemente, as RSSF possibilitaram várias melhorias nos aspectos atuais do SEP como, por exemplo, na geração, no transporte e uso da energia elétrica (GAO; REDFERN, 2011).

Existem dois tipos de infraestruturas de comunicação para o fluxo da informação nas REIs: a comunicação entre sensores e aparelhos elétricos para os medidores inteligentes; e a comunicação entre os medidores inteligentes e as centrais de dados (*data centers*) das concessionárias. A arquitetura das REIs é hierárquica e é constituída por coleta de dados e controle do transporte de energia elétrica. Cada camada da arquitetura das REIs é formada por diversos subsistemas. As principais camadas das REIs são: o sistema SCADA; a rede de sensores; a infraestrutura de comunicação; e o suporte de segurança (GOEL; AGARWAL, 2015).

A Figura 1 ilustra os vários elementos e as suas possíveis interfaces que estão

atreladas aos conceitos das REIs. Observa-se nesta figura, dentre outros, alguns pontos chaves como: a comunicação bidirecional; a presença de geração distribuída; e o monitoramento do sistema realizado de modo que em caso de anormalidades, o sistema de controle atue em tempo real.

Figura 1 – Elementos e interfaces atreladas aos conceitos das REIs.

Fonte: Adaptado de Falvo et al. (2013)

Já segundo Paul et al. (2014), o conceito das REIs combina os sistemas de geração e de distribuição em um único quadro, ou seja, as REIs tornam todo o sistema inteligente. As REIs são ditas inteligentes pelos seguintes fatos: por usarem do sistema de proteção da rede e o centro de controle através do SCADA; pelo monitoramento e diagnóstico de todos os equipamentos de transmissão; por trabalharem com todo o SEP como um sistema adaptativo e complexo; pela computação em nuvem; e por tornar o SEP capaz de se auto ajustar usando agentes inteligentes. Ainda segundo os autores, o medidor inteligente é um elemento das REIs que é necessário e indispensável. Assim, o medidor inteligente deve se utilizar de uma avançada medição em conjunto com sistemas de comunicação para permitir aos clientes do sistema elétrico ter ciência em tempo real da QEE que é fornecida. Os medidores inteligentes também devem auxiliar as concessionárias de energia elétrica a terem a possibilidade de utilizar a

energia elétrica advinda de usuários do sistema. As REIs também possuem como característica a capacidade de se auto ajustar, possibilitando a detecção automática de condições anormais do sistema como, por exemplo: de sobrecorrentes; de surtos de tensão; de correntes de curto-circuito; dentre outras situações (PAUL et al., 2014).

- **A dificuldade de implementação das REIs**

A confiabilidade da infraestrutura das fornecedoras de energia elétrica é um dos quesitos globais mais importantes que reflete diretamente no atendimento e satisfação dos consumidores. Assim, para cada concessionária atender aos seus critérios de confiabilidade, são necessários investimentos na obtenção das medições que permitam observar o atendimento, ou não, da regulamentação vigente a respeito da QEE.

Neste cenário, o ato de não alcançar os valores mínimos que as regulamentações vigentes exigem pode acarretar em multas às empresas do setor de energia, implicando, portanto, em perdas de receita destas empresas. Neste contexto, sabe-se que muitas das vezes os ativos do sistema que pertencem ao modelo tradicional do setor elétrico, podem não possibilitar, por exemplo, o acesso remoto a certas usinas, ou as medições necessárias, considerando um fluxo bidirecional de potência no sistema. Desta maneira, a incorporação de novos ativos no sistema irá implicar em gastos com equipamentos que possibilitem a coexistência entre os paradigmas do antigo e do novo do setor elétrico.

Além deste exemplo, seguem mais algumas das dificuldades para a implantação das REIs: em diversos mercados de energia elétrica que são privatizados existe uma dificuldade de garantir uma maior participação dos usuários do sistema para uma melhor gestão e operação da rede elétrica; diversas tecnologias ainda não estão totalmente desenvolvidas; e o custo elevado para o desenvolvimento das tecnologias necessárias para a implantação das REIs (HAMIDI; SMITH; WILSON, 2010).

- **Os benefícios decorrentes das REIs**

Segundo Gao e Redfern (2011), dentre outros pontos, as REIs permitem uma melhor competitividade entre as empresas fornecedoras de energia elétrica, possibilitando um melhor uso intermitente da energia elétrica. Possibilitam uma capacidade de automação e monitoramento necessários para a transmissão da energia (através de grandes distâncias e na presença da geração distribuída), possibilitando ainda, uma gestão das interrupções mais eficiente.

As REIs, de um modo geral, impactam positivamente nos seguintes quesitos associados aos sistemas elétricos de potência: confiabilidade; flexibilidade; eficiência; sustentabilidade; grau de inteligência na gestão/operação; e no uso crescente de tecnologias que possibilitem comunicação em tempo real entre geração, transmissão, distribuição e os consumidores (HAMIDI; SMITH; WILSON, 2010). Conforme de-

fendido por Khan et al. (2009), com o uso de agentes inteligentes e de comunicação bidirecional entre os mesmos, pode-se ter um ganho na transmissão de energia elétrica entre 50% e 300%. Assim, pelos autores, obtém-se uma infraestrutura do sistema mais inteligente que terá a capacidade de sanar automaticamente certas situações de defeito, e de apresentar outras funções de auto checagem e de proteção. Desta forma as REIs podem garantir ao sistema um fornecimento da energia com maior qualidade, eficiência e confiabilidade. Já Gao e Redfern (2011) comentam que o número de sensores existente nas REIs, bem como a capacidade de processamento, será bem maior do que o número de sensores presentes nos sistemas elétricos atuais. Neste cenário, e, por exemplo, através da comunicação sem fio, os medidores inteligentes poderão prover as informações necessárias de todos os pontos de interesse em um dado sistema elétrico para um elemento mestre, que poderá então estabelecer o controle em tempo real do sistema como um todo (GAO; REDFERN, 2011).

2.2 O sistema de distribuição

A Figura 2 apresenta um SD contendo diversos alimentadores, com a presença de geração distribuída. A complexidade de um SD depende da sua finalidade, assim, tem-se SDs referentes à redes rurais, suburbanas, urbanas, e industriais.

Tipicamente um SD possui as seguintes características (SAHA; IZYKOWSKI; ROSOLOWSKI, 2009a):

- natureza radial;
- contém tanto alimentadores principais (primários) quanto secundários;
- alimenta algumas cargas em Média Tensão (MT) e/ou em Baixa Tensão (BT) que são monofásicas ou bifásicas;
- a maioria dos circuitos do SD são trifásicos, sendo que em redes rurais existe a presença de circuitos monofásicos;
- normalmente o SD é suprido por um único alimentador de Alta Tensão (AT);
- atualmente a presença de geração distribuída está aumentando no SD; e
- os grandes motores presentes no SD, diante de uma situação de falta, podem funcionar como um "gerador distribuído".

Panesso-Hernández, Cadena-Zapata e Mora-Flórez (2014) apresentam algumas características dos SDs que podem vir a afetar o desempenho dos métodos de localização de faltas. As principais características apontadas pelos autores são:

Figura 2 – Configuração típica de uma rede de distribuição de média tensão (MT).

Fonte: Adaptado de Saha, Izykowski e Rosolowski (2009a).

- os SDs em diversas situações não apresentam um caráter uniforme, ou seja, possuem cabos com diversos tamanhos de seção (ou com distintas propriedades físicas) em um mesmo circuito;
- a presença de alimentadores secundários que sejam monofásicos, bifásicos ou trifásicos;
- a presença de desbalanços (desequilíbrios) entre as fases pode prejudicar o desempenho de métodos que se utilizem de componentes simétricas; e
- embora nos métodos de localização de faltas para sistemas de transmissão a impedância da falta possa vir a ser desprezada, em sistemas de distribuição, o seu valor é de grande relevância.

2.2.1 A representação das faltas em um SD

Para o algoritmo do localizador de falta é essencial que o tipo da falta (monofásica, bifásica, bifásica-terra, trifásica, ou trifásica-terra) seja determinada (SAHA; IZYKOWSKI; ROSOLOWSKI, 2009a). Outro ponto chave para a localização das faltas é a devida representação da impedância da falta, que pode ser considerada como sendo apenas uma resistência. Normalmente para as faltas entre fases (bifásicas) a resistência não excede os $0,5\Omega$ (SAHA; IZYKOWSKI; ROSOLOWSKI, 2009a, p.68). Já para as faltas com o envolvimento do terra, a resistência de falta pode ser maior que 10Ω ¹. Em alguns casos a

¹ Mirzaei et al. (2009) apontam que para o SD são considerados valores de resistência da falta compreendidos entre 0 e 50Ω .

Figura 3 – Quadro contendo a representação linear de alguns dos tipos de faltas monofásicas, bifásicas e trifásicas usualmente empregadas.

Fonte: Adaptado de Saha, Izykowski e Rosolowski (2009a).

resistência da falta assume valores muito maiores, como, por exemplo, em casos de faltas envolvendo queda de árvores ou de cabos partidos sobre um solo altamente resistivo.

Nos algoritmos de localização os modelos lineares para representar as situações de faltas são bastante empregados. Nestes modelos a resistência da falta é denotada por R_f e a resistência que está diretamente conectada com o solo (para os casos de falta com envolvimento do terra) é representada por R_g . A Figura 3 ilustra a representação linear de algumas das faltas monofásicas, bifásicas e trifásicas usualmente empregadas.

A Figura 4 representa um modelo generalizado para uma situação de falta. Conforme encontrado em Saha et al. (1999) este modelo possibilita representar qualquer tipo de falta.

Figura 4 – Modelo generalizado para uma situação de falta.

Fonte: Adaptado de Saha et al. (1999).

2.3 A qualidade do serviço prestado pelas concessionárias

A QEE aborda todos os aspectos relacionados ao fornecimento no SEP relativos aos níveis de tensão na geração, transmissão e distribuição, até os usuários finais. A expressão qualidade da energia usualmente está vinculada a alguns termos, como confiabilidade do sistema supridor, qualidade do produto, e QS. Assim, pode-se compreender a QEE como sendo, principalmente, referenciada a qualidade da tensão (e quando necessário a corrente), sendo definida sobre a medida, análise, e melhoria da tensão de barra (ponto de conexão da rede com o usuário, ou ponto de acoplamento comum) para manter uma forma de onda senoidal com amplitude e frequência fixas e dentro do desejado para uma adequada operação do SEP. Contudo, dentre as origens dos distúrbios de QEE estão os fenômenos imprevisíveis que correspondem a 60% dos problemas de QEE, sendo que as principais causas incluem os curto-circuitos, as descargas atmosféricas, os problemas de ressonância e de ferroressonância, dentre outros (FUCHS; MASOUM, 2011).

2.3.1 A QEE e a qualidade do serviço

A Agência Nacional de Energia Elétrica (ANEEL) pelo Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST), define e apresenta os conceitos pertinentes ao que é esperado pela QS prestada pelas concessionárias aos consumidores (ANEEL, módulo 08, resolução normativa n 728/2016.2017). Dentre o que é

esperado e apresentado no PRODIST referente à QS, tem-se:

“Fornecer mecanismo para acompanhamento e controle do desempenho das distribuidoras e das transmissoras detentoras de demais instalações de transmissão; fornecer subsídios para os planos de reforma, melhoramento e expansão da infraestrutura das distribuidoras; oferecer aos consumidores parâmetros para a avaliação do serviço prestado pela distribuidora (ANEEL, módulo 08, resolução normativa n 728/2016.2017)”.

Na avaliação da QS são consideradas a qualidade do atendimento prestado pelas concessionárias aos consumidores de uma forma em geral, bem como às ocorrências emergenciais. Quanto aos indicadores, existe o Tempo Médio de Preparação (TMP), o Tempo Médio de Deslocamento (TMD), o Tempo Médio de Execução (TME), o Percentual do Número de Emergências com Interrupções de Energia (PNIE), a Duração de Interrupção Individual por Unidade Consumidora ou por Ponto de Conexão (DIC), a Duração Equivalente de Interrupção por Unidade Consumidora (DEC), a Frequência de Interrupção por Unidade Consumidora ou por Ponto de Conexão (FIC), a Frequência Equivalente de Interrupção por Unidade Consumidora (FEC), entre outros. Estes índices, que são utilizados para avaliar a QS, evidenciam como a interrupção e a duração das interrupções podem vir a prejudicar a avaliação das concessionárias por parte dos órgãos regulamentadores.

Pelo tópico seguinte, busca-se destacar a importância de uma precisa localização das situações de faltas para uma melhoria da QS prestado pelas concessionárias.

2.3.2 A localização dos curtos-circuitos e a qualidade do serviço

Em Saha, Izykowski e Rosolowski (2009a) são apontados alguns dos principais aspectos pertinentes à localização de faltas no sistema de potência. Como ressaltado pelos autores, a localização da falta é um processo destinado à determinação da posição precisa de ocorrência de uma falta no sistema de potência. Contudo, vale enfatizar que o localizador de faltas é um suplemento ao sistema de proteção que aplica algoritmos de localização de falta para inferir na distância da falta com relação a algum ponto de medição do sistema.

Sendo assim, como função adicional, os localizadores de falta podem ser implementados em: relés de proteção microprocessados; gravadores digitais de falta; equipamentos específicos para a localização de falta; e/ou em programas de análise de pós-falta.

Relembrando um pouco do cenário mundial, verifica-se o rápido crescimento do SEP nas últimas décadas, o que implica em um aumento considerável no número de linhas de transmissão e de distribuição em operação. Diante deste fato, cada vez mais, termos como interoperabilidade, continuidade na operação e fornecimento da energia, bem como confiabilidade do sistema elétrico vem ganhando grande importância. E nesse

contexto, a necessidade por sistemas de proteção e de controle, juntamente com suas funções complementares, continuam sendo, cada vez mais relevantes.

Vale comentar que os sistemas de transmissão e de distribuição, principalmente os aéreos, estão constantemente sujeitos às situações de falta que podem ser causadas por fenômenos naturais, como, por exemplo, por descargas atmosféricas, ou por outros eventos, tais quais como pelo contato indevido de animais, falhas de isolamento, dentre outros.

Mediante a manifestação de alguma condição de falta, a restauração do sistema pode ser feita agilmente a partir da localização de forma rápida e com precisão razoável. Vale frisar, que a depender da sua concepção, os localizadores de falta permitem fazer estimativas tanto para faltas que já estejam em regime permanente, quanto para faltas de caráter temporário (transitório). Lembra-se que no princípio das pesquisas relativas à localização de faltas o foco era a localização de faltas em sistemas de transmissão, e que, com o aumento, e maior disputa das áreas de concessão por parte das distribuidoras, bem como pela maior cobrança por parte dos usuários finais da energia, muitas linhas de pesquisas começaram a ser direcionadas aos estudos da localização de faltas para as linhas de subtransmissão e de distribuição, na presença, ou não, da geração distribuída (SAHA; IZYKOWSKI; ROSOLOWSKI, 2009a).

No contexto apresentado, é fato que, atualmente, as cargas instaladas pelos consumidores finais estão cada vez mais sensíveis aos distúrbios na QEE que lhe é prestada. Assim, o desenvolvimento e aprimoramento de métodos eficientes para uma localização de faltas em sistemas de distribuição são essenciais e indispensáveis para minimizar as situações de defeitos passíveis de ocorrência sobre os sistemas elétricos.

2.4 Considerações finais

Neste capítulo foi apresentada uma visão geral das REIs. Foram apresentados o contexto, os benefícios e os desafios que existem na implantação deste novo modelo sobre o SEP atual. Também foi apresentada a importância da localização de faltas para que haja garantia de uma boa QEE prestada pelas concessionárias aos usuários do sistema elétrico. No capítulo 3 será percorrido do estado da arte sobre a localização de faltas em sistemas de distribuição, tomando como base, trabalhos correlatos à temática principal e encontrados para o momento.

O estado da arte

Neste capítulo são apresentados alguns métodos para a localização de faltas em sistemas de distribuição. A apresentação dos métodos está dividida em dois grupos: métodos baseados na estimação dos fasores de tensão e de corrente com base na componente de frequência fundamental, e métodos baseados em técnicas de inteligência computacional e/ou aprendizagem de máquina.

Um ponto a se observar é que os métodos baseados em componentes de alta frequência possuem uma implementação mais complexa e mais onerosa computacionalmente que os métodos baseados nos fasores na frequência fundamental, uma vez que exigem o uso de *GPS* (em inglês *Global Positioning System*), detectores de transitórios e *softwares* de diagnóstico. Além disso, devido à complexidade dos sistemas de distribuição, a instalação destes detectores de transitórios se torna bastante complexa (MIRZAEI et al., 2009). Por estas razões, na revisão bibliográfica realizada nesta dissertação não serão contempladas as técnicas baseadas em componentes de alta frequência.

Após os métodos de localização de faltas serem apresentados, será realizada uma comparação entre estes métodos, destacando-se alguns pontos relacionados ao que se pretende realizar e responder por esta pesquisa.

3.1 Métodos baseados na estimação de fasores na frequência fundamental

- Trindade, Freitas e Vieira (2014) apresentam um método que faz uso de medições de tensão advindas de medidores instalados em diversos barramentos do sistema para estimar o local em que a falta ocorreu. Partindo de uma prévia detecção e classificação da falta, o método proposto se utiliza da sensibilidade frente aos afundamentos de tensão que venham a ser captados por medidores inteligentes para localizar a falta. Considerando a devida detecção da falta, o valor *RMS* da tensão anterior e após a ocorrência da falta é calculado por meio de uma taxa amostral de 64 amostras/ciclo do sinal de tensão. A partir destes valores calculados, e com base nas medições dos medidores inteligentes presentes no sistema, o desvio de tensão (ΔV) é calculado. De

modo a identificar a atual barra sob falta é calculado um índice δ_k . Este índice realiza a soma das diferenças das N correntes de falta estimadas levando-se em consideração que a barra k está sob falta. Caso haja múltiplas estimações para a posição da falta, Trindade, Freitas e Vieira (2014) também propõem o uso de um mapeamento das interrupções para eliminar as estimativas de localização de falta que não sejam coerentes, como, por exemplo, com as ligações de consumidores que venham a ocorrer devido à falta de energia elétrica. Segundo os autores, uma forma de automatizar este mapeamento das interrupções seria com a supervisão da atuação de alguns elementos do sistema de proteção, como, por exemplo, a abertura de religadores. Este mapeamento das interrupções pode ser vinculado com o algoritmo de localização de faltas de duas formas: usando-o em primeira instância para reduzir o espaço de busca do algoritmo de localização de faltas, ou usando-o somente em caso de múltiplas estimações de posição de faltas. Nos testes realizados foram considerados valores de resistência de falta de $0, 5\Omega$ e 10Ω . Foram realizados testes variando as impedâncias das cargas sempre na mesma proporção, considerando a presença de erros nos valores de tensão advindos dos medidores inteligentes e variando a posição dos medidores inteligentes. Pelos testes realizados, verificou-se o impacto do uso dos fasores completos de tensão (considerando magnitude e fase) no desempenho do algoritmo proposto, e de cargas com comportamento dinâmico. Constatou-se que o método proposto apresentou um bom desempenho para ambas as impedâncias de falta consideradas; que a variação proporcional do carregamento do sistema não impactou severamente o método; que os erros nas medições afetaram um pouco os resultados; que não foi possível através de diversas alocações (não otimizadas) dos medidores inteligentes determinar uma expressão analítica que correlacionasse a posição destes mesmos medidores com o desempenho do algoritmo na localização das faltas; com o uso do fasor de tensão no algoritmo de localização de faltas verificou-se uma melhoria do desempenho do algoritmo, tanto para situações de falta contendo valores de resistência de falta maiores, quanto na presença de erros nas medições dos medidores inteligentes; e que o método apresentou um bom desempenho diante das cargas dinâmicas.

- Naidu, George e Ashok (2015) apresentam um método para a localização de faltas baseado em medições de tensão e de corrente advindas da subestação. É utilizada a transformada discreta de Fourier para a extração dos fasores de tensão e de corrente das componentes de frequência fundamental. O método proposto busca o local hipotético da falta em cada uma das seções do sistema e utiliza o valor da impedância da falta para a tomada de decisão do real ponto de ocorrência da falta. A parte imaginária da impedância de falta ($Im\{Z\}$) é positiva para uma posição anterior ao local da falta (d), e será negativa caso d esteja após a posição da falta. Caso $Im\{Z\}$ seja nula, implicará que o valor de d representa o local exato

de ocorrência da falta no sistema. Enquanto d não implicar em um valor muito baixo para $Im\{Z\}$, o seu valor deverá ser atualizado para mais ou para menos. Em suma, existem dois critérios que determinam o local da falta: (1) $0 < d < 1$; e $Z < limiar$. Para a validação do algoritmo proposto, os autores aplicaram alguns testes considerando $|Z| \in \{0,01; 1; 10; 50; 100\} \Omega$; ângulo de incidência da falta de 0, 30 e 60°; e a influência do ângulo de carga. Segundo os autores, nenhum destes pontos levantados influenciaram consideravelmente no desempenho do algoritmo proposto.

