

Universidade Federal de Juiz De Fora
Faculdade de Engenharia
Programa de Pós-Graduação em Engenharia Elétrica

Luciana Carvalho Acácio

**ALOCAÇÃO ÓTIMA DE MEDIDORES PARA FINS DE DETECÇÃO DE
FALHAS**

Juiz de Fora

2017

Luciana Carvalho Acácio

ALOCAÇÃO ÓTIMA DE MEDIDORES PARA FINS DE DETECÇÃO DE FALHAS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, na área de concentração em Sistema de Energia Elétrica, como parte dos requisitos para obtenção do título de Mestre em Ciências em Engenharia Elétrica.

Orientadora: Débora Rosana Ribeiro Penido Araujo
Coorientador: Leandro Ramos de Araujo

Juiz de Fora

2017

Acácio, Luciana Carvalho.

ALOCAÇÃO ÓTIMA DE MEDIDORES PARA FINS DE
DETECÇÃO DE FALHAS / Luciana Carvalho Acácio. -- 2017.
138 f. : il.

Orientadora: Débora Rosana Ribeiro Penido Araujo

Coorientador: Leandro Ramos Araujo

Dissertação (mestrado acadêmico) - Universidade Federal de
Juiz de Fora, Faculdade de Engenharia. Programa de Pós
Graduação em Engenharia Elétrica, 2017.

1. Introdução. 2. Definições e Fundamentação Teórica. 3. Método
para Alocação Otimizada de Equipamentos de Medição para
Detecção de Falhas. 4. Resultados. 5. Conclusões. I. Araujo, Débora
Rosana Ribeiro Penido , orient. II. Araujo, Leandro Ramos, coorient.
III. Título.

Luciana Carvalho Acácio

ALOCAÇÃO ÓTIMA DE MEDIDORES PARA FINS DE DETECÇÃO DE FALHAS

Dissertação Apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, na área de concentração em Sistema de Energia Elétrica, como parte dos requisitos para obtenção do título de Mestre em Ciências em Engenharia Elétrica.

Aprovada em 25/08/2017.

BANCA EXAMINADORA:

Prof. Débora Rosana Ribeiro Penido Araujo, D.Sc
Universidade Federal de Juiz de Fora

Prof. Leandro Ramos de Araujo, D.Sc
Universidade Federal de Juiz de Fora

Prof. Vander Menengoy da Costa, D.Sc.
Universidade Federal de Juiz de Fora

Prof. Vitor Hugo Ferreira, D. Sc.
Universidade Federal Fluminense

AGRADECIMENTOS

Agradeço primeiramente a Deus, que sempre me proporcionou tudo que tenho de melhor até hoje. Agradeço às dificuldades colocadas durante minha trajetória, pois cresci e evolui com cada uma delas.

Agradeço aos meus orientadores, Profa. Débora e ao Prof. Leandro, que acreditaram no meu potencial em um momento turbulento da minha vida. Ressalto que mesmo à distância, vocês conseguiram me orientar de uma forma excepcional.

Agradeço ao meu esposo Thiago, que foi essencial nessa minha caminhada. Só você sabe o quanto foi difícil para mim, o quanto abdiquei de lazeres. Se estou concluindo esta etapa, devo muito a você.

Agradeço a minha mãe por sempre estar ao meu lado em todos os momentos da minha vida, me dando suporte para que eu chegasse até aqui. Obrigada por acreditar em mim nos momentos que eu mesma duvidei da minha capacidade intelectual e emocional. Suas palavras foram fundamentais para eu concluir essa etapa.

Agradeço ao meu pai, que mesmo não estando presente fisicamente neste momento, me incentivou desde antes da conclusão da graduação a iniciar o mestrado. Nos momentos mais difíceis lembrei que esta é a realização de um sonho dele, e por isso, estou muito feliz em conseguir finalizar essa etapa.

As minhas irmãs, Letícia e Larissa, por sempre me ajudarem nos momentos difíceis da minha vida, seja com ações ou com conselhos.

Aos amigos do Mestrado, com quem compartilhei minhas dificuldades, realizei diversos trabalhos e assisti várias aulas.

À Coordenadoria de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro dado a este trabalho.

Ao Povo Brasileiro que indiretamente ou diretamente financiou este trabalho.

Resumo da Dissertação apresentada ao PPEE/UFJF como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

ALOCAÇÃO ÓTIMA DE MEDIDORES PARA FINS DE DETECÇÃO DE FALHAS

Luciana Carvalho Acácio

Agosto / 2017

Orientadores: Profa. Débora Rosana Ribeiro Penido Araujo

Prof. Leandro Ramos de Araujo

Programa: Engenharia Elétrica

Este trabalho propõe um método baseado em algoritmos genéticos para alocação ótima de medidores na rede. A partir da alocação dos medidores, é verificada a assertividade alcançada na detecção de defeitos monofásicos, por área, com impedância na média tensão de sistemas de distribuição. Assim, é avaliado o desempenho da metodologia de alocação ótima dos medidores. A saída do algoritmo, indica as posições que os medidores devem ser alocados, que formarão as respectivas áreas de observações para detecção. Para realizar a detecção de defeitos em sistemas de distribuição foi desenvolvido também um método utilizando redes neurais artificiais, que é utilizado como rotina interna do método de alocação de medidores, onde as entradas são grandezas elétricas de tensão e corrente, podendo ser medições fasoriais e/ou não-fasoriais, oriundas dos medidores definidos no método de alocação. Esta variação de tipos de medições serviu para analisar o desempenho na detecção do defeito do emprego de diferentes tipos de equipamentos de medição. A escolha da detecção de defeitos monofásicos é baseada no fato de que estes são a grande maioria nos sistemas de distribuição. O método desenvolvido consegue detectar defeitos monofásicos com resistência de arco variando entre 0 a 200 ohms, considerando ainda, variação do carregamento do sistema.

O método proposto para alocação, bem como a rotina para detecção de falhas foi desenvolvido no ambiente MatLab®. Os testes foram realizados em sistemas do IEEE, apresentando bons resultados.

Palavras-chave: Algoritmo genético. Rede neural artificial. Sistemas de distribuição. Detecção e localização de falta de alta impedância. Medições fasoriais e não fasoriais.

Abstract of Thesis presented to PPEE/UFJF as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

OPTIMUM DISTRIBUTION OF MEASUREMENT UNITS AIMING FAULT
DETECTION

Luciana Carvalho Acácio

Agosto / 2017

Advisors: Profa. Débora Rosana Ribeiro Penido Araujo

Prof. Leandro Ramos de Araujo

Department: Electrical Engineering

The proposal of this work is to develop a method based on genetic algorithms for optimal allocation of measurements units the distribution grid, which aims to detect monophasic defects with impedance in the medium voltage of distribution systems. The detection is performed by artificial neural networks. The developed methodology for optimal distribution of meters indicates as output the positions that the units should be allocated, creating detection areas. Artificial neural networks were used to perform fault detection in distribution systems, which is an internal routine of the measurement units distribution method. The inputs of the artificial neural networks are voltage and current. These electrical parameters can be either phasor measurements and/or non-phasor, depending on the category of meters defined in the allocation algorithm. The performance of different types of measurement equipment was executed by the analysis of different measurement types. It was selected single-phase defects due to the fact that these are the vast majority of faults in distribution systems. The developed method is able to identify single-phase defects with arc resistance ranging from 0 to 200 ohms, and it is also capable of correctly detect faults when considering load variation.

The method of measurement unit allocation and the fault detection algorithm were developed in the software MatLab®. Tests were performed in IEEE systems, presenting good results.

Index-terms: Genetic algorithm. Artificial neural network. Distribution systems. Detection and location of high impedance faults. Phasor and non-phasor measurements

SUMÁRIO

LISTA DE FIGURAS.....	xi
LISTA DE TABELAS	xiii
Capítulo 1 Introdução.....	1
1.1 Contextualização.....	1
1.2 Motivações	2
1.3 Revisão Bibliográfica.....	5
1.3.1 Análise de Defeitos.....	5
1.3.2 Identificação e Localização de Falhas	6
1.4 Objetivos do Trabalho.....	9
1.5 Publicações Relacionadas ao Trabalho.....	9
1.6 Estrutura do Trabalho	10
1.7 Convenções e Nomenclaturas Utilizadas	10
Capítulo 2 Definições e Fundamentação Teórica	11
2.1 Considerações Iniciais	11
2.2 Redes Neurais.....	11
2.2.1 Modelo Geral de Redes Neurais Artificiais	12
2.2.2 Principais Tipos de Função de Ativação.....	14
2.2.3 Principais Tipos de Arquitetura de Rede Neural	15
2.2.4 Processo de Aprendizagem – Treinamento	18
2.3 Algoritmo Genético.....	19
2.3.1 Nomenclatura	20
2.3.2 Operadores Genéticos.....	21
2.3.2.1 Recombinação.....	21
2.3.2.2 Mutação	22
2.3.2.3 Seleção.....	23
2.4 Medidores Fasoriais e Não-Fasoriais	23
2.4.1 Medidores Fasoriais.....	24
2.4.2 Medições Não Fasoriais.....	25
2.5 Rede de Distribuição.....	28
Capítulo 3 Método para Alocação Otimizada de Equipamentos de Medição para Detecção de Falhas.....	31
3.1 Introdução	31
3.2 Problema Proposto	32
3.3 Método Proposto para a Solução do Problema.....	34
3.3.1 Módulo Base de Dados.....	35
3.3.2 Módulo de Otimização - Algoritmos Genéticos	38
3.3.3 Função Fitness	42
3.3.4 Módulo para separar área.....	49
Capítulo 4 Resultados	51
4.1 Introdução	51
4.2 Testes com o Sistema IEEE13 – Não Fasorial (RMS).....	56
4.2.1 IEEE13 – Não Fasorial (RMS) - Topologia (i).....	57
4.2.1.1 IEEE13 – Não Fasorial (RMS) - Topologia (i) - Carga Fixa	57

4.2.1.2	IEEE13 – Não Fasorial (RMS) - Topologia (i) - Carga Variável	62
4.2.2	IEEE13 – Não Fasorial (RMS) - Topologia (ii).....	67
4.2.2.1	IEEE13 – Não Fasorial (RMS) - Topologia (ii) - Carga Fixa	67
4.2.2.2	IEEE13 – Não Fasorial (RMS) - Topologia (ii) – Carga Variável.....	71
4.2.3	IEEE13 – Não Fasorial (RMS) - Topologia (iii)	76
4.2.3.1	IEEE13 – Não Fasorial (RMS) - Topologia (iii) – Carga Fixa	76
4.2.3.2	IEEE13 – Não Fasorial (RMS) - Topologia (iii) – Carga Variável.....	76
4.3	Testes com o Sistema IEEE13 – Fasorial (Sequência)	81
4.3.1	IEEE13 – Fasorial (Sequência) - Topologia (i)	81
4.3.1.1	IEEE13 – Fasorial (Sequência) - Topologia (i) – Carga Fixa	81
4.3.1.2	IEEE13 – Fasorial (Sequência) - Topologia (i) – Carga Variável	81
4.3.2	IEEE13 – Fasorial (Sequência) - Topologia (ii)	86
4.3.2.1	IEEE13 – Fasorial (Sequência) - Topologia (ii) – Carga Fixa	86
4.3.2.2	IEEE13 – Fasorial (Sequência) - Topologia (ii) – Carga Variável	86
4.3.3	IEEE13 – Fasorial (Sequência) - Topologia (iii).....	91
4.3.3.1	IEEE13 – Fasorial (Sequência) - Topologia (iii) – Carga Fixa.....	91
4.3.3.2	IEEE13 – Fasorial (Sequência) - Topologia (iii) – Carga Variável	91
4.4	Testes com o Sistema IEEE13 – Fasorial (PMU)	97
4.4.1	IEEE13 – Fasorial (PMU) - Topologia (i)	97
4.4.1.1	IEEE13 – Fasorial (PMU) - Topologia (i) – Carga Fixa.....	97
4.4.1.2	IEEE13 – Fasorial (PMU) - Topologia (i) – Variável.....	97
4.4.2	IEEE13 – Fasorial (PMU) - Topologia (ii).....	102
4.4.2.1	IEEE13 – Fasorial (PMU) - Topologia (ii) – Carga Fixa.....	102
4.4.2.2	IEEE13 – Fasorial (PMU) - Topologia (ii) – Carga Variável	103
4.4.3	IEEE13 – Fasorial (PMU) - Topologia (iii).....	107
4.4.3.1	IEEE13 – Fasorial (PMU) - Topologia (iii) – Carga Fixa.....	107
4.4.3.2	IEEE13 – Fasorial (PMU) - Topologia (iii) – Carga Variável	107
4.5	Constatações pelas comparações entre as situações analisadas do sistema IEEE13 ..	112
4.6	Testes com o Sistema IEEE123.....	115
4.7	Constatações pelas comparações entre as situações analisadas do sistema IEEE123	120
Capítulo 5	Conclusões	121
5.1	Considerações Finais	121
5.2	Sugestões de Trabalhos Futuros.....	122

LISTA DE FIGURAS

Figura 1 - Acompanhamento DEC e FEC no Brasil (ANEEL, 2017).....	2
Figura 2 - Esquema de um Neurônio Biológico, (DA SILVA RAYBOLT, 2011).....	12
Figura 3 - Modelo de um Neurônio Artificial, (DA SILVA RAYBOLT, 2011).....	13
Figura 4 - Função Degrau, (DA SILVA RAYBOLT, 2011).....	14
Figura 5 - Função Linear por Parte, (DA SILVA RAYBOLT, 2011).....	14
Figura 6 - Função Sigmoide, (DA SILVA RAYBOLT, 2011).....	15
Figura 7 - Modelo de Rede Alimentada com uma Camada, (DA SILVA RAYBOLT, 2011).....	16
Figura 8 - Modelo de Rede Alimentada Adiante com Múltiplas Camadas, (DA SILVA RAYBOLT, 2011).....	17
Figura 9 - Modelo de Rede Recorrente, (DA SILVA RAYBOLT, 2011).....	17
Figura 10 - Aprendizado Supervisionado, (DINIZ, 2015).....	18
Figura 11 - Aprendizado Não Supervisionado, (DINIZ, 2015).....	19
Figura 12 - Procedimento Básico, (WESTPHAL, 2006).....	20
Figura 13 - Recombinação Ponto Único, (CASTILHO, 2003).....	21
Figura 14 - Recomposição Multiponto, (CASTILHO, 2003).....	22
Figura 15 - Exemplo de Mutação, (CASTILHO, 2003).....	23
Figura 16 - Representação de um sistema de medição fasorial sincronizado via GPS, (PIRES; BORBA, 2006).....	24
Figura 17 - Esquema Comunicação GPRS.....	27
Figura 18 - Esquema Comunicação Rádio.....	27
Figura 19 - Esquema Comunicação BGAN.....	28
Figura 20 - Esquema sistema de distribuição (NASCIMENTO, 2017).....	29
Figura 21 - Representação do tipo de defeito, (GIMENEZ, 2016).....	32
Figura 22 - Áreas de observação dos medidores, (GIMENEZ, 2016).....	33
Figura 23 - Fluxograma Básico.....	35
Figura 24 - Módulo da Criação de Base de Dados.....	36
Figura 25 - Exemplo da base de dados.....	37
Figura 26 - Módulo de Otimização.....	39
Figura 27 - Cromossomo Proposto – Exemplo.....	40
Figura 28 - Áreas formadas a partir do cromossomo – Exemplo.....	41
Figura 29 - Função Fitness.....	44
Figura 30 - Definição das Redes Neurais.....	45
Figura 31 - Possíveis resultados de uma rede neural (PENIDO et al., 2013).....	46
Figura 32 - Módulo para separar área.....	49
Figura 33 - Atualização das áreas.....	50
Figura 34 - IEEEE13 / RMS / Carga Fixa / Nada no primário - AOM 2 Medidores.....	57
Figura 35 - IEEEE13 / RMS / Carga Fixa / Nada no primário / 2 Medidores - Resultados.....	58
Figura 36 - IEEEE13 / RMS / Carga Fixa / Nada no primário - AOM 3 Medidores.....	59
Figura 37 - IEEEE13 / RMS / Carga Fixa / Nada no primário / 3 Medidores - Resultados.....	59
Figura 38 - IEEEE13 / RMS / Carga Fixa / Nada no primário - AOM 7 Medidores.....	60
Figura 39 - IEEEE13 / RMS / Carga Fixa / Nada no primário / 7 Medidores - Resultados.....	61
Figura 40 - IEEEE13 / RMS / Carga Variável/ Nada no primário - AOM 2 Medidores.....	62
Figura 41 - IEEEE13 / RMS / Carga Variável / Nada no primário / 2 Medidores - Resultados.....	63
Figura 42 - IEEEE13 / RMS / Carga Variável / Nada no primário - AOM 3 Medidores.....	64
Figura 43 - IEEEE13 / RMS / Carga Variável / Nada no primário / 3 Medidores - Resultados por área.....	64
Figura 44 - IEEEE13 / RMS / Variável/ Nada no primário - AOM 7 Medidores.....	65
Figura 45 - IEEEE13 / RMS / Carga Variável / Nada no primário / 7 Medidores - Resultados por área.....	66
Figura 46 - IEEEE13 / RMS / Carga Fixa / Capacitor no primário - AOM 2 Medidores.....	67
Figura 47 - IEEEE13 / RMS / Carga Fixa / Capacitor no primário / 2 Medidores - Resultados.....	68
Figura 48 - IEEEE13 / RMS / Carga Fixa / Capacitor no primário - AOM 3 Medidores.....	69
Figura 49 - IEEEE13 / RMS / Carga Fixa / Capacitor no primário / 3 Medidores - Resultados.....	69
Figura 50 - IEEEE13 / RMS / Carga Fixa / Capacitor no primário - AOM 7 Medidores.....	70
Figura 51 - IEEEE13 / RMS / Carga Fixa / Capacitor no primário / 7 Medidores – Resultados.....	70
Figura 52 - IEEEE13 / RMS / Carga Variável / Capacitor no primário - AOM 2 Medidores.....	71

Figura 53 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 2 Medidores – Resultados.....	72
Figura 54 - IEEE13 / RMS / Carga Variável / Capacitor no primário - AOM 3 Medidores	73
Figura 55 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 3 Medidores - Resultados	73
Figura 56 - IEEE13 / RMS / Carga Variável / Capacitor no primário - AOM 7 Medidores	74
Figura 57 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 7 Medidores - Resultados por área	75
Figura 58 - IEEE13 / RMS / Carga Variável / Tudo no primário - AOM 2 Medidores	76
Figura 59 - IEEE13 / RMS / Carga Variável / Tudo no primário / 2 Medidores - Resultados	77
Figura 60 - IEEE13 / RMS / Carga Variável / Tudo no primário - AOM 3 Medidores	78
Figura 61 - IEEE13 / RMS / Carga Variável / Tudo no primário / 3 Medidores - Resultados	78
Figura 62 - IEEE13 / RMS / Carga Variável / Tudo no primário - AOM 7 Medidores	79
Figura 63 - IEEE13 / RMS / Carga Variável / Tudo no primário / 7 Medidores – Resultados	80
Figura 64 - IEEE13 / Sequência / Carga Variável / Nada no primário - AOM 2 Medidores.....	81
Figura 65 - IEEE13 / Sequência / Carga Variável / Nada no primário / 2 Medidores - Resultados	82
Figura 66 - IEEE13 / Sequência / Carga Variável / Nada no primário - AOM 3 Medidores	83
Figura 67 - IEEE13 / Sequência / Carga Variável / Nada no primário / 3 Medidores - Resultados	83
Figura 68 - IEEE13 / Sequência / Carga Variável / Nada no primário / 7 Medidores - Resultados	84
Figura 69 - IEEE13 / Sequência / Carga Variável / Nada no primário / 7 Medidores - Resultados	85
Figura 70 - IEEE13 / Sequência / Carga Variável / Capacitor no primário - AOM 2 Medidores.....	86
Figura 71 – IEEE13 / Sequência / Carga Variável / Capacitor no primário / 2 Medidores - Resultados	87
Figura 72 - IEEE13 / Sequência / Carga Variável / Capacitor no primário - AOM 3 Medidores.....	88
Figura 73 - IEEE13 / Sequência / Carga Variável / Capacitor no primário / 3 Medidores - Resultados.....	89
Figura 74 - IEEE13 / Sequência / Carga Variável / Capacitor no primário - AOM 7 Medidores.....	90
Figura 75 - IEEE13 / Sequência / Carga Variável / Capacitor no primário / 7 Medidores - Resultados.....	90
Figura 76 - IEEE13 / Sequência / Carga Variável / Tudo no primário - AOM 2 Medidores	92
Figura 77 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 2 Medidores - Resultados.....	93
Figura 78 - IEEE13 / Sequência / Carga Variável / Tudo no primário - AOM 3 Medidores	94
Figura 79 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 3 Medidores - Resultados.....	94
Figura 80 - IEEE13 / Sequência / Carga Variável / Tudo no primário - AOM 7 Medidores	95
Figura 81 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 7 Medidores - Resultados.....	96
Figura 82 - IEEE13 / PMU / Carga Variável / Nada no primário - AOM 2 Medidores.....	98
Figura 83 - IEEE13 / PMU / Carga Variável / Nada no primário / 2 Medidores - Resultados.....	98
Figura 84 - IEEE13 / PMU / Carga Variável / Nada no primário - AOM 3 Medidores.....	99
Figura 85 - IEEE13 / PMU / Carga Variável / Nada no primário / 3 Medidores - Resultados.....	100
Figura 86 - IEEE13 / PMU / Carga Variável / Nada no primário - AOM 7 Medidores.....	101
Figura 87 - IEEE13 / PMU / Carga Variável / Nada no primário / 7 Medidores - Resultados.....	101
Figura 88 - IEEE13 / PMU / Carga Variável / Capacitor no primário - AOM 2 Medidores	103
Figura 89 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 2 Medidores - Resultados	104
Figura 90 - IEEE13 / PMU / Carga Variável / Capacitor no primário - AOM 2 Medidores	104
Figura 91 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 3 Medidores - Resultados	105
Figura 92 - IEEE13 / PMU / Carga Variável / Capacitor no primário – AOM 7 Medidores.....	106
Figura 93 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 7 Medidores - Resultados	106
Figura 94 - IEEE13 / PMU / Carga Variável / Tudo no primário - AOM 2 Medidores	108
Figura 95 - IEEE13 / PMU / Carga Variável / Tudo no primário / 2 Medidores - Resultados	108
Figura 96 - IEEE13 / PMU / Carga Variável / Tudo no primário - AOM 3 Medidores	109
Figura 97 - IEEE13 / PMU / Carga Variável / Tudo no primário / 3 Medidores - Resultados	110
Figura 98 - IEEE13 / PMU / Carga Variável / Tudo no primário - AOM 7 Medidores	111
Figura 99 - IEEE13 / PMU / Carga Variável / Tudo no primário / 7 Medidores - Resultados	111
Figura 100 - Sistema IEEE123.....	116
Figura 101 - Simulações Sistemas IEEE123 - 2000 Casos	118
Figura 102 - - Simulações Sistemas IEEE123 - 5000 Casos.....	119