- Iurinic et al. (2015) propõem uma formulação analítica para a localização de faltas considerando faltas de alta impedância em sistemas de distribuição. Pela metodologia, deve-se empregar o método dos mínimos quadrados para a estimação dos parâmetros do modelo da falta de alta impedância, juntamente com o uso e aplicação do algoritmo de localização de faltas. A modelagem proposta fornecerá tanto os parâmetros do modelo de falta de alta impedância, quanto a estimativa da posição da falta. A resolução deste modelo foi pelo método dos mínimos quadrados como ponto de partida. Conforme apresentado pelos autores, caso a distância da falta estimada seja maior do que o tamanho da seção do sistema em análise, todo o procedimento exposto até então deverá ser repetido para a próxima seção do sistema.
- Souto, Manassero e Santo (2016) apresentam um método para a localização de faltas em sistemas de distribuição de média tensão considerando a presença de geração distribuída. No método, as informações foram extraídas de dispositivos eletrônicos inteligentes, do inglês *Intelligent Electronic Device* (IED), localizados na subestação e nos barramentos dos pontos de geração distribuída. Vale apontar que neste trabalho os IEDs foram considerados sincronizados no tempo. Em resumo, o algoritmo calcula a representação de duas portas da rede na seção sob investigação, calcula os fasores das correntes de falta, e compara tanto os fasores das correntes medidas, como os calculados para determinar o erro. Vale enfatizar que as medições utilizadas neste algoritmo são procedentes de um único terminal. Nos testes realizados, considerou-se: a resistência de falta igual a 0, 1, 5, 20 e 50 Ω ; incertezas devido ao comportamento não determinístico da carga; e incertezas nas medições dos fasores de tensão e de corrente. Conforme relatado pelos autores, para os testes envolvendo erros na estimação das cargas, houve uma boa precisão na estimação da posição da falta. Já para o caso envolvendo erros na medição dos fasores de tensão e de corrente, estes implicaram em uma imprecisão considerável na estimação da posição da falta.
- Vianna, Araujo e Penido (2016) apresentam um método de identificação de áreas de ocorrência de faltas de alta impedância em um sistema de distribuição desbalanceado. Neste método, as medições são realizadas por meio dos pontos de medição, e somente

são consideradas as componentes simétricas. O método é baseado no cálculo da componente quase-diferencial de sequência zero.

3.2 Métodos baseados em técnicas de inteligência computacional e aprendizagem de máquina

- Lovisolo et al. (2012) fazem uma classificação do tipo de falta utilizando máquinas de vetor de suporte, do inglês *Support Vector Machine* (SVM), e a localização de faltas através de RNAs. A Figura 5 apresenta a metodologia adotada para a classificação e a localização das faltas, utilizando-se de uma decomposição dos sinais armazenados após a detecção da falta em modelos de senoides amortecidas. O sinal é decomposto considerando o armazenamento dos dados a partir de um ciclo de pré-falta, considerando a frequência fundamental do sistema.

Figura 5 – Estratégia para a classificação e a localização de faltas através da decomposição do sinal armazenado em modelos de senoides amortecidas.

Fonte: Adaptado de Lovisolo et al. (2012).

As formas de onda de tensão e de corrente são modeladas como a soma de senoides amortecidas que possuem frequência múltipla inteira da frequência fundamental ($f_q = k_q F$). Desta forma, segue o modelo matemático de como ocorre esta decomposição do sinal original ($f(t)$):

$$f(t) \simeq \sum_{q=0}^{Q-1} \gamma_q \cos(2\pi k_q F t + \phi_q) e^{-\rho_q(t-t_{sq})} [u(t - t_{sq}) - u(t - t_{eq})] \quad (3.1)$$

Cada componente do sinal é descrita pelos elementos $(\gamma_q, k_q, \rho_q, t_{sq}, t_{eq})$. Neste modelo, o sinal é decomposto em Q senoides amortecidas com frequência $k_q F$. F é a frequência da componente fundamental, k_q é o índice da componente harmônica, ϕ_q é o ângulo de fase associada a cada componente harmônica, o fator de amortecimento é dado por ρ_q , γ_q está relacionada com a energia de cada componente, e tanto t_{sq} , como t_{se} , são os tempos associados a cada componente amortecida do sinal $y(t)$.

Para a classificação do tipo da falta, Lovisolo et al. (2012) utilizaram uma SVM para cada uma das fases. Os parâmetros de entrada de cada uma destas SVM foram as amplitudes da primeira e segunda componentes extraídas das formas de onda de tensão e corrente através do modelo da Equação (3.1). Deste modo, as SVM serão utilizadas para indicar se a fase está, ou não, diretamente envolvida na situação de falta.

Para a localização da falta foram considerados, nesta metodologia, os três primeiros níveis a partir da decomposição do sinal em senoides amortecidas para as tensões e correntes trifásicas. Sendo que para cada uma destas decomposições foram extraídos 6 parâmetros $(\gamma_q, k_q, \rho_q, t_{sq}, t_{eq})$, o que implica em 108 parâmetros ao todo. Desta forma, foram utilizadas RNAs para descobrir quais os parâmetros mais significativos para o propósito da localização da falta. Após esta etapa, o número de parâmetros que descrevem o fenômeno foi reduzido de 108 para 30. Uma *Perceptron* Multicamadas foi treinada considerando 30 entradas (os parâmetros que foram selecionados como sendo os mais significativos) e 3 saídas (possíveis lugares em que a falta possa ter ocorrido).

Para o treinamento das RNAs foram simuladas situações para todos os tipos de falta, com exceção da *abc-terra*, e para resistências de falta de 0,001 e 10 Ω . Foram considerados 8 valores para a duração da falta, duração esta que se encontra entre 8.33 ms e 50 ms. Ao todo foram realizadas 480 simulações, e para o projeto das RNAs, 70% destas situações de faltas foram aplicadas na fase de treinamento, e 30% na fase de teste/validação. O algoritmo de treinamento das RNAs foi o *back-propagation* otimizado com o termo de *momentum*. Os melhores resultados obtidos foram para 32 neurônios na única camada escondida.

- Dehghani e Nezami (2013) utilizaram de amostras dos sinais de corrente advindos da subestação de um sistema de distribuição para inicialmente inferir no tipo da falta. Assim foram treinadas RNAs para cada tipo de falta. Em seguida, as RNAs foram treinadas para estimar a distância das faltas em relação a subestação.

Na etapa de identificação do tipo da falta, as RNAs foram treinadas com os fasores de corrente calculados a partir de dados da subestação. Para as RNAs que estimam a distância da falta, foram usados como parâmetros de entrada, destas RNAs, os valores trifásicos de tensão, corrente e potência ativa de pré e pós falta. Para o cálculo dos fasores foi considerado 1 ciclo anterior à falta e 3 ciclos após a detecção da falta.

Nas simulações que foram realizadas para a elaboração do banco de dados necessário para o treinamento e validação das RNAs, considerou-se um sistema de distribuição contendo cargas desbalanceadas e linhas não-homogêneas. Ao todo foram criados 2.366 padrões de entrada para cada tipo de falta, conforme os seguintes critérios: a

cada quilômetro de linha foram aplicadas 25 situações de faltas em posições aleatórias; em cada caso de falta as cargas desbalanceadas foram produzidas aleatoriamente; e a resistência de falta foi escolhida randomicamente no intervalo $[0, 50] \Omega$. A componente de sequência zero também foi utilizada devido ser útil para caracterizar as falta monofásicas. Com base neste banco de dados, 75% dos casos foram aplicados no treinamento, e 25% dos casos destinados à validação das RNAs.

Para validar melhor o desempenho das RNAs foram realizados testes variando a topologia do sistema, considerando erros nas medições das magnitudes dos fasores de tensão de $\pm 5\%$ e nas medições das magnitudes dos fasores de corrente de $\pm 3\%$. Foi constatado que o erro médio quadrático para as situações em que houve variação da topologia do sistema foi maior do que para as situações contendo erros nas medições dos fasores de tensão e de corrente.

- Zayandehroodi et al. (2013) apresentam o uso de RNAs de função de base radial com o método do máximo declive, do inglês *Radial Basis Function Neural Network with Optimum Steepest Descent* (RBFNN-OSD), para localizar faltas em um SD contendo geração distribuída. O algoritmo de treinamento *optimum steepest descent* imprimiu uma melhoria no processo de treinamento da *Radial Basis Function Neural Network* (RBFNN). Neste trabalho, em uma etapa *offline*, as RBFNN-OSD são treinadas com o banco de dados obtido a partir de simulações de curto-circuito realizadas no sistema teste utilizado. Em seguida, as RBFNN-OSD são usadas em modo *online* para determinar o tipo da falta e o local da falta. Após identificar o tipo da falta, a informação do tipo da falta e das correntes da subestação e dos pontos contendo geração distribuída são enviadas para as RBFNN-OSD de modo a determinar o local exato de ocorrência da falta. O banco de dados para o treinamento das RBFNN-OSD foi gerado através de simulações de curtos-circuitos considerando que as faltas foram aplicadas a cada 100 m para cada linha, e considerando diversos tipos de falta. Do banco de dados gerado, 80 % foi empregado para o treinamento das RBFNN-OSD, e 20 % para a validação. Foram realizados testes para diversos tipos de faltas, considerando faltas em diversas posições no sistema de modo a avaliar o impacto da geração distribuída. O método proposto foi comparado com um mais convencional e apresentou um bom resultado.
- Lout e Aggarwal (2013) utilizaram RNAs para a classificação do tipo da falta, identificação de qual seção do sistema ocorreu a falta, e estimação da distância da falta. Para a compilação dos parâmetros de entrada, foi utilizada a Transformada Wavelet Discreta (TWD). Para a elaboração do banco de dados para o treinamento e validação das RNAs foram aplicados curtos-circuitos no alimentador principal de 3 em 3 km, e nos alimentadores secundários de 1 em 1 km. Foram considerados ângulos de incidência de 0 e 90°, e impedâncias de falta de $\{0, 25, 50\} \Omega$. A frequência

amostral utilizada foi de 100 kHz. Quanto à TWD, a *wavelet* mãe utilizada foi a *db4* e foram realizadas decomposições do sinal até o 4 nível. Para o emprego da TWD foram utilizados 1 ciclo do sinal de corrente de pré-falta, e 2 ciclos de pós-falta.

Para a RNA responsável pela classificação das faltas foram utilizados como parâmetros de entrada 5 detalhes da TWD para os sinais de corrente das fases *A*, *B* e *C*. A topologia da RNA contém 22 neurônios na camada escondida e 4 neurônios na camada de saída. Assim, as saídas da RNA são: *A*, *B*, *C* e *G*; permitindo desta forma, inferir no tipo da falta e também se houve ou não envolvimento do *terra*.

Para inferir se a falta ocorreu no alimentador principal, ou em algum dos alimentadores secundários, foi implementada uma RNA para cada tipo de falta. Os parâmetros de entrada são 10 detalhes da TWD referentes ao sinal de corrente de cada fase. O número de saídas da RNA diz respeito a dois elementos que indicam em qual região ocorreu as faltas.

Para a estimação da distância da falta foram implementadas RNAs para cada uma das regiões em que a falta poderia ter ocorrido. Os parâmetro de entrada das RNAs que estimam a distância da falta são os mesmos da RNA que inferiu sobre a região de ocorrência da falta.

Após os testes, Lout e Aggarwal (2013) constataram que os algoritmos são imunes às variações na impedância da falta e no ângulo de incidência da falta.

- Ray, Mishra e Panda (2015) propõem um método híbrido para a localização de faltas em um sistema de distribuição. No método proposto, um único ciclo dos sinais de tensão e de corrente de pós-falta são medidos e processados através da *Wavelet Packet Transform* (WPT). Ao usar a WPT o sinal é decomposto até o 4 nível e então é aplicada uma técnica de otimização conhecida por Otimização por Enxame de Partículas, do inglês Particle Swarm Optimization (PSO), para determinar os melhores parâmetros que servirão na estimação do local da falta. Tendo os parâmetros com maior peso na estimação do local da falta, é então aplicada a RBFNN para a localização da falta.

Ao aplicar a WPT o sinal é decomposto em componentes de aproximação (*a*) e de detalhe (*d*). A Figura 6 apresenta a decomposição de um sinal por meio da WPT até o 4 nível de decomposição.

Na elaboração do banco de dados foram realizadas simulações de curto-circuito considerando uma frequência amostral de $30kHz$. Após, os sinais coletados foram decompostos até o 4 nível e as energias dos 16 coeficientes foram calculadas. Nas simulações foram considerados 10 tipos de falta (monofásica, bifásica-terra, bifásica e trifásica). Foram também consideradas na elaboração das simulações, as resistências de falta de $\{1, 3, 5, 10, 15, 20, 35\}\Omega$ e o ângulo de incidência da falta de

$\{11, 15, 20, 25, 90\}$ graus. Já na elaboração do banco de dados para a validação da RBFNN, foram adotadas as resistências de falta de $\{2, 9, 20, 24, 30\}\Omega$ e o ângulo de incidência de $\{5, 35, 45, 60, 75\}$ graus.

Para a validação do método, os resultados da RBFNN foram comparados com uma *Support Vector Machine* (SVM). No projeto da RBFNN foram adotados 50 neurônios na camada escondida e 1 neurônio na camada de saída. Ray, Mishra e Panda (2015) também apresentam os parâmetros do PSO e da SVM.

Ao utilizar o PSO para a determinação dos parâmetros da WPT que melhor contribuem para a estimação da distância da falta foram selecionados os parâmetros: $aaad_4$, $aaaa_4$, $adad_4$, $daaa_4$, $ddaa_4$ e $dada_4$ (Figura 6). Os resultados obtidos com a RBFNN foram comparados com a SVM e se observou que, embora ambos tenham obtido bons resultados, a SVM foi mais precisa que a RBFNN.

Figura 6 – Árvore de decomposição através da WPT.

Fonte: Adaptado de Ray, Mishra e Panda (2015).

- Tong et al. (2015) utilizam-se de RNAs com o algoritmo de treinamento *back-propagation*. Os parâmetros de entrada adotados foram os valores normalizados de tensão e de corrente. A RNA treinada contém 17 neurônios na camada escondida.

dida. Nos testes realizados foram considerados valores de resistência de falta de $\{0.1, 1, 10, 50, 100\}\Omega$. Quanto aos resultados obtidos, constatou-se que o erro percentual da estimação na distância da falta não estava diretamente relacionado com o aumento da distância da falta.

- Festa (2015) desenvolveu uma metodologia para a estimação do local da falta baseada em RNAs e em dados advindos de medidores de QEE. Um ponto chave desta metodologia está no uso de uma prévia alocação otimizada dos medidores de QEE para então aplicar a metodologia para a localização de faltas.

Inicialmente, foi feita uma alocação dos medidores de QEE utilizando o método apresentado por Kempner (2012). Após isto, o sistema de distribuição utilizado para os testes foi dividido em áreas, sendo a posição e a dimensão destas áreas relacionadas com a posição dos medidores. Para as simulações de curto-circuitos, considerou-se: faltas monofásicas, bifásicas-terra, bifásicas, trifásicas-terra e trifásicas; resistência de falta de $\{0, 10, 20, 50, 100\}\Omega$, sendo que para as faltas bifásicas foi adotada a resistência de falta entre as fases como sendo nula; quanto à posição da falta foram aplicadas faltas nas barras principais e a 25%, 50% e 75% do comprimento de todas as linhas. Com base nos dados obtidos das simulações de faltas aplicadas, foram treinadas RNAs para os seguintes propósitos: inferir em qual região ocorreu a falta; classificar o tipo da falta; e estimar a distância da falta com relação ao medidor da área em que a falta ocorreu.

Para a RNA responsável para a indicação da região em que ocorreu a falta foram adotados 12 neurônios na camada escondida e 4 neurônios na camada de saída (um neurônio para cada uma das quatro regiões definidas sobre o SD teste). Como parâmetros de entrada foram adotados os valores eficazes das tensões trifásicas de cada um dos medidores. Já para a RNA responsável por estimar a distância da falta, foram utilizados como parâmetros de entrada, os valores eficazes das tensões das fases diretamente envolvidas na falta do medidor (da área em que a falta ocorreu como das áreas adjacentes), e o valor eficaz da corrente das fases envolvidas diretamente com as faltas observadas na subestação.

3.3 Principais aspectos metodológicos observados nesta revisão bibliográfica

Conforme a revisão bibliográfica que foi apresentada neste capítulo, as pesquisas relacionadas com a localização de faltas em sistemas de distribuição, além da localização das faltas buscam, juntamente a isto, resolver o problema das múltiplas estimações. Além disso, estas pesquisas podem ser categorizadas em dois grupos distintos: as que estimam a distância da falta com relação a algum referencial (geralmente a subestação), e as que identificam uma região na qual a falta tenha ocorrido (ou seja uma estimação menos precisa da falta). Quanto aos métodos que utilizaram sistemas inteligentes, há uma prévia

extração de informações, através de um pré-processamento dos sinais de pós-falta das correntes e tensões trifásicas.

Com base nestes trabalhos, observa-se que para a formação do banco de dados para o treinamento dos algoritmos de aprendizagem utilizados, considerou-se uma variação do tipo, da impedância e do ângulo de incidência da falta, bem como da posição da falta no sistema utilizado para os testes. Quanto à formação do banco de dados para a validação do algoritmo de aprendizagem, de modo geral, foram observados dois tipos de abordagem: uma na qual o banco de dados de validação tem o mesmo perfil do banco de dados da fase de treinamento; e casos em que o banco de dados de validação possui natureza distinta do conjunto de dados empregado para o treinamento.

Outra questão a ser destacada é a quantidade de pontos de medição e o uso, ou não, de medidores otimamente posicionados no sistema. Tendo pesquisas utilizando apenas um ponto de medição, pesquisas utilizando vários pontos de medição, e pesquisas utilizando diversos pontos de medição que estejam otimamente alocados no sistema.

Quanto aos testes de sensibilidade, em geral, foram realizados testes variando o carregamento do sistema, testes considerando a presença de erros de medição e testes variando a posição dos medidores presentes no sistema.

Desta forma, algumas das principais características observadas nos trabalhos elencados nesta revisão bibliográfica podem ser sumarizadas através da Tabela 1. Nesta tabela, caso a área quadriculada associada às colunas de *C1* a *C13* esteja colorida em preto, a mesma indicará que a pesquisa denotada pela referência apresentada, contempla, ou procurou responder pelas questões levantadas abaixo:

C1 O SEP considerado é aéreo?

C2 Existem vários pontos de medição no sistema em análise?

C3 Foi considerada uma alocação otimizada dos medidores?

C4 Foi considerada uma divisão prévia do sistema em regiões?

C5 A distância física da falta é estimada?

C6 O problema das múltiplas estimações é tratado?

C7 Técnicas de inteligência computacional e/ou de aprendizagem de máquina são empregadas?

C8 Nos testes foram consideradas variações na posição da falta?

C9 Nos testes foram consideradas mudanças no carregamento do sistema?

C10 Nos testes foram consideradas variações na resistência da falta?

C11 Nos testes foram considerados erros na medição?

C12 Nos testes foram considerados vários tipos de falta?

C13 É feita uma análise de sensibilidade de quais parâmetros mais afetaram a localização da falta?

[illegible]

Estas características observados foram levadas em consideração na elaboração da metodologia desta pesquisa.

3.4 Considerações finais

Neste capítulo foi apresentada uma revisão bibliográfica que contempla algumas das pesquisas e métodos aplicados em específico para a localização de faltas no SEP. Desta revisão bibliográfica foram denotados alguns pontos importantes sobre como o problema da localização de faltas é comumente tratado, e como as soluções apontadas são avaliadas. Dentre os vários pontos observados na literatura correlata, esta pesquisa buscará então, além da localização da falta que é o foco principal, melhor avaliar a presença de vários pontos de medição, a alocação otimizada de medidores de QEE, a divisão prévia do sistema em regiões, a sensibilidade do algoritmo diante de uma variação no carregamento do sistema, a sensibilidade do algoritmo na presença de erros de medição, e a identificação de quais parâmetros mais afetam o algoritmo de localização de faltas.

No capítulo 4 será apresentada a metodologia desenvolvida e implementada nesta pesquisa.

Metodologia

Neste capítulo será apresentada a metodologia seguida nesta pesquisa. Serão descritos alguns módulos que deverão fazer parte do algoritmo de localização de faltas, bem como, os principais fundamentos que nortearão os mesmos. Os módulos estão divididos em duas etapas principais: a *offline*, e a de operação.

A Figura 7 apresenta os módulos a serem seguidos nesta pesquisa. Conforme pode ser observado pela figura, existem duas etapas principais, uma que é a *offline* e outra a operação do algoritmo de localização de faltas. A etapa *offline* corresponde à modelagem do sistema teste que será utilizado para esta pesquisa, à alocação otimizada dos medidores de QEE (alocação realizada por Gomes (2016)), ao processamento dos sinais obtidos após as simulações, à definição das áreas (segmentação do sistema mais geral) e regiões (segmentação do sistema mais específica), e ao treinamento das RNAs e das árvores de decisão. Já a etapa de operação corresponde à aquisição dos dados dos medidores alocados, à detecção e à classificação da falta, bem como a aplicação do algoritmo de localização de faltas.

No que segue, os principais módulos serão apresentados e comentados no contexto da pesquisa delineada.

4.1 Etapa offline

4.1.1 Modelagem do sistema teste

Para o desenvolvimento desta pesquisa, o sistema de distribuição do IEEE de 34 barras (KERSTING, 2001) foi inicialmente escolhido como o ambiente de realização dos testes. Este sistema de distribuição aéreo, representado após modificações (acrécimo de chaves para a aplicação de curtos-circuitos) pelas Figuras 8 e 9, apresenta como características básicas: possuir tensão nominal de 24,9 kV, ser muito longo e levemente carregado; apresentar dois reguladores de tensão instalados no sistema; ter um segundo transformador abaixador presente em uma pequena seção do sistema; ter cargas desbalanceadas (contendo

Figura 7 – Fluxogramas das etapas e módulos considerados na pesquisa.

cargas tanto centralizadas quanto distribuídas); e possuir bancos de capacitores *shunt* instalados. Para a simulação deste sistema foi utilizado o software ATPDRAW (PRIKLER; HOIDALEN, 2002). Para automatizar as simulações foi empregada uma integração com o *software* MATLAB (MATLAB, 2012).

Figura 8 – Sistema do IEEE de 34 barras com a representação da posição das chaves, permitindo a aplicação dos curtos-circuitos de interesse, e dos medidores de QEE (PARTE 1).

Figura 9 – Sistema do IEEE de 34 barras com a representação da posição das chaves, permitindo a aplicação dos curtos-circuitos de interesse, e dos medidores de QEE (PARTE 2).

4.1.2 Alocação otimizada dos medidores de qualidade da energia elétrica

Cabe adiantar e esclarecer que a alocação otimizada dos medidores de QEE no sistema de distribuição do IEEE de 34 barras não será o foco principal desta pesquisa. A alocação propriamente dita será adotada conforme executada e anteriormente reportada por Gomes (2016).

Um ponto importante da metodologia de localização de faltas adotado neste trabalho está no fato de possibilitar uma ação conjunta entre a posição dos medidores com a localização de faltas. Com base na alocação dos monitores de QEE, o sistema de distribuição em questão será dividido em áreas. Estas áreas serão consideradas no algoritmo de localização de faltas.

As Figuras 8 e 9 apresentam o sistema do IEEE de 34 barras modelado via o *software* ATP. Vale observar que as posições das chaves utilizadas para as simulações dos curtos-circuitos para a realização dos testes da metodologia como um todo, já estão incorporadas nas duas figuras. Outro ponto é que já estão também representadas as posições dos três medidores de QEE otimamente alocados.

Em Gomes (2016) são apresentadas as possibilidades para a alocação dos medidores de QEE apresentadas pela Tabela 2. Nesta tabela, para cada limiar¹ de tensão há um número e posições otimizadas para a alocação dos medidores de QEE. As numerações das barras estão de acordo com a numeração descrita em Feeders (2013).

Tabela 2 – Possibilidades para a alocação dos medidores de QEE conforme os limiares de tensão desejados.

Limiar	Número de medidores	Barras p/ instalação dos medidores
0,9 p.u.	3	802, 808 e 816
0,9 a 0,7 p.u.	4	802, 808, 812 e 816
0,9 a 0,6 p.u.	6	802, 808, 812, 814, 820 e 830
0,9 a 0,5 p.u.	8	802, 808, 812, 814, 820, 830, 832 e 836

O limiar de 0,9 p.u. foi adotado para esta pesquisa pois, além de já responder adequadamente aos propósitos da sua alocação no contexto da QEE, este limiar apresenta o uso de um número reduzido de medidores de QEE instalados no sistema e, como consequência, implica em um menor custo na compra destes mesmos medidores de QEE.

4.1.2.1 Simulações dos curtos-circuitos

Nesta pesquisa foi considerada a modelagem do sistema de distribuição do IEEE de 34 barras, onde a situação padrão considera três medidores de QEE otimamente alocados.

¹ Vale observar que este limiar de tensão está relacionado à sensibilidade do medidor alocado em observar fenômenos relacionados às variações de tensão de curta duração no sistema em análise.

Todo o processamento dos dados foi realizado em um PC core i7 @3.6GHz e 16GB RAM. Nas simulações considerou-se uma interface entre o ATP e o MATLAB para melhor tratar e processar as informações necessárias.

Em cada simulação dos curtos-circuitos aplicados, considerou-se uma taxa amostral de 256 amostras/ciclo ². Com foco na estimação da distância da falta a partir dos três medidores alocados, foi considerado o segundo ciclo ³ de pós-falta dos sinais de tensão e corrente trifásicos. O segundo ciclo de pós-falta foi empregado devido apresentar uma menor presença dos transitórios que aparecem nestes sinais a partir do instante de ocorrência da falta.

Para esta pesquisa foi considerado que todo o processamento das informações advindas dos três medidores de QEE alocados será concentrado no sistema de localização de faltas, conforme ilustrado na Figura 10.

Quanto à posição das faltas, para o conjunto de treinamento, estas foram aplicadas nos ramos do SD com comprimento inferior a 200 m a 1%, 25%, 50%, 75% e 99% do respectivo comprimento. Para os trechos maiores do que 200 m, as situações de curtos-circuitos foram aplicadas a cada 50 m. Além da variação da posição das faltas, também foram considerados os valores das impedâncias de falta de 0,0001 Ω , 10 Ω , 20 Ω , 30 Ω , 40 Ω e 50 Ω , e ângulos de incidência da falta de 0°, 30°, 60° e 90°.

Para gerar o banco de dados de teste, foram aplicadas faltas a cada 125 m, considerando impedâncias de falta de 5 Ω , 15 Ω , 25 Ω , 35 Ω e 45 Ω , e ângulos de incidência da falta de 15°, 45° e 75°.

Conforme o exposto, a Tabela 3 apresenta o número de simulações de curtos-circuitos aplicados no SD do IEEE de 34 barras considerando o banco de dados de treinamento e de teste, e também tipo de falta passível de ocorrência. Na Tabela 3, os "Demais tipos" correspondem às faltas *C-terra*, *AB*, *BC*, *CA*, *AB-terra*, *BC-terra*, *CA-terra*, *ABC* e *ABC-terra*, sendo que para cada tipo de falta, foram geradas 30.576 situações de curtos-circuitos para o treinamento, e 8.325 para a fase de teste. Assim, ao todo, foram simuladas para esta situação padrão (3 medidores otimamente alocados e 256 amostras/ciclo), 446.427 situações de falta.

Vale observar que para as faltas bifásicas, bifásicas-terra, trifásicas e trifásicas-terra foi considerada uma impedância equivalente entre fases de 0,5 Ω .

² Esta taxa amostral foi escolhida com base na revisão bibliográfica realizada.

³ Nesta pesquisa, considerou-se que mesmo com a atuação do sistema de proteção haverá ao menos dois ciclos de pós-falta disponíveis, uma vez que há um atraso na atuação do sistema de proteção (em especial na abertura dos disjuntores). Foi escolhido o segundo ciclo de pós-falta de modo a evitar os transitórios presentes no primeiro ciclo de pós-falta dos sinais em análise.

Tabela 3 – Número de simulações realizadas para cada tipo de falta.

Tipo de falta	Treinamento	Teste
A-terra	39.984	10.755
B-terra	35.904	9.675
Demais tipos	30.576	8.325

4.1.3 Processamento dos sinais de pós-falta

Para o contexto desta pesquisa, foram calculados diversos parâmetros a partir do segundo ciclo de amostras dos sinais de tensão e de corrente trifásicos extraídos após a detecção da falta. Os parâmetros calculados foram:

- i) valor *RMS* (*Root Mean Square*);
- ii) as amplitudes e fases das componentes da frequência fundamental; e
- iii) a energia dos coeficientes do 4º nível de decomposição da WPT (RAY; MISHRA; PANDA, 2015), utilizando como *wavelet* mãe a Daubecheis com suporte 4 (db4).

Conforme apresentado, para a definição da nomenclatura destes parâmetros foram adotados os seguintes critérios:

- i) RMS_i para $i \in \{IA, IB, IC, VA, VB, VC\}$ indica o valor *RMS* dos sinais de tensão e corrente trifásicos;
- ii) Amp_i e Fas_i para $i \in \{IA, IB, IC, VA, VB, VC\}$ indicam respectivamente os valores das amplitudes e fases dos sinais de tensão e corrente trifásicos; e
- iii) $\{En01_i, En02_i, En03_i, \dots, En16_i\}$, no qual $i \in \{IA, IB, IC, VA, VB, VC\}$, indicam a energia dos coeficientes do 4 nível de decomposição da *Wavelet Packet Transform*, com *wavelet* mãe a Daubechies com suporte 4, dos sinais de tensão e corrente trifásicos.

Desta forma, por exemplo:

- i) RMS_{IA} é o valor *RMS* dos sinais de correntes registrados pelos medidores instalados no sistema referente à fase *A*;
- ii) Amp_{VC} e Fas_{VC} são, respectivamente, as amplitudes e as fases dos sinais de tensão de falta registrados pelos medidores instalados no sistema referentes à fase *C*; e

Figura 10 – Fluxo de informações entre os medidores instalados e o sistema de localização das faltas.

- iii) $En01_{IB}$ e $En02_{IB}$ são a energia dos dois primeiros coeficientes da WPT dos sinais de corrente de falta registrados pelos medidores instalados no sistema referentes à fase B .

Foram extraídos ao todo 114 parâmetros. Com base nessas informações serão desenvolvidos os algoritmos para a estimação da distância da falta com relação à subestação, e para identificar em qual área e região do sistema a falta ocorreu. Um ponto importante é que após a realização deste processamento dos sinais dos curtos-circuitos simulados, foram removidas situações de faltas com algum parâmetro considerado como sendo um *outlier*.

Para ter uma visão geral sobre as faltas simuladas no sistema, a Figura 11 apresenta os valores RMS das correntes trifásicas para alguns tipos de faltas simuladas.

Figura 11 – Valores RMS dos sinais das corrente trifásicas para as faltas A -terra, AB , AB -terra e ABC .

4.1.4 Divisão do sistema de distribuição radial em áreas

Inicialmente o SD do IEEE de 34 barras foi dividido em áreas conforme o número (N) de medidores presentes no sistema. Desta forma, se forem considerados N medidores haverá, portanto N áreas. Outro aspecto a ser observado é que esta é uma segmentação mais geral do sistema, e será apresentada ainda nesta seção uma segmentação mais específica para sistemas de distribuição radiais.

A Figura 12 apresenta o algoritmo utilizado para a definição das áreas. Neste fluxograma ficam evidenciadas três partes do algoritmo: a parte em azul é para a definição das áreas dos medidores que estiverem no ramal principal; a parte em vermelho é para definir as áreas dos medidores que não estiverem no ramal principal (o maior trecho trifásico do sistema foi considerado como sendo o ramal principal); e a parte em verde é uma parte de transição do algoritmo, ou seja, é o momento em que o algoritmo passará a definir, caso necessário, a área referente ao próximo medidor, ou se irá tomar as últimas medidas até a conclusão de todo o processo.

Inicialmente o algoritmo começa a identificar a área do primeiro medidor ($M=1$), verificando se este medidor está ou não no ramal principal. Em seguida é constatado se existe, ou não, um outro medidor ($M+1$). Caso haja mais um medidor, é observado se

este medidor está ou não no ramal principal. Com base nestas análises, é por fim definida a área para cada um dos N medidores instalados no sistema. Após todos os medidores terem suas áreas devidamente definidas, é realizada uma agregação à área do primeiro medidor ($M=1$) de todos os trechos do sistema que estejam entre a subestação e este primeiro medidor.

De modo a exemplificar o uso do algoritmo apresentado serão utilizados para este intento quatro exemplos. O primeiro é um sistema genérico e os demais são baseados no SD do IEEE de 34 barras. Um destaque é que todos estes exemplos baseados no SD do IEEE de 34 barras serão referenciados mais adiante no final deste capítulo de metodologia e no capítulo de resultados e discussões.

Figura 12 – Algoritmo para a divisão do sistema de distribuição radial em áreas.

- Exemplo 01: A Figura 13 apresenta um sistema ilustrativo contendo 5 medidores. Vale observar que existem medidores tanto no ramal principal quanto em ramais laterais.

Figura 13 – Sistema ilustrativo contendo 5 medidores.

Após avaliar a situação de cada um destes medidores, pode-se extrair os seguintes pontos: $M1$ está no ramal principal, existe um medidor na sequência ($M2$), e $M2$ não pertence ao ramal principal; $M2$ não pertence ao ramal principal, existe um medidor na sequência ($M3$), e $M3$ pertence ao ramal principal; $M4$ não pertence ao ramal principal, existe um medidor na sequência ($M5$), e $M5$ não pertence ao ramal principal; e $M5$ não pertence ao ramal principal e não existe um medidor na sequência. Considerando estes pontos e aplicando o algoritmo para a definição das áreas obtêm-se as áreas da Figura 14. A etapa final do algoritmo é acrescentar à área do primeiro medidor os trechos do sistema que estejam entre este medidor e a subestação. A Figura 15 apresenta a definição de áreas para o sistema ilustrativo de 5 barras da Figura 13, após o algoritmo de definição de áreas ter sido completamente percorrido.

Figura 14 – Definição das áreas para o sistema ilustrativo de 5 barras após analisar todos os medidores.

Figura 15 – Definição final das áreas para o sistema ilustrativo de 5 barras após analisar todos os medidores.

- Exemplo 02: A Figura 16 ilustra o SD do IEEE de 34 barras com 3 medidores, conforme a alocação de Gomes (2016). Após avaliar a situação de cada um destes medidores pode-se extrair os seguintes pontos: $M1$ pertence ao ramal principal, existe um medidor na sequência ($M2$), e $M2$ pertence ao ramal principal; $M2$ pertence ao ramal principal, existe um medidor na sequência ($M3$), e $M3$ pertence ao ramal principal; e $M3$ pertence ao ramal principal e não existe um medidor na sequência. Após a conclusão do algoritmo de definição de áreas para a situação retratada na Figura 10, foram obtidas as áreas conforme ilustrado na Figura 16.
- Exemplo 03: A Figura 17 ilustra o SD do IEEE de 34 barras com 4 medidores, conforme a alocação de Gomes (2016).
- Exemplo 04: A Figura 18 ilustra o SD do IEEE de 34 barras com 4 medidores sem adotar uma alocação otimizada.

4.1.5 Divisão do sistema de distribuição radial em regiões

Para cada um dos medidores alocados foi delimitada uma área específica. Além desta definição de área, também foram definidas regiões de modo a refinar mais a localização destas faltas. Desta forma, após a detecção da ocorrência da falta e da sua classificação em relação ao tipo do curto-circuito, será também estimada a região onde a falta ocorreu.

Assim, as distintas regiões de um SD qualquer foram caracterizadas seguindo duas opções:

- i) todos os trechos do ramal principal que estiverem anteriores a um ramal lateral definirão uma região; e
- ii) cada ramal lateral foi considerado como sendo uma região.

Figura 16 – Definição de áreas para o SD do IEEE de 34 barras considerando 3 medidores otimamente alocados.

Seguindo estas diretrizes, a Figura 20 apresenta o SD do IEEE de 34 barras dividido em dezessete regiões. A Tabela 4 apresenta as regiões relacionadas à cada tipo de falta passível de ocorrência sobre o SD do IEEE de 34 barras. Os "Demais tipos" referem-se às nove outras possibilidades de tipos de curtos-circuitos que possam ocorrer sobre o SD em análise. É importante observar que existe uma questão topológica envolvida na definição das regiões de ocorrência de cada um dos tipos de falta avaliados, uma vez que existem ramais monofásicos presentes neste sistema.

Após fazer esta definição inicial das regiões, foi aplicado um algoritmo para agrupar as regiões próximas de modo a não ter regiões muito pequenas. Para esta etapa será utilizado como base a estimativa da distância da falta realizada por meio de RNAs *Perceptron* Multicamadas. Vale observar que a metodologia adotada para a estimativa da

Figura 17 – Definição de áreas para o SD do IEEE de 34 barras considerando 4 medidores otimamente alocados.

distância da falta com relação à subestação será detalhada ainda neste capítulo.

Considerando, com base na Tabela 4, que quando aplicadas sobre o SD do IEEE de 34 barras as situações de falta fase *A*-terra, fase *B*-terra e fase *C*-terra, todas as regiões passíveis de ocorrência da faltas serão contempladas, essas três situações de faltas monofásicas serão usadas para a avaliação final das regiões que serão utilizadas para a localização das faltas.

Para esta etapa de refinamento das definições das regiões, conforme observado anteriormente, serão utilizadas as estimações das distâncias das faltas das situações de validação por parte das RNAs referentes às faltas monofásicas (fase *A*-terra, fase *B*-terra e fase *C*-terra) e o menor erro médio verificado por estas RNAs. O objetivo de utilizar o menor erro médio está em evitar um agrupamento excessivo de regiões. Já a justificativa

Figura 18 – Definição de áreas para o SD do IEEE de 34 barras considerando 4 medidores sem adotar uma alocação otimizada.

de utilizar o erro como critério é devido ao fato de que se a diferença entre a média das estimações das distâncias das faltas das regiões adjacentes for menor que o erro, então a falta pode ocorrer fora da região estimada.

A Figura 21 apresenta o algoritmo utilizado para o refinamento da definição de regiões adotado nesta pesquisa. A seguir este algoritmo será detalhado, sendo utilizada as faltas fase *A*-terra para a ilustração das principais etapas do mesmo.

O algoritmo inicia recebendo dados de treinamento e de validação para encontrar a melhor topologia para as RNAs que serão utilizadas para a estimativa da distância das faltas fase *A*-terra, fase *B*-terra e fase *C*-terra. Nesta etapa serão armazenados o menor erro médio dentre os 3 ($N=3$) tipos de faltas considerados e a média das estimações das distâncias das faltas de cada falta em cada uma das M regiões. Conforme a Tabela 4, para

Tipo da falta	Regiões
A-terra	01, 03, 04, 07, 08, 09, 11, 12, 13, 14 ,15, 16, e 17
B-terra	01, 02, 03, 05, 06, 07, 09, 10, 11, 12, 13, 14 ,15, 16, e 17
Demais tipos	01, 03, 07, 09, 11, 12, 13, 14 ,15, 16, e 17

as faltas fase *A*-terra $M = 13$, para as faltas fase *B*-terra $M = 15$ e para os demais tipos de falta $M = 11$. A Tabela 5 apresenta a média das estimações das distâncias para as faltas fase *A*-terra em cada uma das regiões relacionadas a este tipo de falta. Vale observar, conforme a Figura 20, que estas regiões estão ordenadas de acordo com a proximidade física entre elas. Outro elemento a ser observado nesta ilustração é que o menor erro médio obtido foi o das faltas fase *B*-terra, e foi de $1,6 \text{ km}$.

Após obter as médias das estimações das faltas de cada tipo, para cada uma das regiões relacionadas, e o menor erro médio dentre os três tipos de faltas consideradas, será calculada uma matriz de distância para cada tipo de falta. Esta matriz de distância tem o objetivo de apresentar as diferenças entre as médias das estimações das distâncias das faltas de cada região com relação às demais regiões consideradas. A Tabela 6 apresenta a matriz de distância referente às faltas fase *A*-terra. Esta matriz de distância representa a diferença (km) entre a estimativa média das distâncias das faltas de cada uma das regiões com relação às demais regiões. Por exemplo, a primeira linha da Tabela 6 apresenta a diferença entre a média das estimações das distâncias das faltas fase *A*-terra de todas as regiões consideradas (para este tipo de falta) e a média das estimações das distâncias de falta que ocorreram na região 01.

Tabela 5 – Distância média das regiões consideradas para a falta fase *A*-terra.

Região	Distância média (km)
1	5,1
3	21,8
4	41,4
11	33,4
12	38,8
13	46,9
7	54,6
14	53,5
8	53,1
15	55,1
9	57,1
16	56,5
17	56,9

Após a montagem das matrizes de distância referentes a cada um dos tipos de faltas considerados, são determinadas quais regiões devem ou não ser agrupadas. Para esta etapa é considerado como valor de referência (limiar) o menor erro médio obtido para os K tipos de faltas utilizados.

A Figura 22 apresenta as etapas adotadas para a realização, ou não, dos agrupamentos entre regiões adjacentes. Nesta etapa são percorridas as linhas da matriz de distância e observados sempre os elementos adjacentes ao elemento da diagonal principal. Assim, para as faltas fase *A*-terra, seja $MD(i, j)$ os elementos da matriz de distâncias, primeiramente, o algoritmo vai testar se haverá a necessidade em agrupar a única região adjacente da primeira região ($R. 01$). Assim, caso $MD(1, 2)$ seja menor ou igual ao limiar (P), que é o menor erro médio avaliado entre os tipos das faltas, serão agrupadas as regiões 01 e 03. Para $i > 1$ e $i < M$, serão avaliados se $MD(i, i-1)$ ou $MD(i, i+1)$ são menores ou iguais ao limiar (P) de modo a realizar, ou não, os devidos agrupamentos. Por fim, caso $i = M$ será avaliado se $MD(i, i-1)$ é menor ou igual ao limiar proposto, fazendo, ou não, o agrupamento entre estas regiões adjacentes. Após realizar esta etapa e remover as redundâncias encontradas, são obtidas as regiões adjacentes que devem ser agrupadas. Desta forma, para o cenário das faltas fase *A*-terra, devem ser agrupadas as regiões [7,14,8] e [9,16,17]. Após repetir o procedimento para as faltas fase *B*-terra e fase *C*-terra foram obtidos os resultados presentes na Tabela 7.

Figura 21 – Fluxograma para a divisão do sistema de distribuição radial em regiões.

Tabela 6 – Distâncias (km) entre a média das estimações das distâncias das estimações da falta fase A-terra de cada uma das regiões consideradas com relação às demais regiões.

	R.01	R.03	R.04	R.11	R.12	R.13	R.07	R.14	R.08	R.15	R.09	R.16	R.17
R.01	0,0	16,7	36,3	28,3	33,7	41,8	49,5	48,4	48,0	50,0	52,0	51,4	51,8
R.03	16,7	0,0	19,6	11,6	17,0	25,1	32,8	31,7	31,3	33,3	35,3	34,7	35,1
R.04	36,3	19,6	0,0	8,0	2,6	5,5	13,2	12,1	11,7	13,7	15,8	15,1	15,5
R.11	28,3	11,6	8,0	0,0	5,3	13,5	21,1	20,1	19,7	21,7	23,7	23,1	23,5
R.12	33,7	17,0	2,6	5,3	0,0	8,1	15,8	14,7	14,3	16,3	18,4	17,7	18,1
R.13	41,8	25,1	5,5	13,5	8,1	0,0	7,7	6,6	6,2	8,2	10,2	9,6	10,0
R.07	49,5	32,8	13,2	21,1	15,8	7,7	0,0	1,1	1,5	0,5	2,6	1,9	2,3
R.14	48,4	31,7	12,1	20,1	14,7	6,6	1,1	0,0	0,4	1,6	3,7	3,0	3,4
R.08	48,0	31,3	11,7	19,7	14,3	6,2	1,5	0,4	0,0	2,0	4,1	3,4	3,8
R.15	50,0	33,3	13,7	21,7	16,3	8,2	0,5	1,6	2,0	0,0	2,1	1,4	1,8
R.09	52,0	35,3	15,8	23,7	18,4	10,2	2,6	3,7	4,1	2,1	0,0	0,7	0,3
R.16	51,4	34,7	15,1	23,1	17,7	9,6	1,9	3,0	3,4	1,4	0,7	0,0	0,4
R.17	51,8	35,1	15,5	23,5	18,1	10,0	2,3	3,4	3,8	1,8	0,3	0,4	0,0

Tabela 7 – Agrupamentos de regiões adjacentes obtidos para as faltas fase *A*-terra, fase *B*-terra e fase *C*-terra.