LISTA DE TABELAS

<i>Tabela 1 - Sistemas e cenários analisados.....</i>	<i>52</i>
<i>Tabela 2 - IEEE13 / RMS / Carga Fixa / Nada no primário / 2 Medidores - Resultados por área</i>	<i>58</i>
<i>Tabela 3 - IEEE13 / RMS / Carga Fixa / Nada no primário / 3 Medidores - Resultados por área</i>	<i>60</i>
<i>Tabela 4 - IEEE13 / RMS / Carga Fixa / Nada no primário / 7 Medidores - Resultados por área</i>	<i>61</i>
<i>Tabela 5 IEEE13 / RMS / Carga Variável / Nada no primário / 2 Medidores - Resultados por área</i>	<i>63</i>
<i>Tabela 6 - IEEE13 / RMS / Carga Variável / Nada no primário / 3 Medidores - Resultados por área.....</i>	<i>65</i>
<i>Tabela 7 - IEEE13 / RMS / Carga Variável / Nada no primário / 7 Medidores - Resultados por área.....</i>	<i>66</i>
<i>Tabela 8 - IEEE13 / RMS / Carga Fixa / Capacitor no primário / 2 Medidores - Resultados por área.....</i>	<i>68</i>
<i>Tabela 9 - IEEE13 / RMS / Carga Fixa / Capacitor no primário / 3 Medidores - Resultados por área.....</i>	<i>69</i>
<i>Tabela 10 - IEEE13 / RMS / Carga Fixa / Capacitor no primário / 7 Medidores - Resultados por área.....</i>	<i>71</i>
<i>Tabela 11 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 2 Medidores - Resultados por área</i>	<i>72</i>
<i>Tabela 12 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 3 Medidores - Resultados por área</i>	<i>74</i>
<i>Tabela 13 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 7 Medidores - Resultados por área</i>	<i>75</i>
<i>Tabela 14 - IEEE13 / RMS / Carga Variável / Tudo no primário / 2 Medidores - Resultados por área</i>	<i>77</i>
<i>Tabela 15 - IEEE13 / RMS / Carga Variável / Tudo no primário / 3 Medidores - Resultados por área</i>	<i>79</i>
<i>Tabela 16 - IEEE13 / RMS / Carga Variável / Tudo no primário / 7 Medidores - Resultados por área</i>	<i>80</i>
<i>Tabela 17 - IEEE13 / Sequência / Carga Variável / Nada no primário / 2 Medidores - Resultados por área</i>	<i>82</i>
<i>Tabela 18 - IEEE13 / Sequência / Carga Variável / Nada no primário / 3 Medidores - Resultados por área</i>	<i>84</i>
<i>Tabela 19 - IEEE13 / Sequência / Carga Variável / Nada no primário / 7 Medidores - Resultados por área</i>	<i>85</i>
<i>Tabela 20 - IEEE13 / Sequência / Carga Variável / Capacitor no primário / 2 Medidores - Resultados por área</i>	<i>87</i>
<i>Tabela 21 - IEEE13 / Sequência / Carga Variável / Capacitor no primário / 3 Medidores - Resultados por área</i>	<i>89</i>
<i>Tabela 22 - IEEE13 / Sequência / Carga Variável / Capacitor no primário / 7 Medidores - Resultados por área</i>	<i>91</i>
<i>Tabela 23 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 2 Medidores - Resultados por área.....</i>	<i>93</i>
<i>Tabela 24 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 3 Medidores - Resultados por área.....</i>	<i>95</i>
<i>Tabela 25 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 7 Medidores - Resultados por área.....</i>	<i>96</i>
<i>Tabela 26 - IEEE13 / PMU / Carga Variável / Nada no primário / 2 Medidores - Resultados por área</i>	<i>99</i>
<i>Tabela 27 - IEEE13 / PMU / Carga Variável / Nada no primário / 3 Medidores - Resultados por área</i>	<i>100</i>
<i>Tabela 28 - IEEE13 / PMU / Carga Variável / Nada no primário / 7 Medidores - Resultados por área</i>	<i>102</i>
<i>Tabela 29 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 2 Medidores - Resultados por área....</i>	<i>104</i>
<i>Tabela 30 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 3 Medidores - Resultados por área....</i>	<i>105</i>
<i>Tabela 31 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 7 Medidores - Resultados por área....</i>	<i>107</i>
<i>Tabela 32 - IEEE13 / PMU / Carga Variável / Tudo no primário / 2 Medidores - Resultados por área.....</i>	<i>109</i>
<i>Tabela 33 - IEEE13 / PMU / Carga Variável / Tudo no primário / 3 Medidores - Resultados por área.....</i>	<i>110</i>
<i>Tabela 34 - IEEE13 / PMU / Carga Variável / Tudo no primário / 7 Medidores - Resultados por área.....</i>	<i>112</i>
<i>Tabela 35 - Resumo dos Resultados.....</i>	<i>113</i>

Capítulo 1 Introdução

1.1 Contextualização

Ao longo dos últimos anos, o sistema de distribuição de energia elétrica vem passando por grandes transformações, devido principalmente à evolução tecnológica dos sistemas de comunicação. Tal evolução está permitindo a entrada massiva de geração distribuída no sistema elétrico, a integração entre os sistemas de medição e controle, e também, a utilização de medidores inteligentes que permitem o gerenciamento da utilização da energia elétrica pelo consumidor (definindo *Smart Grids*). Assim, a maneira como as concessionárias gerenciam seus ativos de rede, relacionam com seus clientes e com mercado está passando por uma transformação.

O próprio planejamento e a operação passam a contar com diferentes possibilidades, considerando novos equipamentos, a disponibilidade de mais medições, dentre outros aspectos que podem e devem ser utilizados visando menores custos e melhores índices de desempenho. Importante observar que novas aplicações também podem contribuir para elevação da complexidade do sistema, aumentando assim, a probabilidade de defeitos em sistemas de distribuição.

Para atender às necessidades de qualidade e continuidade na entrega de energia, com essa mudança de paradigma, existem diversos desafios a serem vencidos. Um deles é conseguir uma melhor eficácia na detecção, localização e mitigação de defeitos nos sistemas de distribuição. Neste sentido é importante pensar no aproveitamento da estrutura de medição que vem sendo aos poucos implantada nos sistemas, onde há uma tendência positiva de crescimento. Mas sem esquecer de seus custos adicionais, ou seja, buscando sempre a otimização das disponibilidades.

Como os defeitos são inerentes ao funcionamento do sistema, e podem impactar negativamente nos indicadores de qualidade e continuidade, causando grandes prejuízos de ordem econômica, ou principalmente de segurança, os estudos sobre detecção e localização de defeitos têm recebido bastante interesse e vem associados a esta nova estrutura pensada para os *Smart Grids*.

1.2 Motivações

Tendo em vista a importância e necessidade da melhoria dos índices de continuidade das empresas do setor elétrico, a ANEEL publicou e vem constantemente revisando os Procedimentos de Distribuição (ANEEL, 2017). Neste documento, há a definição de indicadores de continuidade para grupos de consumidores (coletivos), como o DEC – duração equivalente de interrupção por unidade consumidora e o FEC – frequência equivalente de interrupção por unidade consumidora, e para os individuais, como o DIC – duração de interrupção individual por unidade consumidora ou por ponto de conexão, FIC – frequência de interrupção individual por unidade consumidora ou por ponto de conexão, dentre outros. A partir desses indicadores, são definidos alguns padrões mínimos da qualidade do serviço prestado pela concessionária, os quais, quando não cumpridos, acarretam o repasse de compensações financeiras aos consumidores através de descontos nas faturas (ANEEL, 2017). Dessa forma, além da perda de faturamento ocorrido pela energia não distribuída, a concessionária é também penalizada com “descontos” na fatura do consumidor.

Importante observar que a cada revisão do PRODIST, os padrões mínimos de qualidade do serviço prestado pelas concessionárias são mais exigidos pelo órgão regulador, como pode ser observado na Figura 1.




Figura 1 - Acompanhamento DEC e FEC no Brasil (ANEEL, 2017)

Analisando a Figura 1 pode-se perceber que em todos os anos o indicador de DEC anual foi violado. Enquanto o FEC ficou com uma margem em relação ao limite

estabelecido pelo regulador. Essa análise permite verificar que apesar do número de interrupção estar dentro das expectativas, o tempo de restabelecimento fere o limite regulatório, o que pode ser mitigado com uma rápida e correta detecção e localização de defeitos.

Importante observar que anomalias dentro dos sistemas de distribuição são comumente causadas por problemas em equipamentos, oriundos da deterioração ao longo do tempo ou por defeitos ocasionados por agentes externos, por exemplo, contato de animais em partes energizadas, atos de vandalismo, árvore na rede, rompimentos de cabo ao solo ou acidentes de uma forma em geral. Tais anomalias podem ser permanentes ou temporárias, sendo na maioria das vezes temporários dentro do sistema de distribuição (GÖNEN, 1986).

Uma classe especial de faltas que podem ocorrer em sistemas de distribuição são os defeitos de alta impedância (DAZ ou do inglês HIF–High impedance fault). Seu nome provém do fato de que geralmente este tipo de falta apresenta uma resistência de contato entre a fase e o solo de valor elevado. Com isso, o módulo da corrente apresenta uma magnitude baixa, se comparada com os outros tipos de defeito. Uma característica importante é a não linearidade, que está associada principalmente ao arco elétrico que pode estar presente no ponto de contato do condutor com a terra ou outro objeto durante a ocorrência deste tipo de falta.

A baixa magnitude de corrente gerada pelos DAZ pode fazer com que sua presença seja confundida com acréscimo de carga ou chaveamento de banco capacitores no sistema. Como resultado, os sistemas de proteção podem não atuar corretamente na eliminação deste tipo de defeito, colocando em riscos a população e impactando os indicadores de qualidade, como o DEC, devido à dificuldade em localizar a falta.

Diante dessas particularidades, sistemas eficientes para detecção e localização de faltas começam a tomar grande importância para as empresas de distribuição à medida que contribuem de forma significativa na redução de eventos de maior impacto financeiro, e também, na redução de custos da interrupção do fornecimento, além de aspectos sociais relativos a segurança.

Apesar de existirem inúmeras metodologias desenvolvidas relacionadas ao diagnóstico de defeitos no sistema de distribuição, essa tarefa ainda está longe de estar completamente dominada. Isso ocorre, pois existem inúmeros fatores que afetam a eficiência dos métodos, tais como impedância de falta, local da falta, tipo da falta, presença ou ausência de cabos neutros e aterramentos, tipos de carga, desequilíbrios do

sistema, geração distribuída, topologia das redes de distribuição entre outros aspectos (LEDESMA; ARAUJO; PENIDO, 2016).

As tecnologias existentes para detecção de defeitos em sistemas de distribuição (SEL, 2017), (ABB, 2017), (SIEMENS, 2017), (SCHNEIDER, 2017), (WEG, 2017), possuem custos extremamente elevados, além de não garantirem um elevado índice de acertos, quando se trata de sistemas muito ramificados ou de defeitos de alta impedância (DAZ).

Atualmente, as tecnologias existentes para detecção de DAZ são implantadas utilizando um novo conceito, que é conhecido como Sistema de Gerenciamento de Distribuição Avançado (ADMS). Este conceito consiste em uma solução unificada, contemplando: Sistemas de Supervisão e Aquisição de Dado (SCADA), Sistemas de Gerenciamento de Interrupção (OMS) e Sistema de Gestão de Energia (EMS). Entretanto, as distribuidoras brasileiras ainda estão analisando a viabilidade para implantar essa nova forma de operar. Para isso, é necessário um alto investimento por parte da distribuidora. Entretanto, os fabricantes garantem um alto desempenho da rede de distribuição, assegurando assim, a viabilidade econômica necessária para a mudança de paradigma na forma de operar. Mas, infelizmente, os ganhos estimados pelos fabricantes, não garantem que o ADMS detecte os defeitos de alta impedância.

Desta forma, sistemas inteligentes de baixo custo e alto valor agregado para detecção e localização de defeitos de alta impedância são de grande interesse e podem rapidamente se converter em retornos financeiros. Associando isto ao novo paradigma dos *Smart Grids*, com possibilidade de aumento de medições, tem-se a motivação para desenvolver trabalhos na área, considerando todos os aspectos citados, buscando novas ferramentas para aplicação em sistemas reais de distribuição, que possam auxiliar na melhoria dos índices de desempenho, em economia para as distribuidoras e na melhoria da qualidade do serviço e continuidade para os consumidores.

1.3 Revisão Bibliográfica

Para o presente trabalho as linhas de pesquisa de maior importância são aquelas relacionadas à detecção, localização e análise dos defeitos nos sistemas de distribuição.

Cabe ressaltar que a questão da aplicação da medição também é importante no trabalho, mas tem características mais práticas do que a abordagem verificada nas pesquisas, por isso não está contemplada nesta seção.

A seguir será apresentada a base de pesquisa usada para o desenvolvimento deste trabalho.

1.3.1 Análise de Defeitos

Neste trabalho foi feita uma revisão bibliográfica simplificada sobre metodologias de análise de falhas, a qual está apresentada por completo na dissertação (GIMENEZ, 2016). Para este trabalho não se consultou todos os trabalhos originais citados na dissertação, mas os mesmos foram conhecidos por seus resumos, e alguns foram revistos na íntegra.

Em (BRAHMA; GIRGIS, 2004) foi desenvolvida uma metodologia para análise de curto-circuito em sistemas de distribuição, com representação da geração distribuída e das cargas do sistema. Neste trabalho dividiu-se o sistema em subsistemas, e cada subsistema foi delimitado através de relés digitais. Na presença de uma falha, somente o subsistema sob defeito é ilhado do resto do sistema. Este isolamento só é factível se todos os disjuntores estiverem sincronizados com um PMU (phasor measurement unit). O algoritmo é testado em um alimentador real, apresentando excelentes resultados.

Já em (LAI et al., 2006) é apresentada uma metodologia para planejamento de alimentadores primários. Neste trabalho, são encontradas curvas detalhadas sobre a capacidade de curto-circuito para os equipamentos que fazem parte do sistema de distribuição. Com o mesmo, é possível perceber as principais características dos componentes, como por exemplo, a impedância do transformador, a impedância dos cabos, comprimento das linhas dos alimentadores, etc.

(RIANI et al., 2008) apresenta uma metodologia para análise de defeitos em coordenadas de fase e, também, a modelagem de sistemas elétricos a quatro condutores. A principal característica deste trabalho é a representação explícita do cabo neutro, juntamente com a representação das impedâncias de aterramento do sistema em condições de defeito. O método é baseado na técnica de fluxo de potência continuado, e

é fundamentado no método de injeção de corrente trifásico a quatro condutores em coordenadas retangulares.

Em (LEDESMA, 2012) é abordado uma metodologia para análise de defeitos em sistemas de distribuição pelo método de injeção de correntes em coordenadas de fase retangulares, e o sistema é modelado a quatro condutores. Existem dois métodos de solução: direto e iterativo. Para o método direto, as cargas são modeladas como impedância constante e assim a convergência é alcançada na primeira iteração. Já no método iterativo, as cargas são inicialmente modeladas como impedância constante, e a parametrização delas varia de acordo com as tensões nodais durante o processo iterativo e suas características originais.

Já em (PENIDO et al., 2013) é implementada uma metodologia de análise de defeitos para qualquer tipo de instalação elétrica. O método é baseado em injeções de correntes a n condutores em coordenadas de fase na forma retangular, denominada NCIM. Neste trabalho os equipamentos são modelados, considerando as impedâncias mútuas, cabos neutros, cabos de aterramento, e também, alguns equipamentos com função de controle. Esse trabalho apresentou convergência com poucas iterações e baixo esforço computacional, permitindo ainda calcular diretamente as tensões e correntes de todos os equipamentos.

(PENIDO et al., 2013) apresenta uma metodologia de análise de defeito similar a apresentada anteriormente, considerando algumas características intrínsecas, como o desequilíbrio entre fases, diferentes tipos de cargas, representação dos cabos neutros, representação dos cabos de aterramento, diferentes tipos de transformadores e de geradores nas subestações. Nesse método permite-se calcular inclusive curtos-circuitos internos dentro dos equipamentos. Os mesmos também orientam que uma representação bem detalhada do sistema de distribuição impacta diretamente nos resultados das análises de defeitos, principalmente se tratando de sistemas desequilibrados.

1.3.2 Identificação e Localização de Faltas

Em (BUTLER; MOMOH, 1993) é proposta uma rede neural para detectar e classificar os defeitos em sistemas de distribuição. A rede neural busca identificar defeitos com resistência de arco. A principal desvantagem dessa metodologia é considerar o sistema de distribuição equilibrado. Esse trabalho permite, também, uma monitoração de variações significativas dos valores eficazes de corrente. Os autores sugerem mais testes para obter melhor desempenho da rede neural.

Em (HUANG; YANG; HUANG, 1997) é apresentado um método baseado em redes neurais para detecção de defeitos. Neste trabalho é identificada a seção em defeito, e também, o tipo de defeito através de uma rede neural perceptron multicamadas (MLP). A modelagem da rede neural considera camadas intermediárias de neurônios nas MLPs, permitindo assim, o tratamento de problemas não linearmente separáveis.

Já em (BI et al., 2000) a metodologia é baseada em algoritmo genético em conjunto com redes neurais artificiais, a fim de permitir diagnósticos de faltas em sistema de distribuição. A rede neural é composta por três camadas ocultas e a topologia utilizada é do tipo feedforward. Utiliza-se algoritmo genético para aperfeiçoar a topologia da rede neural a fim de detectar faltas. Os resultados foram satisfatórios, apesar de terem sido obtidos com um sistema com quatro linhas e um transformador. Por isso, sugere-se que sejam realizadas simulações em sistemas com características mais próximas dos sistemas de distribuição reais.

Em (KEZUNOVIC, 2004) são apresentadas as vantagens da utilização de técnicas inteligentes para detecção e classificação de defeitos, utilizando lógica *fuzzy* e redes neurais. A rede neural possibilita uma identificação correta mesmo sob alterações nas condições das faltas. A lógica *fuzzy* melhora o desempenho das soluções, quando os dados são incompletos ou imprecisos. Neste trabalho é destacada a importância de a rede neural permitir a inclusão do conhecimento a priori da rede de distribuição, além da facilidade de adequar para novos casos.

(SENGER et al., 2005) apresenta uma metodologia para localização de faltas. Os dados de entrada são oriundos de dispositivos eletrônicos inteligentes (IED), que apresentam a função oscilografia. Os fasores pré-falta e pós-falta são estimados, e por isso aplica-se a transformada de Fourier. Após a identificação da falta são extraídas duas janelas de dados, uma para a região pré-falta e outra para a região em falta.

Já em (SALIM et al., 2008) é apresentada uma metodologia utilizando um sistema híbrido para a detecção e localização de defeitos em sistemas de distribuição. Utiliza-se a transformada de *wavelet* e para estimar o local do defeito são utilizados sinais de tensão e corrente fasoriais como grandezas de entrada de uma rede neural.

Em (ZAMBONI et al., 2011) é proposta uma arquitetura referente a um sistema automático que permite monitorar *online* as possíveis ocorrências de faltas em redes de distribuição. A metodologia utiliza decomposição por componentes ortogonais, a fim de

identificar e localizar os defeitos, considerando tensões de fase e as correntes de linha obtidas por oscilografias nas subestações.

Já em (SARLAK; SHAHRTASH, 2011) é apresentado um algoritmo para detecção de falta de alta impedância baseado em reconhecimento de padrões considerando condutores partidos, comutação de bancos de capacitores, mudanças de cargas, e outros comportamentos. Utiliza-se o método de multiresolução gradiente morfológico (MMG) para a extração dos dados para alimentar três redes neurais do tipo perceptron com base nos três primeiros ciclos da onda de corrente pós-falta.

Em (DECANINI, 2012) é descrito um conjunto integrado de diversas modelagens – transformada de *wavelet*, análise multiresolução, rede neural do tipo ARTMAP-Fuzzy e a teoria da evidência de Dempster-Shafer – para localização automática de faltas em sistemas de distribuição. A metodologia utiliza oscilografias provenientes de um sistema de medição instalados nas subestações.

Já em (NIKOOFEKR; SARLAK; SHAHRTASH, 2013) são utilizadas redes neurais do tipo Adaptive Resonance Theory (ART), que possuem propriedades úteis na área de reconhecimento de padrões. Em um ciclo de onda são extraídas informações da corrente de defeito e, então tais informações são aplicadas as estas redes ART, para detecção de defeitos nos sistemas de distribuição.

(GARCÍA; GARCÍA; KAGAN, 2014) apresenta uma metodologia para detecção de defeitos em sistemas de distribuição com base em grandezas de um medidor de qualidade de energia (PQM). A cada ciclo, são extraídas as componentes harmônicas e as de sequência referentes às correntes medidas nas subestações.

Em (IURINIC et al., 2016) é apresentada uma nova metodologia de detecção e localização de defeitos de alta impedância em sistemas de distribuição. O método é desenvolvido no domínio do tempo através de um modelo composto por uma resistência, uma indutância e dois diodos, que simula a falta de alta impedância. Neste modelo, a distância da falta e seus parâmetros – resistência de falta, indutância de falta, corrente de falta, tensão positiva do arco voltaico e a tensão negativa do arco voltaico – são estimados como um problema de minimização. São consideradas nessa metodologia as tensões da fonte, as correntes da fonte, a capacitância da linha e o sistema sendo unicamente radial.

1.4 Objetivos do Trabalho

Considerando todos os aspectos mencionados na contextualização, motivação, e a ausência de trabalhos que garatam a detecção e localização de faltas correta de todas as faltas com alta resistência, tem-se como objetivo do presente trabalho otimizar a localização de medidores a fim de conseguir uma maior assertividade na detecção, por área, de defeitos monofásicos com alta resistência de contato (100-200 ohms). Para isso, serão utilizadas redes neurais de reconhecimento de padrão para detecção dos defeitos, e uma ferramenta baseada em algoritmo genético a fim de alocar os medidores de corrente no sistema de distribuição.

Também é objetivo do presente trabalho verificar o impacto da variação da carga dos sistemas de distribuição no processo de localização de defeitos. Também serão analisados três tipos distintos de topologia: *i*) Nenhum equipamento com conexão direta para a terra está alocado nos alimentadores de média tensão (primário) e as cargas são conectadas através de transformadores do tipo delta-estrela. Essa topologia é referente aos sistemas de distribuição brasileiros com nenhum equipamento conectado ao primário; *ii*) Os capacitores de distribuição e as capacitâncias parasitas são conectadas na média tensão e as cargas são conectadas através de transformadores do tipo delta-estrela. Essa topologia é referente aos sistemas brasileiros reais e *iii*) todos os equipamentos e cargas são conectados na média tensão através de transformadores monofásicos conforme disposto originalmente nos casos base do IEEE (os transformadores monofásicos não são representados no caso IEEE123). Essa topologia é semelhante aos sistemas de distribuição norte-americanos.

1.5 Publicações Relacionadas ao Trabalho

ACÁCIO, L. C., GUARACY, P. A., DINIZ, T. O., PENIDO, D. R. R., ARAUJO, L. R., 2017, “Evaluation of the Impact of Different Neural Network Structure and Data Input on Fault Detection”, IEEE PES Innovative Smart Grid Technologies Latin America 2017, ISGT-LA 2017, Quito, no Equador, Setembro.

1.6 Estrutura do Trabalho

Este trabalho é composto de cinco capítulos, incluindo este de introdução e os outros que serão descritos a seguir.

Capítulo 2 descreve os conceitos e teorias básicas para a elaboração do trabalho.

Capítulo 3 descreve o método proposto para otimizar a localização dos medidores, e também, a metodologia aplicada para detecção das faltas de alta impedância.

Capítulo 4 apresenta os resultados e as análises realizadas com o método desenvolvido, a partir de testes e simulações em sistemas elétricos.

Capítulo 5 apresenta as conclusões gerais do trabalho e os trabalhos futuros.

1.7 Convenções e Nomenclaturas Utilizadas

AG: Algoritmo Genético

ANEEL: Agência Nacional de Energia Elétrica

ART: Adaptive Resonance Theory

DIL: Detecção Identificação e Localização

IED: Intelligent Electronic Device

IA: Inteligência Artificial

MLP: Multi-layer Perceptron

MMG: Multiresolução Gradiente Morfológico

PMDC: Phasor Measurements Data Concentrator

PMU: Phasor Measurement Unit

PPS: Pulse per Second

PRODIST: Procedimento de Distribuição

RMS: Root Mean Square

SMFS: Medição Fasorial Sincronizada

TC: Transformador de Corrente

TP: Transformor de Potencial

Capítulo 2 Definições e Fundamentação Teórica

2.1 Considerações Iniciais

Ao longo deste capítulo será apresentada a fundamentação teórica acerca dos principais tópicos que foram à base do desenvolvimento deste trabalho.

Serão abordados os conceitos básicos de redes neurais, a fim de possibilitar a compreensão do método aplicado na detecção e localização de defeitos. Da mesma forma, serão apresentados os conceitos básicos de algoritmos genéticos, visando permitir a compreensão do método desenvolvido para otimizar a alocação dos medidores ao longo do sistema de distribuição.

Por fim, serão apresentados diferentes tipos de equipamentos que possuem medição, tanto os fasoriais quanto os não fasoriais, bem como uma pequena introdução aos sistemas de distribuição.

2.2 Redes Neurais

Nesta seção os principais conceitos de redes neurais serão baseados no descrito em (DA SILVA; SPATTI; FLAUZINO, [s.d.]), e serão apresentados nos seguintes tópicos.

- Modelos gerais de redes neurais artificiais;
- Principais tipos de função de ativação;
- Principais tipos de arquitetura de redes neurais;
- Função de treinamento;
- Avaliação de Performance;
- Rede de reconhecimento de padrões.

A rede neural é uma técnica de Inteligência Artificial (IA) que tenta simular em computadores o funcionamento do cérebro humano de uma maneira simplificada. Os sistemas computacionais imitam as funcionalidades do sistema nervoso, através de elementos processadores interconectados, chamados neurônios artificiais (HAYKIN, 2001).

Assim sendo, as redes neurais são baseadas na biologia humana, sendo então formadas por neurônios e conexões. O neurônio pode ser dividido em três partes: dendritos, soma (ou corpo celular) e axônio.




Figura 2 - Esquema de um Neurônio Biológico, (DA SILVA RAYBOLT, 2011)

A Figura 2 apresenta de forma simplificada um neurônio biológico. Nela pode-se observar:

- Os axônios vêm de outros neurônios mandando sinais para um neurônio particular;
- A sinapse é o ponto de contato entre a terminação axônica e o(s) dendrito(s) de outro(s) neurônio(s), sendo capaz de controlar o fluxo da informação;
- Os dendritos recebem informações oriundas de outros neurônios e as conduzem até o corpo celular;
- O corpo celular pode modificar os sinais por um peso na sinapse e depois são somados todos os pesos das entradas;
- O neurônio transmite apenas uma saída através do axônio;
- A saída de um neurônio particular pode ir para muitos outros neurônios.

2.2.1 Modelo Geral de Redes Neurais Artificiais

Um modelo simplificado de um neurônio pode ser visualizado na Figura 3. O mesmo pode ser considerado uma unidade de processamento de informação, representando um conjunto básico de um neurônio biológico e se constituindo em uma generalização do modelo de McCulloch e Pitts (DA SILVA RAYBOLT, 2011).

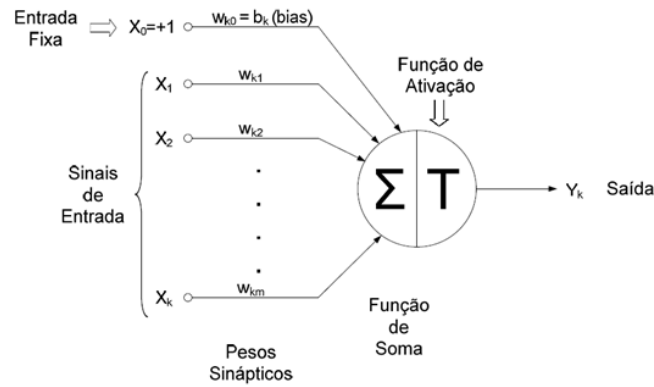


Figura 3 - Modelo de um Neurônio Artificial, (DA SILVA RAYBOLT, 2011)

O neurônio recebe um conjunto de sinais de entrada x_p , cada qual multiplicado por um peso sináptico w_{km} . O peso sináptico é de extrema importância para o modelo de uma RNA, pois é responsável pelo ajuste da importância relativa das conexões aos outros neurônios. O modelo inclui, também, uma referência (bias) b_k externa, com objetivo de aumentar ou diminuir a entrada da função de ativação, dependendo do seu sinal, positivo ou negativo.

Assim, os sinais de entrada ponderados pelas respectivas sinapses do neurônio são então somados. Uma função de ativação é utilizada com o objeto de restringir a amplitude da saída.

Um neurônio k é descrito pelas seguintes equações matemáticas.

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \quad (2.1)$$

$$y_k = \varphi(u_k + b_k) = \varphi \left[\sum_{j=1}^m w_{kj} \cdot x_j + b_k \right] \quad (2.2)$$

Onde:

- x_j : é j -ésimo sinal de entrada do k -ésimo neurônio;
- w_{kj} : é o j -ésimo peso sináptico do k -ésimo neurônio;
- u_k : é a saída do combinador linear do k -ésimo neurônio;
- b_k : é o bias aplicado ao k -ésimo neurônio;
- $\varphi(\cdot)$: é a função de ativação do k -ésimo neurônio;
- y_k : é o sinal de saída do k -ésimo neurônio.

Observa-se que o índice k se refere a um neurônio particular e o índice m ao número de entradas para esse neurônio.

2.2.2 Principais Tipos de Função de Ativação

Diversas funções de ativação existem. A seguir serão apresentados os tipos básicos:

- a) **Função degrau:** Ajusta a saída do neurônio igual a 1, e tem a seguinte definição, conforme a equação (2.3) e sua curva é exemplificada na Figura 4.

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (2.3)$$




Figura 4 - Função Degrau, (DA SILVA RAYBOLT, 2011)

- b) **Função linear por parte:** É definida pela equação (2.4) e sua curva é exemplificada na Figura 5.

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 1 \\ v, & \text{se } +1 > v > -1 \\ 0, & \text{se } v \leq -1 \end{cases} \quad (2.4)$$




Figura 5 - Função Linear por Parte, (DA SILVA RAYBOLT, 2011)

- c) **Função Sigmoidal:** É a função de ativação mais utilizada nos neurônios. Pode ser representada por uma função logística ou por uma função tangente hiperbólica. A mesma é definida pelas equações (2.5), (2.6).

$$\partial(v) = \frac{1}{1 + e^{-\alpha v}} \quad (2.5)$$

$$\partial(v) = tgh(v) = \frac{1 - e^{-2\alpha v}}{1 + e^{-2\alpha v}} \quad (2.6)$$

Onde α é o parâmetro de inclinação da função sigmoide.

A curva da equação (2.6) é exemplificada na Figura 6.




Figura 6 - Função Sigmoide, (DA SILVA RAYBOLT, 2011)

As funções de ativação descritas anteriormente apresentam resultados com limite $[0,1]$.

2.2.3 Principais Tipos de Arquitetura de Rede Neural

Os neurônios devem ser conectados entre si de forma a estabelecer uma rede. A maneira em que eles estão estruturados está relacionada com as habilidades de aprendizagem utilizadas no treinamento da rede.

Em geral, três tipos de arquitetura se destacam como as mais utilizadas nos estudos de RNA e podem ser observadas a seguir:

- a) **Redes Feedforward de Camada Única:** Está é considerada a forma mais simples de uma RNA. Os neurônios são organizados em uma camada única. Essa rede é do tipo “alimentada adiante”, já que a camada de entrada de nós de fonte se projeta sobre a camada de saída, sem laços

de realimentação. Essas redes são capazes de resolver problemas multivariáveis, mas com algumas restrições por serem de uma única camada. Essa rede é exemplificada na Figura 7.




Figura 7 - Modelo de Rede Alimentada com uma Camada, (DA SILVA RAYBOLT, 2011)

- b) **Redes Feedforward de Múltiplas Camadas:** Esta arquitetura apresenta uma ou mais camadas intermediárias, sendo essas os nós computacionais (conhecidos como neurônios ocultos) entre as camadas de entrada e saída. A camada intermediária confere a RNA uma maior capacidade computacional de aproximação de função contínuas. Na Figura 8 é apresentada esta arquitetura, dita totalmente conectada devido ao fato de que um dos nós de certa camada está conectado a todos os nós da camada logo adiante. Caso a rede não apresente estas conexões, ela é denominada parcialmente conectada.




Figura 8 - Modelo de Rede Alimentada Adiante com Múltiplas Camadas, (DA SILVA RAYBOLT, 2011)

c) **Redes Recorrentes:** As redes recorrentes se distinguem das redes feedforward pelo fato de terem pelo menos um laço de realimentação. A Figura 9 ilustra um modelo de redes recorrentes com neurônios ocultos e neurônios de saída. Observa-se que os laços de realimentação apresentam elementos de atraso unitários. A utilização destes elementos resulta em um comportamento dinâmico não-linear, admitindo-se que a rede contenha unidades não-lineares. Esse tipo de arquitetura é utilizado em problemas que envolvam processamento temporal, como por exemplo, em previsão de eventos futuros.




Figura 9 - Modelo de Rede Recorrente, (DA SILVA RAYBOLT, 2011)

2.2.4 Processo de Aprendizagem – Treinamento

Uma das principais características das RNAs é a capacidade de aprender através de exemplos e fazer interpolações e extrapolações do que foi aprendido, a fim de obter melhorias no seu desempenho. Um algoritmo de aprendizado é responsável em adaptar os parâmetros de uma RNA para que a mesma possa aprender uma determinada função.

O processo de aprendizagem consiste em um processo iterativo onde os parâmetros da rede são ajustados através dos pesos das conexões entre as unidades de processamento até que no final do processo o conhecimento adquirido pela rede do ambiente é guardado nos pesos.

Os diversos métodos criados para aprendizagem de redes neurais são classificados como:

- a) **Aprendizado Supervisionado (aprendizagem com o professor):** Este é o método mais comum de treinamento de RNAs. O Objetivo é fazer com que os parâmetros da rede sejam ajustados, de maneira a encontrar uma ligação entre os dados de entrada e saída fornecidos. Neste processo, é conhecida a resposta para uma entrada, e caso a resposta da rede neural seja diferente da resposta previamente conhecida (do professor), os pesos sinápticos são ajustados de maneira que a saída da rede neural fique próxima ao do professor. Na Figura 10 pode-se visualizar o esquemático desse tipo de aprendizado.




Figura 10 - Aprendizado Supervisionado, (DINIZ, 2015)

- b) **Aprendizado Não-Supervisionado:** Neste método apenas os dados de entrada estão disponíveis. A rede estabelece uma harmonia com as regularidades estatísticas dos dados de entrada e desenvolve habilidade

de formar representações internas com o objetivo de codificar as características de entrada e criar classes ou grupos automaticamente. Entretanto, para encontrar as características dos dados de entradas, é necessária redundância dos dados, caso contrário esse tipo de aprendizado se torna impossível. A seguir, na Figura 11, o esquemático desse tipo de aprendizado.




Figura 11 - Aprendizado Não Supervisionado, (DINIZ, 2015)

2.3 Algoritmo Genético

Algoritmo Genético (AG) é um método computacional de busca baseado em mecanismos da evolução natural e na genética. Em AG, uma população de possíveis soluções evolui de acordo com operadores probabilísticos concebidos a partir de metáforas biológicas, de tal modo que exista uma tendência de que, na média, os indivíduos representem soluções cada vez melhores, à medida que o processo evolutivo continue. Ou seja, o AG realiza uma simulação de evolução biológica por meio de uma busca multidirecional no espaço de soluções potenciais do problema. A cada geração, a população é modificada de maneira que as boas soluções permaneçam e possam reproduzir-se, e as ruins sejam descartadas. Os princípios básicos de AGs foram estabelecidos em (HOLLAND, 1992). O procedimento básico para um AG pode ser visto na Figura 12.

De maneira simplificada um AG consiste em: uma população de soluções potenciais, uma maneira de quantificar e qualificar uma solução, um método para compor novas soluções a partir de parte das melhores soluções, um operador de mutação para manter a diversidade da população.


```

iniciar
  t ← 0
  inicializar P(t)
  avaliar P(t)
  Enquanto (critério de parada não satisfeito)
    faça
      t ← t + 1;
      selecionar P(t)
      recombinar P(t)
      mutar P(t)
      avaliar P(t)
    fim_enquanto
fim

```

Figura 12 - Procedimento Básico, (WESTPHAL, 2006)

2.3.1 Nomenclatura

Sendo o AG um método inspirado na evolução natural, muito dos termos encontrados são originados da Biologia.

- **Gene:** é a unidade básica que controla uma determinada propriedade de um indivíduo. Representa parte de uma característica da solução.
- **Indivíduo ou Cromossomo:** é a representação da solução do modelo sendo formado por conjunto de genes.
- **População:** conjunto de indivíduos que representam o atual espaço de busca do problema.
- **Geração:** identifica a evolução de uma população, ou seja, o número da iteração que o algoritmo genético executa.
- **Função de Avaliação:** é a função que se quer otimizar. Representa as características do problema e é usada para avaliar o nível de aptidão dos cromossomos.
- **Fitness:** valor que mede o grau de aptidão de um cromossomo. Identifica se uma solução é boa ou ruim.
- **Recombinação:** consiste na troca (evento aleatório) de informações entre dois cromossomos.
- **Mutação:** consiste na troca (evento aleatório) da característica de um gene (Variável) em determinado cromossomo.

2.3.2 Operadores Genéticos

Operadores genéticos são aplicados aos cromossomos da população com o objetivo de reproduzir novos e melhores indivíduos a partir dos já existentes. As operações são necessárias para permitir a diversidade dos indivíduos, bem como explorar outras regiões do espaço de busca. Os principais operadores são recombinação e mutação.

2.3.2.1 Recombinação

O objetivo desta aplicação é a troca de informação entre diferentes soluções candidatas.

Altas taxas de recombinação reduzem as chances de convergência para um máximo local, mas acabam exigindo maior desempenho computacional devido à extrapolação de regiões não promissoras dentro do espaço de busca.

Na literatura encontra-se grande quantidade de operadores de recombinação, com aplicação direcionada a diferentes tipos de codificações e problemas. Os mais comuns serão apresentados a seguir (CASTILHO, 2003).

- **Recombinação ponto único**

Um ponto de cruzamento é escolhido e a partir deste ponto as informações genéticas são trocadas conforme a Figura 13.



Figura 13 - Recombinação Ponto Único, (CASTILHO, 2003)

- **Recombinação multiponto**

Análogo a anterior, com a diferença que vários pontos de cruzamento podem ser utilizados, conforme mostrado na Figura 14.



Figura 14 - Recombinação Multiponto, (CASTILHO, 2003)

- **Recombinação uniforme**

Não utiliza pontos de cruzamentos. A recombinação é determinada por uma máscara de bits aleatórios nas quais os genes de cada pai são herdados por cada filho. Em resumo, a cada bit 1 da máscara, o gene é copiado do pai para o filho 1, caso contrário (bit 0 da máscara), o bit da mãe é copiado. Para o filho 2, inverte o processo.

Segundo (VON ZUBEN; N. DE CASTRO, 2000) não se pode afirmar que uma técnica de recombinação é melhor que a outra. Dependendo do problema, pode-se ter um desempenho melhor de uma técnica de recombinação em relação às outras.

2.3.2.2 Mutação

O objetivo deste operador é manter e propiciar a diversidade genética da população, através de alteração aleatória de uma ou mais características de um cromossomo.

Normalmente a mutação é aplicada aos indivíduos após a recombinação. Em casos que a taxa de mutação é baixa, pode haver comprometimento na diversidade dos indivíduos. Contudo, se for alta, pode haver perturbações aleatórias de tal forma que os filhos provavelmente perderão suas semelhanças com os pais podendo comprometer a convergência. A seguir, na Figura 15, está uma exemplificação do processo.



Figura 15 - Exemplo de Mutação, (CASTILHO, 2003)

2.3.2.3 Seleção

O processo de seleção ocorre após a avaliação de cada indivíduo pertencente na população, normalmente sendo baseado no princípio da sobrevivência dos melhores indivíduos. Os cromossomos com melhores níveis de aptidão possuem uma maior probabilidade de serem mantidos e selecionados para a etapa da reprodução. Da mesma forma, os cromossomos com baixos níveis de aptidão possuem pouca probabilidade de permanecer e, conseqüentemente, podem ser eliminados da população. Resumidamente, pretende-se escolher os indivíduos que devem continuar o processo evolutivo conforme a estratégia adotada.

As principais formas de seleção, que são apresentadas na literatura são: seleção por roleta, seleção rank, seleção por torneio e técnica elitista.

2.4 Medidores Fasoriais e Não-Fasoriais

Os medidores implantados no sistema elétrico podem ser fasoriais e não-fasoriais. A maioria das concessionárias de energia usam as medições não-fasoriais. Nos transformadores de distribuição, os medidores só são instalados a pedido de cliente, devido à reclamação de variação de tensão (ANEEL, 2017) ou para medições amostrais da ANEEL. Outra forma atual de medir na média tensão é a utilização dos religadores instalados em pontos estratégicos da rede elétrica. Esses medidores medem tensão, corrente, potência, fator de potência, entre outras grandezas.

2.4.1 Medidores Fasoriais

A medição fasorial é conceituada como a estimação dos parâmetros de fase, amplitude e frequência do componente fundamental.

As tecnologias de monitoramento do sistema elétrico de potência vêm ganhando espaço em virtude do aumento da dificuldade de controle, do aumento da complexidade dos sistemas e do aumento de exigência por confiabilidade. Nesta direção surgiram as unidades de medição fasorial sincronizadas chamadas PMUs (*phasor measurement units*), que permitem ao operador saber o estado do sistema elétrico em tempo real e com sincronismo. Conseqüentemente, a PMU pode ser utilizada para permitir medidas corretivas antes que um colapso aconteça.

Atualmente, as PMUs se mostram eficientes no registro de perturbações, monitoração de segurança, controle de emergência e implementações de caráter experimental, entretanto sua utilização em larga escala esbarra no custo para aquisição dos equipamentos. Sua função é coletar e registrar medições de tensão e de corrente instantâneas, a fim de se calcularem os fasores (módulo e ângulo) sincronizados no tempo, empregando a tecnologia do GPS (global positioning system). Vários países possuem estudos de implementações, tais como: Estados Unidos, Dinamarca, Japão, China, Islândia, França, entre outros, (DINIZ, 2015).

A Figura 16 mostra o conceito de Sistemas de Medição Fasorial Sincronizada (SMFS). O SMFS é um sistema de medição de fasores de grandezas elétricas, coletadas em instalações geográficas distintas. O sinal denominado PPS (pulse per second) das unidades de Medição Fasorial, denominadas PMDC (Phasor Measurements Data Concentrator), é obtido a partir da sincronização do GPS. Este sinal é a referência temporal, a partir da qual as fases dos fasores remotos podem ser estimadas.




Figura 16 - Representação de um sistema de medição fasorial sincronizado via GPS, (PIRES; BORBA, 2006)

2.4.2 Medições Não Fasoriais

Os equipamentos auxiliares mais importantes, atualmente para as empresas de distribuição, são os transformadores de instrumentos ou de medição. Os mesmos possibilitam que tensões ou correntes primárias, normalmente elevadas, sejam transformadas em valores secundários, apropriados para uso de medidores ou de instrumentos de medidas elétricas. Ainda permitem o isolamento entre o circuito primário (alta tensão) e o circuito secundário (baixa tensão) ou de medição. Existem dois tipos de transformadores de instrumentos ou de medição, que serão apresentados a seguir.

- **Transformador de Corrente (TC):**

Equipamento destinado a produzir proporcionalmente no circuito secundário a corrente presente no circuito primário, com a posição fasorial mantida, conhecida e adequada para uso em equipamentos de medição, controle e proteção.

- **Transformador de Potencial (TP)**

São equipamentos que permitem aos instrumentos de medição e proteção funcionarem adequadamente, sem que seja necessário possuir tensão de isolamento de acordo com a da rede a qual estão ligados.

Na sua forma mais simples, os transformadores de potencial possuem um enrolamento primário com muitas espiras e um enrolamento secundário com poucas espiras.

Existem alguns tipos de equipamentos que podem realizar medição de grandezas elétricas nas redes de distribuição, os principais são apresentados a seguir:

- **Regulador de Tensão**

O regulador de tensão é um equipamento que, ao ser instalado na rede, mantém um nível de tensão pré-determinado no ponto de regulação, apesar das variações das cargas, desde que sua margem de regulação não seja ultrapassada. Construtivamente, o regulador é composto basicamente de um autotransformador, um comutador automático de derivação (tap) sob carga e de um sistema de controle, que corrige os desvios momentâneos da tensão de regulação, relativos ao valor especificado.

Usualmente, os reguladores para aplicação em linhas de distribuição são equipamentos monofásicos. Sua instalação é realizada através da formação de bancos trifásicos.

- **Religador**

O religador é um dispositivo interruptor autocontrolado com capacidade para detectar condições de defeitos, especialmente sobrecorrentes, e interromper o circuito se a sobrecorrente persiste por um tempo pré-especificado. Como o nome sugere, o equipamento religa automaticamente após a abertura, restaurando a continuidade do circuito mediante faltas de natureza temporária ou interrompe o circuito mediante falta permanente.

A maior dificuldade enfrentada por muitas distribuidoras diz respeito ao meio de comunicação dos equipamentos. A intermitência no meio de comunicação faz com que os equipamentos operem sem supervisão direta, impossibilitando manobras, análise dos valores de curto e esquemas de restabelecimento automático centralizado (*Self-healing*). A seguir serão apresentadas algumas formas de comunicação utilizadas pelas distribuidoras.

- GPRS (Celular)

Um esquema de comunicação GPRS (*General Packet Radio Service*) é apresentado na Figura 17. Este sistema possui as seguintes características: Utiliza a tecnologia de comunicações via sinal GPRS (celular), através das operadoras de telefonia; chamadas de voz possuem prioridade maior do que as transmissões de dados por pacotes, o que resulta nas variações da velocidade de conexão; baixo custo; problemas com a manutenção das baterias das ERBs.