Situação	Agrupamentos
A-terra	[7 14 8] e [9 16 17]
B-terra	[7 14] e [9 10 16 17]
C-terra	[14 15] e [9 16 17]

A partir dos resultados obtidos para o agrupamento de regiões adjacentes, com base na estimação da distância realizada pelas RNAs para as faltas fase *A*-terra, fase *B*-terra e fase *C*-terra, foi obtida a definição final de regiões para o SD do IEEE de 34 barras conforme a Figura 23, na qual é observada a união das regiões [7 14 8 15] e [9 10 16 17]. Ao final do processo estes dois grupos obtidos foram agrupados devido à diferença entre as estimações de distâncias das faltas nas regiões 9 e 15 não ser muito maior que o limiar adotado. Desta forma ao término do processo foram obtidas 10 regiões bem definidas.

Com base na Figura 23, a Tabela 8 apresenta em quais regiões os diversos tipos de falta podem ocorrer.

Tabela 8 – Regiões finais relacionadas a cada tipo de falta.

Tipo da falta	Regiões
A-terra	01, 03, 04, 05, 07, 09, 10
B-terra	01, 02, 03, 04, 05, 06, 07, 08, 09, 10
Demais tipos	01, 03, 05, 07, 09, 10

4.1.6 Treinamento das RNAs para a estimação da distância da falta

Nesta pesquisa foram utilizadas RNAs *Perceptron* Multicamadas, por meio da *toolbox* disponível no *software* MATLAB conhecida como *nntool* utilizando a otimização do treinamento por levenberg-marquardt (SILVA; SPATTI; FLAUZINO, 2010), para a estimação da distância da falta com relação à subestação. A seguir são apresentados alguns aspectos que devem ser levados em consideração ao utilizar RNAs (MITCHELL et al., 1997):

- As instâncias são representadas por muitos pares valor-atributo: as instâncias são definidas por um vetor de características pré-definido. Estas características de entrada podem estar fortemente correlacionadas ou serem independentes entre si. Os valores de entrada podem assumir qualquer valor real.
- Uma RNA pode ser utilizada para estimar um ou vários parâmetros.
- O banco de dados de treinamento pode conter erros.

Figura 23 – SD do IEEE de 34 barras dividido em 10 regiões finais.

- Longos tempos de treinamentos são aceitáveis.
- O uso das RNAs para estimar um valor de saída com base em um vetor de parâmetros de entrada é rápido.
- Não é relevante compreender a forma como a RNA correlacionou as variáveis de entrada com a saída, ou saídas, desejada.

Desta forma, sendo o problema da estimação da distância da falta um problema de aproximação de função (SILVA; SPATTI; FLAUZINO, 2010) que pode ser resolvido por meio de RNAs *Perceptron* Multicamadas, foram utilizados estes recursos para este intento.

Figura 24 – Exemplo de uma RNA *Perceptron* Multicamadas.

Fonte: Adaptado de Mitchell et al. (1997).

A Figura 24 apresenta uma ilustração para uma RNA *Perceptron* Multicamadas. O algoritmo de aprendizagem *Backpropagation* é utilizado para encontrar uma relação entre as variáveis de entrada com o parâmetro, ou parâmetros, de saída. Esta relação é obtida encontrando valores para os pesos $\vec{\omega}$. Este algoritmo se utiliza do gradiente descendente para minimizar o erro quadrático entre os valores de saída desejados da rede neural artificial e os valores estimados ($E(\vec{\omega}) = 1/2 \sum_{d \in D} \sum_{k \in saída} (a_{kd} - e_{kd})^2$).

Para o treinamento de uma RNA, contendo apenas uma camada escondida, são considerados os seguintes elementos: *camada neural de saída* é o conjunto de neurônios artificiais de saída, a_{kd} e e_{kd} são os valores desejados e estimados associados com a k – ésima unidade de saída do padrão de entrada d . Cada padrão de entrada do conjunto de treinamento é um par na forma $\langle \vec{x}, \vec{a} \rangle$, onde $\vec{x}$ é um vetor de valores de entrada da rede neural artificial, e $\vec{a}$ é o vetor de valores de saída desejado da rede neural artificial. η é a taxa de aprendizagem, $n_{entrada}$ é o número de parâmetros do vetor de valores de entrada, e n_{saida} é o número de neurônios da camada neural de saída (MITCHELL et al., 1997).

Com base nos elementos básicos de uma RNA, a seguir, são apresentadas, de forma bem resumida, as principais etapas do algoritmo de treinamento *backpropagation* (MITCHELL et al., 1997):

- Criar a RNA com base em $n_{entrada}$, $n_{escondida}$ e n_{saida} .

- Atribuir valores iniciais para os pesos. Estes valores devem ser pequenos e aleatórios.
- Para cada um dos pares $\langle \vec{x}, \vec{a} \rangle$, fazer:
 - Propagar as entradas através da RNA.
 - Propagar os erros através da RNA e, na sequência, atualizar os pesos ($\vec{\omega}$).

A Figura 25 apresenta o algoritmo utilizado para o projeto destas RNAs para cada um dos tipos de falta considerados. Para cada tipo de falta, são inicialmente utilizados os bancos de dados de treinamento e de validação para encontrar as RNAs com melhor topologia para a estimação da distância da falta. Ao final do processo, estarão disponíveis ao todo 11 RNAs (uma para cada tipo de falta K).

A seguir serão apresentadas as principais etapas do algoritmo supracitado.

4.1.6.1 Parâmetros de entrada e de saída das RNAs

As RNAs *Perceptron* Multicamadas utilizadas possuem um treinamento supervisionado, portanto, necessitam ter acesso aos dados de entrada (informações dos sinais) e aos dados de saída (distância das faltas) desejados.

Para cada um dos sinais trifásicos de tensão e de corrente, foram extraídos ao todo 114 parâmetros. Destes 114 parâmetros somente 6 foram utilizados para, por meio das RNAs, serem relacionados com a distância em que a falta ocorreu no sistema com relação à subestação. Os parâmetros de entrada utilizados foram as amplitudes dos sinais de tensão e corrente trifásicos advindos da subestação. Já o parâmetro de saída é a própria distância da falta com relação à subestação, uma vez que é este o que se deseja estimar. A Figura 26 ilustra as RNAs utilizadas para a estimação da distância da falta. Nesta ilustração pode-se observar que os parâmetros de entrada da RNA são as amplitudes dos sinais trifásicos de tensão e corrente e que a saída da RNA é a distância da falta com relação à subestação. Vale enfatizar que o que vai variar na RNA de um tipo de falta para outro, dentre outras coisas, é o número de neurônios das camadas escondidas.

Figura 25 – Algoritmo para o projeto das RNAs para a estimação da distância da falta com relação à subestação.

4.1.6.2 Normalização dos parâmetros de entrada e de saída das RNAs

Os dados de entrada e de saída das RNAs precisam ser devidamente normalizados. A Figura 27 representa o banco de dados utilizado para o treinamento e validação das RNAs. A seguir, tem-se como foram normalizados os dados de entrada e de saída.

Figura 26 – Representação genérica das RNAs utilizadas para a estimação da distância da falta.

Figura 27 – Ilustração do banco de dados utilizado para o treinamento e validação das RNAs.

	V_a	V_b	V_c	I_a	I_b	I_c	Dist.
Situação de falta 1	<i>V_a Sit. 01</i>	<i>V_b Sit. 01</i>	<i>V_c Sit. 01</i>	<i>I_a Sit. 01</i>	<i>I_b Sit. 01</i>	<i>I_c Sit. 01</i>	<i>Dist. Sit. 01</i>
Situação de falta 2	<i>V_a Sit. 02</i>	<i>V_b Sit. 02</i>	<i>V_c Sit. 02</i>	<i>I_a Sit. 02</i>	<i>I_b Sit. 02</i>	<i>I_c Sit. 02</i>	<i>Dist. Sit. 02</i>
Situação de falta 3	<i>V_a Sit. 03</i>	<i>V_b Sit. 03</i>	<i>V_c Sit. 03</i>	<i>I_a Sit. 03</i>	<i>I_b Sit. 03</i>	<i>I_c Sit. 03</i>	<i>Dist. Sit. 03</i>
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Situação de falta N	<i>V_a Sit. N</i>	<i>V_b Sit. N</i>	<i>V_c Sit. N</i>	<i>I_a Sit. N</i>	<i>I_b Sit. N</i>	<i>I_c Sit. N</i>	<i>Dist. Sit. N</i>

- Normalização dos dados de entrada: Na normalização dos parâmetros de entrada, os vetores dos parâmetros de cada situação de falta foram normalizados dividindo cada um dos seus elementos pelo valor máximo observado de cada parâmetro. Assim, baseado na Figura 27, tem-se que:

$$MaxParam_j = \max\left(\bigcup_{i=1}^N Param_j \text{ Sit. } i\right); \quad (4.1)$$

e

$$\{Param_j \text{ Sit. } i = \frac{Param_j \text{ Sit. } i}{MaxParam_j}\}_{j=1}^N. \quad (4.2)$$

Na qual N é o número de parâmetros considerados ($N=6$), $Param \in \{V_a, V_b, V_c, I_a, I_b, I_c\}$, e $j \in \{1, \dots, M\}$, para M sendo o número máximo de situações de falta presentes no banco de dados.

- Normalização dos dados de saída: Para a normalização dos dados de saída (distância das faltas com relação à subestação) do banco de dados de treinamento e de validação, para cada uma das situações de falta, o valor da distância desta falta foi dividido pela maior distância da falta observada no conjunto de dados de treinamento. Desta forma, seja $j \in \{1, \dots, M\}$ para M sendo o número máximo de situações de falta presentes no banco de dados, e $max \text{ dist}$ o maior valor de distância observado no banco de dados de treinamento e validação, tem-se:

$$Dist. j = \frac{Dist. j}{max \text{ dist}}. \quad (4.3)$$

4.1.6.3 Busca da melhor topologia

Uma etapa importante no projeto das RNAs que serão utilizadas na estimação da distância da falta é determinar qual a melhor topologia para as redes. Vale observar que encontrar a melhor topologia para as RNAs é determinar, conforme a Figura 26, o número de neurônios na primeira camada escondida ($N1$) e o número de neurônios para a segunda camada escondida ($N2$). A Figura 28 apresenta o algoritmo utilizado para obter a melhor topologia para cada uma das RNAs utilizadas nesta pesquisa. Vale observar que este algoritmo é empregado para cada uma das RNAs, e que há uma RNA para cada tipo de falta.

Inicialmente o algoritmo considera i e j iguais a 5, e $K=1$. Assim, é realizado um treinamento para a topologia com $N1=5$ e $N2=5$. Após treinar esta RNA é feita uma validação desta RNA com um banco de dados próprio para isto. Ao todo esta topologia inicial é treinada e validada por 3 vezes ($N=3$), e para cada uma destas vezes, o 95º percentil ($P95$) do erro obtido na etapa de validação é armazenado. Ao término do treinamento e da validação desta topologia inicial por 3 vezes, o menor valor de $P95$ encontrado é armazenado e vinculado à topologia de $N1=5$ e $N2=5$. Na sequência $N2$ é acrescido de 2 e todo o processo descrito é repetido até que $N2$ seja maior que 25. Após isto $N1$ é acrescido de 2 e $N2$ volta a ser 5. O processo continua até que $N1$ e $N2$ sejam iguais a 25. Vale comentar que ao todo $N1$ e $N2 \in \{5, 7, 9, \dots, 23, 25\}$ e que ao término do processo, para cada tipo de falta, são realizados 363 treinamentos e validações das topologias. Após aplicar o algoritmo para a obtenção da melhor topologia para cada tipo de falta, foram obtidos os dados da Tabela 9.

Tabela 9 – Melhor topologia obtida para cada um dos tipos de falta.

Tipo de falta	N1	N2
A-terra	7	13
B-terra	5	25
C-terra	5	17
AB	19	25
BC	15	11
AC	5	13
AB-terra	5	23
BC-terra	5	21
AC-terra	5	23
ABC	21	25
ABC-terra	19	11

4.1.7 Treinamento das árvores de decisão para identificar a área e a região do sistema nas quais a falta ocorreu

Para o uso das árvores de decisão foi utilizada a *toolbox Statistics and Machine Learning* disponível no software MATLAB. Foram utilizadas árvores de decisão treinadas com o algoritmo *CART* (do inglês *Classification and Regression Trees*) (JAMES et al., 2013) direcionado à função de classificação.

As árvores de decisão classificam as instâncias a partir da raiz da árvore para algum nó folha, que fornece a classificação desta instância. Para exemplificar, a Figura 29 apresenta uma árvore de decisão para avaliar se determinada instância pertence, ou não, às classes 01 ou 02. Desta forma, se *Atributo 01* = *Opção 01* e *Atributo 02* = *Opção 03*,

Figura 28 – Algoritmo utilizado para obter a topologia adequada para a estimação da distância das faltas.

então a instância pertence à classe 02. Conforme apresentado, a árvore de decisão vai percorrendo desde o nó raiz até os nós terminais (nós folhas) (MITCHELL et al., 1997).

A seguir são apresentados alguns aspectos que devem ser levados em consideração ao utilizar as árvores de decisão (MITCHELL et al., 1997):

- As instâncias são representadas por pares atributo-valor;
- A saída da função que se deseja aprender por meio da árvore de decisão deve ter saída discreta;
- A árvore de decisão naturalmente representa expressões dinjuntivas;
- O banco de dados de treinamento pode conter erros; e

Figura 29 – Exemplo de árvore de decisão.

Fonte: Adaptado de Mitchell et al. (1997).

- O banco de dados de treinamento pode conter valores em falta.

Assim como as RNAs, as árvores de decisão também possuem um treinamento supervisionado (JAMES et al., 2013). Desta forma, o banco de dados de treinamento deve conter os parâmetros de entrada (informação do sinal) e as saídas (área ou região de ocorrência da falta) desejadas para cada padrão de entrada. Ao término do treinamento, conforme a Figura 30, a árvore é formada por uma série de condições SE-ENTÃO (expressões disjuntivas) que levam à área ou região de ocorrência da falta.

O algoritmo de treinamento *CART* pode ser dividido nas seguintes etapas: conjunto de perguntas binárias, critérios de divisão, associar uma classe à folha e a poda (RAIMUNDO et al., 2008). A seguir tem-se um breve descritivo destas etapas:

- Conjunto de perguntas binárias: um conjunto de perguntas binárias são utilizadas para efetuar a divisão de cada nó.
- Critério de divisão: nesta etapa deverá ser decidido quais atributos serão divididos. Esta escolha é baseada no cálculo da entropia.
- Associar uma classe à folha: após a divisão dos atributos e a construção da árvore é atribuído a cada nó folha uma classe.
- Poda: como após a realização de todas as divisões que forem inicialmente feitas implicará em uma árvore de decisão grande e cheia de redundâncias, é adotado

Figura 30 – Ilustração de uma árvore de decisão genérica para identificar a área e/ou a região de ocorrência da falta.

um critério para uma simplificação desta árvore de decisão original. Para isto, é considerado o erro estimado pela substituição de um determinado nó, ou seja, com base no erro causado por esta substituição, é decidido se há ou não a poda de determinado nó.

Tanto para estimar a área de ocorrência da falta, quanto para determinar em qual região ocorreu a falta, serão utilizados todos os 114 parâmetros extraídos dos sinais trifásicos de tensão e corrente. Entretanto, há diferenças entre o banco de dados de treinamento das árvores de decisão que irão estimar a área, e o banco de dados das árvores de decisão que irão estimar a região na qual a falta ocorreu.

Quanto às configurações das árvores de decisão, tanto as árvores de decisão que estimam a área, quanto as que estimam a distância são idênticas. Portanto, a diferença está basicamente nos dados de entrada e saída, ou seja, no banco de dados de treinamento e de validação.

Outro ponto de destaque é que, para cada tipo de falta, só há uma única árvore de decisão para estimar a área de ocorrência da falta, enquanto para estimar a região de ocorrência da falta há uma para cada medidor. A Figura 31 apresenta os algoritmos para o treinamento das árvores de decisão supracitadas. Vale observar que N é o número de situações de falta ($N=11$), e que M é o número de medidores instalados no sistema ($M=3$).

A seguir será detalhada a constituição do banco de dados utilizado nesta etapa da pesquisa.

- Banco de dados de treinamento e de validação da árvore de decisão para identificar a área de ocorrência da falta: Conforme apresentado na Figura 31, para cada tipo de falta será projetada apenas uma árvore de decisão para identificar em qual área do sistema a falta ocorreu. Para isto, o banco de dados de treinamento é constituído pelos 114 parâmetros advindos do processamento dos sinais trifásicos de tensão e corrente de cada um dos medidores instalados no sistema. Desta forma, considerando 3 medidores alocados no sistema, haverá 342 parâmetros ao todo.
- Banco de dados de treinamento das árvores de decisão para identificar a região de ocorrência da falta: Para as árvores de decisão que identificam em qual região do sistema a falta ocorreu, será uma árvore para cada medidor. O banco de dados de treinamento e de validação é constituído pelos 114 parâmetros advindo do processamento dos sinais de tensão e corrente trifásicas, pela área de ocorrência da falta e pela estimação da distância da falta com relação à subestação. Desta forma, para cada uma destas árvores de decisão existem ao todo 116 parâmetros de entrada.

A Figura 53 do Apêndice A apresenta uma árvore de decisão obtida com os dados do medidor *M01* (considerando o cenário de três medidores otimamente alocados) para a identificação das regiões de ocorrência das faltas fase *A-terra*. Já a Figura 54 do Apêndice A apresenta uma árvore de decisão utilizada para a identificação das áreas de ocorrência das faltas fase *A-terra*. A Figura 53, com base nos parâmetros de entrada usados no treinamento, utilizou os parâmetros x_1 (*Área*), x_2 (*Distância da falta*), x_4 (RMS_{IC}) x_{48} ($En13_{IB}$), x_{70} ($En03_{VA}$), x_{82} ($En15_{VA}$), x_{89} ($En06_{VB}$), x_{94} ($En11_{VB}$), x_{112} ($En13_{VC}$) e x_{114} ($En15_{VC}$). Já a Figura 54, com base nos parâmetros de entrada usados no treinamento, utilizou os parâmetros x_{115} (RMS_{IA} referente ao *M02*) e x_{229} (RMS_{IA} referente ao *M03*).

A Figura 32 apresenta um gráfico *bubble chart* que sumariza as árvores de decisão obtidas para a identificação da região de ocorrência da falta com base nos dados do medidor *M01* referente à alocação de 3 medidores de QEE no sistema de distribuição do IEEE de 34 barras. Neste gráfico é possível observar quais parâmetros foram utilizados para cada um dos tipos de falta e a presença de cada um deles (indicado pelo tamanho dos

Figura 31 – Algoritmos para o treinamento das árvores de decisão utilizadas.

círculos). Por exemplo, para a localização das faltas *A-terra* foram utilizados parâmetros tais como a área de ocorrência da falta, a estimação da distância da falta, os valores *RMS*, e a energia dos coeficientes da WPT. Já para todos os demais tipos de falta, com exceção das faltas fase *A-terra* e *B-terra*, somente foram utilizados a área de ocorrência da falta e a estimação da distância da falta com relação à subestação. Vale observar que o motivo pelo qual as faltas do tipo fase *C-terra*, e fases *AB*, *BC*, *AC*, *AB-terra*, *BC-terra*, *AC-terra*, *ABC* e *ABC-terra* adotarem os mesmos parâmetros de entrada (a estimação da distância

da falta com relação à subestação e a identificação da área de ocorrência da falta) está na topologia do sistema.

Figura 32 – Gráfico *bubble chart* dos parâmetros utilizados por algumas árvores de decisão treinadas.

4.2 Etapa de operação

4.2.1 Aquisição dos dados dos medidores de QEE

Considerando o contexto das redes elétricas inteligentes, as informações adquiridas pelos medidores de QEE serão encaminhadas para um elemento central que fará o processamento da informação. Este processamento visa extrair as informações que sejam relevantes para a detecção, classificação e localização da falta em questão.

A Figura 10 ilustra genericamente um sistema com medidores de QEE instalados. Os sinais de tensão e de corrente são amostrados, por exemplo, em 256 amostras/ciclo, e então enviados através de uma rede de comunicação até uma subestação, ou centro de operação, onde estará instalado fisicamente o sistema de localização das faltas. O sistema de localização processará os dados advindos de todos os medidores instalados no sistema e, com base no módulo de detecção implementado e ativado, apontará o instante inicial de ocorrência da falta. Tendo sido o instante de ocorrência da falta detectado, é armazenado o segundo ciclo de pós-falta dos sinais de interesse. Após a detecção do instante da ocorrência da falta, e dos dados de pós-falta das tensões e correntes trifásicas terem sido armazenados, é então aplicado outro algoritmo que fará a classificação do tipo da falta (módulo de classificação). O algoritmo de classificação da falta irá determinar se a falta é monofásica (fase A-terra, fase B-terra ou fase C-terra), bifásica (fases AB, fases AC

ou fases *BC*), bifásica-terra (fases *AB*-terra, fases *AC*-terra ou fases *BC*-terra), trifásica ou trifásica-terra.