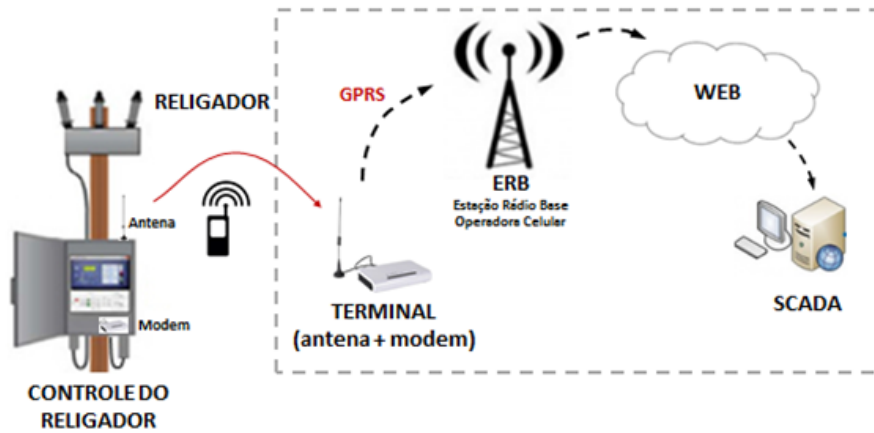


Figura 17 - Esquema Comunicação GPRS

- Rádio

Um esquema de comunicação por Rádio é apresentado na Figura 18. Este sistema possui as seguintes características: Alta confiabilidade; elevados custos de implantação (torre, equipamentos, etc.); Necessidade de manutenção das baterias, inversores e retificadores das torres.

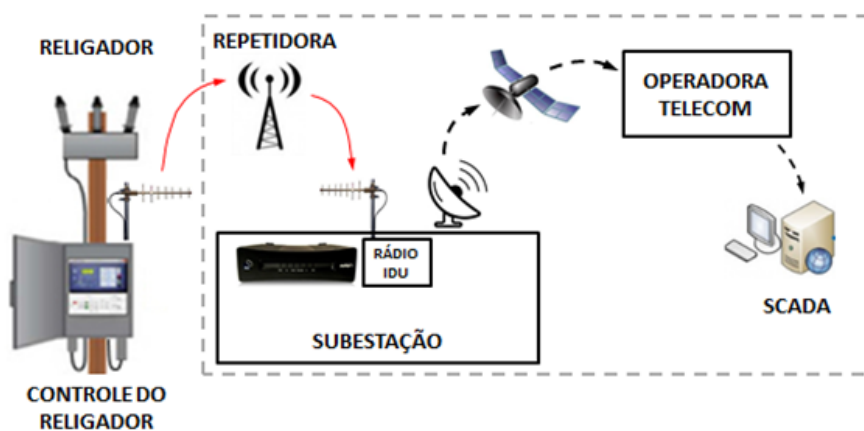


Figura 18 - Esquema Comunicação Rádio

- BGAN

Um esquema de comunicação BGAN (*Broadband Global Area Network*) é apresentado na Figura 19. Este sistema possui as seguintes características: Utiliza a tecnologia de comunicação via satélite BGAN, em banda L, e pode ser utilizado em redes corporativas e operativas; A contratação é baseada em planos de consumo; a

banda L é menos suscetível às condições climáticas que podem influenciar os serviços de comunicação via satélite.

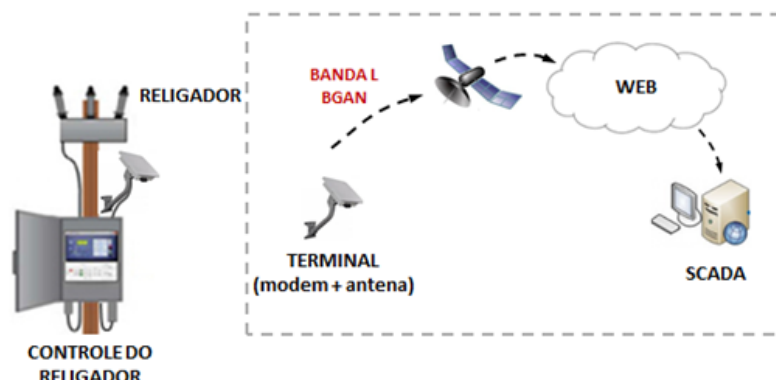


Figura 19 - Esquema Comunicação BGAN

2.5 Rede de Distribuição

Os sistemas de distribuição de energia são responsáveis pela ligação entre o consumidor final e o sistema de transmissão, provendo energia instantaneamente, na tensão e frequência especificadas e na quantidade necessária para o consumidor.

No entanto, sistemas de energia, especialmente sistemas de distribuição, estão sujeitos a diversas perturbações causadas por crescimento de cargas, faltas ocasionadas por fontes naturais, falhas de equipamentos, etc. O caráter de regime permanente da energia fornecida ao consumidor é mantido basicamente por dois fatores: a grande dimensão do sistema frente às cargas individuais e as corretas ações corretivas tomadas pelos sistemas de proteção em casos de distúrbios.

Assim, a instalação e ajustes dos equipamentos de proteção em uma linha de distribuição (alimentador) devem levar em conta a existência de cargas e ramificações em seu percurso. Além disso, chaves distribuídas ao longo do sistema podem mudar a topologia de um determinado alimentador em caso de ocorrência de faltas, sobrecargas ou manutenções programadas, o que também deve ser considerado na proteção. Essas características fazem com que frequentemente haja a necessidade de instalação de dispositivos de proteção (chaves, religadores) em diversos pontos do sistema.

A localização dos equipamentos de proteção deve ser feita de forma estratégica, a fim de auxiliar na recomposição do sistema em ocorrências de faltas. Normalmente a

localização dos dispositivos é definida levando em consideração o histórico de ocorrências em determinada região e/ou acessibilidade à mesma.

Como pode ser visto na Figura 20, o sistema de distribuição é composto por alimentadores troncos e também por ramais. Atualmente, em todo início de ramal, existe uma chave fusível, para que em casos de faltas a jusante deste ponto, o defeito seja isolado do tronco do alimentador, reduzindo a abrangência da falta de energia.

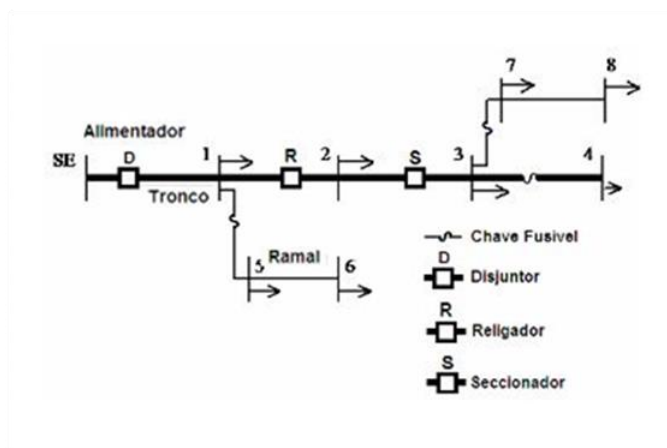


Figura 20 - Esquema sistema de distribuição (NASCIMENTO, 2017)

Os dispositivos seccionalizadores (chave faca, por exemplo), são espalhados pela rede a fim de auxiliar no isolamento do defeito, reduzindo assim a abrangência.

Um desafio enfrentado pelas distribuidoras de energia é a alocação ideal dos equipamentos de medição e também dos equipamentos seccionalizadores, que muitas vezes ao longo do tempo possuem sua alocação alterada, por acreditarem que este novo ponto trará ganhos mais significativos.

Para análise de defeitos, nas redes de distribuição, um fator importante é a análise do comprimento dos alimentadores. Em um alimentador longo se o defeito ocorrer perto da subestação a tendência é que a proteção detecte defeitos de baixas e médias resistências. Já se o defeito ocorrer longe da subestação é mais difícil a detecção de defeito de baixas e médias resistências.

Analisando o alimentador curto, para o defeito que ocorre perto da subestação, a proteção detecta mais facilmente quando são defeitos de baixas e médias resistências. Se o defeito ocorrer longe da subestação, em um alimentador curto, um defeito de baixa resistência será mais fácil de detectar e o defeito de média resistência mais difícil. Defeito de alta impedância é sempre muito difícil de identificar.

Outra característica das cargas no sistema de distribuição é o tipo de conexão. Geralmente as cargas estão conectadas através de transformadores e o tipo de conexão é delta no lado primário e estrela aterrada no lado secundário.

As informações deste capítulo servem de base para o entendimento do método que será apresentado no próximo capítulo.

Capítulo 3 Método para Alocação Otimizada de Equipamentos de Medição para Detecção de Falhas

3.1 Introdução

Os defeitos mais comuns encontrados nos sistemas de distribuição são os contatos dos condutores de fase com a terra, com ou sem impedância de contato. A dificuldade em detectar defeitos monofásicos consiste no fato de que quanto maior o valor da impedância entre a fonte e o ponto de defeito, ou do valor da resistência de contato, tende-se a ter um valor de corrente de defeito na mesma ordem de grandeza da corrente de carga, dificultando a detecção e localização do defeito. Pode-se perceber que, devido a importância do tema, existe uma grande disponibilidade de ferramentas computacionais para realizar estas tarefas, porém, para a distribuição ainda existem questões que podem ser melhoradas, devido à natureza desequilibrada, ramificada, com grandes variações de carga e poucos pontos de medição.

(GIMENEZ, 2016) realizou um estudo para verificar a influência da variação da resistência de contato nas correntes de curto-circuito em regime permanente. Nota-se que, à medida que o valor da impedância de falta aumenta, a corrente de curto-circuito vai decaindo até perto do valor da corrente de carga, tornando-se imperceptível o defeito para os sistemas clássicos de proteção (proteção de sobrecorrente de fase e neutro).

Em (GIMENEZ, 2016) também foram abordados os desequilíbrios característicos dos sistemas de distribuição, os quais devem ser representados nas ferramentas de análises de defeitos, pois afetam o ajuste de proteção. A variação de corrente entre as fases resultante dos efeitos dos desequilíbrios pode chegar a quase 20% e esses desequilíbrios tendem a aumentar com a inserção da geração distribuída na rede.

No trabalho de (GIMENEZ, 2016), desenvolveu-se um método para localização de faltas, considerando algumas possibilidades de medições disponíveis (em posicionamentos pré-determinados) como dados de entrada para o método. A partir de seus resultados entendeu-se ser importante fazer um melhor aproveitamento dos medidores disponíveis, pois na maioria das vezes não são muitos, sendo este o tema de desenvolvimento deste trabalho. Logo, neste capítulo propõe-se um método para otimizar a alocação dos medidores no sistema de distribuição, de forma a obter melhores resultados na detecção de defeitos, também considerando desequilíbrios dos sistemas, variação de carga e diferentes impedâncias de defeito.

3.2 Problema Proposto

O método proposto para alocação ótima de medidores para a detecção de defeitos por área será apresentado a partir desta seção. Considera-se que os defeitos tenham resistência de contato variando de 100 a 200 ohms. As características dos sistemas de distribuição e do tipo de falta estudados neste trabalho são apresentadas na Figura 21.

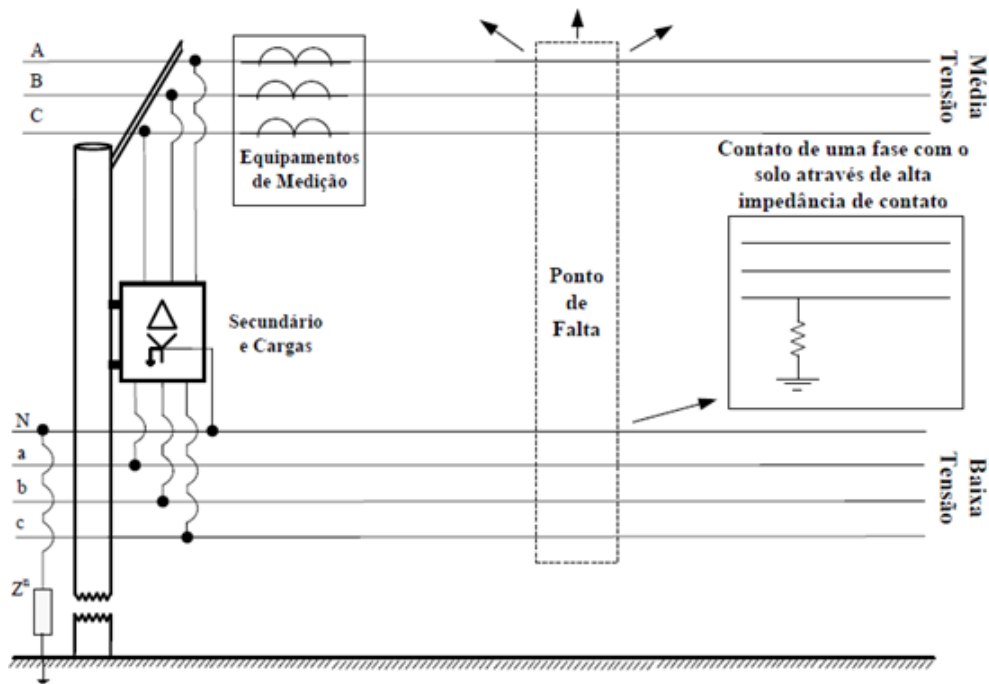


Figura 21 - Representação do tipo de defeito, (GIMENEZ, 2016)

Os limites de áreas para localização de defeitos são apresentados na Figura 22-A, onde existem n medidores de correntes/tensões. Cada área é delimitada entre dois ou mais medidores ou entre um medidor e o fim do alimentador. Cada área será denominada neste trabalho como área de observação dos medidores (AOM). Como exemplo, apresenta-se mais detalhadamente uma AOM na Figura 22-B.




Figura 22 - Áreas de observação dos medidores, (GIMENEZ, 2016)

O problema a ser solucionado pelo método proposto pode ser descrito de maneira genérica com a equação (3.3).

$$TP' = \frac{TP}{NBP} \cdot 100\% \quad (3.1)$$

$$TN' = \frac{TN}{NBN} \cdot 100\% \quad (3.2)$$

$$FOB = \min \left(\sum_{i=1}^{nArea} |(TP' - 100\%)|^2 + |(TN' - 100\%)|^2 \right) \quad (3.3)$$

Onde:

TP – É a quantidade de casos avaliados que indicam defeitos;

NBP – É o número de casos que foram avaliados pela rede neural e que realmente ocorreu defeito;

TN – É a quantidade de casos avaliados que não indicam defeitos;

NBN – É o número de casos que foram avaliados pela rede neural e que realmente não ocorreu defeito;

Como pode ser observado pela equação (3.3), o problema é de natureza não-linear inteira mista (PNLIM) sendo de difícil solução se forem utilizadas técnicas clássicas de otimização. Além disto, ainda deve ser tratada a questão da detecção de defeitos de alta resistência em sistema de distribuição, que por si só, já é um problema de grande dificuldade de solução.

Tem-se então:

- Uma função objetivo a ser minimizada representada por uma função de erro quadrático (relacionada a não assertividade na detecção dos defeitos (3.3)).

- O número de medidores que serão alocados é determinado pelo usuário no início da rotina, sendo este número fixo após a decisão do usuário.

Neste problema, duas questões complexas devem ser tratadas para chegar a solução: (i) rotina de otimização de alocações de medidores e (ii) rotinas para a detecção de defeitos de alta resistência em sistemas de distribuição com representação da variação da carga, sendo que a aplicação de (ii) deverá estar embutida no processo de otimização de (i).

Para tratar este problema de difícil solução serão utilizadas duas técnicas inteligentes. Os algoritmos genéticos serão utilizados para as rotinas de alocação (item i) e as redes neurais para as rotinas de detecção de defeitos em AOM (item ii), sendo o método proposto uma conjunção da aplicação das duas técnicas.

3.3 Método Proposto para a Solução do Problema

O fluxograma básico do método proposto para a solução do problema apresentado na seção 3.2 é mostrado na Figura 23.

Simplificadamente o módulo Base de Dados cria uma base de dados para treinamento, teste e validação das redes neurais. Para o presente trabalho a base de

dados foi dividida deixando 50% dos dados para treinamento, 15% para validação e 35% para teste. Essa rotina será apresentada em detalhes na seção 3.3.1. O módulo de Otimização - AG realiza procedimentos de otimização baseados em algoritmos genéticos e será explorado em detalhes na seção 3.3.2. A função Fitness - RN verifica a eficiência na detecção e localização de defeitos de um determinado posicionamento de medidores e será tratada na seção 3.3.3, a função formar Área de Observação de Medidores (AOM) indica quais barras estarão em uma determinada área, sendo que os limites de cada área mudam de acordo com o posicionamento dos medidores. Detalhes desta função são apresentados na seção 3.3.4.

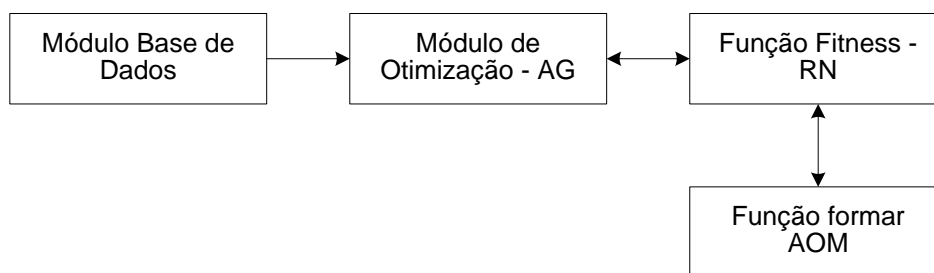


Figura 23 - Fluxograma Básico

3.3.1 Módulo Base de Dados

Na Figura 24 é apresentado o algoritmo para a criação da base de dados que será alterada após a alocação dos medidores pela rotina que utiliza algoritmo genético, e em seguida, entrada para a rotina de detecção de defeitos que utiliza rede neural. A necessidade desta base de dados se dá devido às inúmeras situações diferentes que ocorrem no sistema elétrico, como defeitos com resistência de contato desconhecida, variações do carregamento, defeitos em diversas barras e fases, além de condições de não defeito. Todas estas situações devem ser representadas para o treinamento, validação e teste da rede neural para que ela tenha um funcionamento adequado.

A confecção desta base de dados representa as cargas detalhadamente e também a variação das mesmas conforme acontece em sistemas reais. Estas características reais torna mais difícil a detecção de faltas de alta resistência. Diversos trabalhos não consideram estas variações. Para maiores informações, recomenda-se a literatura (GIMENEZ, 2016), que foi a base para este módulo.

Módulo da Criação da Base de Dados

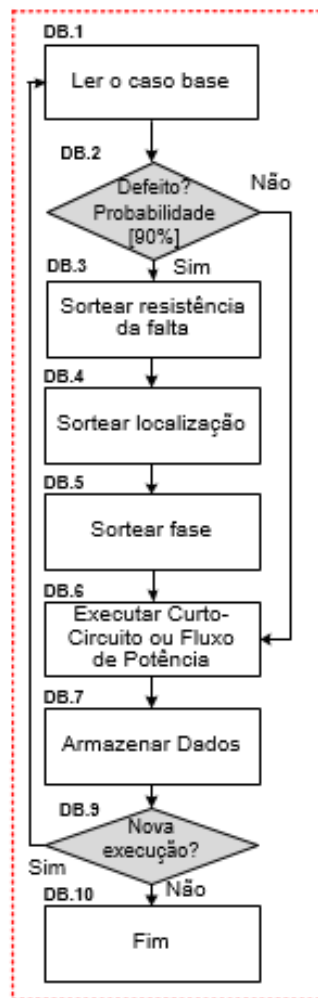


Figura 24 - Módulo da Criação de Base de Dados

DB.1: Neste passo são lidos os dados de barras, cargas, transformadores e alimentadores relativos ao caso base.

DB.2: Neste passo é feito um sorteio aleatório para definir se o caso apresentará um defeito ou não. O objetivo deste sorteio é inserir também casos sem defeito na base de dados para evitar *overtraining* no treinamento da rede neural e permitir que a rede neural perceba que não existem defeitos em determinadas condições. Por isso, 10% dos casos não apresentam defeitos.

DB.3: Neste passo é sorteada a resistência de falta do defeito, cujos valores variam aleatoriamente de 0 a 200 ohms, ou outro intervalo definido pelo usuário.

DB.4: Neste passo é sorteada a barra para a inserção do defeito. Os defeitos só são aplicados em barras de média tensão.

DB.5: Neste passo é escolhida a fase para aplicação de um defeito fase-terra.

DB.6: Neste passo é realizada a execução de um programa de fluxo de potência ou de análise de defeito de acordo com a decisão feita no passo **DB.5**

O programa de fluxo de potência utilizado é apresentado em (PENIDO et al., 2013) e o programa de análise de defeitos utilizado é apresentado em (PENIDO; DE

ARAUJO; DE CARVALHO FILHO, 2015). Ressalta-se que estes programas foram apenas utilizados nesta dissertação e nenhum desenvolvimento adicional foi realizado.

DB.7: Os resultados da simulação realizada em **DB.6** são gravados em um arquivo no formato texto para serem utilizados nos algoritmos de alocação de medidores e de detecção de defeitos.

Por fim, no passo **DB.8** é verificado se foi simulado o número de casos definido para a criação da base de dados. Neste trabalho foram definidas 2000 simulações. Caso contrário o processo é reiniciado.

O formato da base de dados criada é apresentado na Figura 25, onde cada linha do arquivo é o resultado de uma simulação de defeito. Os valores de corrente em todos os ramos de média tensão do sistema são armazenados.

CC	Fase	Barra	Area	Rf	Ia-m1	Ta-m1	Ib-m1	Tb-m1	Ic-m1	Tc-m1	Ia-m2	Ta-m2
1	2	18	2	6.820	557.887	-68.464	785.919	-173.375	531.651	56.652	537.930	-68.173
1	2	108	6	0.839	554.683	-72.050	1724.872	165.576	498.784	60.653	535.162	-71.801
1	1	29	7	11.588	730.934	-61.559	469.382	178.032	539.442	56.535	712.465	-61.130
1	2	78	5	16.187	557.056	-68.394	593.145	-177.244	530.428	57.446	537.911	-68.072
1	2	61	4	11.489	556.641	-68.825	641.429	-175.705	531.144	57.465	538.384	-68.510
1	2	21	2	16.713	564.893	-68.162	590.906	-176.726	530.967	57.443	546.201	-67.910
1	3	61	4	16.109	555.872	-68.389	472.449	178.141	666.313	61.364	535.712	-68.116
1	3	25	7	9.100	546.559	-68.224	478.129	178.068	762.165	63.368	527.211	-67.833
1	1	76	5	13.494	701.629	-62.869	469.389	178.135	545.761	56.424	683.534	-62.490
1	2	29	7	11.983	567.641	-68.272	652.226	-176.047	538.391	57.120	548.833	-68.061
1	2	97	6	10.099	566.184	-69.392	664.661	-175.551	536.513	57.747	546.343	-69.062
1	2	72	5	1.550	574.923	-71.576	1483.116	176.507	512.589	59.136	555.067	-71.391
1	1	42	3	1.156	1844.585	-67.299	438.994	-179.837	547.958	52.090	1827.561	-67.182
1	3	30	7	16.114	565.363	-68.364	469.357	177.513	665.425	62.044	548.643	-68.134
1	1	56	4	13.754	703.531	-62.674	458.062	178.820	545.254	57.114	684.779	-62.254
0	2	7	1	15.739	543.322	-68.391	456.842	179.253	533.785	57.168	525.631	-68.232
1	3	1	1	18.731	557.717	-68.408	463.992	178.084	647.607	62.657	539.210	-68.078
1	3	60	4	0.548	495.373	-63.908	458.558	171.094	2307.854	42.261	478.850	-63.508
1	2	152	4	19.931	556.437	-68.198	579.637	-176.909	534.789	56.944	536.628	-67.902
1	2	99	6	4.676	576.779	-69.459	886.357	-176.284	529.806	57.622	557.297	-69.204
0	2	55	4	5.756	558.744	-68.779	462.756	178.802	543.934	57.679	541.012	-68.512
1	3	56	4	14.677	551.931	-68.022	475.450	177.633	675.312	62.093	533.473	-67.736
0	1	63	4	7.033	562.589	-68.268	467.444	178.042	539.954	57.759	544.247	-67.976
1	2	54	4	16.753	555.482	-67.975	588.754	-176.274	520.679	57.101	537.300	-67.769

Figura 25 - Exemplo da base de dados

Onde (identificador localizado no cabeçalho do arquivo da Figura 25):

- CC – Indica a existência ou não de defeito na simulação (1 com defeito, 0 sem defeito);
- Fase – Indica a fase em que foi aplicado o defeito;
- Barra – Indica a barra na qual foi aplicado o defeito;
- Área – Indica a parte do sistema entre dois ou mais medidores na qual foi aplicado o defeito. Estes valores dependem da posição dos medidores alocados e são redefinidos diversas vezes durante a execução do algoritmo genético. Esta redefinição é realizada em uma etapa posterior do método, pela rotina formar AOM, detalhada na seção 3.3.4.
- Rf – Indica a resistência de arco (contato) do defeito;
- Ia-m1 – Módulo da corrente medida no medidor 1 na fase a;

- T_{a-m1} – Ângulo da corrente medida no medidor 1 na fase a;
- I_{b-m1} – Módulo da corrente medida no medidor 1 na fase b;
- T_{b-m1} – Ângulo da corrente medida no medidor 1 na fase b;
- I_{c-m1} – Módulo da corrente medida no medidor 1 na fase c;
- T_{c-m1} – Ângulo da corrente medida no medidor 1 na fase c;
- I_{a-m2} – Módulo da corrente medida no medidor 2 na fase a;
- T_{a-m2} – Ângulo da corrente medida no medidor 2 na fase a.

Os dados assim gerados serão utilizados primeiramente no módulo de otimização, em seguida passarão por alterações no módulo separar área, item 3.3.4. Por fim, servirão de entrada para o módulo função fitness, item 3.3.3.

3.3.2 Módulo de Otimização - Algoritmos Genéticos

Visto que a alocação dos medidores no sistema de distribuição trata de um problema de otimização combinatória, é importante salientar que tais processos de otimização estudam problemas que se caracterizam pelo número finito de soluções possíveis. Embora, em princípio, a solução ótima possa ser obtida através enumeração, na prática, frequentemente isto se torna inviável devido ao número extremamente alto de soluções viáveis. Assim, estudando as propriedades estruturais do problema, métodos heurísticos têm sido apresentados pela comunidade científica para obter soluções aproximadas. Algumas heurísticas, denominadas meta-heurísticas, podem ser usadas na resolução de diversos problemas de otimização combinatória através de uma representação adequada e adaptação de alguns parâmetros para cada problema específico.

Os AGs são métodos robustos que podem ser utilizados para resolver problemas em pesquisa numérica, otimização de funções e aprendizagem de máquinas, entre outros. Eles têm sido apontados como técnicas promissoras para solucionar problemas combinatoriais, como os clássicos problemas de programação inteira. Apesar de não garantirem otimalidade, possuem como principal vantagem melhor desempenho computacional, em relação aos métodos concorrentes, além de ser um procedimento de relativa simplicidade.

Na Figura 26 é apresentado o algoritmo do método proposto para otimização da alocação de medidores utilizando algoritmos genéticos.

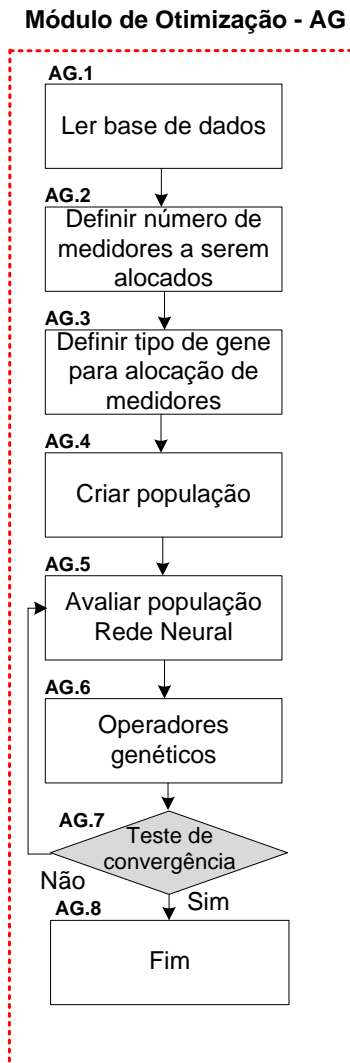


Figura 26 - Módulo de Otimização

AG.1: Neste passo a base de dados criada no passo **DB.7** é lida e os valores são armazenados em vetores e matrizes internos no MatLab®.

AG.2: Neste passo é definido o número fixo de medidores que se deseja alocar no sistema de distribuição. Em alguns casos o número de medidores ótimo não é interessante para o usuário devido à grande dificuldade em quantificar os custos advindos da detecção da falta em relação ao preço dos medidores. Desta forma, foi permitido ao usuário pré-definir o número de medidores a ser instalado na rede de distribuição. Isto é feito limitando o tamanho do cromossomo. De qualquer forma,

pode-se executar diversas vezes o programa com número de medidores diferentes e verificar a situação que melhor se encaixa aos interesses do usuário.

AG.3: Neste passo é definida a estrutura do cromossomo que será utilizado no processo de otimização. O cromossomo proposto é apresentado na Figura 27 e nele constam apenas informações sobre a posição dos medidores. O número de genes é igual ao número de medidores que deseja alocar. Ressalta-se que o método sempre considera que a subestação possui um medidor instalado, logo sua alocação não é considerada como um novo medidor. A alocação do medidor na subestação não entra no processo de otimização, apenas são consideradas as suas informações.

Também deve ser informada uma tabela para decodificar o gene, ou seja, indicar a qual ramo o gene se refere. Cada medidor possui um valor de identificação e indica as barras DE e PARA onde ele está instalado conforme pode ser visto na Figura 27 (Fig-a). Na Figura 28, são apresentadas as AOM para o cromossomo indicado na Figura 27.

Cada cromossomo é um potencial candidato para solução da otimização da alocação.




Figura 27 - Cromossomo Proposto – Exemplo

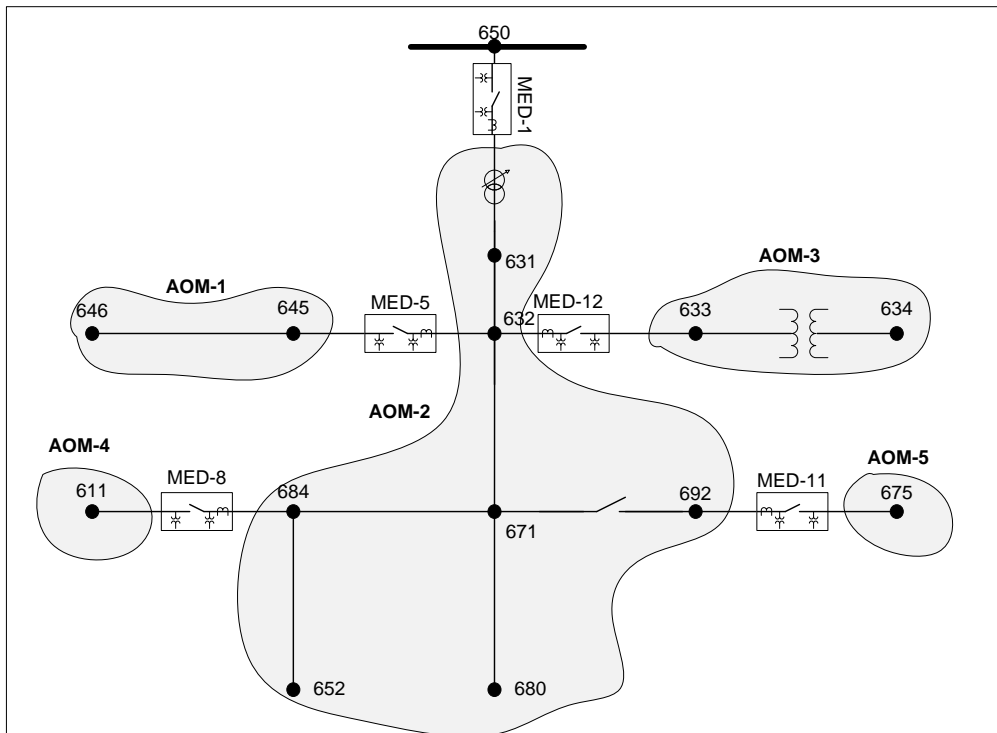


Figura 28 - Áreas formadas a partir do cromossomo – Exemplo

Antes de iniciar a execução, o usuário define o tipo de medidores que deseja considerar na simulação. Importante observar que todos os medidores são do mesmo tipo, uma vez definido pelo usuário.

AG.4: Neste passo a população inicial de cromossomos (candidatos a solução) é criada de forma aleatória. Durante as simulações, percebeu-se que o tamanho da população interfere no refinamento do resultado, entretanto existe uma dimensão máxima, que contribui de maneira significativa nos resultados. Para evitar que fosse criada uma população com genes semelhantes (alocação de medidores somente nos mesmos locais), foi implantada uma rotina a fim de verificar a semelhança dos genes da mesma população e eliminá-las em casos que ocorressem.

AG.5: Neste passo a população será avaliada segundo uma função *fitness*, ou seja, cada cromossomo terá sua aptidão avaliada. No caso específico deseja-se aumentar a eficiência na detecção de defeitos em sistemas de distribuição, que equivale a diminuir os erros de detecção. Para atender a este objetivo, e devido a sua importância e complexidade no método, a função *fitness* é detalhada na seção 3.3.3.

AG.6: Neste passo são aplicados os operadores evolutivos na população. As opções de reprodução especificam como o algoritmo genético cria “filhos” para a próxima geração.

Uma opção na reprodução é o elitismo, que especifica o número de indivíduos que serão garantidos para sobreviver à próxima geração. O elitismo deve ser definido como um número inteiro positivo menor ou igual ao tamanho da população, no presente trabalho considerou-se igual a 2.

Outro operador aplicado na metodologia é o *crossover*, que cria “filhos” a partir da combinação dos genes dos pais. A função *crossover* é selecionar aleatoriamente uma entrada, ou gene, na mesma coordenada dos dois pais e atribui ao filho. Foi utilizado o *default* do matlab, sendo 0,8 o valor correspondente.

Também foi aplicado o operador genético de mutação, na qual são feitas pequenas mudanças aleatórias nos indivíduos da população para fornecer diversidade genética e permitirão o algoritmo genético procurar em um espaço mais amplo.

Por fim, no passo **AG.7** é avaliado a convergência do método pelo número de gerações ou estagnação da população. Caso não se tenha tido a convergência, o processo retorna para o passo **AG.5**.

3.3.3 Função Fitness

No método de otimização de alocação de medidores proposto neste trabalho, cada cromossomo precisa ser avaliado em busca de uma configuração que traga os menores erros de detecção, aumentando assim a eficiência na detecção de defeitos. Esta avaliação do cromossomo é essencial dentro do processo de otimização, e no caso deste trabalho é realizada na realidade por outro método para detecção e localização de defeitos, baseado em outra técnica inteligente, que são as redes neurais artificiais. Esta combinação de procedimentos traz certa complexidade ao método como um todo. Isto ocorre pois para cada candidato gerado no âmbito do algoritmo genético é necessária uma definição e aplicação de redes neurais artificiais. Por isso, nesta seção esta questão será detalhada.

O método proposto para a detecção e localização dos defeitos utiliza a técnica inteligente de Redes Neurais Artificiais aplicada a medições não-fasoriais ou fasoriais feitas no sistema de distribuição. Atualmente a maioria dos equipamentos na

distribuição fornece apenas medições não-fasoriais, mas há uma tendência de que existam, cada vez mais, equipamentos que permitam a obtenção de medições fasoriais nos sistemas. Logo, estas duas possibilidades foram exploradas no desenvolvimento do método. No trabalho (GIMENEZ, 2016), foi proposto essa consideração sendo reproduzida no presente trabalho.

Os estudos com RNAs buscam diminuir o erro de previsão. Almeja-se uma precisão, para garantir que os resultados da detecção de defeitos sejam os mais próximos da realidade encontrada pelas concessionárias. Existem diferentes tipos de redes neurais para diferentes aplicações, sendo que a precisão também está relacionada a uma correta definição da rede. Em (GIMENEZ, 2016) e (DINIZ, 2015) foram feitas diversas simulações com diversos tipos de redes e treinamentos para fins de detecção de defeitos, sendo que as redes neurais do tipo *Pattern Recognition Network* – PRN e a função de treinamento *Levenberg-Marquardt Backpropagation* - LMB apresentaram bons resultados em todos os casos testados. Logo, neste trabalho foi escolhida a dupla PRN-LMB, e não foram avaliadas outras funções de treinamento.

Na Figura 29 é apresentada a montagem das estruturas neurais utilizadas e o cálculo da função *fitness*.

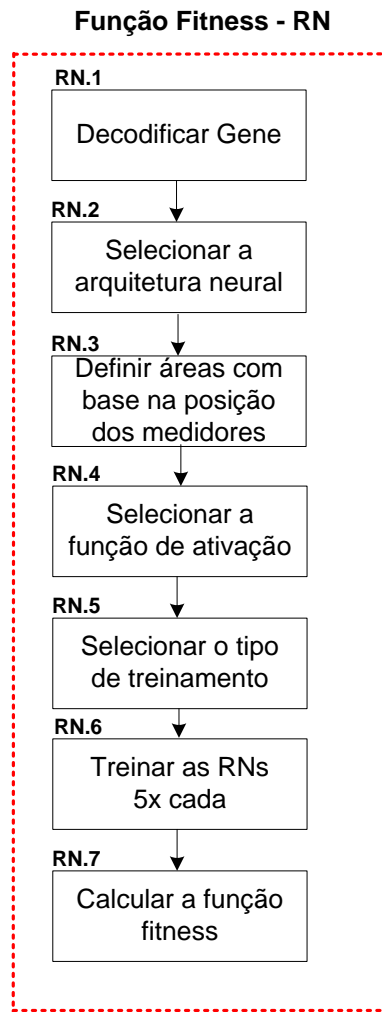


Figura 29 - Função *Fitness*

RN.1: Neste passo o cromossomo é decodificado conforme apresentado no passo **AG.3**, na seção anterior.

RN.2: Neste passo são definidos o número de camadas ocultas e o número de neurônios de cada camada oculta. Estes valores são definidos pelo usuário e não podem ser alterados durante o processo iterativo.

RN.3: Neste passo é chamada a rotina do módulo Separar Áreas, seção 3.3.4, para definir as AOMs. Após a separação de áreas é definido o número de redes neurais que devem ser criadas, sendo o número de redes criadas igual ao número de AOMs. O tipo de entrada de cada rede é função do tipo de medidores informados no passo **AG.3**, sendo o mesmo pré-definido pelo usuário, conforme dito anteriormente.

Na Figura 30 é apresentada uma representação gráfica como exemplo para ilustrar este passo. Nela, percebe-se que ao considerar o número de medidores igual a dois, são criados duas AOMs, e conseqüentemente são implementadas duas redes neurais, uma

para cada AOM. O número de variáveis, para a rede neural é dependente do tipo de dados e também do número de medidores na fronteira das áreas, sendo que:

- Se for medidor PMU serão seis variáveis por medidor, desta forma o número de variáveis será seis vezes o número de medidores de fronteira;
- Se for medidor SEQ (sequência) serão três variáveis por medidor, logo o número de variáveis será três vezes o número de medidores de fronteira;
- Se for medidor RMS serão três variáveis por medidor, logo o número de variáveis será três vezes o número de medidores de fronteira.

Assim sendo, na Figura 30 foram criadas duas AOMs, a AOM1 possui dois medidores de fronteiras (MED1 e MED2), e a AOM2 possui apenas um medidor de fronteira (MED2). Considerando a entrada de dados em PMU, entende-se o fato da RN referente a AOM1 possuir 12 entradas de dados (6 por medidor), e a RN referente a AOM2 possuir 6 entradas de dados (6 por medidor).

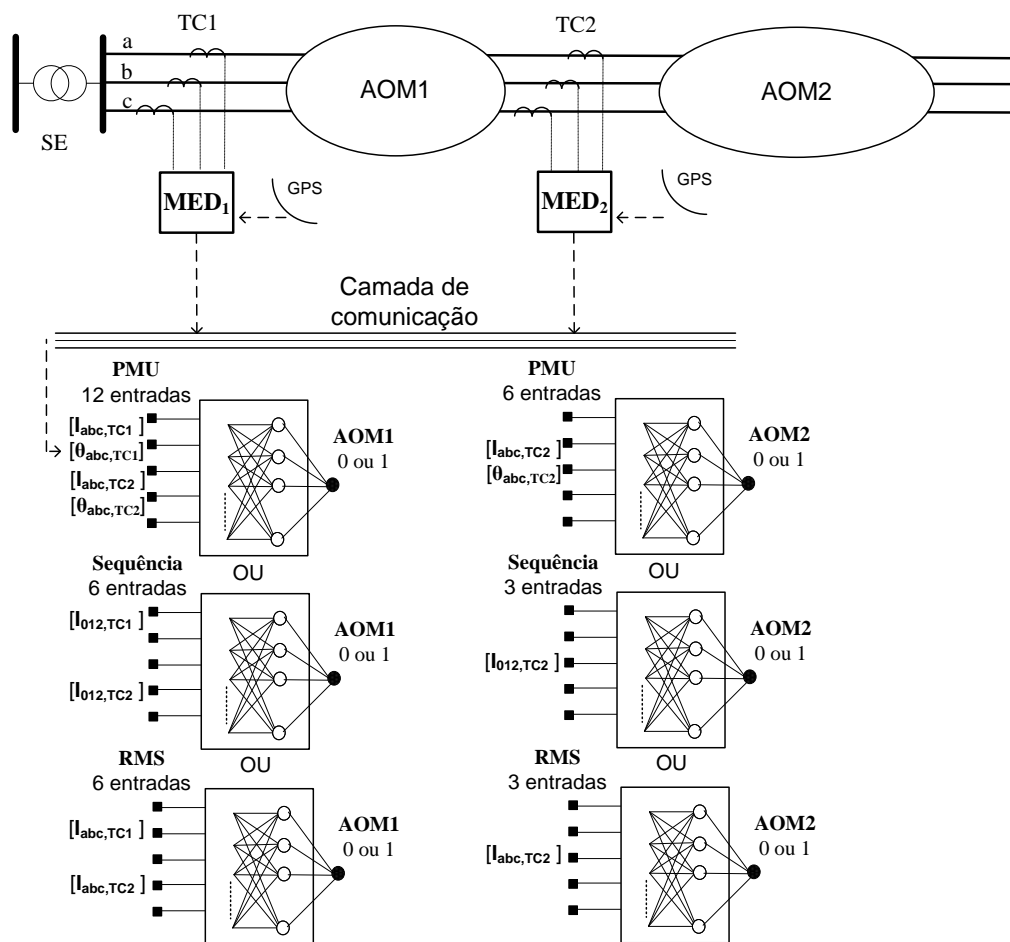


Figura 30 - Definição das Redes Neurais

RN.4: São selecionados os tipos de ativação dos neurônios. Neste trabalho foi escolhida a função de ativação sigmoideal para os neurônios das camadas ocultas e ativação linear para a camada de saída.

RN.5: Neste passo é escolhido o tipo de treinamento da rede neural. Neste trabalho foram escolhidas as redes neurais do tipo *Pattern Recognition Network*. A função de treinamento utilizada foi *Levenberg-Marquardt Backpropagation*, e não foram avaliadas outras funções de treinamento.

RN.6: Neste passo são treinadas cinco vezes cada rede neural para cada AOM. Isto é realizado porque o desempenho da rede neural é dependente da qualidade dos dados de entrada. Assim, treinando cinco vezes cada rede neural cada AOM tenta-se maximizar a eficiência da rede permitindo cinco chances para a escolha de dados de entrada que possam melhorar a eficiência da rede. O algoritmo seleciona a rede neural que apresentou maior eficiência em cada área.

RN.7: Neste passo é calculada a função fitness. Existem quatro tipos possíveis de resultados de uma rede neural com um neurônio na camada de saída. Um gráfico com os possíveis resultados é apresentado na Figura 31.




Figura 31 - Possíveis resultados de uma rede neural (PENIDO et al., 2013)

Onde:

True Negative: É o verdadeiro negativo. Significa a rede neural informar que não existe defeito e realmente não existir defeito no sistema de distribuição. Neste caso é considerado um acerto da rede neural.

True Positive: É o verdadeiro positivo. Significa a rede neural informar que existe defeito e realmente existir defeito no sistema de distribuição. Neste caso é considerado um acerto da rede.

False Negative: É o falso negativo. Significa a rede neural informar que não existe defeito e existir defeito no sistema de distribuição. Neste caso é considerado um erro da rede.

False Positive: É o falso positivo. Significa a rede neural informar que existe defeito e não existir defeito no sistema de distribuição. Neste caso é considerado um erro da rede.

Em (DINIZ, 2015) a eficiência da rede foi definida conforme a equação (3.4).

$$EF (\%) = \frac{TN + TP}{NS} \cdot 100\% \quad (3.4)$$

Onde:

NS – É o número de casos que foram avaliados pela rede neural;

TN – É a quantidade de verdadeiros negativos nos casos avaliados;

TP – É a quantidade de verdadeiros positivos nos casos avaliados

Mas esta função apresentou um grave problema, pois não representava corretamente a eficiência da rede. Por exemplo, considere um conjunto de 100 casos, dentre estes, 10 apresentam defeitos. Quando a rede neural é utilizada para testar os casos, ela indica que não existe nenhum caso com defeito e sua eficiência é 90%. Mas ela errou todos os casos de defeitos, ou seja, ela é “cega” para os defeitos.

Assim, como apresentado no item 3.2, uma nova função de avaliação da eficiência da rede neural (fitness) foi proposta nesta dissertação e é apresentada pelas as equações (3.5), (3.6) e (3.7). Nesta nova função, a avaliação dos casos com defeitos e sem defeitos são avaliados de forma separada e elevados ao quadrado para majorar o erro obtido pela rede neural em relação ao esperado. Logo no caso exemplo, o valor de eficiência TP' é 0% e valor de TN' é 111% (ou seja, 11% de erro). Quando estes valores são submetidos à equação (3.7) obtém-se um valor de 221%, sendo ideal o valor 0%.

$$TP' = \frac{TP}{NBP} \cdot 100\% \quad (3.5)$$

$$TN' = \frac{TN}{NBN} \cdot 100\% \quad (3.6)$$

$$FOB = \min \left(\sum_{i=1}^{nArea} |(TP' - 100\%)|^2 + |(TN' - 100\%)|^2 \right) \quad (3.7)$$

Onde:

TP – É a quantidade de casos avaliados que indicam defeitos;

NBP – É o número de casos que foram avaliados pela rede neural e que realmente ocorreu defeito;

TN – É a quantidade de casos avaliados que não indicam defeitos;

NBN – É o número de casos que foram avaliados pela rede neural e que realmente não ocorreu defeito;

nArea – Número de áreas formadas pelos medidores. O número de medidores determina a quantidade de áreas.