Cabe frisar para o momento, que tanto o módulo de detecção, como o de classificação, poderão ser desenvolvidos de forma independente ao módulo de localização, que será o foco principal desta pesquisa. Os módulos de detecção e de classificação não foram implementados nesta pesquisa.

4.2.2 Detecção da ocorrência da falta

Este módulo tem a importância de determinar o instante no tempo em que a falta ocorreu de modo a ser possível extrair informações de pré e de pós-falta. Para realizar a detecção do instante de ocorrência da falta, pode ser utilizado algum dos algoritmos existentes na literatura, dentre os quais, destacam-se:

- Gilbert e Morrison (1997) que utilizam uma abordagem baseada em um método estatístico para a detecção do instante de ocorrência de faltas; e
- Bísaro (2013) que utiliza uma abordagem estatística baseada no uso da transformada *Wavelet*.

4.2.3 Classificação do tipo da falta

Tendo os dados de pós-falta identificados e extraídos, será empregado um algoritmo que identificará o tipo da falta. Por identificar o tipo da falta diz-se apontar se a falta é monofásica, bifásica-terra, bifásica, trifásica-terra ou trifásica. Este módulo poderá ser implementado dispondo de algoritmos propostos na literatura para realizar a classificação do tipo da falta. Este módulo, assim como o de detecção, não será implementado nesta pesquisa. Contudo, será considerado assim como o fosse, visto que o módulo de localização dependerá das informações pertinentes ao mesmo. Dentre as técnicas utilizadas para a classificação do tipo da falta podem-se destacar:

- Saha, Izykowski e Rosolowski (2009b) que apresentam uma técnica utilizando as assinaturas da falta obtidas por meio da relação entre componentes simétricas de *sequência positiva Vs. sequência negativa Vs. sequência zero*; e
- Bísaro (2013) que utiliza redes neurais artificiais *ARTMAP-Fuzzy* para determinar quais as fases envolvidas na falta utilizando índices comportamentais.

4.2.4 Algoritmo para a localização da falta

A partir do devido treinamento das RNAs e das árvores de decisão, pode-se utilizá-las na localização completa da falta. A forma como estes elementos estão relacionados

para a localização da falta, como um todo, está representado na Figura 33. Ao término de todo o algoritmo de localização de faltas, será possível ter acesso à área de ocorrência da falta, à região de ocorrência da falta e à distância da falta com relação à subestação.

Conforme observado no algoritmo de localização de faltas presente na Figura 33, este algoritmo contém uma integração de diversas ferramentas apresentadas ao longo deste capítulo. Sendo assim, o algoritmo de localização de faltas pode ser dividido em quatro etapas principais, as quais são:

- **Processamento dos sinais:** Inicialmente o localizador de faltas recebe 256 amostras por ciclo dos sinais trifásicos de tensão e corrente advindos da subestação e dos medidores) para, na sequência, detectar, caso necessário, o instante de ocorrência da falta, e o tipo da falta. Após isto, é realizado um processamento do segundo ciclo de pós-falta destes sinais. Ao todo são obtidos 114 parâmetros para cada um dos sinais de tensão e corrente trifásicos coletados.
- **Estimar a distância da falta:** Dos parâmetros obtidos após o processamento dos sinais trifásicos de tensão e corrente advindos da subestação, as amplitudes destes sinais são utilizadas como entrada das RNAs para estimar a distância da falta com relação à subestação. Para tanto, com base no tipo da falta, é escolhida uma RNAs adequada, e por fim, a distância da falta é estimada.
- **Identificar a área de ocorrência da falta:** Nesta etapa, todos os 114 parâmetros extraídos de cada um dos sinais de tensão e corrente trifásicos referentes a todos os medidores alocados no sistema são utilizados como entrada de uma das árvores de decisão já previamente treinada. Desta forma, com a informação sobre o tipo da falta, é escolhida uma das árvores de decisão para identificar em qual das áreas já previamente definidas a falta ocorreu.
- **Identificar a região de ocorrência da falta:** Por fim, para identificar em qual das regiões, já previamente definidas, a falta ocorreu, são utilizados todos os parâmetros extraídos a partir dos medidores instalados no sistema, a área na qual a falta ocorreu, e a estimação da distância da falta com relação à subestação como entradas para as árvores de decisão que já foram previamente treinadas para este intento. Estas árvores de decisão são escolhidas a partir do tipo da falta. Nesta etapa vale frisar que ao todo existe, para cada tipo de falta, um número de árvores de decisão igual ao número de medidores instalados no sistema. Outro ponto, é que cada uma destas árvores de decisão tem como entrada os parâmetros obtidos após o processamento dos sinais advindos do medidor no qual ela está vinculada, a área na qual a falta ocorreu e a distância estimada da falta com relação à subestação. Com base nisso, cada uma destas árvores de decisão irá identificar em qual região a falta ocorreu. Por conta disso, é adotado um critério final de decisão com base na possível redundância

que possa haver nestes resultados. O critério de decisão considera que: se a maioria dos resultados tendem a uma mesma região, então a falta ocorreu nesta região; caso contrário, a resposta tomada como definitiva é a do medidor da área na qual a falta ocorreu.

Figura 33 – Algoritmo completo da localização de faltas.

De modo a ilustrar a aplicação do algoritmo de localização de faltas como um todo, segue um exemplo. A Figura 34 apresenta, a partir da detecção do instante de ocorrência da falta e da classificação do tipo da falta, a estimação da distância da falta (*Dist*) com relação à subestação a partir do uso das RNAs treinadas. Entretanto, conforme exposto na Figura 35, pode ocorrer o problema de múltiplas estimações, por exemplo, ao localizar faltas fase *A*-terra onde os círculos vermelhos indicam dois possíveis locais de ocorrência da falta que por ventura possam a mesma distância com relação à subestação. De modo a resolver estes possíveis problemas de múltiplas estimações, inicialmente, é identificada a área de ocorrência da falta (*Área 3*), conforme a Figura 36, para finalmente determinar a *Região 9* como a de ocorrência da falta (Figura 37).

Figura 34 – Ilustração da aplicação do algoritmo de localização de faltas na estimação da distância da falta.

4.3 Testes de sensibilidade realizados para a avaliação do algoritmo de localização de faltas proposto

A seguir são apresentados todos os testes de sensibilidade adotados nesta pesquisa. Vale frisar que todos estes testes de sensibilidade somente foram realizados para as faltas monofásicas, devido serem as faltas mais frequentes em sistemas de distribuição. Já a situação padrão (com 3 medidores otimamente alocados e 256 amostras/ciclo) considera todos os tipos de falta. Outro ponto de destaque é que em quase todos os testes de

Figura 35 – Ilustração do problema das múltiplas estimações na localização de faltas fase A-terra no SD do IEEE de 34 barras.

sensibilidade não haverá um novo treinamento das RNAs e das árvores de decisão, ou seja, serão utilizadas as mesmas estruturas que foram aplicadas para a situação padrão. O único caso no qual haverá um novo treinamento das RNAs e das árvores de decisão será para os testes que consideram uma redução na taxa amostral.

4.3.1 Variação do carregamento do sistema

Nesta etapa a impedância de todas as cargas anexadas ao sistema de distribuição do IEEE de 34 barras tiveram seus valores reduzidos para 80% e, posteriormente, aumentados para 120%. Também foram realizados testes variando aleatoriamente cada uma das cargas num intervalo de [95%,105%] e [90%,110%]. O objetivo é, considerando as mesmas RNAs e árvores de decisão já treinadas, verificar o impacto da flutuação do carregamento do sistema no desempenho do algoritmo de localização de faltas proposto, e identificar até que ponto estes algoritmos mantêm uma taxa de acerto aceitável.

4.3.2 Impacto de erros de medição na localização da falta

Nesta etapa será superposto, a cada uma das amostras dos sinais trifásicos de tensão e corrente, um ruído aleatório. Este ruído seguirá uma distribuição normal com média zero e desvio padrão de 0.5%.

Figura 36

4.3.3 Variação do número de medidores

A situação padrão considera 3 medidores otimamente posicionados no sistema. Serão realizados testes considerando, conforme a Tabela 2 e a Figura 17, 4 medidores no sistema. O objetivo é observar o impacto do aumento do número de medidores no algoritmo de localização de faltas.

4.3.4 Variação do número de medidores e considerando uma alocação não otimizada

Para observar se o algoritmo está fortemente relacionado à presença de uma alocação otimizada dos medidores, serão realizados testes, conforme a Figura 18, considerando um número de 4 medidores com alocações aleatórias no sistema.

4.3.5 Variação da taxa amostral utilizada

A situação padrão considera um número de 256 amostras/ciclo. Para verificar o impacto do número de amostras/ciclo, serão realizados também testes para 128 e 64 amostras/ciclo.

Figura 37

4.4 Considerações finais

Ao longo deste capítulo foi apresentado o algoritmo de localização de faltas e detalhados todos os seus elementos constituintes. O sistema utilizado para os testes é o sistema de distribuição do IEEE de 34 barras, considerando 256 amostras/ciclo, 3 medidores otimamente alocados, e sem variações no carregamento do sistema. Também foram detalhados os testes de sensibilidades que serão aplicados para avaliar o desempenho do algoritmo de localização de faltas diante de diversas cenários.

O próximo capítulo contém os resultados obtidos a partir da aplicação da metodologia adotada e dos testes de sensibilidade realizados.

Resultados e discussões

Para a apresentação e discussão inicial dos resultados será considerado um cenário padrão, caracterizado por uma taxa amostral de 256 amostras/ciclo, o SD do IEEE de 34 barras sem alterações no carregamento, sem erro nas medições, e também com 3 medidores de QEE otimamente alocados. Inicialmente serão apresentados os resultados para a estimação da distância da falta e, na sequência, os resultados para a identificação das áreas e regiões de ocorrência das faltas.

Além disso, serão percorridos (apenas para faltas monofásicas, devido a sua maior presença em sistemas de distribuição) os resultados referentes aos seguintes pontos que podem vir a evidenciar uma sensibilidade da metodologia proposta:

- A variação do carregamento do sistema;
- Erros nas medições;
- O aumento do número de medidores alocados (considerando, e desconsiderando, uma alocação otimizada destes mesmos medidores); e
- A redução da taxa amostral.

5.1 O desempenho do algoritmo para o cenário padrão

Nesta seção são apresentados os resultados obtidos para o cenário padrão de testes. Conforme anteriormente comentado, este cenário padrão consiste em uma taxa amostral de 256 amostras/ciclo, com 3 medidores alocados de forma otimizada no sistema, com ausência de erros de medição, e com ausência de flutuações no carregamento do sistema.

Para a apresentação dos resultados, para os cenários de estudo, serão utilizados os seguintes critérios de análise:

- Análise da estimação da distância da falta com relação à subestação:

Para avaliar o desempenho das RNAs treinadas na estimação da distância das faltas com relação à subestação, será avaliado o erro percentual da distância estimada da falta com relação à distância real da falta a partir da Equação 5.1:

$$Erro \% = 100 \cdot \frac{|Dist. real - Dist. estimada|}{Comprimento total do sistema}; \quad (5.1)$$

na qual *Dist. real* é a distância real da falta com relação à subestação, *Dist. estimada* é a distância da falta com relação à subestação estimada pela RNA, e *Comprimento total do sistema* é o comprimento do maior trecho trifásico presente no sistema. Com base nestes valores de erro percentual, referentes a cada falta, serão utilizados de gráficos *box plot* que apresentam informações estatísticas destes mesmos erros percentuais (menor erro percentual, maior erro percentual, primeiro quartil, mediana, terceiro quartil, e os *outliers*). A Figura 38 mostra um exemplo de gráfico *box plot* com suas principais informações evidenciadas. Para aprofundar a análise destes erros percentuais também foram utilizados de histogramas.

Figura 38 – Detalhamento das principais informações presentes em um gráfico *box plot*.

Com o intuito de apresentar o impacto da variação da impedância da falta, e do ângulo de incidência da falta, foram utilizados gráficos que retratem a distribuição dos erros de estimação. O objetivo é observar se a variação de alguma destas características da falta implicam em uma distribuição diferente dos erros percentuais.

- Análise da identificação da região de ocorrência da falta:

Para observar a eficiência das árvores de decisão na avaliação da região de ocorrência da falta foram utilizadas matrizes de confusão. Com elas é possível identificar o desempenho geral do algoritmo para cada tipo de falta e também evidenciar em qual

(ou quais) regiões houve uma maior dificuldade em localizar devidamente as faltas e como este erro de localização se procedeu.

De forma geral, o terceiro quartil (Q_3) do erro percentual obtido na estimação da distância da falta ficou em torno de 5%. Quanto à identificação da região de ocorrência da falta o pior caso observado foi para as faltas fases AC -terra, sendo neste caso obtida uma taxa de acerto de 96,71%. Já o tipo de falta em que houve um menor número de regiões contendo erro de identificação da falta foram as faltas fase C -terra. Na maioria dos tipos de falta foi evidenciado que a região 9 apresentou uma menor taxa de acerto.

5.1.1 Resultados para a estimação da distância da falta

As Figuras 39 a 46 apresentam os resultados obtidos para a estimação das distâncias das faltas com relação à subestação. Estes resultados contemplam as faltas monofásicas, bifásicas, bifásicas-terra, trifásicas e trifásicas-terra.

Figura 39 – Gráficos *box plot* dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra, fase C-terra, fases AB, fases BC e fases AC.

Figura 40 – Gráficos *box plot* dos erros de estimação da distância da falta para os tipos de falta fases AB-terra, fases BC-terra, fases AC-terra, fases ABC e fases ABC-terra.

(a) AB-terra.

(b) BC-terra.

(c) AC-terra.

(d) ABC.

(e) ABC-terra.

Figura 41 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra, fase C-terra, fases AB, fases BC e fases AC.

(a) A-terra.

(b) B-terra.

(c) C-terra.

(d) AB.

(e) BC.

(f) AC.

Figura 42 – Histograma dos erros de estimação da distância da falta para os tipos de falta fases AB-terra, fases BC-terra, fases AC-terra, fases ABC e fases ABC-terra.

(a) AB-terra.

(b) BC-terra.

(c) AC-terra.

(d) ABC.

(e) ABC-terra.

Figura 43 – Distribuição dos erros de estimação da distância da falta para a impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra.

(a) A-terra.

(b) B-terra.

(c) C-terra.

Figura 44 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fases AB-terra, fases BC-terra, fases AC-terra e fases ABC-terra.

(a) AB-terra.

(b) BC-terra.

(c) AC-terra.

(d) ABC-terra.

Figura 45 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra, fase C-terra, fases AB, fases BC e fases AC.

Figura 46 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 15° , 45° e 75° , e para os tipos de falta fases AB-terra, fases BC-terra, fases AC-terra, fases ABC e fases ABC-terra.

As Figuras 39 e 40 apresentam o erro percentual da estimação da distância da falta através de gráficos *box plot*. Estes gráficos possibilitam evidenciar alguns aspectos estatísticos dos dados, como por exemplo: o primeiro quartil (Q_1), a mediana (Q_2), o terceiro quartil (Q_3), o valor mínimo (min), o valor máximo (max) e o número de *outliers*. A Tabela 10 sumariza estes dados para cada um dos tipos de falta. Desta forma, por

exemplo, para as faltas fase A-terra, tem-se que o menor valor de erro percentual observado foi de 4,02E-04%, o maior valor de erro percentual observado foi de 26,89%, 25 % dos casos avaliados apresentaram erro percentual de até 0,76%, 50% dos casos observados apresentaram um erro percentual de até 2,33%, 75% dos casos apresenta erro percentual de até 4,69%, e o número total de outliers foi de 113.

Tabela 10 – Resultados gerais apresentados com base nos gráficos *box plot* referentes à estimação da distância da falta.

	Min (%)	Max (%)	Q_1 (%)	Q_2 (%)	Q_3 (%)	<i>Outliers</i>
A-terra	4,02E-04	26,89	0,76	2,33	4,69	113
B-terra	1,14E-04	19,83	0,61	1,65	4,58	129
C-terra	4,10E-04	35,65	1,02	2,59	5,09	269
AB	2,25E-05	15,06	0,45	1,84	4,93	10
BC	1,73E-05	16,58	0,57	1,99	5,18	30
AC	5,00E-05	12,15	0,59	2,06	5,17	5
AB-terra	2,03E-04	16,37	0,66	2,09	5,19	73
BC-terra	4,16E-04	12,87	0,62	2,08	5,10	5
AC-terra	3,13E-04	41,83	0,62	2,13	5,45	83
ABC	1,01E-03	19,17	0,67	2,12	5,28	30
ABC-terra	3,06E-03	15,19	0,95	2,54	4,67	170

As Figuras 41 e 42 apresentam os histogramas do erro percentual. Observa-se que em todos os tipos de falta, mais de 90% das situações testadas apresentaram um erro percentual de até 10%.

As Figuras 43, 44, 45 e 46 buscam determinar o impacto da variação da impedância da falta e do ângulo de incidência da falta no erro percentual na estimação da distância da falta. Nestas figuras fica constatado que, mesmo variando a impedância da falta e o ângulo de incidência da falta, o comportamento da distribuição do erro percentual das situações de falta do banco de dados de validação foi similar. Foi observado um comportamento menos idêntico para as faltas com o envolvimento da terra. Esses resultados levam a concluir que a variação da impedância da falta e do ângulo de incidência não são fatores determinantes no aumento do erro percentual na estimação da distância da falta realizada pelas RNAs.

5.1.2 Resultados para a identificação da área de ocorrência da falta

Conforme apresentado no Capítulo 4, para a identificação da área de ocorrência da falta foi utilizado, para cada tipo de falta, uma única árvore de decisão. Esta árvore de decisão possui como entradas, após a aplicação do seu algoritmo de treinamento (algoritmo de treinamento de árvores de decisão do tipo *CART*), os parâmetros que foram evidenciados como os mais importantes e necessários para esta tarefa. Após aplicar estas árvores de decisão já treinadas para inferir em qual área do sistema as faltas ocorreram foram obtidos

os resultados conforme a Tabela 11. Estes resultados evidenciam a facilidade, para as árvores de decisão treinadas, na indentificação destas áreas.

Tabela 11 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário padrão de testes.

Tipo da falta	Taxa de acerto (%)
A-terra	100
B-terra	100
C-terra	100
AB	100
BC	100
AC	100
AB-terra	100
BC-terra	100
AC-terra	100
ABC	100
ABC-terra	100

5.1.3 Resultados para a identificação da região de ocorrência da falta

A Tabela 12 apresenta a taxa de acerto obtida na identificação da região de ocorrência das faltas. As Figuras 47 e 48 apresentam, para cada um destes tipos de falta, a sua respectiva matriz de confusão. Desta forma a Figura 47a é a matriz de confusão referente às faltas associadas à fase *A-terra*. Nesta matriz de confusão, as linhas indicam as estimações da região de ocorrência da falta, e as colunas indicam a região de referência da falta. Desta forma, por exemplo, 834 casos de falta foram devidamente estimados como ocorrendo na região 07, 35 das faltas que ocorreram na região 07 foram incorretamente vinculadas à região 05, e 17 casos de falta que ocorreram na região 07 foram indevidamente relacionadas à região 09. Com base neste exemplo, houve uma taxa de acerto de 94,1% na identificação das faltas da fase *A-terra* aplicadas na região 07, e uma taxa de acerto total de 98% para a localização de faltas da fase *A-terra* com relação a todas as regiões.

Figura 47 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra, fase C-terra, fases AB, fases BC e fases AC.

Região estimada	1	1091 10.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2429 23.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	2253 21.8%	27 0.3%	0 0.0%	0 0.0%	0 0.0%	98.8% 1.2%
	5	0 0.0%	0 0.0%	8 0.1%	352 3.4%	0 0.0%	0 0.0%	0 0.0%	97.8% 2.2%
	7	0 0.0%	0 0.0%	0 0.0%	53 0.5%	817 7.9%	75 0.7%	0 0.0%	86.5% 13.5%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 12.9%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1904 18.4%	100% 0.0%
		100% 0.0%	100% 0.0%	99.6% 0.4%	81.5% 18.5%	100% 0.0%	94.7% 5.3%	100% 0.0%	98.4% 1.6%
		1	3	4	5	7	9	10	
		Região de referência							

(a) A-terra.

Região estimada	1	1079 11.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	148 1.6%	55 0.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	72.9% 27.1%
	3	0 0.0%	0 0.0%	2475 26.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	360 3.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	116 1.2%	34 0.4%	0 0.0%	0 0.0%	77.3% 22.7%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	17 0.2%	845 9.1%	15 0.2%	60 0.6%	90.2% 9.8%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	830 8.9%	10 0.1%	98.8% 1.2%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	47 0.5%	1288 13.9%	96.5% 3.5%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1904 20.5%	100% 0.0%
		100% 0.0%	100% 0.0%	97.8% 2.2%	100% 0.0%	87.2% 12.8%	96.1% 3.9%	93.0% 7.0%	94.8% 5.2%	100% 0.0%
		1	2	3	5	6	7	8	9	10
		Região de referência								

(b) B-terra.

Região estimada	1	1245 15.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2508 30.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	360 4.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	853 10.5%	79 1.0%	0 0.0%	91.5% 8.5%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.4%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	33 0.4%	1722 21.2%	98.1% 1.9%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	92.3% 7.7%	100% 0.0%	98.6% 1.4%
		1	3	5	7	9	10	
		Região de referência						

(c) C-terra.

Região estimada	1	1185 14.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2505 31.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	360 4.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	870 10.8%	75 0.9%	0 0.0%	92.1% 7.9%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.6%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1735 21.5%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	94.7% 5.3%	100% 0.0%	99.1% 0.9%
		1	3	5	7	9	10	
		Região de referência						

(d) AB.

Região estimada	1	1280 15.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2495 30.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	360 4.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	850 10.4%	75 0.9%	0 0.0%	91.9% 8.1%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.4%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1740 21.4%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	94.7% 5.3%	100% 0.0%	99.1% 0.9%
		1	3	5	7	9	10	
		Região de referência						

(e) BC.

Região estimada	1	1345 16.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2520 30.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	360 4.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	870 10.6%	75 0.9%	0 0.0%	92.1% 7.9%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.2%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1730 21.0%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	94.7% 5.3%	100% 0.0%	99.1% 0.9%
		1	3	5	7	9	10	
		Região de referência						

(f) AC.

Figura 48 – Matrizes de confusão para os tipos de falta fases AB-terra, fases BC-terra, fases AC-terra, fases ABC e fases ABC-terra.

Região estimada	1	1266 15.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2373 29.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	288 3.6%	22 0.3%	50 0.6%	0 0.0%	80.0% 20.0%
	7	0 0.0%	0 0.0%	0 0.0%	810 10.1%	135 1.7%	0 0.0%	85.7% 14.3%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.6%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	11 0.1%	1739 21.7%	99.4% 0.6%
		100% 0.0%	100% 0.0%	100% 0.0%	97.4% 2.6%	87.2% 12.8%	100% 0.0%	97.3% 2.7%
		Região de referência						
		1	3	5	7	9	10	

(a) AB-terra.

Região estimada	1	1220 15.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2515 31.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	288 3.5%	72 0.9%	0 0.0%	0 0.0%	80.0% 20.0%
	7	0 0.0%	0 0.0%	0 0.0%	798 9.8%	147 1.8%	0 0.0%	84.4% 15.6%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.4%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1744 21.5%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	91.7% 8.3%	90.1% 9.9%	100% 0.0%	97.3% 2.7%
		Região de referência						
		1	3	5	7	9	10	

(b) BC-terra.

Região estimada	1	1247 15.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2491 30.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	288 3.5%	72 0.9%	0 0.0%	0 0.0%	80.0% 20.0%
	7	0 0.0%	0 0.0%	0 0.0%	752 9.3%	193 2.4%	0 0.0%	79.6% 20.4%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.5%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	1733 21.4%	99.9% 0.1%
		100% 0.0%	100% 0.0%	100% 0.0%	91.3% 8.7%	87.3% 12.7%	100% 0.0%	96.7% 3.3%
		Região de referência						
		1	3	5	7	9	10	

(c) AC-terra.

Região estimada	1	1130 14.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2520 31.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	360 4.5%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	900 11.2%	45 0.6%	0 0.0%	95.2% 4.8%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.6%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1735 21.6%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	96.7% 3.3%	100% 0.0%	99.4% 0.6%
		Região de referência						
		1	3	5	7	9	10	

(d) ABC.

Região estimada	1	1320 16.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2520 30.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	360 4.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	870 10.6%	75 0.9%	0 0.0%	92.1% 7.9%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.3%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1735 21.1%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	94.7% 5.3%	100% 0.0%	99.1% 0.9%
		Região de referência						
		1	3	5	7	9	10	

(e) ABC-terra.

Tabela 12 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta.

Tipo da falta	Taxa de acerto (%)
A-terra	98,42
B-terra	97,44
C-terra	98,62
AB	99,07
BC	99,08
AC	99,09
AB-terra	97,28
BC-terra	97,28
AC-terra	96,71
ABC	99,44
ABC-terra	99,08

A Tabela 13 sumariza alguns aspectos referentes às Figuras 47 e 48. Nesta tabela é evidenciado, para cada tipo de falta, as regiões em que houve algum erro de localização, a região com o menor erro não nulo e a região com o maior erro de localização. Com base nesta tabela, podem ser pontuados os seguintes aspectos:

- dentre as faltas monofásicas, a fase *C*-terra foi a com menor número de regiões com erro de localização e a fase *B*-terra foi a com maior número;
- as faltas bifásicas, trifásicas e trifásicas-terra tiveram o mesmo desempenho das faltas fase *C*-terra; e
- as faltas bifásicas-terra tiveram o mesmo desempenho.

Tabela 13 – Resultados gerais observados nas matrizes de confusão referentes ao cenário padrão de testes.

	Regiões com erros de localização	Região com menor erro não nulo de localização	Região com maior erro de localização
A-terra	[4 5 9]	4	5
B-terra	[3 6 7 8 9]	3	6
C-terra	9	9	9
AB	9	9	9
BC	9	9	9
AC	9	9	9
AB-terra	[7 9]	7	9
BC-terra	[7 9]	7	9
AC-terra	[7 9]	7	9
ABC	9	9	9
ABC-terra	9	9	9

5.2 Desempenho do algoritmo considerando a variação no carregamento do sistema

A seguir serão discutidos os resultados para a localização de faltas diante de uma variação no perfil das cargas do sistema teste. O objetivo desta análise é avaliar até que ponto o algoritmo tolera uma variação no carregamento do sistema. Serão apresentados os resultados para 4 cenários, sendo eles: (1) todas as cargas do sistema em 80% de seu carregamento nominal; (2) variação aleatória, de cada uma das cargas do sistema, para carregamentos entre 95% e 105% de seu valor nominal; (3) variação aleatória, de cada uma das cargas do sistema, para carregamentos entre 90% e 110% de seu valor nominal; (4) e todas as cargas do sistema em 120% de seu valor nominal.

De modo geral, evidenciado pelos histogramas do erro percentual, foi observado que o algoritmo proposto apresentou um melhor resultado para a situação (2). Outro ponto geral nestes resultados está na análise da relação entre a variação da impedância da falta com o erro percentual, no qual não há a mesma uniformidade que foi verificada no cenário padrão de testes.

5.2.1 Cargas com carregamento em 80% do valor nominal

5.2.1.1 Resultados para a estimação da distância da falta

A Figura 55 do Apêndice B apresenta os gráficos *box plot* referentes ao erro percentual da estimação da distância da falta com relação à subestação, e considerando uma redução em 80% do carregamento. Estes gráficos podem ser sumarizados conforme a Tabela 14.

Tabela 14 – Resultados gerais da estimação da distância da falta para o cenário com carregamento reduzido para 80% da carga instalada.

	Min (%)	Max (%)	Q_1 (%)	Q_2 (%)	Q_3 (%)	<i>Outliers</i>
A-terra	6,05E-02	471,44	145,38	408,81	431,27	0
B-terra	5,75E+01	156,24	74,02	94,52	122,45	0
C-terra	5,77E-04	37,67	4,42	10,36	26,27	0

Na Tabela 14 fica evidenciado que neste cenário as RNAs tiveram um erro percentual muito elevado. A Figura 49 evidencia o que está por trás destes valores tão elevados. Esta figura apresenta, para cada uma das amostras, os valores normalizados de Amp_{IA} , Amp_{IB} e Amp_{IC} correspondentes ao sistema com carregamento reduzido para 80% da carga instalada e para faltas da fase A-terra. Este gráfico mostra que Amp_{IB} e Amp_{IC} assumem valores maiores do que 1, e isto implica que as entradas das RNAs utilizadas para a estimação da distância da falta com relação à subestação estarão recebendo parâmetros fora da faixa de valores que foi considerado no treinamento. Desta forma, todas as RNAs

tenderão a inferir valores de distância da falta com um erro elevadíssimo. A Figura 50 apresenta os valores de amplitudes das correntes trifásicas em situações de falta fase *A*-terra aplicadas no sistema com carregamento normal. Nesta figura é apresentado em destaque as faltas que ocorrem na região mais terminal do sistema. Observa-se que nestas regiões são obtidos os valores de amplitude de falta mais próximos de 1. Com base nisso, conforme a Figura 49, se com uma redução no carregamento do sistema, os valores de Amp_{IB} e Amp_{IC} são maiores que 1, isso implica numa correlação de que todas as faltas estariam no final do sistema.

Figura 49 – Amplitudes das correntes trifásicas em situações de falta fase *A*-terra aplicadas no sistema com carregamento reduzido para 80% do seu valor nominal.

Figura 50 – Amplitudes das correntes trifásicas em situações de falta fase A-terra aplicadas no sistema com carregamento normal.

Figura 51 – Comparativo entre os valores das amplitudes das fases trifásicas do sistema com carregamento normal, e do sistema com carregamento reduzido para 80% do seu valor nominal, considerando a aplicação de faltas fase *A*-terra.

Outro ponto para destacar está no impacto de utilizar fases que não estejam diretamente envolvidas na falta como parâmetros de entrada das RNAs. A Figura 51 apresenta um comparativo entre os valores das amplitudes das fases trifásicas do sistema com carregamento normal, e do sistema com carregamento reduzido para 80% do seu valor nominal. Neste comparativo, fica evidenciado que as amplitudes (Amp_{IA}) observadas na fase *A* diante da aplicação de faltas fase *A*-terra no sistema, quando comparados os cenários de carregamento normal e carregamento reduzido para 80% do valor nominal, pouco diferem. Já os valores de amplitudes (Amp_{IB} e Amp_{IC}) observados nas fases *B* e *C* possuem uma diferença clara quando comparados os cenários de carregamento normal e carregamento reduzido para 80% do valor nominal.

5.2.1.2 Resultados para a identificação da área de ocorrência da falta

Para a identificação da área de ocorrência da falta para faltas fase *A*-terra, *B*-terra e *C*-terra foi obtida uma taxa de acerto conforme a Tabela 15. Para este cenário, fica evidenciada uma maior dificuldade, por parte das árvores de decisão, na identificação da área de ocorrência das faltas monofásicas avaliadas.

Tabela 15 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta considerando o carregamento reduzido para 80% do seu valor nominal.

Tipo da falta	Taxa de acerto (%)
A-terra	99,62
B-terra	99,86
C-terra	99,78

5.2.1.3 Resultados para a identificação da região de ocorrência da falta

A Tabela 16 sumariza os resultados apresentados nas matrizes de confusão da Figura 59 do Apêndice B. Nestas matrizes de confusão vale observar que em todos os tipos de falta monofásicos o algoritmo não reconheceu a situação de falta para algumas regiões. Este comportamento está coerente com a Figura 32, uma vez que todas as árvores de decisão utilizadas para a identificação da região de ocorrência da falta possuem como parâmetro de entrada a distância estimada pelas RNAs. Desta forma, como as RNAs estão apresentando um erro elevadíssimo, isso implicará em uma identificação incorreta da região de ocorrência da falta.

Tabela 16 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta considerando as cargas com carregamento reduzido para 80% do seu valor nominal.

Tipo da falta	Taxa de acerto (%)
A-terra	52,06
B-terra	58,66
C-terra	58,49

5.2.2 Cargas com carregamento aleatório entre 95% e 105% do valor nominal

5.2.2.1 Resultados para a estimação da distância da falta

A Figura 60 do Apêndice C apresenta os gráficos *box plot* referentes ao erro percentual da estimação da distância da falta com relação à subestação, e considerando uma variação aleatória em cada uma das cargas entre 95% e 105%.

Estes gráficos podem ser generalizados pela Tabela 17. Nota-se que o erro na estimação da distância da falta para este cenário é bem inferior, em comparação ao caso de estudo anterior. Um destaque está na observância de um maior erro percentual na estimação da distância das faltas fase C-terra com relação à subestação.

Tabela 17 – Resultados gerais para a estimação da distância da falta para o cenário considerando uma variação aleatória em cada uma das cargas entre 95% e 105% do seu valor nominal.

	Min (%)	Max (%)	Q_1 (%)	Q_2 (%)	Q_3 (%)	<i>Outliers</i>
A-terra	8,86E-05	17,49	0,89	2,65	4,89	205
B-terra	2,95E-04	13,35	0,65	2,22	4,51	76
C-terra	7,61E-04	31,44	1,35	3,00	5,21	331

5.2.2.2 Resultados para a identificação da área de ocorrência da falta

Para a identificação da área de ocorrência da falta, foram obtidos resultados conforme a Tabela 18.

Tabela 18 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta considerando uma variação aleatória em cada uma das cargas entre 95% e 105% do seu valor nominal.

Tipo da falta	Taxa de acerto (%)
A-terra	100
B-terra	100
C-terra	100

5.2.2.3 Resultados para a identificação da região de ocorrência da falta

A Tabela 19 sumariza os resultados apresentados nas matrizes de confusão da Figura 64 do Apêndice C. É observada uma menor taxa de acerto na identificação da região de ocorrência das faltas fase C-terra. Outro ponto é que houve uma maior dificuldade em identificar devidamente as faltas que ocorreram na região 5.

Tabela 19 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta considerando as cargas com carregamento aleatório entre 95% e 105% do seu valor nominal.

Tipo da falta	Taxa de acerto (%)
A-terra	90,25
B-terra	96,05
C-terra	89,47

5.2.3 Cargas com carregamento aleatório entre 90% e 110% do valor nominal

5.2.3.1 Resultados para a estimação da distância da falta

A Figura 65 do Apêndice D apresenta os gráficos *box plot* referentes ao erro percentual da estimação da distância da falta com relação à subestação, e considerando uma variação aleatória em cada uma das cargas entre 90% e 110%. Os resultados observados podem ser generalizados pela Tabela 20. É constatado que para este caso de estudo, enquanto a estimação das faltas fase *C*-terra apresentam um resultado próximo do caso padrão de testes, as faltas fase *A*-terra e fase *B*-terra apresentaram resultados muito discrepantes.

Tabela 20 – Resultados gerais para a estimação da distância da falta considerando uma variação aleatória em cada uma das cargas entre 90% e 110% do seu valor nominal.

	Min (%)	Max (%)	Q_1 (%)	Q_2 (%)	Q_3 (%)	<i>Outliers</i>
A-terra	2,31E-03	88,91	7,03	18,38	25,08	425
B-terra	2,91E-03	93,63	14,54	49,99	67,11	0
C-terra	8,98E-04	20,80	1,69	3,76	6,15	183

5.2.3.2 Resultados para a identificação da área de ocorrência da falta

Para a identificação da área de ocorrência da falta, foram obtidos resultados conforme a Tabela 21.

Tabela 21 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta considerando uma variação aleatória em cada uma das cargas entre 90% e 110% do seu valor nominal.

Tipo da falta	Taxa de acerto (%)
A-terra	100
B-terra	100
C-terra	100

5.2.3.3 Resultados para a identificação da região de ocorrência da falta

A Tabela 22 sumariza os resultados apresentados nas matrizes de confusão da Figura 69 do Apêndice D. O comportamento das taxas de acerto seguem os resultados evidenciados na Tabela 20. Fica evidenciado que os piores resultados estão na identificação da região de ocorrência das faltas fase B-terra, e os melhores resultados estão na identificação da região de ocorrência das faltas fase C-terra.

Tabela 22 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta considerando as cargas com carregamento aleatório entre 90% e 110% do valor nominal.

Tipo da falta	Taxa de acerto (%)
A-terra	65,39
B-terra	42,16
C-terra	79,10

5.2.4 Cargas com carregamento em 120% do valor nominal

5.2.4.1 Resultados para a estimação da distância da falta

A Figura 70 do Apêndice E apresenta os gráficos *box plot* referentes ao erro percentual da estimação da distância da falta com relação à subestação, e considerando um aumento para 120% do carregamento. Estes gráficos podem ser sumarizados pela Tabela 23 que segue. Conforme apresentado, o maior valor de Q_3 está para as faltas fase C-terra. De modo geral, foram obtidos resultados ruins para a estimação da distância das faltas para este cenário.

Tabela 23 – Resultados gerais referentes à estimação da distância da falta para o cenário com o carregamento aumentado para 120% da carga instalada.

	Min (%)	Max (%)	Q_1 (%)	Q_2 (%)	Q_3 (%)	<i>Outliers</i>
A-terra	5,18E-02	452,42	21,03	37,34	72,16	811
B-terra	1,58E-03	61,87	16,08	30,89	45,56	0
C-terra	4,36E-03	311,31	18,92	129,60	168,77	0

5.2.4.2 Resultados para a identificação da área de ocorrência da falta

Para a identificação da área de ocorrência da falta, foram obtidos resultados conforme a Tabela 24.

Tabela 24 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta considerando uma variação aleatória em cada uma das cargas com o carregamento aumentado para 120% da carga instalada.

Tipo da falta	Taxa de acerto (%)
A-terra	100
B-terra	100
C-terra	100

5.2.4.3 Resultados para a identificação da região de ocorrência da falta

A Tabela 25 sumariza os resultados apresentados nas matrizes de confusão da Figura 69 do Apêndice E. Fica evidenciado que para este nível de variação no carregamento do sistema o algoritmo de localização de faltas proposto não foi capaz de realizar uma devida identificação da região de ocorrência da falta.

Tabela 25 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta, considerando as cargas com carregamento 120% do valor nominal.

Tipo da falta	Taxa de acerto (%)
A-terra	53,27
B-terra	35,13
C-terra	45,57

5.3 Desempenho do algoritmo considerando erros na medição

Nesta seção é apresentado o impacto dos erros de medição na metodologia proposta. É evidenciado como estes erros afetam os parâmetros baseados nos coeficientes da WPT. Assim, os resultados que seguem foram obtidos após inserir em cada uma das amostras dos sinais de tensão e corrente trifásicos um ruído gaussiano com média zero e desvio padrão de 0.5%.

5.3.1 Resultados para a estimação da distância da falta

A Figura 75 do Apêndice F apresenta os gráficos *box plot* referentes ao erro percentual da estimação da distância da falta com relação à subestação, e considerando a presença de erros de medição. Estes gráficos podem ser sumarizados conforme a Tabela 26.

Tabela 26 – Erros gerais referentes à estimação da distância da falta para o cenário contendo erros de medição.

	Min (%)	Max (%)	Q_1 (%)	Q_2 (%)	Q_3 (%)	<i>Outliers</i>
A-terra	5,67E-04	272,95	1,21	3,07	5,93	612
B-terra	7,91E-04	99,28	2,48	5,62	10,96	790
C-terra	1,12E-03	73,95	2,10	4,76	8,26	581

Em comparação ao cenário de testes sem erros de medição, pode-se observar que houve um aumento considerável no erro percentual máximo (*Max*) e na quantidade de *outliers*.

As Figuras 77 e 78 do Apêndice F apresentam a distribuição dos casos de falta com relação ao erro percentual, com base na impedância e no ângulo de incidência da falta. São observados resultados similares ao caso em que não há erro de medição.

5.3.2 Resultados para a identificação da área de ocorrência da falta

Para a identificação da área de ocorrência da falta, foram obtidos resultados conforme a Tabela 27.

Tabela 27 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário contendo erros de medição.

Tipo da falta	Taxa de acerto (%)
A-terra	100
B-terra	100
C-terra	100

5.3.3 Resultados para a identificação da região de ocorrência da falta

A Tabela 28 sumariza os resultados apresentados nas matrizes de confusão da Figura 79 do Apêndice F. Há um maior erro na localização das faltas fase *A-terra*, e um menor erro na localização das faltas fase *C-terra*. Este comportamento pode ser justificado através das Figuras 32 e 52. Conforme a Figura 32, as árvores de decisão referentes à localização das faltas fase *A-terra* e fase *B-terra* utilizam da energia dos coeficientes da WPT, enquanto as árvores de decisão referentes às faltas fase *C-terra* apenas utilizam da área de ocorrência da falta e da distância estimada da falta.

A Figura 52 mostra o impacto da presença de ruído na medição em $En12_{IB}$. Com base nestas duas figuras fica claro haver uma taxa de acerto na localização das faltas fase *A-terra* menor que a da *B-terra*, uma vez que as árvores de decisão responsáveis pela localização das faltas fase *A-terra* utilizam mais parâmetros relacionados com a energia dos coeficientes da WPT, do que as árvores que fazem a localização das faltas fase *B-terra*. Pelo mesmo raciocínio, há uma taxa de acerto maior para a localização das faltas fase *C-terra* devido às árvores de decisão referentes a este tipo de falta apenas utilizarem a área de ocorrência da falta e a distância estimada da falta como parâmetros de entrada.

Tabela 28 – Taxa de acerto para a identificação da região de ocorrência das faltas com base no tipo de falta considerando a presença de erros de medição.

Tipo da falta	Taxa de acerto (%)
A-terra	68,79
B-terra	73,48
C-terra	82,35

5.4 Desempenho do algoritmo considerando 4 medidores otimamente posicionados

Nesta seção, a metodologia que foi aplicada para 3 medidores otimamente posicionados, conforme a metodologia de Gomes (2016), foi replicada considerando 4 medidores otimamente posicionados conforme a Tabela 2. Como um acréscimo no número de medidores não afeta a estimativa¹ da distância da falta com relação à subestação e tão pouco a definição de regiões², serão somente apresentados os resultados para a identificação da área³ de ocorrência das faltas e na identificação da região de ocorrência das faltas. As áreas, para este cenário, estão definidas conforme a Figura 17.

5.4.1 Resultados para a identificação da área de ocorrência da falta

Para a identificação da área de ocorrência da falta, foram obtidos resultados conforme a Tabela 29.

Tabela 29 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário com 4 medidores otimamente alocados.

Tipo da falta	Taxa de acerto (%)
A-terra	100
B-terra	100
C-terra	100

¹ O acréscimo no número de medidores não afeta a estimativa inicial da distância das faltas, pois o algoritmo que estima inicialmente a distância das faltas somente utiliza informações advindas da subestação.

² Como o algoritmo que define as regiões no sistema depende do erro na estimativa inicial da distância da falta, e a estimativa inicial da distância da falta apenas depende de dados advindos da subestação, é mantida, portanto, a mesma definição das regiões utilizada para o cenário contendo 3 medidores alocados no sistema.

³ Para este cenário já são definidas 4 áreas, uma vez que o algoritmo que faz a delimitação das áreas depende do número e da quantidade de medidores alocados no sistema.