A equação (3.7) representa a aptidão de cada cromossomo sorteado pelo módulo de otimização (algoritmo genético). No fim do processo deseja-se minimizar o valor desta equação.

A fim de quantificar o impacto do aumento do número de medidores, será calculado o erro médio por área, conforme a equação (3.8). Assim, será comparada a eficiência do método por área.

$$EMA (\%) = \frac{\sqrt{\text{Fitness}}}{nArea} \quad (3.8)$$

Onde:

Fitness: Função de aptidão, conforme apresentado na seção 3.3.3.

nArea: Número de área.

Ao fim desta seção se tem a melhor rede neural para cada área definida, o valor da função objetivo para o presente cromossomo candidato à solução e também a eficiência do método por área.

3.3.4 Módulo para separar área

A população do algoritmo genético a ser testada é criada no passo **AG.4**, e vê-se que no módulo da rede neural é necessário delimitar para cada cromossomo a ser testado as áreas de observações dos medidores (AOMs), que são formadas devido à disposição dos medidores em cada caso e informar quais barras pertencem às mesmas. Para isso, foi implementado um módulo de separação de áreas conforme apresentado na Figura 32.

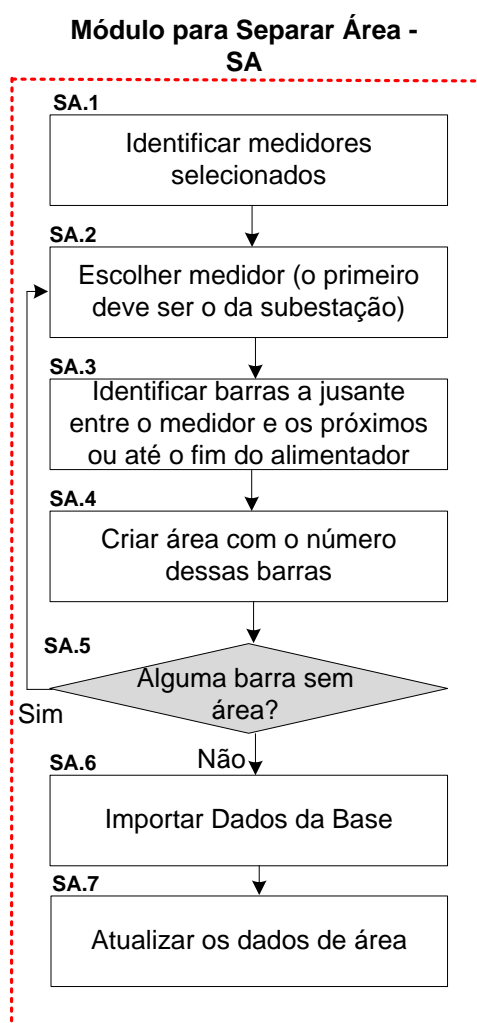


Figura 32 - Módulo para separar área

Em seguida ao passo **RN.3**, precisa-se decodificar as posições dos medidores que foram sorteados.

SA.1: Neste passo é realizada a identificação dos medidores, em que cada ramo do sistema é uma possível posição de alocação do medidor, estando o mesmo localizado na barra DE do ramo.

SA.2: Neste passo é determinado as AOM inicializando o processo pelo medidor da subestação, e em seguida o processo vai direcionando para os demais medidores sorteados. O medidor da subestação não é considerado no processo de otimização, entretanto as informações do mesmo fazem parte do processo de rede neural para identificação das falhas.

SA.3: Após ter sido escolhido o medidor em observação no passo **SA.2** salva-se todas as barras a jusante desse medidor até o final do alimentador ou até encontrar outro medidor no percurso, excluindo as barras de fronteiras com os outros medidores.

SA.4: Após o passo anterior, são conhecidas todas as barras pertencentes a cada área. Assim nesse passo é criado um vetor para cada área, com todas as barras pertencentes a ela.

SA.5: Neste passo verifica se existem barras sem área identificada, em caso positivo reinicializa o procedimento no passo **SA.2**.

SA.6: Após o passo **SA.4**, são conhecidas todas as barras pertencentes a cada área. Com isso, neste passo importa-se a base de dados para em seguida atualizar a coluna 4 do banco de dados **DB.9**.

SA.7: Neste passo é atualizado o valor de área de cada barra.

Esta rotina para separar área é uma interessante contribuição do presente trabalho, visto que, as detecções dos defeitos são realizadas por AOM. Assim, considerando diferentes AOM, pode-se conseguir uma maior taxa de assertividade nas detecções de defeitos.

Na Figura 33 é apresentada a base de dados de um estudo de caso. Assim, a rotina percorre todas as linhas da coluna 3 (Barra), e atualiza a coluna 4 (Área) com a nova área que esta barra pertence, após a escolha dos medidores.

CC	Fase	Barra	Area	Rf	Ia-m1	Ta-m1	Ib-m1	Tb-m1	Ic-m1	Tc-m1	Ia-m2	Ta-m2	
1	2	18	2	6.820	557.887	-68.464	785.919	-173.375	531.651	56.652	537.930	-68.173	758.396
1	2	108	6	0.839	554.683	-72.050	1724.872	165.576	498.784	60.653	535.162	-71.801	1703.990
1	1	29	7	11.588	730.934	-61.559	469.382	178.032	539.442	56.535	712.465	-61.130	444.129
1	2	78	5	16.187	557.056	-68.394	593.145	-177.244	530.428	57.446	537.911	-68.072	563.387

Figura 33 - Atualização das áreas

Capítulo 4 Resultados

4.1 Introdução

Nesta seção serão apresentados resultados obtidos com o método baseado em algoritmos genéticos para alocação ótima de medidores na rede de distribuição para a detecção de defeitos monofásicos com alta resistência na média tensão. A detecção de faltas é realizada por um método baseado em redes neurais artificiais conforme apresentado no Capítulo 3.

Foram utilizados os sistemas IEEE 13 barras e o IEEE 123 barras para a realização dos testes. Ao longo deste capítulo, serão apresentados os resultados obtidos variando o tipo de medição (RMS, PMU, Sequência) e a quantidade de medidores alocados. Lembrando que o tipo de medição impacta na rede neural, devido as diferentes entradas possíveis, e a quantidade de medidores impacta na rede neural, devido a quantidade de entradas, e no método de alocação, devido a quantidade a alocar.

Foram realizados testes considerando a variação da carga (situação mais real) no treinamento das redes e considerando apenas um patamar (prática muito utilizada em vários trabalhos). Esta questão será melhor explicada adiante.

Três considerações de topologia sistêmica foram testadas: (i) Nenhum equipamento com conexão direta para a terra está alocado nos alimentadores de média tensão (primário) e as cargas são conectadas através de transformadores do tipo delta-estrela. Essa topologia é referente aos sistemas de distribuição brasileiros com nenhum equipamento conectado ao primário; (ii) Os capacitores de distribuição e as capacitâncias parasitas são conectadas na média tensão e as cargas são conectadas através de transformadores do tipo delta-estrela. Essa topologia é referente aos sistemas brasileiros reais e (iii) todos os equipamentos e cargas são conectados diretamente na média tensão conforme disposto originalmente nos casos base do IEEE. Essa topologia refere-se aos sistemas de distribuição norte-americanos.

Para cada uma das topologias foram simulados os cenários apresentados na Tabela 1. Não serão apresentados os resultados dos cenários com carga fixa para as topologias – ii, iii – pois em todos os casos, apresentaram assertividade de 100%.

Tabela 1 - Sistemas e cenários analisados

Sistema	Cenário	Topologia	Quantidade de Medidores	Variação da carga	Entrada
IEEE13	1	(i) Nada no primário	2	Não	RMS
	2	(i) Nada no primário	3	Não	RMS
	3	(i) Nada no primário	7	Não	RMS
	4	(i) Nada no primário	2	Sim	RMS
	5	(i) Nada no primário	3	Sim	RMS
	6	(i) Nada no primário	7	Sim	RMS
	7	(ii) Capacitor no primário	2	Não	RMS
	8	(ii) Capacitor no primário	3	Não	RMS
	9	(ii) Capacitor no primário	7	Não	RMS
	10	(ii) Capacitor no primário	2	Sim	RMS
	11	(ii) Capacitor no primário	3	Sim	RMS
	12	(ii) Capacitor no primário	7	Sim	RMS
	13	(iii) Tudo no primário	2	Sim	RMS
	14	(iii) Tudo no primário	3	Sim	RMS
	15	(iii) Tudo no primário	7	Sim	RMS
	16	(i) Nada no primário	2	Sim	PMU
	17	(i) Nada no primário	3	Sim	PMU
	18	(i) Nada no primário	7	Sim	PMU
	19	(ii) Capacitor no primário	2	Sim	PMU
	20	(ii) Capacitor no primário	3	Sim	PMU
	21	(ii) Capacitor no primário	7	Sim	PMU

	22	(iii) Tudo no primário	2	Sim	PMU
	23	(iii) Tudo no primário	3	Sim	PMU
	24	(iii) Tudo no primário	7	Sim	PMU
	25	(i) Nada no primário	2	Sim	SEQ
	26	(i) Nada no primário	3	Sim	SEQ
	27	(i) Nada no primário	7	Sim	SEQ
	28	(ii) Capacitor no primário	2	Sim	SEQ
	29	(ii) Capacitor no primário	3	Sim	SEQ
	30	(ii) Capacitor no primário	7	Sim	SEQ
	31	(iii) Tudo no primário	2	Sim	SEQ
	32	(iii) Tudo no primário	3	Sim	SEQ
	33	(iii) Tudo no primário	7	Sim	SEQ
IEEE123	34	(iii) Tudo no primário	6	Não	RMS
	35	(iii) Tudo no primário	6	Não	PMU
	36	(iii) Tudo no primário	6	Não	SEQ
	37	(iii) Tudo no primário	6	Sim	RMS
	38	(iii) Tudo no primário	6	Sim	PMU
	39	(iii) Tudo no primário	6	Sim	SEQ
	40	(iii) Tudo no primário	11	Não	RMS
	50	(iii) Tudo no primário	11	Não	PMU
	51	(iii) Tudo no primário	11	Não	SEQ
	52	(iii) Tudo no primário	11	Sim	RMS
	53	(iii) Tudo no primário	11	Sim	PMU
	54	(iii) Tudo no primário	11	Sim	SEQ

Para os cenários apresentados na Tabela 1, foram criadas diversas base de dados, conforme exposto na seção 3.3.1. As bases de dados do caso IEEE13 são compostas de 2000 casos simulados. Para o sistemas IEEE123 foram criadas bases de dados com 2000 e 5000 casos. Em ambas as situações utilizou-se o método proposto em (PENIDO, 2015), considerando os seguintes pontos:

1. O carregamento foi representado de formas distintas, para cenários diferentes:
 - 1.1. Em alguns cenários as cargas são consideradas constantes. Apesar de ser considerada uma razoável aproximação do sistema real para vários estudos, esta condição pode influenciar nos resultados da aplicação da rede neural, tornando a detecção mais fácil a princípio, porém, resultará em um aumento da taxa de erro da rede neural quando aplicada em outros sistemas reais.
 - 1.2. Em outros cenários as cargas são variadas de forma aleatória. Nestes casos, cada carga individualmente possui seu valor base multiplicado por um valor escolhido aleatoriamente entre 0,75 a 1,25 para cada simulação realizada. O objetivo disto é representar alguma variação da carga durante o dia e com isto tentar evitar o problema de particularização da rede neural para apenas um determinado patamar de carregamento.
2. Para cada cenário, foi considerada uma chance de 10% de não ser simulado um defeito. O objetivo disto é fornecer subsídios para que a rede neural definida com estes casos possa diferenciar condições normais das condições de defeito.
3. Para cada simulação da rede com defeito, uma fase e uma barra são escolhidas aleatoriamente para a aplicação do defeito.
4. A impedância de defeito é escolhida aleatoriamente entre 100 e 200 ohms.

Foram realizados testes para definir as redes neurais, associada a uma alocação ótima de medidores, que apresentam melhor desempenho para a detecção de defeitos monofásicos. Para tanto foram propostos três tipos de redes neurais para serem testados, considerando entrada não-fasorial (dados apenas de módulos em coordenadas de fase), considerando entrada fasorial em sequência (dados de módulos e ângulos em coordenadas de sequencia) e considerando entrada fasorial em coordenadas de fase (dados de módulos e ângulos em coordenadas de fase). A seguir as definições para os tipos de entradas consideradas:

- Não-Fasorial – Nas redes desenvolvidas nesta característica são utilizados dados de entrada não-fasoriais (considera-se somente os módulos das grandezas em coordenadas de fase nas entradas da rede neural). Essas considerações foram basicamente realizadas para atender a situação mais comum atualmente, na qual os medidores instalados nos sistemas de distribuição disponibilizam informações de módulos das grandezas para serem utilizados nas detecções;
- Fasorial em coordenadas de fase – Nas redes desenvolvidas nesta característica são utilizados dados de entrada fasoriais (consideram-se os módulos e ângulos das grandezas em coordenadas de fase nas entradas da rede neural). A principal ideia é a possibilidade de termos, cada vez mais, equipamentos nos sistemas de distribuição que disponibilizem as grandezas de forma fasorial para serem utilizadas nas detecções;
- Fasorial em coordenadas de sequência – É uma opção de utilização dos dados na forma fasorial. Porém, nesta abordagem os dados de entrada são representados em componentes de sequência (exemplo: I_0, I_+, I_-);

Como descrito no item 3.3.3 para avaliar a eficiência da metodologia utiliza-se a função de aptidão e também a eficiência média por área, que são descritas pelas equações (4.3) e (4.4), que já foram apresentadas na seção de referência.

$$TP' = \frac{TP}{NBP} \cdot 100\% \quad (4.1)$$

$$TN' = \frac{TN}{NBN} \cdot 100\% \quad (4.2)$$

$$FOB = \min \left(\sum_{i=1}^{nArea} |(TP' - 100\%)|^2 + |(TN' - 100\%)|^2 \right) \quad (4.3)$$

Onde:

TP – É a quantidade de casos avaliados que indicam defeitos;

NBP – É o número de casos que foram avaliados pela rede neural e que realmente ocorreu defeito;

TN – É a quantidade de casos avaliados que não indicam defeitos;

NBN – É o número de casos que foram avaliados pela rede neural e que realmente não ocorreu defeito;

$$EMA (\%) = \frac{\sqrt{\text{Fitness}}}{n\text{Area}} \quad (4.4)$$

Onde:

Fitness: Função de aptidão, conforme apresentado na seção 3.3.3.

nArea: Número de área.

Nas próximas seções serão apresentados os resultados dos testes realizados para definir qual tipo de rede neural, associado a alocação ótima de medidores, apresenta melhor desempenho para cada cenário. Em todos os gráficos apresentados, o eixo das ordenadas indica a assertividade em percentual na detecção de defeitos por AOM, para cada um dos cenários apresentados na Tabela 1. Nos gráficos são apresentados, as assertividades de cada rede neural para os defeitos dentro da AOM e fora da mesma. Importante observar que cada AOM é composta pelas as barras a jusante do medidor alocado até o final do alimentador ou até encontrar outro medidor no percurso, excluindo as barras de fronteiras com os outros medidores. Por fim, ressalta-se que é determinada uma rede neural ótima para cada AOM.

4.2 Testes com o Sistema IEEE13 – Não Fasorial (RMS)

Nesta seção serão apresentados os resultados obtidos com a aplicação do método proposto no sistema IEEE13, considerando a rede neural com entradas do tipo não fasorial. Um barramento extra foi incluído para representar a subestação. Foi considerada a alocação na rede de distribuição de 2, 3 e 7 medidores. Lembrando que um dos medidores é sempre instalado no alimentador que deixa a subestação de distribuição, ou seja, a otimização da alocação dos medidores realizados pelo módulo de otimização 3.3.2, considera um medidor a menos do total alocado na rede de distribuição.

Nas próximas subseções serão separados os resultados para cada uma das topologias de sistema testadas e para as diferentes considerações das cargas.

4.2.1 IEEE13 – Não Fasorial (RMS) - Topologia (i)

Para facilitar o entendimento, será lembrado no início das subseções, o conceito de cada topologia. Nesta seção os testes foram realizados considerando nenhum equipamento com conexão direta para a terra alocado nos alimentadores de média tensão e as cargas são conectadas através de transformadores do tipo delta-estrela.

4.2.1.1 IEEE13 – Não Fasorial (RMS) - Topologia (i) - Carga Fixa

- 2 Medidores

A Figura 34 e a Figura 35 representam os resultados das simulações do sistema com o cenário de carga fixa com a alocação de dois medidores do tipo RMS. A Figura 34 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 20 neurônios na camada oculta de cada rede neural.




Figura 34 - IEEE13 / RMS / Carga Fixa / Nada no primário - AOM 2 Medidores

O valor da função aptidão neste cenário foi zero, ou seja, ambas as redes neurais tiveram 100% de acerto. O gráfico da Figura 35 mostra que a rede neural referente a AOM1 indicou corretamente todos os casos de defeitos dentro da AOM1 (azul) e foi insensível para os defeitos fora da AOM1. Comportamento análogo foi verificado para a AOM2.

Na Tabela 2 são mostrados os resultados detalhados. Os valores referentes aos "Acertos Defeitos" são os verdadeiros positivos e os valores referentes ao "Acertos Fora" são os verdadeiros negativos.

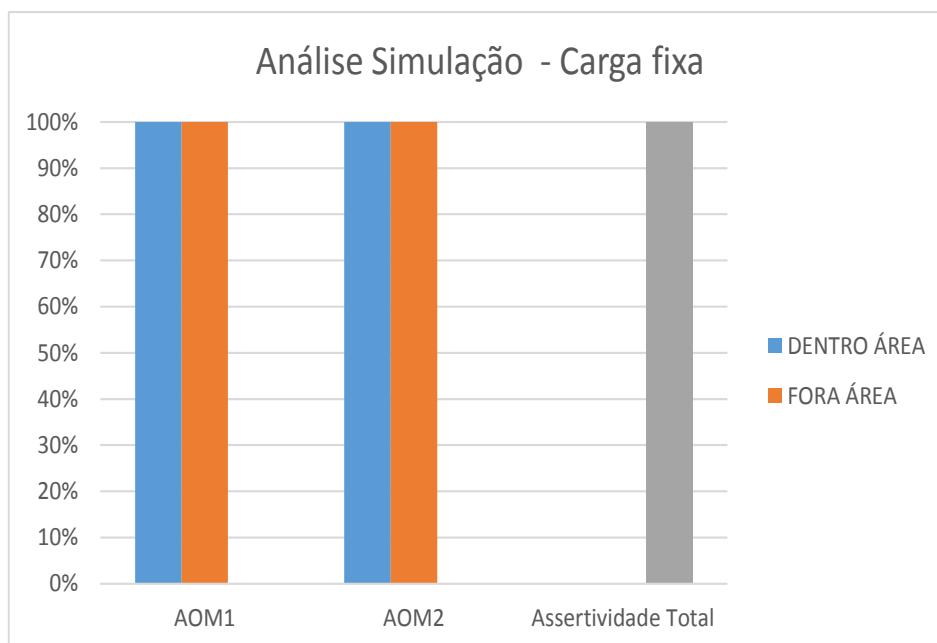


Figura 35 – IEEE13 / RMS / Carga Fixa / Nada no primário / 2 Medidores - Resultados

Tabela 2 - IEEE13 / RMS / Carga Fixa / Nada no primário / 2 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1444	1444	100	556	100
2	556	556	100	1444	100

A quantidade de defeitos fora da AOM sempre será 2000 menos a quantidade de defeitos na AOM.

- **3 Medidores**

A Figura 36 e a Figura 37 representam os resultados das simulações do sistema com o cenário de carga fixa com a alocação de três medidores do tipo RMS. A Figura 36 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 20 neurônios na camada oculta de cada rede neural.




Figura 36 - IEEE13 / RMS / Carga Fixa / Nada no primário - AOM 3 Medidores

O valor da função aptidão neste cenário foi zero, ou seja, as três redes neurais tiveram 100% de acerto. O gráfico da Figura 37 mostra que a rede neural referente a AOM1 indicou corretamente todos os casos de defeitos dentro da AOM1 (azul) e foi insensível para os defeitos fora da AOM1. Comportamento semelhante foi verificado para a AOM2 e AOM3. Na Tabela 3 são mostrados os resultados detalhados.




Figura 37 - IEEE13 / RMS / Carga Fixa / Nada no primário / 3 Medidores - Resultados

Tabela 3 - IEEE13 / RMS / Carga Fixa / Nada no primário / 3 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	712	712	100	1288	100
2	1089	1089	100	911	100
3	199	199	100	1801	100

- **7 Medidores**

A Figura 38 e a Figura 39 representam os resultados das simulações do sistema com o cenário de carga fixa com a alocação de sete medidores do tipo RMS. A Figura 38 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 20 neurônios na camada oculta de cada rede neural.

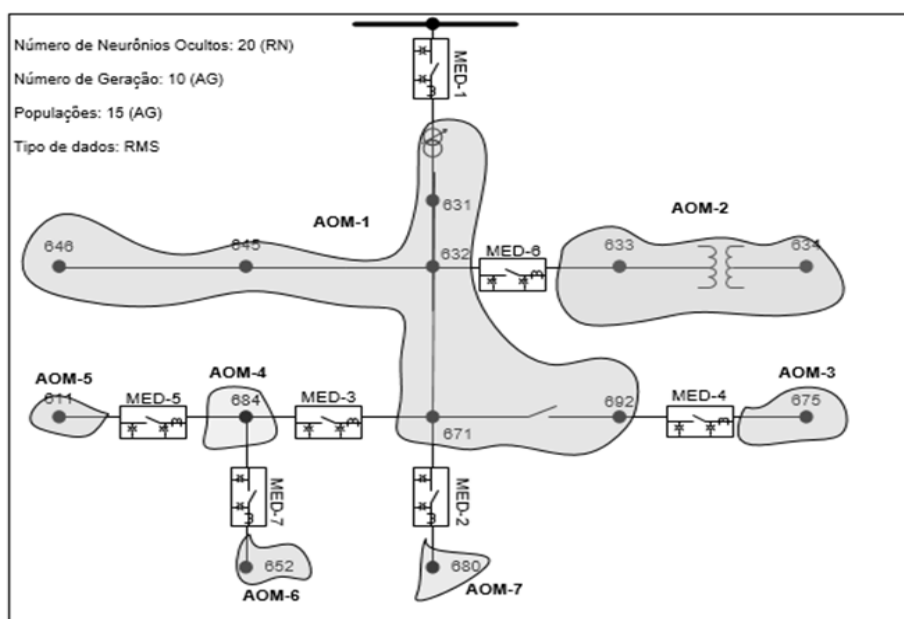


Figura 38 - IEEE13 / RMS / Carga Fixa / Nada no primário - AOM 7 Medidores

O valor da função aptidão neste cenário foi zero, ou seja, as sete redes neurais tiveram 100% de acerto conforme apresentado no gráfico da Figura 39. Na Tabela 4 são mostrados os resultados detalhados.