Figura 52 – Impacto do erro de medição em $En12_{IB}$.

5.4.2 Resultados para a identificação da região de ocorrência da falta

A Tabela 30 sumariza os resultados apresentados nas matrizes de confusão da Figura 80 do Apêndice G. É observada uma taxa de acerto similar à obtida na situação padrão de testes. Vale destacar a obtenção de uma taxa de acerto na identificação da região de ocorrência das faltas fase *C*-terra, superior ao desempenho obtido (para este mesmo tipo de falta) no cenário padrão de testes.

A Tabela 31 sumariza alguns aspectos referentes às Figuras 80 do Apêndice G. Com base nesta tabela fica destacado que para este cenário de testes são cometidos erros de localização seguindo o mesmo perfil observado para o cenário padrão de teste.

Tabela 30 – Taxa de acerto para a identificação da região de ocorrência das faltas considerando 4 medidores otimamente alocados.

Tipo da falta	Taxa de acerto (%)
A-terra	96,96
B-terra	97,44
C-terra	99,39

Tabela 31 – Resultados gerais observados nas matrizes de confusão referentes ao contexto padrão de testes na presença de 4 medidores instalados.

	Regiões com erros de localização	Região com menor erro não nulo de localização	Região com maior erro de localização
A-terra	[4 5 9]	4	5
B-terra	[3 6 7 8 9]	3	6
C-terra	9	9	9

5.5 Desempenho do algoritmo considerando 4 medidores não otimamente posicionados

Nesta seção foram realizados testes avaliando o impacto do uso de uma alocação não otimizada dos medidores de QEE. Para tanto foi empiricamente adotada a alocação apresentada na Figura 18.

5.5.1 Resultados para a identificação da área de ocorrência da falta

Para a identificação da área de ocorrência da falta, foram obtidos resultados conforme a Tabela 32.

Tabela 32 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário com 4 medidores não otimamente alocados.

Tipo da falta	Taxa de acerto (%)
A-terra	100
B-terra	100
C-terra	100

5.5.2 Resultados para a identificação da região de ocorrência da falta

A Tabela 33 sumariza os resultados apresentados nas matrizes de confusão da Figura 81 do Apêndice H. É observado uma taxa de acerto muito similar à obtida na situação padrão de testes.

Tabela 33 – Taxa de acerto para a identificação da região de ocorrência das faltas considerando 4 medidores não otimamente alocados.

Tipo da falta	Taxa de acerto (%)
A-terra	98,40
B-terra	97,40
C-terra	98,60

A Tabela 34 sumariza alguns aspectos referentes às Figuras 81 do Apêndice H. Com base nesta tabela fica destacado que para este cenário de testes são cometidos erros de localização seguindo o mesmo perfil observado para o cenário padrão de teste.

Tabela 34 – Resultados gerais observados nas matrizes de confusão referentes ao contexto padrão de testes.

	Regiões com erros de localização	Região com menor erro não nulo de localização	Região com maior erro de localização
A-terra	[4 5 9]	4	5
B-terra	[3 6 7 8 9]	3	6
C-terra	9	9	9

5.6 Desempenho do algoritmo considerando uma redução na taxa amostral

Nesta seção é analisado o impacto da redução da taxa amostral na metodologia proposta. Inicialmente, são apresentados os resultados considerando uma taxa amostral de 128 amostras/ciclo, e, na sequência, é considerada uma taxa amostral de 64 amostras/ciclo. É evidenciado que a redução na taxa amostral e o desempenho da metodologia estão inversamente relacionados. Vale destacar que em ambos os cenários (e para todas as faltas monofásicas) pelo menos 90% (conforme as Figuras 85 e 90) das situações de faltas apresentaram uma taxa de acerto de até 10%, e continua havendo uma baixa correlação da variação da impedância e do ângulo de incidência da falta com o erro percentual. Quanto à estimação da distância da falta, ambos possuem um resultado similar ao caso padrão de testes. O destaque fica para o número de *outliers* na estimação da distância das faltas fase B-terra para taxa amostral de 64 amostras/ciclo.

5.6.1 Resultados considerando uma taxa amostral de 128 amostras/ciclo

5.6.1.1 Resultados para a estimação da distância da falta

A Figura 83 do Apêndice I apresenta os gráficos *box plot* referentes ao erro percentual da estimação da distância da falta com relação à subestação, e, considerando uma taxa amostral de 128 amostras/ciclo. Estes gráficos podem ser sumarizados pela Tabela 35 que segue. Conforme o exposto, foram obtidos resultados similares com relação ao cenário padrão.

Tabela 35 – Resultados gerais referentes à estimação da distância da falta considerando uma taxa amostral de 128 amostras/ciclo.

	Min (%)	Max (%)	Q_1 (%)	Q_2 (%)	Q_3 (%)	<i>Outliers</i>
A-terra	9,25E-05	20,47	0,75	2,13	4,74	138
B-terra	8,82E-05	11,61	0,57	1,63	4,36	26
C-terra	6,33E-04	13,89	0,83	2,38	4,96	76

5.6.1.2 Resultados para a identificação da área de ocorrência da falta

Para a identificação da área de ocorrência da falta, foram obtidos resultados conforme a Tabela 36.

Tabela 36 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário com taxa amostral de 128 amostras/ciclo.

Tipo da falta	Taxa de acerto (%)
A-terra	100
B-terra	100
C-terra	100

5.6.1.3 Resultados para a identificação da região de ocorrência da falta

A Tabela 37 sumariza os resultados apresentados nas matrizes de confusão da Figura 86 do Apêndice I. Assim como para a estimação da distância da falta, para a identificação da região de ocorrência da falta apresentou resultados satisfatórios. Entretanto, vale destacar que as faltas fase A-terra e B-terra apresentam uma menor taxa de acerto pois são dependentes da energia de alguns coeficientes da WPT.

Tabela 37 – Taxa de acerto para a identificação da região de ocorrência das faltas considerando uma taxa amostral de 128 amostras/ciclo.

Tipo da falta	Taxa de acerto (%)
A-terra	93,59
B-terra	93,23
C-terra	98,43

5.6.2 Resultados considerando uma taxa amostral de 64 amostras/ciclo

5.6.2.1 Resultados para a estimação da distância da falta

A Figura 88 do Apêndice J apresenta os gráficos *box plot* referentes ao erro percentual da estimação da distância da falta com relação à subestação, e, considerando uma taxa amostral de 64 amostras/ciclo. Estes gráficos podem ser sumarizados pela Tabela 38 apresentada. Assim como para o caso de 128 amostras/ciclo, este cenário apresenta na estimação da distância da falta uma estimação similar ao do cenário padrão.

Tabela 38 – Resultados gerais referentes à estimação da distância da falta considerando uma taxa amostral de 64 amostras/ciclo.

	Min (%)	Max (%)	Q_1 (%)	Q_2 (%)	Q_3 (%)	<i>Outliers</i>
A-terra	6,42E-05	18,74	0,75	2,4	4,67	31
B-terra	3,70E-04	13,5317	0,91	2,17	4,13	450
C-terra	1,91E-03	13,31	0,63	2,02	5,21	6

5.6.2.2 Resultados para a identificação da área de ocorrência da falta

Para a identificação da área de ocorrência da falta, foram obtidos resultados conforme a Tabela 39.

Tabela 39 – Taxa de acerto para a identificação da área de ocorrência das faltas com base no tipo de falta para o cenário com taxa amostral de 64 amostras/ciclo.

Tipo da falta	Taxa de acerto (%)
A-terra	100
B-terra	100
C-terra	100

5.6.2.3 Resultados para a identificação da região de ocorrência da falta

A Tabela 40 sumariza os resultados apresentados nas matrizes de confusão da Figura 91 do Apêndice J. Para as faltas fase A-terra e fase B-terra, para a identificação da região de ocorrência da falta, foram obtidos erros mais severos.

Tabela 40 – Taxa de acerto para a identificação da região de ocorrência das faltas considerando uma taxa amostral de 64 amostras/ciclo.

Tipo da falta	Taxa de acerto (%)
A-terra	67,23
B-terra	92,34
C-terra	98,27

5.7 Considerações finais

Neste capítulo foram apresentados e discutidos os resultados obtidos com a aplicação da metodologia proposta nesta pesquisa para a localização de faltas em um sistema de distribuição radial. Foram aplicados e analisados diversos testes para avaliar a robustez da metodologia proposta. De modo geral, com base nos resultados apresentados, a metodologia proposta atende ao propósito de localizar faltas em um sistema de distribuição radial. Foram obtidos bons resultados para a estimação da distância da falta e na identificação da região de ocorrência da falta. Assim, auxiliando na amenização do problema de múltiplas estimações. Foi constatado que o algoritmo proposto é sensível a uma variação muito brusca no carregamento do sistema, à presença de erros de medição e à uma redução elevada no número de amostras/ciclo (sendo tolerável a redução de 256 amostras/ciclo para 128 amostras/ciclo). Quanto à variação do número de medidores de 3 para 4 foi constatada que repercutiu em uma variação insignificante na precisão do algoritmo. Quanto ao uso de uma alocação não otimizada também foi constatada uma variação insignificante na precisão do algoritmo, entretanto deve ser destacado que a alocação dos medidores, que foi adotada nesta pesquisa, não foi feita visando as necessidades de uma boa localização de faltas. Além disso, a metodologia apresentou ser pouco influenciada pela variação na impedância da falta e no ângulo de incidência da falta.

No próximo capítulo são apresentados os aspectos conclusivos da pesquisa realizada como um todo.

Conclusões e trabalhos futuros

As redes elétricas inteligentes trazem novas perspectivas para o aprimoramento e desenvolvimento de metodologias e aplicações no setor de energia elétrica, uma vez que novas necessidades surgem, juntamente com a mudança no paradigma do sistema elétrico de potência atual. Dentre essas necessidades podem ser enfatizados estudos referentes ao monitoramento, controle e operação das redes elétricas inteligentes.

Ao levar em consideração que é preciso um aumento da qualidade do serviço que é prestado aos consumidores finais do sistema, o estudo de técnicas de monitoramento (e controle) que garantam, por exemplo, uma localização de faltas rápida e precisa vem ganhando destaque. Com uma rápida e precisa localização dos curtos-circuitos, há a possibilidade de rapidamente restaurar o sistema à sua operação normal, sanando o problema, de modo a melhorar os índices que são empregados pelos órgãos regulamentadores para avaliar o serviço prestado pelas distribuidoras para os usuários finais.

Frente ao monitoramento dos distúrbios passíveis de ocorrência nos sistemas de distribuição, esta pesquisa buscou o desenvolvimento de uma metodologia, com a consequente implementação de um algoritmo, para a localização de faltas baseado em redes neurais artificiais e em árvores de decisão. Outro ponto é que os dados utilizados como base para este algoritmo de localização de faltas advém de medidores de qualidade da energia elétrica que foram posicionados de forma otimizada no sistema em análise. Para o contexto desta pesquisa, o objetivo desta alocação otimizada dos medidores foi de garantir benefícios para o desempenho do algoritmo de localização, uma vez que as variações de tensão ocorridas no sistema de distribuição poderão ser devidamente observadas sem que haja a necessidade de uma quantidade elevada de medidores instalados.

Sendo assim, neste pesquisa, foi apresentada uma metodologia utilizando redes neurais artificiais e árvores de decisão para a localização de faltas em um sistema de distribuição radial. As ferramentas foram utilizadas a partir de uma alocação otimizada de medidores de qualidade da energia elétrica. Inicialmente foram extraídos resultados para um cenário padrão de testes (3 medidores otimamente alocados, 256 amostras/ciclo,

sem erros de medição e sem alterações no carregamento do sistema).

Para a situação padrão de testes foi obtida uma taxa de acerto na identificação da região de ocorrência da falta acima de 97% para todos os tipos de falta e um terceiro quartil do erro percentual da estimação da distância da falta com relação à subestação acima de 4,58%.

Após avaliar a metodologia para este cenário padrão, foram realizados testes de sensibilidade para avaliar a robustez da metodologia frente à situações distintas.

Quanto aos testes de sensibilidade realizados, os seguintes apontamentos gerais podem ser evidenciados:

- quanto à variação no carregamento do sistema foram obtidos bons resultados para uma variação aleatória das cargas num intervalo de 95% a 105% de seus valores nominais;
- foi avaliado que a presença de erros na medição afeta mais a identificação da região de ocorrência da falta do que a estimação da distância da falta;
- ao aumentar o número de medidores otimamente alocados não foi obtido um aumento considerável no desempenho do algoritmo;
- o desempenho do algoritmo para 4 medidores não otimamente alocados foi muito similar ao cenário padrão de testes; e
- a redução da taxa amostral afeta bastante a identificação da região de ocorrência de faltas fase A-terra, mas não afeta tanto a estimação da distância da falta com relação à subestação.

Outro ponto de destaque é que, de modo geral, a metodologia proposta é pouco influenciada pela variação na impedância e do ângulo de incidência da falta. Também vale frisar a capacidade das árvores de decisão como seletor de atributos, uma vez que consegue determinar os parâmetros mais relevantes para a identificação da região de ocorrência da falta. Além de identificar os atributos que mais impactam no propósito de localizar as regiões (e áreas) de ocorrência das faltas, as árvores de decisão, através de seu algoritmo de treinamento, determinam por si só as regras SE-ENTÃO que serão usadas na localização da falta. Isto é importante pois com a mudança do sistema de distribuição a árvore de decisão identificará as regras SE-ENTÃO que se aplicam a este novo sistema. Outra vantagem está nas árvores de decisão oferecerem um ambiente de mais fácil uso por parte dos operadores do sistema.

6.1 Trabalhos futuros

Para a continuidade da pesquisa podem ser considerados os seguintes pontos:

- desenvolver uma metodologia que atenda à sistemas com presença de geração distribuída;
- usar o sinal de frequência para identificar perfis em sistemas com elevada penetração de geração distribuída;
- utilizar o Método de Monte Carlo para avaliar o localizador de faltas;
- replicar a metodologia para outros sistemas de distribuição;
- utilizar a matriz de tensões durante a falta para definir as regiões;
- utilizar algoritmos de clusterização para definir as regiões;
- utilizar técnicas de compressão de sinais para então extrair as características de cada situação de falta;
- reavaliar o nível de decomposição para a *Wavelet Packet Transform*;
- avaliar a utilização da transformada S no lugar da *Wavelet Packet Transform*;
- desenvolver uma metodologia mais tolerante às flutuações no carregamento do sistema;
- avaliar o impacto da falta de sincronismo entre os dados advindos dos medidores no algoritmo de localização de faltas;
- estender a metodologia para a localização de faltas incipientes (ou espúrias);
- considerar um módulo de qualidade da energia elétrica que anteceda o localizador de faltas;
- desenvolver uma metodologia para sistemas com natureza não-radial;
- aplicar técnicas de *ensemble learning* para o algoritmo de localização de faltas; e
- utilizar uma alocação otimizada de medidores de qualidade da energia elétrica voltada para a localização de faltas.

APÊNDICES

Exemplos de árvores de decisão treinadas

Figura 53 – Árvore de decisão para a identificação das regiões de ocorrência das faltas fase A-terra para os dados do medidor M01.

Figura 54 – Árvore de decisão para a identificação das áreas de ocorrência das faltas fase A-terra.

Gráficos dos testes considerando cargas com carregamento em 80% do valor nominal

Figura 55 – Gráficos *box plot* dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando redução da impedância das cargas em 80%.

Figura 56 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando redução da impedância das cargas em 80%.

Figura 57 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma redução da impedância das cargas em 80%.

Figura 58 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma redução da impedância das cargas em 80%.

Figura 59 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma redução da impedância das cargas em 80%.

Região estimada	1	1052 10.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	39 0.4%	96.4% 3.6%
	3	0 0.0%	2429 23.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2280 22.0%	0.0% 100%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	360 3.5%	0.0% 100%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	945 9.1%	0.0% 100%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 12.9%	0.0% 100%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1904 18.4%	100% 0.0%
		100% 0.0%	100% 0.0%	NaN% NaN%	NaN% NaN%	NaN% NaN%	NaN% NaN%	27.7% 72.3%	52.1% 47.9%
		1	3	4	5	7	9	10	
		Região de referência							

(a) A-terra.

Região estimada	1	1066 11.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	13 0.1%	98.8% 1.2%
	2	0 0.0%	0 0.0%	203 2.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	3	0 0.0%	0 0.0%	2475 26.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	360 3.9%	0.0% 100%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	150 1.6%	0.0% 100%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	937 10.1%	0.0% 100%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	840 9.0%	0.0% 100%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 14.4%	0.0% 100%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1904 20.5%	100% 0.0%
		100% 0.0%	NaN% NaN%	92.4% 7.6%	NaN% NaN%	NaN% NaN%	NaN% NaN%	NaN% NaN%	34.4% 65.6%	58.7% 41.3%
		1	2	3	5	6	7	8	9	10
		Região de referência								

(b) B-terra.

Região estimada	1	1227 15.1%	0 0.0%	18 0.2%	0 0.0%	0 0.0%	0 0.0%	98.6% 1.4%
	3	0 0.0%	2508 30.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	138 1.7%	222 2.7%	0 0.0%	0 0.0%	38.3% 61.7%
	7	0 0.0%	0 0.0%	9 0.1%	923 11.3%	0 0.0%	0 0.0%	99.0% 1.0%
	9	0 0.0%	0 0.0%	0 0.0%	1335 16.4%	0 0.0%	0 0.0%	0.0% 100%
	10	0 0.0%	0 0.0%	375 4.6%	1380 17.0%	0 0.0%	0 0.0%	0.0% 100%
		100% 0.0%	100% 0.0%	25.6% 74.4%	23.9% 76.1%	NaN% NaN%	NaN% NaN%	59.0% 41.0%
		1	3	5	7	9	10	
		Região de referência						

(c) C-terra.

Gráficos dos testes considerando cargas com carregamento entre 95% e 105% do valor nominal

Figura 60 – Gráficos *box plot* dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma redução aleatória da impedância das cargas entre 95% e 105% do valor nominal.

(a) A-terra.

(b) B-terra.

(c) C-terra.

Figura 61 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma impedância das cargas aleatória entre 95% e 105% do valor nominal.

Figura 62 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 95% e 105% do valor nominal.

Figura 63 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 95% e 105% do valor nominal.

Figura 64 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 95% e 105% do valor nominal.

Região estimada	1	1091 10.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2429 23.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	1812 17.5%	72 0.7%	396 3.8%	0 0.0%	0 0.0%	79.5% 20.5%
	5	0 0.0%	0 0.0%	0 0.0%	228 2.2%	132 1.3%	0 0.0%	0 0.0%	63.3% 36.7%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	890 8.6%	55 0.5%	0 0.0%	94.2% 5.8%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	52 0.5%	1281 12.4%	2 0.0%	96.0% 4.0%
	10	0 0.0%	0 0.0%	300 2.9%	0 0.0%	0 0.0%	0 0.0%	1602 15.5%	84.2% 15.8%
		100% 0.0%	100% 0.0%	85.8% 14.2%	76.0% 24.0%	60.5% 39.5%	95.9% 4.1%	99.9% 0.1%	90.2% 9.8%
		1	3	4	5	7	9	10	
		Região de referência							

(a) A-terra.

Região estimada	1	1079 11.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	143 1.5%	60 0.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	70.4% 29.6%
	3	0 0.0%	0 0.0%	2475 26.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	360 3.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	8 0.1%	100 1.1%	42 0.5%	0 0.0%	0 0.0%	66.7% 33.3%
	7	0 0.0%	0 0.0%	0 0.0%	100 1.1%	0 0.0%	762 8.2%	15 0.2%	60 0.6%	81.3% 18.7%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	820 8.8%	20 0.2%	0 0.0%	97.6% 2.4%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	12 0.1%	1323 14.3%	0 0.0%	99.1% 0.9%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	42 0.5%	10 0.1%	1852 20.0%	97.3% 2.7%
		100% 0.0%	100% 0.0%	97.6% 2.4%	76.9% 23.1%	100% 0.0%	94.8% 5.2%	82.2% 7.8%	93.6% 6.4%	96.0% 4.0%
		1	2	3	5	6	7	8	9	10
		Região de referência								

(b) B-terra.

Região estimada	1	1245 15.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2508 30.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	360 4.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	273 3.4%	659 8.1%	0 0.0%	0 0.0%	70.7% 29.3%
	9	0 0.0%	0 0.0%	19 0.2%	314 3.9%	1002 12.3%	0 0.0%	75.1% 24.9%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	251 3.1%	1504 18.5%	85.7% 14.3%
		100% 0.0%	100% 0.0%	55.2% 44.8%	67.7% 32.3%	80.0% 20.0%	100% 0.0%	89.5% 10.5%
		1	3	5	7	9	10	
		Região de referência						

(c) C-terra.

Gráficos dos testes considerando cargas com carregamento aleatório entre 90% e 110% do valor nominal

Figura 65 – Gráficos *box plot* dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma redução aleatória da impedância das cargas entre 90% e 110% do valor nominal.

Figura 66 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 90% e 110% do valor nominal.

Figura 67 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 90% e 110% do valor nominal.

Figura 68 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 90% e 110% do valor nominal.

Figura 69 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas aleatória entre 90% e 110% do valor nominal.

Região estimada	1	1091 11.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2429 26.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	1087 11.8%	1020 11.0%	68 0.7%	58 0.6%	47 0.5%	47.7% 52.3%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	18 0.2%	342 3.7%	0.0% 100%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	332 3.6%	613 6.6%	0.0% 100%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	383 4.1%	952 10.3%	28.7% 71.3%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	130 1.4%	669 7.2%	83.7% 16.3%
		100% 0.0%	100% 0.0%	100% 0.0%	0.0% 100%	0.0% 100%	41.6% 58.4%	25.5% 74.5%	61.3% 38.7%
		1	3	4	5	7	9	10	
		Região de referência							

(a) A-terra.

Região estimada	1	1079 11.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	0 0.0%	203 2.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	3	0 0.0%	0 0.0%	2475 26.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	5	0 0.0%	0 0.0%	0 0.0%	360 3.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	150 1.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	7	0 0.0%	0 0.0%	0 0.0%	937 10.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	8	0 0.0%	0 0.0%	0 0.0%	840 9.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	9	0 0.0%	0 0.0%	0 0.0%	1335 14.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	10	0 0.0%	0 0.0%	0 0.0%	1829 19.7%	0 0.0%	75 0.8%	0 0.0%	0 0.0%	0.0% 100%
		100% 0.0%	NaN% NaN%	92.4% 7.6%	6.6% 93.4%	NaN% NaN%	NaN% NaN%	0.0% 100%	NaN% NaN%	42.2% 57.8%
		1	2	3	5	6	7	8	9	10
		Região de referência								

(b) B-terra.

Região estimada	1	1245 15.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2508 30.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	341 4.2%	19 0.2%	0 0.0%	0 0.0%	94.7% 5.3%
	7	0 0.0%	0 0.0%	83 1.0%	774 9.5%	75 0.9%	0 0.0%	83.0% 17.0%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.4%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	375 4.6%	1380 17.0%	78.6% 21.4%
		100% 0.0%	100% 0.0%	80.4% 19.6%	97.6% 2.4%	74.8% 25.2%	100% 0.0%	93.2% 6.8%
		1	3	5	7	9	10	
		Região de referência						

(c) C-terra.

Gráficos dos testes considerando cargas com carregamento em 120% do valor nominal

Figura 70 – Gráficos *box plot* dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando redução aleatória da impedância das cargas em 120% do valor nominal.

Figura 71 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas em 120% do valor nominal.

Figura 72 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas em 120% do valor nominal.

Figura 73 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas em 120% do valor nominal.

Figura 74 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a impedância das cargas em 120% do valor nominal.

Região estimada	1	1091 11.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2429 24.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	1929 19.4%	0 0.0%	0 0.0%	0 0.0%	351 3.5%	84.6% 15.4%
	5	0 0.0%	0 0.0%	167 1.7%	24 0.2%	0 0.0%	0 0.0%	169 1.7%	6.7% 93.3%
	7	0 0.0%	0 0.0%	310 3.1%	56 0.6%	0 0.0%	0 0.0%	579 5.8%	0.0% 100%
	9	0 0.0%	0 0.0%	572 5.8%	0 0.0%	2 0.0%	0 0.0%	761 7.7%	0.0% 100%
	10	0 0.0%	0 0.0%	1388 14.0%	0 0.0%	65 0.7%	0 0.0%	43 0.4%	2.9% 97.1%
		100% 0.0%	100% 0.0%	44.2% 55.8%	30.0% 70.0%	0.0% 100%	NaN% NaN%	2.3% 97.7%	55.5% 44.5%
		1	3	4	5	7	9	10	
		Região de referência							

(a) A-terra.

Região estimada	1	1079 11.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	0 0.0%	203 2.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	3	0 0.0%	0 0.0%	2475 26.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	360 3.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	150 1.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	7	0 0.0%	0 0.0%	0 0.0%	937 10.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	8	0 0.0%	0 0.0%	0 0.0%	840 9.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	9	0 0.0%	0 0.0%	0 0.0%	1335 14.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	10	0 0.0%	0 0.0%	0 0.0%	1904 20.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
		100% 0.0%	NaN% NaN%	92.4% 7.6%	6.5% 93.5%	NaN% NaN%	NaN% NaN%	NaN% NaN%	NaN% NaN%	42.2% 57.8%
		1	2	3	5	6	7	8	9	10
		Região de referência								

(b) B-terra.

Região estimada	1	1245 15.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2508 30.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	360 4.4%	0.0% 100%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	932 11.5%	0.0% 100%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.4%	0.0% 100%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1755 21.6%	100% 0.0%
		100% 0.0%	100% 0.0%	NaN% NaN%	NaN% NaN%	NaN% NaN%	40.1% 59.9%	67.7% 32.3%
		1	3	5	7	9	10	
		Região de referência						

(c) C-terra.

Gráficos dos testes considerando a presença de erros na medição

Figura 75 – Gráficos *box plot* dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a presença de erro na medição.

Figura 76 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a presença de erro na medição.

Figura 77 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a presença de erro na medição.

Figura 78 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando a presença de erro na medição.

Gráficos do teste considerando 4 medidores
otimamente posicionados

Figura 80 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando 4 medidores otimamente alocados.

Região estimada	1	1091 10.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2429 23.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	2253 21.8%	27 0.3%	0 0.0%	0 0.0%	0 0.0%	98.8% 1.2%
	5	0 0.0%	0 0.0%	8 0.1%	352 3.4%	0 0.0%	0 0.0%	0 0.0%	97.8% 2.2%
	7	0 0.0%	0 0.0%	0 0.0%	53 0.5%	817 7.9%	75 0.7%	0 0.0%	86.5% 13.5%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 12.9%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1904 18.4%	100% 0.0%
		100% 0.0%	100% 0.0%	99.6% 0.4%	81.5% 18.5%	100% 0.0%	94.7% 5.3%	100% 0.0%	98.4% 1.6%
		1	3	4	5	7	9	10	
		Região de referência							

(a) A-terra.

Região estimada	1	1079 11.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	148 1.6%	55 0.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	72.9% 27.1%
	3	0 0.0%	0 0.0%	2475 26.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	360 3.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	116 1.2%	34 0.4%	0 0.0%	0 0.0%	77.3% 22.7%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	17 0.2%	845 9.1%	15 0.2%	60 0.6%	90.2% 9.8%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	830 8.9%	10 0.1%	98.8% 1.2%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	47 0.5%	1288 13.9%	96.5% 3.5%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1904 20.5%
		100% 0.0%	100% 0.0%	97.8% 2.2%	100% 0.0%	87.2% 12.8%	96.1% 3.9%	93.0% 7.0%	94.8% 5.2%	100% 0.0%
		1	2	3	5	6	7	8	9	10
		Região de referência								

(b) B-terra.

Região estimada	1	1245 15.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2508 30.8%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	360 4.4%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	853 10.5%	79 1.0%	91.5% 8.5%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.4%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	33 0.4%	1722 21.2%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	92.3% 7.7%	100% 0.0%
		1	3	5	7	9	10
		Região de referência					

(c) C-terra.

Gráficos do teste considerando 4 medidores
não otimamente posicionados

Figura 81 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando 4 medidores não otimamente alocados.

Região estimada	1	1091 10.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2429 23.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	2253 21.8%	27 0.3%	0 0.0%	0 0.0%	0 0.0%	98.8% 1.2%
	5	0 0.0%	0 0.0%	8 0.1%	352 3.4%	0 0.0%	0 0.0%	0 0.0%	97.8% 2.2%
	7	0 0.0%	0 0.0%	0 0.0%	53 0.5%	817 7.9%	75 0.7%	0 0.0%	86.5% 13.5%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 12.9%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1904 18.4%	100% 0.0%
		100% 0.0%	100% 0.0%	99.6% 0.4%	81.5% 18.5%	100% 0.0%	94.7% 5.3%	100% 0.0%	98.4% 1.6%
		1	3	4	5	7	9	10	
		Região de referência							

(a) A-terra.

Região estimada	1	1079 11.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	148 1.6%	55 0.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	72.9% 27.1%
	3	0 0.0%	0 0.0%	2475 26.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	360 3.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	116 1.2%	34 0.4%	0 0.0%	0 0.0%	77.3% 22.7%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	17 0.2%	845 9.1%	15 0.2%	60 0.6%	90.2% 9.8%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	830 8.9%	10 0.1%	98.8% 1.2%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	47 0.5%	1288 13.9%	96.5% 3.5%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1904 20.5%
		100% 0.0%	100% 0.0%	97.8% 2.2%	100% 0.0%	87.2% 12.8%	96.1% 3.9%	93.0% 7.0%	94.8% 5.2%	100% 0.0%
		1	2	3	5	6	7	8	9	10
		Região de referência								

(b) B-terra.

Região estimada	1	1245 15.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2508 30.8%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	360 4.4%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	853 10.5%	79 1.0%	91.5% 8.5%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.4%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	33 0.4%	1722 21.2%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	92.3% 7.7%	98.1% 1.9%
		1	3	5	7	9	10
		Região de referência					

(c) C-terra.

Gráficos do teste considerando uma taxa amostral de 128 amostras/ciclo

Figura 82 – Gráficos *box plot* dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 128 amostras/ciclo.

Figura 83 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 128 amostras/ciclo.

Figura 84 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 128 amostras/ciclo.

Figura 85 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 128 amostras/ciclo.

Figura 86 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 128 amostras/ciclo.

Região estimada	1	1091 10.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2429 23.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	1887 18.3%	0 0.0%	393 3.8%	0 0.0%	0 0.0%	82.8% 17.2%
	5	0 0.0%	0 0.0%	63 0.6%	240 2.3%	57 0.6%	0 0.0%	0 0.0%	66.7% 33.3%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	870 8.4%	75 0.7%	0 0.0%	92.1% 7.9%
	9	0 0.0%	0 0.0%	4 0.0%	0 0.0%	8 0.1%	1323 12.8%	0 0.0%	99.1% 0.9%
	10	0 0.0%	0 0.0%	21 0.2%	0 0.0%	42 0.4%	0 0.0%	1829 17.7%	96.7% 3.3%
		100% 0.0%	100% 0.0%	95.5% 4.5%	100% 0.0%	63.5% 36.5%	94.6% 5.4%	100% 0.0%	93.6% 6.4%
		1	3	4	5	7	9	10	
		Região de referência							

(a) A-terra.

Região estimada	1	1079 11.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	84 0.9%	119 1.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	41.4% 58.6%
	3	0 0.0%	0 0.0%	2475 26.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	360 3.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	116 1.2%	34 0.4%	0 0.0%	0 0.0%	77.3% 22.7%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	17 0.2%	845 9.1%	15 0.2%	60 0.6%	90.2% 9.8%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	516 5.6%	324 3.5%	61.4% 38.6%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	59 0.6%	1276 13.7%	0 0.0%	95.6% 4.4%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1904 20.5%	100% 0.0%
		100% 0.0%	100% 0.0%	95.4% 4.6%	100% 0.0%	87.2% 12.8%	96.1% 3.9%	87.5% 12.5%	76.9% 23.1%	100% 0.0%
		1	2	3	5	6	7	8	9	10
		Região de referência								

(b) B-terra.

Região estimada	1	1245 15.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2508 30.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	360 4.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	834 10.3%	98 1.2%	0 0.0%	89.5% 10.5%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.4%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	30 0.4%	1725 21.2%	98.3% 1.7%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	91.3% 8.7%	100% 0.0%	98.4% 1.6%
		1	3	5	7	9	10	
		Região de referência						

(c) C-terra.

Gráficos do teste considerando uma taxa amostral de 64 amostras/ciclo

Figura 87 – Gráficos *box plot* dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 64 amostras/ciclo.

Figura 88 – Histograma dos erros de estimação da distância da falta para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 64 amostras/ciclo.

Figura 89 – Distribuição dos erros de estimação da distância da falta para impedância de falta de 5Ω , 25Ω e 45Ω , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 64 amostras/ciclo.

Figura 90 – Distribuição dos erros de estimação da distância da falta para ângulo de incidência de falta de 15° , 45° e 75° , e para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 64 amostras/ciclo.

Figura 91 – Matrizes de confusão para os tipos de falta fase A-terra, fase B-terra e fase C-terra considerando uma taxa amostral de 64 amostras/ciclo.

Região estimada	1	1091 11.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2429 25.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	1078 11.4%	371 3.9%	831 8.8%	0 0.0%	0 0.0%	47.3% 52.7%
	5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	347 3.7%	13 0.1%	0 0.0%	0.0% 100%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	945 10.0%	0 0.0%	0.0% 100%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	452 4.8%	883 9.3%	33.9% 66.1%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1021 10.8%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	0.0% 100%	0.0% 100%	32.1% 67.9%	53.6% 46.4%	64.2% 35.8%
		1	3	4	5	7	9	10	
		Região de referência							

(a) A-terra.

Região estimada	1	1079 11.6%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	116 1.2%	87 0.9%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	57.1% 42.9%
	3	0 0.0%	0 0.0%	2475 26.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	0 0.0%	351 3.8%	4 0.0%	5 0.1%	0 0.0%	0 0.0%	97.5% 2.5%
	6	0 0.0%	0 0.0%	0 0.0%	70 0.8%	59 0.6%	21 0.2%	0 0.0%	0 0.0%	39.3% 60.7%
	7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	17 0.2%	808 8.7%	48 0.5%	64 0.7%	86.2% 13.8%
	8	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	504 5.4%	336 3.6%	60.0% 40.0%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	59 0.6%	1276 13.7%	95.6% 4.4%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1904 20.5%
		100% 0.0%	100% 0.0%	96.6% 3.4%	83.4% 16.6%	73.8% 26.2%	96.9% 3.1%	82.5% 17.5%	76.1% 23.9%	100% 0.0%
		1	2	3	5	6	7	8	9	10
		Região de referência								

(b) B-terra.

Região estimada	1	1245 15.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	2508 30.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	5	0 0.0%	0 0.0%	360 4.4%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	7	0 0.0%	0 0.0%	0 0.0%	889 10.9%	43 0.5%	0 0.0%	95.4% 4.6%
	9	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1335 16.4%	0 0.0%	100% 0.0%
	10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	98 1.2%	1657 20.4%	94.4% 5.6%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	90.4% 9.6%	100% 0.0%	98.3% 1.7%
		1	3	5	7	9	10	
		Região de referência						

(c) C-terra.

Referências

ANEEL. **Procedimentos de distribuição de energia elétrica no sistema elétrico nacional - Prodist**. [S.l.]: Módulo, módulo 08, resolução normativa n 728/2016.2017.

BÍSCARO, A. d. A. P. **Proposta de Algoritmos Inteligentes para Localizar Falhas e Monitorar a Qualidade da Energia em Redes de Distribuição de Energia Elétrica**. [S.l.]: Universidade Estadual Paulista (UNESP), 2013.

BUNJONGJIT, S.; NGAOPITAKKUL, A.; POTHISARN, C. A discrete wavelet transform and fuzzy logic algorithm for identifying the location of fault in underground distribution system. In: IEEE. **2013 International Conference on Fuzzy Theory and Its Applications (iFUZZY)**. [S.l.], 2013. p. 415–419.

DEHGHANI, F.; NEZAMI, H. A new fault location technique on radial distribution systems using artificial neural network. In: IET. **Electricity Distribution (CIRED 2013), 22nd International Conference and Exhibition on**. [S.l.], 2013. p. 1–4.

FALVO, M. C. et al. Technologies for smart grids: a brief review. In: IEEE. **Environment and Electrical Engineering (EEEIC), 2013 12th International Conference on**. [S.l.], 2013. p. 369–375.

FEEDERS, D. T. **IEEE PES Distribution System Analysis Subcommittee's, Distribution Test Feeder Working Group**. 2013.

FESTA, A. V. **Diagnóstico de curtos-circuitos a partir da alocação otimizada de medidores em um sistema de distribuição subterrâneo**. 2015. Dissertação (Mestrado) — Universidade de São Paulo, 2015.

FUCHS, E.; MASOUM, M. A. **Power quality in power systems and electrical machines**. [S.l.]: Academic press, 2011.

GAO, C.; REDFERN, M. A review of voltage control in smart grid and smart metering technologies on distribution networks. In: VDE. **Universities' Power Engineering Conference (UPEC), Proceedings of 2011 46th International**. [S.l.], 2011. p. 1–5.

GHORBANI, J.; CHOUDHRY, M. A.; FELIACHI, A. Fault location and isolation using multi agent systems in power distribution systems with distributed generation sources. In: IEEE. **Innovative Smart Grid Technologies (ISGT), 2013 IEEE PES**. [S.l.], 2013. p. 1–6.

GILBERT, D.; MORRISON, I. A statistical method for the detection of power system faults. **International Journal of Electrical Power & Energy Systems**, Elsevier, v. 19, n. 4, p. 269–275, 1997.

GOEL, N.; AGARWAL, M. Smart grid networks: A state of the art review. In: IEEE. **Signal Processing and Communication (ICSC), 2015 International Conference on**. [S.l.], 2015. p. 122–126.

GOMES, D. P. S. **Metodologia e simplificação do espaço de busca para a alocação de medidores de qualidade da energia elétrica frente às variações de tensão de curta duração**. 2016. Dissertação (Mestrado) — Universidade de São Paulo, 2016.

HAMIDI, V.; SMITH, K. S.; WILSON, R. C. Smart grid technology review within the transmission and distribution sector. In: IEEE. **2010 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT Europe)**. [S.l.], 2010. p. 1–8.

IURINIC, L. et al. Distribution systems high impedance fault location: a parameter estimation approach. IEEE, 2015.

JAMES, G. et al. **An introduction to statistical learning: with applications in R**. [S.l.]: Springer Science & Business Media, 2013. v. 103.

KEMPNER, T. R. **A robustez de um sistema de distribuição e a alocação de medidores de qualidade da energia elétrica frente aos afundamentos de tensão**. 2012. Dissertação (Mestrado) — Universidade de São Paulo, 2012.

KERSTING, W. H. Radial distribution test feeders. In: IEEE. **Power Engineering Society Winter Meeting, 2001. IEEE**. [S.l.], 2001. v. 2, p. 908–912.

KHAN, H. A. et al. Review of technologies and implementation strategies in the area of smart grid. In: IEEE. **Power Engineering Conference, 2009. AUPEC 2009. Australasian Universities**. [S.l.], 2009. p. 1–6.

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

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. **IET Generation, Transmission & Distribution**, IET, v. 6, n. 12, p. 1225–1234, 2012.

MATLAB, M. The language of technical computing. **The MathWorks, Inc.** <http://www.mathworks.com>, 2012.

MIRZAEI, M. et al. Review of fault location methods for distribution power system. **Australian Journal of Basic and Applied Sciences**, American-Eurasian Network for Scientific Information, v. 3, n. 3, p. 2670–2676, 2009.

MITCHELL, T. M. et al. **Machine learning**. WCB. [S.l.]: McGraw-Hill Boston, MA:, 1997.

- NAIDU, O.; GEORGE, N.; ASHOK, S. An accurate fault location method for radial distribution system using one terminal data. In: IEEE. **Advancements in Power and Energy (TAP Energy), 2015 International Conference on**. [S.l.], 2015. p. 187–192.
- PANESSO-HERNÁNDEZ, A.; CADENA-ZAPATA, J.; MORA-FLÓREZ, J. Location of shunt faults in radial power distribution systems considering capacitive effect and non-homogeneous lines. In: IEEE. **Transmission & Distribution Conference and Exposition-Latin America (PES T&D-LA), 2014 IEEE PES**. [S.l.], 2014. p. 1–6.
- PAUL, S. et al. A review of smart technology (smart grid) and its features. In: IEEE. **Non Conventional Energy (ICONCE), 2014 1st International Conference on**. [S.l.], 2014. p. 200–203.
- PRIKLER, L.; HOIDALEN, H. **ATPDRAW manual**. [S.l.]: S, 2002.
- RAIMUNDO, L. R. et al. O algoritmo de classificação cart em uma ferramenta de data mining. **Anais SULCOMP**, v. 4, 2008.
- RAY, P.; MISHRA, D. P.; PANDA, D. D. Hybrid technique for fault location of a distribution line. In: IEEE. **2015 Annual IEEE India Conference (INDICON)**. [S.l.], 2015. p. 1–6.
- SAHA, M. et al. A new accurate fault locating algorithm for series compensated lines. **IEEE Transactions on Power Delivery**, IEEE, v. 14, n. 3, p. 789–797, 1999.
- SAHA, M. M.; IZYKOWSKI, J. J.; ROSOLOWSKI, E. **Fault location on power networks**. [S.l.]: Springer Science & Business Media, 2009.
- _____. **Fault location on power networks**. [S.l.]: Springer Science & Business Media, 2009.
- SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas curso prático. **Artliber**, SciELO Brasil, 2010.
- SOUTO, L.; MANASSERO, G.; SANTO, S. G. D. Fault location in distribution feeders with distributed generation. In: IEEE. **2016 Clemson University Power Systems Conference (PSC)**. [S.l.], 2016. p. 1–6.
- TONG, Z. et al. A fault location method for active distribution network with renewable sources based on bp neural network. In: IEEE. **Intelligent Human-Machine Systems and Cybernetics (IHMSC), 2015 7th International Conference on**. [S.l.], 2015. v. 1, p. 357–361.
- TRINDADE, F. C.; FREITAS, W.; VIEIRA, J. C. Fault location in distribution systems based on smart feeder meters. **IEEE Transactions on Power Delivery**, IEEE, v. 29, n. 1, p. 251–260, 2014.
- VIANNA, J. T. A.; ARAUJO, L. R.; PENIDO, D. R. R. High impedance fault area location in distribution systems based on current zero sequence component. **IEEE Latin America Transactions**, IEEE, v. 14, n. 2, p. 759–766, 2016.
- ZAPATA-TAPASCO, A.; MORA-FLÓREZ, J.; ALMEIDA, M. C. de. Fault location in power distribution systems using a learning approach based on decision trees. In: IEEE. **Transmission & Distribution Conference and Exposition-Latin America (PES T&D-LA), 2014 IEEE PES**. [S.l.], 2014. p. 1–6.

ZAYANDEHROODI, H. et al. New training strategies for rbf neural networks to determine fault location in a distribution network with dg units. In: IEEE. **Power Engineering and Optimization Conference (PEOCO), 2013 IEEE 7th International**. [S.l.], 2013. p. 450–454.