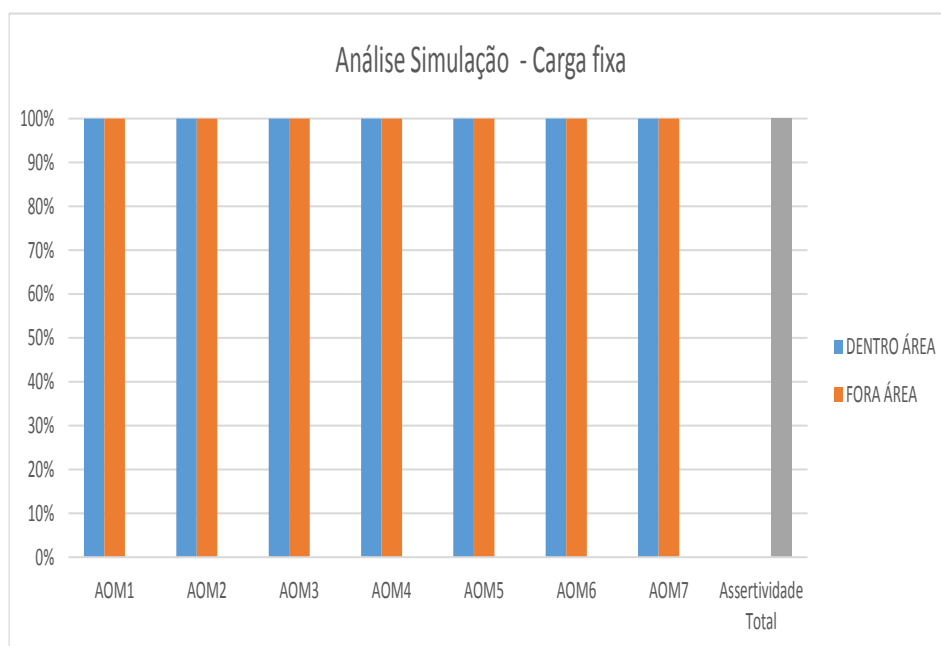


Figura 39 - IEEE13 / RMS / Carga Fixa / Nada no primário / 7 Medidores - Resultados

Tabela 4 - IEEE13 / RMS / Carga Fixa / Nada no primário / 7 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	534	534	100	1466	100
2	555	555	100	1445	100
3	178	178	100	1822	100
4	193	193	100	1807	100
5	186	186	100	1814	100
6	160	160	100	1840	100
7	194	194	100	1806	100

- **Conclusões Parciais: Carga Fixa e Medidores RMS**

Nota-se que para o caso IEEE13, considerando que não há variação de carga e que não existe nenhum equipamento conectado no primário as redes apresentaram eficácia de 100% em todos os cenários. Convém informar que o cenário com dois medidores indica grandes AOMs enquanto que no cenário com sete medidores as áreas de busca dos defeitos são menores, porém o custo associado à instalação de medidores é maior. A decisão de quantos medidores devem ser alocados neste caso deve ser tomada pelo usuário por existirem outras questões associadas dentro de cada concessionária.

4.2.1.2 IEEE13 – Não Fasorial (RMS) - Topologia (i) - Carga Variável

- 2 Medidores

A Figura 40 e a Figura 41 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de dois medidores do tipo RMS. A Figura 40 mostra o local indicado para a instalação dos medidores e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 40 - IEEE13 / RMS / Carga Variável/ Nada no primário - AOM 2 Medidores

O valor da função aptidão neste cenário foi 2052,54 (ou EMA = 22,65). O gráfico da Figura 41 mostra que a rede neural referente à AOM1 indicou corretamente 79,45% dos casos de defeitos dentro a AOM1 (azul) e indicou corretamente que 77,71% dos defeitos (ou casos sem defeitos) fora da AOM 1. Já para a AOM2, foi observado que a rede apresentou 100% de acertos nas detecções dos defeitos. Na Figura 41 são mostrados os resultados detalhados obtidos.




Figura 41 - IEEE13 / RMS / Carga Variável / Nada no primário / 2 Medidores - Resultados

Tabela 5 IEEE13 / RMS / Carga Variável / Nada no primário / 2 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1825	1450	79,45	136	77,71
2	175	175	100	1825	100

- **3 Medidores**

A Figura 42 e a Figura 43 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de três medidores do tipo RMS. A Figura 42 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 42 - IEEE13 / RMS / Carga Variável / Nada no primário - AOM 3 Medidores

O valor da função aptidão neste cenário foi 1582,32 (ou EMA = 13,26). O gráfico da Figura 43 mostra que a rede neural referente à AOM1 indicou corretamente 74,92% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 100% de acertos nas detecções dos defeitos enquanto a AOM3 apresentou 98,96% de acertos na detecção. Na Tabela 6 são mostrados os resultados detalhados obtidos.




Figura 43 - IEEE13 / RMS / Carga Variável / Nada no primário / 3 Medidores - Resultados por área

Tabela 6 - IEEE13 / RMS / Carga Variável / Nada no primário / 3 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1503	938	74,92	565	75,53
2	187	187	100	1813	100
3	561	465	82,89	1424	98,96

- **7 Medidores**

A Figura 44 e a Figura 45 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de sete medidores do tipo RMS. A Figura 44 mostra o local escolhido para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 44 - IEEE13 / RMS / Variável/ Nada no primário - AOM 7 Medidores

O valor da função aptidão neste cenário foi 5949,03 (ou EMA = 11,02). O gráfico da Figura 45 mostra que a rede neural referente à AOM1 indicou corretamente 25,52% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 23,21% de acertos nas detecções dos defeitos. Já a AOM3 apresentou 73,45% de acertos na detecção, a AOM4 100% de acertos. Já as AOM5, AOM6 e AOM7 apresentaram, respectivamente, 49,61%, 100% e 100% de acertos. A partir desse

resultado, serão indicados nos textos, apenas os resultados verdadeiros positivos, entretanto os demais podem ser analisados na Tabela 7.




Figura 45 - IEEE13 / RMS / Carga Variável / Nada no primário / 7 Medidores - Resultados por área

Tabela 7 - IEEE13 / RMS / Carga Variável / Nada no primário / 7 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	533	136	25,52	1493	98,09
2	349	81	23,21	1635	99,03
3	177	130	73,45	1823	100
4	182	182	100	1818	100
5	385	191	49,61	1607	99,5
6	180	180	100	1820	100
7	194	194	100	1806	100

- **Conclusões Parciais: Carga Variável e Medidores RMS**

Neste caso, notou-se que a variação de carga contribuiu para a redução da eficiência do método proposto. O principal motivo consiste no fato que a variação da carga se reflete como uma variação de corrente nos medidores, muitas vezes da mesma ordem de grandeza de uma falta de alta resistência, deste modo a rede neural proposta não conseguiu identificar tão corretamente os defeitos. Verifica-se também que o aumento

do número de medidores aumentou a eficiência da detecção, isto pode ser verificado pelo decremento do EMA e pelo incremento da assertividade total nos gráficos apresentados.

4.2.2 IEEE13 – Não Fasorial (RMS) - Topologia (ii)

Esta topologia considera que os capacitores de distribuição e as capacitâncias parasitas são conectadas ao primário e as cargas são conectadas através de transformadores do tipo delta-estrela;

4.2.2.1 IEEE13 – Não Fasorial (RMS) - Topologia (ii) - Carga Fixa

- 2 Medidores

A Figura 46 e a Figura 47 representam os resultados das simulações do sistema com o cenário de carga fixa com a instalação de dois medidores do tipo RMS. A Figura 46 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 20 neurônios na camada oculta de cada rede neural.

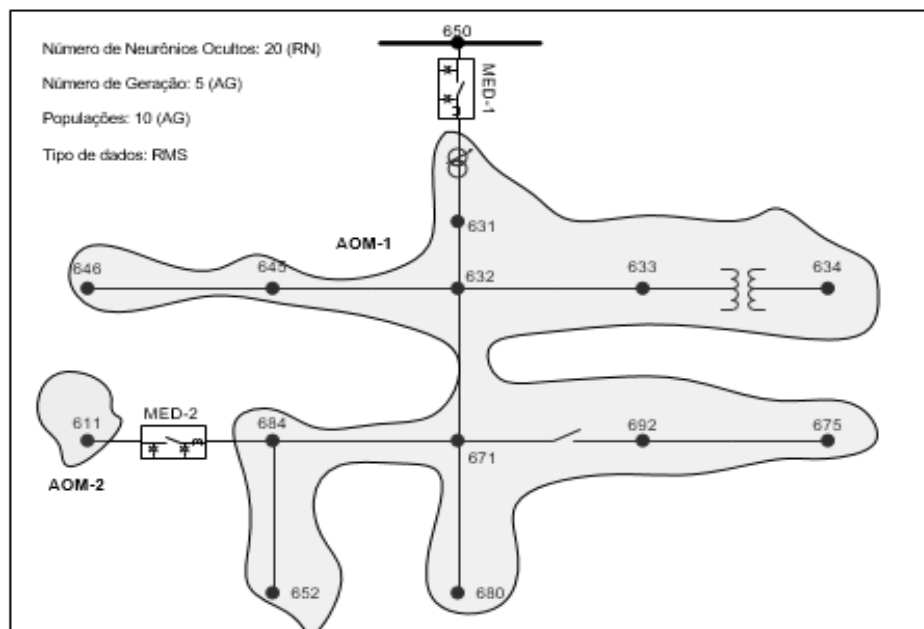


Figura 46 - IEEE13 / RMS / Carga Fixa / Capacitor no primário - AOM 2 Medidores

Inicialmente, analisando as AOMs formadas, as mesmas aparentam-se inusitadas. Entretanto é importante salientar que o cenário observado é com carga fixa, o que deixa o desafio de identificação de defeitos, mais simples.

O valor da função aptidão neste cenário foi zero, ou seja, ambas as redes neurais tiveram 100% de acerto. Na Tabela 8 são mostrados os resultados detalhados obtidos.




Figura 47 - IEEE13 / RMS / Carga Fixa / Capacitor no primário / 2 Medidores - Resultados

Tabela 8 - IEEE13 / RMS / Carga Fixa / Capacitor no primário / 2 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1816	1816	100	184	100
2	184	184	100	1816	100

- **3 Medidores**

A Figura 48 e a Figura 49 representam os resultados das simulações do sistema com o cenário de carga fixa com a instalação de três medidores do tipo RMS. A Figura 48 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 20 neurônios na camada oculta de cada rede neural.




Figura 48 - IEEE13 / RMS / Carga Fixa / Capacitor no primário - AOM 3 Medidores

O valor da função aptidão neste cenário foi zero, ou seja, todas as redes neurais tiveram 100% de acerto. Na

Tabela 9 são mostrados os resultados detalhados obtidos.




Figura 49 - IEEE13 / RMS / Carga Fixa / Capacitor no primário / 3 Medidores - Resultados

Tabela 9 - IEEE13 / RMS / Carga Fixa / Capacitor no primário / 3 Medidores - Resultados por área

OM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1641	1641	100	359	100
2	175	175	100	1825	100
3	184	184	100	1816	100

- **7 Medidores**

A Figura 50 e a Figura 51 representam os resultados das simulações do sistema com o cenário de carga fixa com a instalação de sete medidores do tipo RMS. A Figura 50 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 20 neurônios na camada oculta de rede neural.




Figura 50 - IEEE13 / RMS / Carga Fixa / Capacitor no primário - AOM 7 Medidores

O valor da função aptidão neste cenário foi zero, ou seja, todas as redes neurais tiveram 100% de acerto. Na Tabela 10 são mostrados os resultados detalhados obtidos.




Figura 51 - IEEE13 / RMS / Carga Fixa / Capacitor no primário / 7 Medidores – Resultados

Tabela 10 - IEEE13 / RMS / Carga Fixa / Capacitor no primário / 7 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	548	548	100	1452	100
2	395	395	100	1605	100
3	184	184	100	1816	100
4	181	181	100	1819	100
5	350	350	100	1650	100
6	167	167	100	1833	100
7	175	175	100	1825	100

- **Conclusões Parciais: Carga Fixa e Medidores RMS**

Nota-se que neste cenário as redes neurais apresentaram excelente desempenho mesmo com a consideração de capacitores e as capacitâncias parasitas na média tensão. Isto ocorreu, pois foi considerada a carga fixa, logo as redes conseguem distinguir facilmente entre condições de defeito na área e fora da área. Ressalta-se que esta não é a condição real de operação.

4.2.2.2 IEEE13 – Não Fasorial (RMS) - Topologia (ii) – Carga Variável

- **2 Medidores**

A Figura 52 e a Figura 53 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de dois medidores do tipo RMS. A Figura 52 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 52 - IEEE13 / RMS / Carga Variável / Capacitor no primário - AOM 2 Medidores

O valor da função aptidão neste cenário foi 2581,35 (ou EMA = 25,40). O gráfico da Figura 53 mostra que a rede neural referente a AOM1 indicou corretamente 79,08% dos casos de defeitos dentro a AOM1 (azul) Já a AOM2 indicou corretamente todos os casos de defeito dentro da área. Na Tabela 11 são mostrados os resultados detalhados obtidos.




Figura 53 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 2 Medidores – Resultados

Tabela 11 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 2 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1802	1425	79,08	149	75,25
2	198	198	100	1802	100

- **3 Medidores**

A Figura 54 e a Figura 55 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de três medidores do tipo RMS. A Figura 54 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 50 neurônios na camada oculta de cada rede neural.




Figura 54 - IEEE13 / RMS / Carga Variável / Capacitor no primário - AOM 3 Medidores

O valor da função aptidão neste cenário foi 3671,94 (ou EMA = 20,20). O gráfico da Figura 55 mostra que a rede neural referente a AOM1 indicou corretamente 74,92% dos casos de defeitos dentro a AOM1 (azul). Já a AOM2 indicou corretamente todos os casos de defeito dentro da área, enquanto a AOM3 obteve 82,89% de acertos na detecção dentro da área. Na Tabela 12 são mostrados os resultados detalhados obtidos.




Figura 55 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 3 Medidores - Resultados

Tabela 12 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 3 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1442	1042	72,16	356	64,03
2	376	290	77,13	1624	100
3	180	180	100	1820	100

- **7 Medidores**

A Figura 56 e a Figura 57 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de sete medidores do tipo RMS. A Figura 56 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.

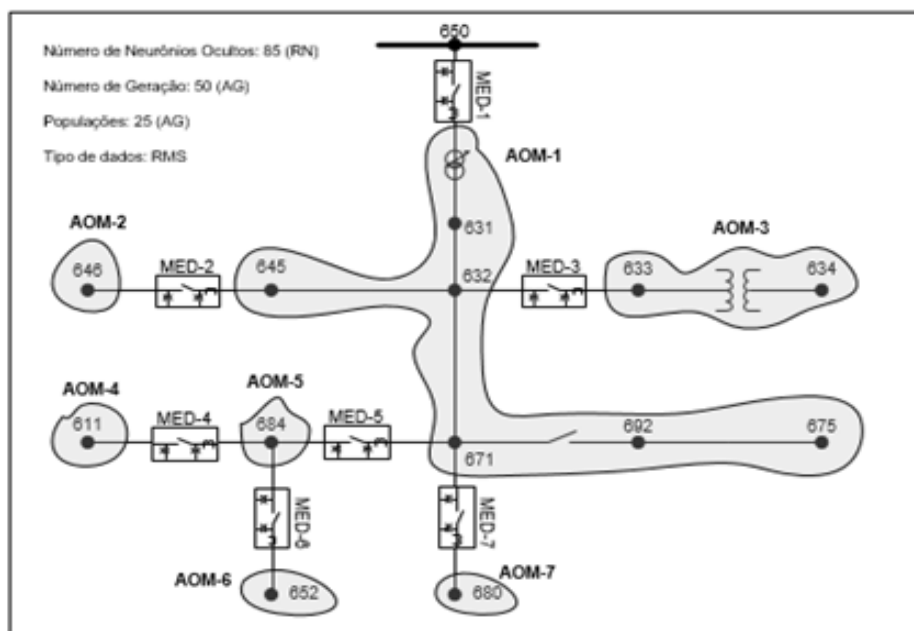


Figura 56 - IEEE13 / RMS / Carga Variável / Capacitor no primário - AOM 7 Medidores

O valor da função aptidão neste cenário foi 7273,67 (ou EMA = 12,18). O gráfico da Figura 57 mostra que a rede neural referente à AOM1 indicou corretamente 20,51% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 36,8% de acertos nas detecções dos defeitos. Já a AOM3 apresentou 46,47% de acertos na detecção, a AOM4 76,32% de acertos. Já as AOM5, AOM6 e AOM7

apresentaram, respectivamente, 100%, 60,2% e 74,58% de acertos. Na Tabela 13 são mostrados os resultados detalhados obtidos.

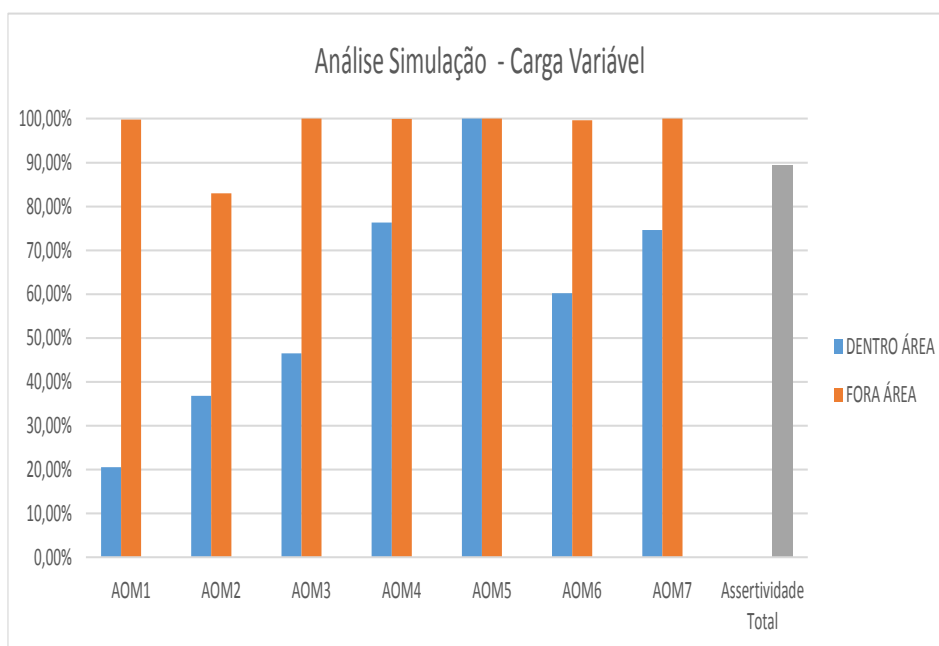


Figura 57 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 7 Medidores - Resultados por área

Tabela 13 - IEEE13 / RMS / Carga Variável / Capacitor no primário / 7 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	156	32	20,51	1841	99,84
2	924	340	36,8	893	82,99
3	170	79	46,47	1830	100
4	190	145	76,32	1809	99,94
5	187	187	100	1813	100
6	196	118	60,20	1797	99,61
7	177	132	74,58	1823	100

- **Conclusões Parciais: Carga Variável e Medidores RMS**

Nota-se que neste cenário as redes neurais apresentaram um baixo desempenho, a inclusão de capacitores e as capacitâncias parasitas na média tensão resultou em uma pequena perda de eficiência quando comparada com a condição de nenhum equipamento com conexão a terra conectado no primário. Essa condição é observada, pois com a presente topologia são gerados desequilíbrios, resultando na presença de

corrente de sequência zero. Por se identificar os defeitos pela corrente de sequência zero, tais desequilíbrios podem ser confundidos com faltas.

4.2.3 IEEE13 – Não Fasorial (RMS) - Topologia (iii)

A presente topologia considera todos os equipamentos e cargas conectados diretamente ao primário conforme disposto originalmente nos casos base do IEEE.

4.2.3.1 IEEE13 – Não Fasorial (RMS) - Topologia (iii) – Carga Fixa

Para este cenário não serão apresentados os resultados dos testes neste documento, apenas para não alongar demais, pois o método proposto apresentou uma taxa de assertividade igual a 100% em todas as situações.

4.2.3.2 IEEE13 – Não Fasorial (RMS) - Topologia (iii) – Carga Variável

- 2 Medidores

A Figura 58 e a Figura 59 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de dois medidores do tipo RMS. A Figura 58 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 58 - IEEE13 / RMS / Carga Variável / Tudo no primário - AOM 2 Medidores

O valor da função aptidão neste cenário foi 4746,46 (ou EMA = 34,45). O gráfico da Figura 59 mostra que a rede neural referente à AOM1 indicou corretamente 77,59% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 48,70% de acertos nas detecções dos defeitos. Na Tabela 14 são mostrados os resultados detalhados obtidos.




Figura 59 - IEEE13 / RMS / Carga Variável / Tudo no primário / 2 Medidores - Resultados

Tabela 14 - IEEE13 / RMS / Carga Variável / Tudo no primário / 2 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1807	1402	77,59	64	33,16
2	193	94	48,70	1797	99,45

- **3 Medidores**

A Figura 60 e Figura 61 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de três medidores do tipo RMS. A Figura 60 mostra o local escolhido para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta.




Figura 60 - IEEE13 / RMS / Carga Variável / Tudo no primário - AOM 3 Medidores

O valor da função aptidão neste cenário foi 3873,45 (ou EMA = 20,74). O gráfico da Figura 61 mostra que a rede neural referente à AOM1 indicou corretamente 71,65% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 87,36% de acertos nas detecções dos defeitos. Já a AOM3 apresentou 33,16% de acertos na detecção. Na Tabela 15 são mostrados os resultados detalhados obtidos.




Figura 61 - IEEE13 / RMS / Carga Variável / Tudo no primário / 3 Medidores - Resultados

Tabela 15 - IEEE13 / RMS / Carga Variável / Tudo no primário / 3 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1633	1170	71,65	172	46,87
2	174	152	87,36	1825	99,95
3	193	129	33,16	1798	99,5

- **7 Medidores**

A Figura 62 e a Figura 63 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de sete medidores do tipo RMS. A Figura 62 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.

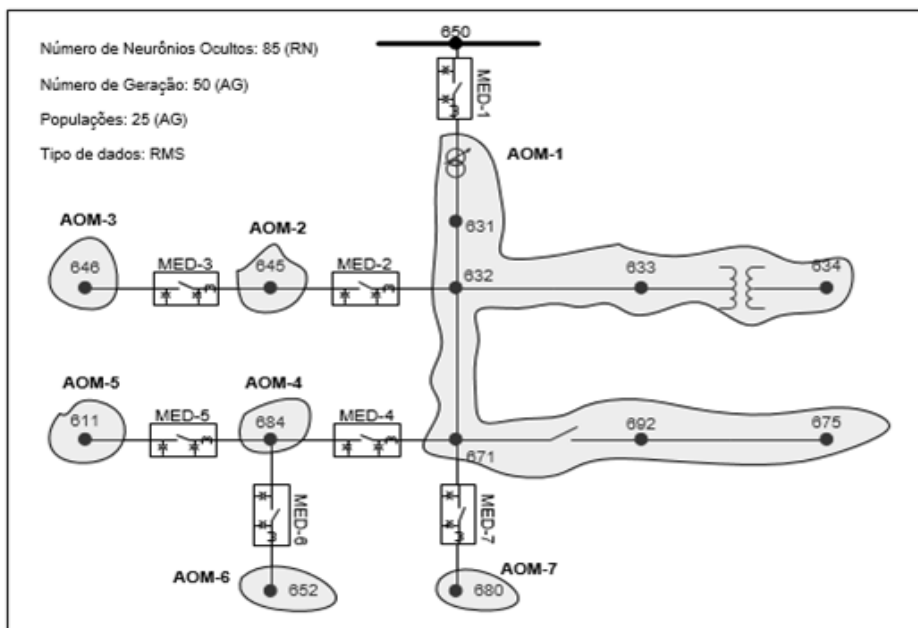


Figura 62 - IEEE13 / RMS / Carga Variável / Tudo no primário - AOM 7 Medidores

O valor da função aptidão neste cenário foi 4669,80 (ou EMA = 9,76). O gráfico da Figura 63 mostra que a rede neural referente à AOM1 indicou corretamente 38,78% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 100% de acertos nas detecções dos defeitos. Já a AOM3 apresentou 23,48% de acertos na detecção, a AOM4 75,79% de acertos. Já as AOM5, AOM6 e AOM7

apresentaram, respectivamente, 85%, 86,21% e 100% de acertos. Na Tabela 16 são mostrados os resultados detalhados obtidos.




Figura 63 - IEEE13 / RMS / Carga Variável / Tudo no primário / 7 Medidores – Resultados

Tabela 16 - IEEE13 / RMS / Carga Variável / Tudo no primário / 7 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	740	287	38,78	1107	87,86
2	191	191	100	1809	100
3	379	89	23,48	1600	98,70
4	190	144	75,79	1810	100
5	160	136	85	1840	100
6	174	150	86,21	1826	100
7	166	166	100	1834	100

- **Conclusões Parciais: Carga Variável e Medidores RMS**

Nota-se que neste cenário as redes neurais considerando carga variável também apresentaram um baixo desempenho quando comparadas as condições de carga fixa. A inclusão de capacitores e cargas na média tensão resultou, no geral, em pequenas modificações de eficiência quando comparada com a condição de nenhum equipamento com conexão a terra conectado no primário. Desta forma, entende-se que a alocação de capacitores e cargas na média tensão não apresentou impacto relevante nas definições das alocações de equipamentos e na aplicação das redes neurais propostas nesta

dissertação utilizando valores de entrada RMS. Já a consideração da variação do carregamento diário apresentou grande impacto nos resultados.

4.3 Testes com o Sistema IEEE13 – Fasorial (Sequência)

4.3.1 IEEE13 – Fasorial (Sequência) - Topologia (i)

Nesta seção os testes foram realizados considerando nenhum equipamento com conexão direta para a terra alocada nos alimentadores de média tensão e as cargas são conectadas através de transformadores do tipo delta-estrela

4.3.1.1 IEEE13 – Fasorial (Sequência) - Topologia (i) – Carga Fixa

Para essa condição de contorno não foram apresentados os resultados dos testes, pois o método proposto apresentou uma taxa de assertividade igual a 100% neste caso.

4.3.1.2 IEEE13 – Fasorial (Sequência) - Topologia (i) – Carga Variável

- **2 Medidores**

A Figura 64 e a Figura 65 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de dois medidores do tipo sequência. A Figura 64 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 64 - IEEE13 / Sequência / Carga Variável / Nada no primário - AOM 2 Medidore

O valor da função aptidão neste cenário foi zero. O gráfico da Figura 65 mostra que a rede neural referente à AOM1 indicou corretamente 100% dos casos de defeitos dentro da AOM1 (azul). A mesma situação e repete para a AOM2. Na Tabela 17 são mostrados os resultados detalhados obtidos.




Figura 65 - IEEE13 / Sequência / Carga Variável / Nada no primário / 2 Medidores - Resultados

Tabela 17 - IEEE13 / Sequência / Carga Variável / Nada no primário / 2 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1615	1615	100	385	100
2	385	385	100	1615	100

- **3 Medidores**

A Figura 66 e a Figura 67 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de três medidores do tipo sequência. A Figura 66 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.

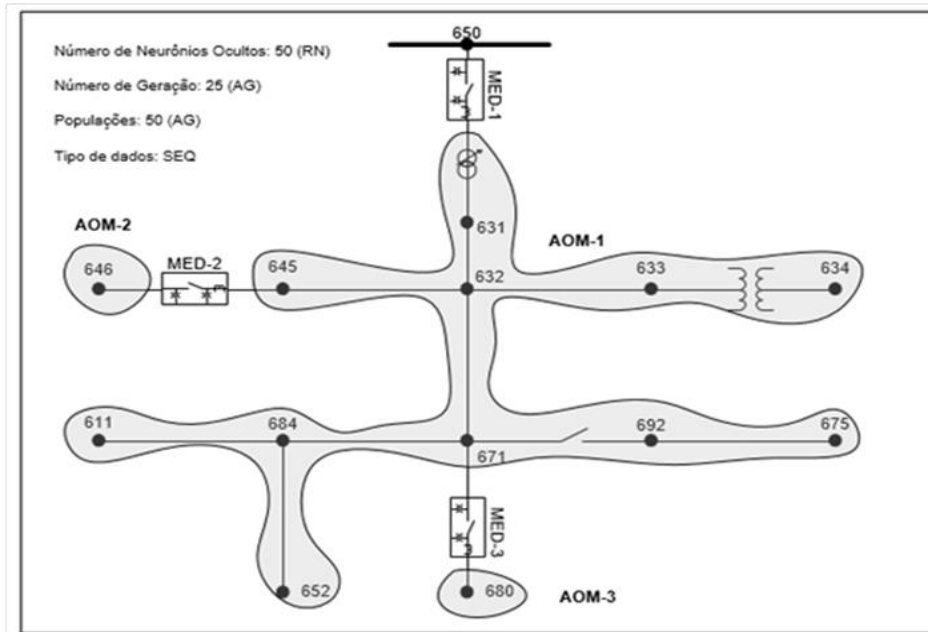


Figura 66 - IEEE13 / Sequência / Carga Variável / Nada no primário - AOM 3 Medidores

O valor da função aptidão neste cenário foi zero. O gráfico da Figura 67 mostra que a rede neural referente à AOM1 indicou corretamente 100% dos casos de defeitos dentro da AOM1 (azul). Para a AOM2, foi observado que a rede apresentou o mesmo desempenho. Na Tabela 18 são mostrados os resultados detalhados obtidos.




Figura 67 - IEEE13 / Sequência / Carga Variável / Nada no primário / 3 Medidores - Resultados

Tabela 18 - IEEE13 / Sequência / Carga Variável / Nada no primário / 3 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1428	1428	100	572	100
2	385	385	100	1615	100
3	187	187	100	1813	100

- **7 Medidores**

A Figura 68 e a Figura 69 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de sete medidores do tipo sequência. A Figura 68 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 68 - IEEE13 / Sequência / Carga Variável / Nada no primário / 7 Medidores - Resultados

O valor da função aptidão neste cenário foi zero. O gráfico da Figura 69 mostra que a rede neural referente à AOM1 indicou corretamente 100% dos casos de defeitos dentro da AOM1 (azul). Para a AOM2, foi observado o mesmo desempenho. Na Tabela 19 são mostrados os resultados detalhados obtidos.




Figura 69 - IEEE13 / Sequência / Carga Variável / Nada no primário / 7 Medidores - Resultados

Tabela 19 - IEEE13 / Sequência / Carga Variável / Nada no primário / 7 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	710	710	100	1290	100
2	174	174	100	1826	100
3	175	175	100	1825	100
4	376	376	100	1624	100
5	196	196	100	1804	100
6	180	180	100	1820	100
7	189	189	100	1811	100

- **Conclusões Parciais: Carga Variável e Medidores Fasoriais (Sequência)**

Nota-se que neste cenário as redes neurais apresentaram um ótimo desempenho, com assertividade de 100% em todos os casos, inclusive com cargas variáveis. Por se tratar de dados de entradas fasoriais, utilizando componentes de sequência, considerando nenhum equipamento com conexão direta para a terra alocada nos alimentadores de média tensão e as cargas conectadas através de transformadores do tipo delta-estrela, esse resultado era esperado.

4.3.2 IEEE13 – Fasorial (Sequência) - Topologia (ii)

Esta topologia considera que os capacitores de distribuição e as capacitâncias parasitas são conectados ao primário e as cargas são conectadas através de transformadores do tipo delta-estrela.

4.3.2.1 IEEE13 – Fasorial (Sequência) - Topologia (ii) – Carga Fixa

Para essa condição de contorno não foram apresentados os resultados dos testes, pois o método proposto apresentou uma taxa de assertividade igual a 100% neste caso.

4.3.2.2 IEEE13 – Fasorial (Sequência) - Topologia (ii) – Carga Variável

- 2 Medidores

A Figura 70 e a Figura 71 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de dois medidores do tipo sequência. A Figura 70 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 70 - IEEE13 / Sequência / Carga Variável / Capacitor no primário - AOM 2 Medidores

O valor da função aptidão neste cenário foi 1235,1396 (ou EMA = 17,57). O gráfico da Figura 71 mostra que a rede neural referente à AOM1 indicou corretamente 78,18% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 100% de acertos nas detecções dos defeitos. Na Tabela 20 são mostrados os resultados detalhados obtidos.




Figura 71 – IEEE13 / Sequência / Carga Variável / Capacitor no primário / 2 Medidores - Resultados

Tabela 20 - IEEE13 / Sequência / Carga Variável / Capacitor no primário / 2 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1439	1125	78,18	489	87,17
2	561	561	100	1439	100

- **3 Medidores**

A Figura 72 e a Figura 73 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de três medidores do tipo sequência. A Figura 72 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.

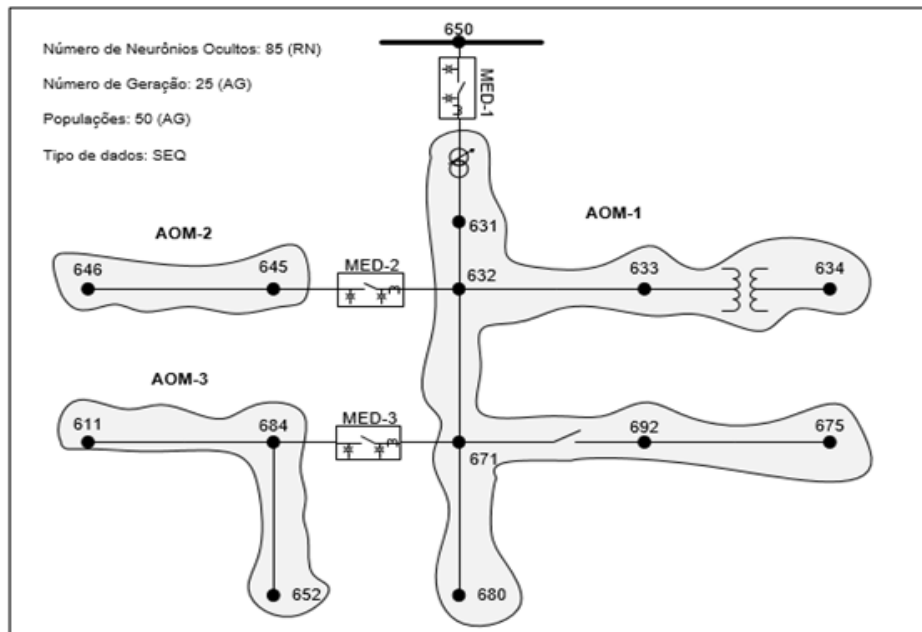


Figura 72 - IEEE13 / Sequência / Carga Variável / Capacitor no primário - AOM 3 Medidores

O valor da função aptidão neste cenário foi 665,4566 (ou EMA = 8,60). O gráfico da Figura 73 mostra que a rede neural referente à AOM1 indicou corretamente 82,43% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 100% de acertos nas detecções dos defeitos. Na Tabela 21 são mostrados os resultados detalhados obtidos.




Figura 73 - IEEE13 / Sequência / Carga Variável / Capacitor no primário / 3 Medidores - Resultados

Tabela 21 - IEEE13 / Sequência / Carga Variável / Capacitor no primário / 3 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1070	883	82,43	854	91,83
2	561	561	100	1439	100
3	369	185	50,14	1606	98,47

- **7 Medidores**

A Figura 74 e a Figura 75 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de sete medidores do tipo sequência. A Figura 74 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.

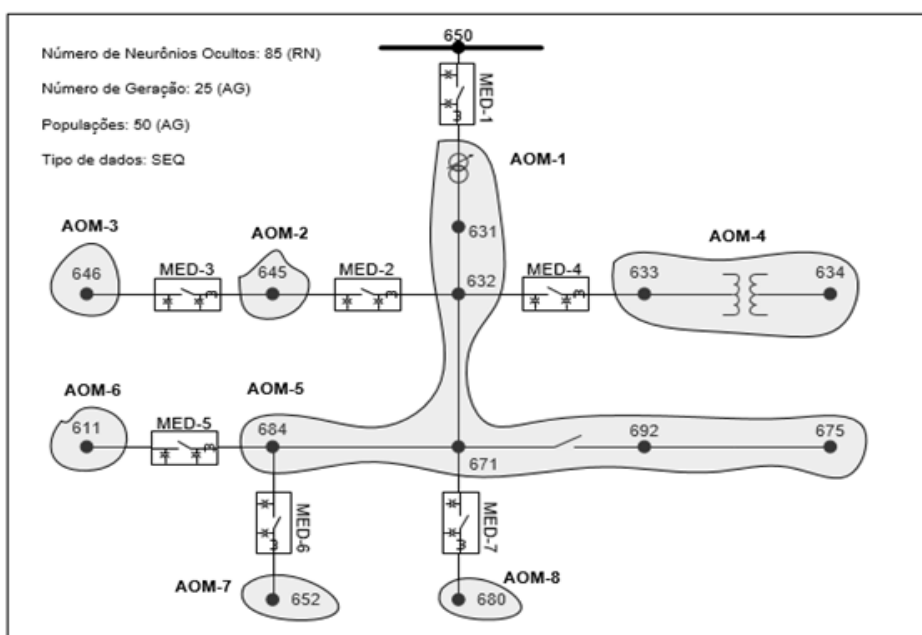


Figura 74 - IEEE13 / Sequência / Carga Variável / Capacitor no primário - AOM 7 Medidores

O valor da função aptidão neste cenário foi 542,1123 (ou EMA = 3,33). O gráfico da Figura 75 mostra que a rede neural referente à AOM1 indicou corretamente 41,72% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 90,45% de acertos nas detecções dos defeitos. Nas áreas AOM3, AOM4, AOM5, as redes neurais apresentaram 100% de acertos. Para as áreas AOM6 e AOM7 foram alcançados 49,05% e 100% de acertos para respectivas áreas. Na Tabela 23 são mostrados os resultados detalhados obtidos.




Figura 75 - IEEE13 / Sequência / Carga Variável / Capacitor no primário / 7 Medidores - Resultados

Tabela 22 - IEEE13 / Sequência / Carga Variável / Capacitor no primário / 7 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	326	136	41,72	1673	99,94
2	377	341	90,45	1616	99,57
3	177	177	100	1823	100
4	190	190	100	1810	100
5	363	363	100	1637	100
6	369	181	49,05	1607	98,53
7	198	198	100	1802	100

- **Conclusões Parciais: Carga Variável e Medidores Fasoriais (Sequência)**

Nota-se que neste cenário as redes neurais também apresentaram um ótimo desempenho, com assertividade total mínima de 90,35%. Este valor corresponde ao percentual de todos os acertos – dentro e fora de todas as AOMs, tal valor está apresentado na, Tabela 35, na coluna assertividade total. Tal valor é o menor valor de assertividade para tais condições – carga variável, medidores fasoriais (sequência), capacitor no primário.

4.3.3 IEEE13 – Fasorial (Sequência) - Topologia (iii)

A presente topologia considera que todos os equipamentos e cargas são conectados diretamente ao primário conforme disposto originalmente nos casos base do IEEE.

4.3.3.1 IEEE13 – Fasorial (Sequência) - Topologia (iii) – Carga Fixa

Para essa condição de contorno não foram apresentados os resultados dos testes, pois o método proposto apresentou uma taxa de assertividade igual a 100% neste caso.

4.3.3.2 IEEE13 – Fasorial (Sequência) - Topologia (iii) – Carga Variável

- **2 Medidores**

A Figura 76 e a Figura 77 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de dois medidores do tipo sequência. A Figura 76 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 76 - IEEE13 / Sequência / Carga Variável / Tudo no primário - AOM 2 Medidores

O valor da função aptidão neste cenário foi 2171,44 (ou EMA = 23,30). O gráfico da Figura 77 mostra que a rede neural referente à AOM1 indicou corretamente 80,34% dos casos de defeitos dentro da AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 100% de acertos nas detecções dos defeitos. Na Tabela 23 são mostrados os resultados detalhados obtidos.




Figura 77 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 2 Medidores - Resultados

Tabela 23 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 2 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1826	1467	80,34	147	84,48
2	174	174	100	1826	100

- **3 Medidores**

A Figura 78 e a Figura 79 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de três medidores do tipo sequência. A Figura 78 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 78 - IEEE13 / Sequência / Carga Variável / Tudo no primário - AOM 3 Medidores

O valor da função aptidão neste cenário foi 4669,80 (ou EMA = 22,78). O gráfico da Figura 63 mostra que a rede neural referente à AOM1 indicou corretamente 78,99% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 90% de acertos nas detecções dos defeitos. Já a AOM3 apresentou 100% de acertos na detecção. Na Tabela 24 são mostrados os resultados detalhados obtidos.




Figura 79 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 3 Medidores - Resultados

Tabela 24 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 3 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1647	1301	78,99	287	81,3
2	160	144	90	1840	100
3	193	193	100	1807	100

- **7 Medidores**

A Figura 80 e a Figura 81 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de sete medidores do tipo sequência. A Figura 80 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 80 - IEEE13 / Sequência / Carga Variável / Tudo no primário - AOM 7 Medidores

O valor da função aptidão neste cenário foi 845,12 (ou EMA = 4,15). O gráfico da Figura 63 mostra que a rede neural referente à AOM1 indicou corretamente 99,73% dos casos de defeitos dentro da AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 23,59% de acertos nas detecções dos defeitos. Já a AOM3 apresentou 100% de acertos na detecção, a AOM4 100% de acertos. Já as AOM5, AOM6 e AOM7 apresentaram, respectivamente, 100%, 44,85% e 89,38% de acertos. Na Tabela 25 são mostrados os resultados detalhados obtidos.

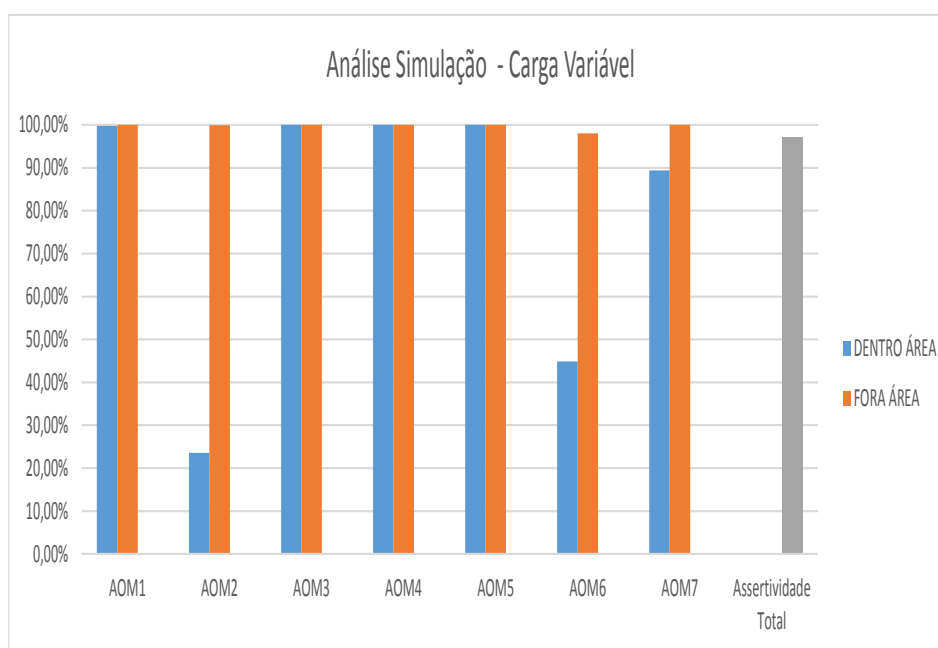


Figura 81 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 7 Medidores - Resultados

Tabela 25 - IEEE13 / Sequência / Carga Variável / Tudo no primário / 7 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	370	369	99,73	1630	100
2	195	46	23,59	1804	99,94
3	356	356	100	1644	100
4	175	175	100	1825	100
5	365	365	100	1635	100
6	379	170	44,85	1589	98,03
7	160	143	89,38	1840	100

- **Conclusões Parciais: Carga Variável e Medidores Fasorial (Sequência)**

Neste caso, notou-se que o método apresentou bons resultados, com assertividade total mínima 90,35% para uma área. Este valor corresponde ao percentual de todos os acertos – dentro e fora de todas as AOMs, tal valor está apresentado na, Tabela 35, na coluna assertividade total. Tal valor é o menor valor de assertividade para tais condições – carga variável, medidores fasoriais (sequência), tudo no primário. Pode-se perceber que os resultados foram melhores em relação a utilização dos medidores RMS, o principal motivo e que os ângulos entre as fases são considerados, trazendo informações importantes utilizados para fazer a transformação para componentes simétricas. Uma característica em comum com os testes realizados considerando medidores com dados em sequência, é que o aumento do número de medidores aumentou a eficiência da detecção, isto pode ser verificado pelo decremento da EMA e pelo incremento da assertividade total nos gráficos apresentados.

4.4 Testes com o Sistema IEEE13 – Fasorial (PMU)

4.4.1 IEEE13 – Fasorial (PMU) - Topologia (i)

Nesta seção os testes foram realizados considerando nenhum equipamento com conexão direta para a terra alocado nos alimentadores de média tensão e as cargas são conectadas através de transformadores do tipo delta-estrela

4.4.1.1 IEEE13 – Fasorial (PMU) - Topologia (i) – Carga Fixa

Para essa condição de contorno não foram apresentados os resultados dos testes, pois o método proposto apresentou uma taxa de assertividade igual a 100% neste caso.

4.4.1.2 IEEE13 – Fasorial (PMU) - Topologia (i) – Variável

- **2 Medidores**

A Figura 82 e a Figura 83 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de dois medidores do tipo PMU. A Figura 82 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 82 - IEEE13 / PMU / Carga Variável / Nada no primário - AOM 2 Medidores

O valor da função aptidão neste cenário foi 779,5087 (ou EMA = 13,96). O gráfico da Figura 83 mostra que a rede neural referente à AOM1 indicou corretamente 83,34% dos casos de defeitos dentro da AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 100% de acertos nas detecções dos defeitos. Na Tabela 26 são mostrados os resultados detalhados obtidos.




Figura 83 - IEEE13 / PMU / Carga Variável / Nada no primário / 2 Medidores - Resultados

Tabela 26 - IEEE13 / PMU / Carga Variável / Nada no primário / 2 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1705	1346	83,34	332	86,23
2	385	385	100	1615	100

- **3 Medidores**

A Figura 84 e a Figura 85 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de três medidores do tipo PMU. A Figura 84 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 84 - IEEE13 / PMU / Carga Variável / Nada no primário - AOM 3 Medidores

O valor da função aptidão neste cenário foi 63,8842 (ou EMA = 2,66). O gráfico da Figura 77 mostra que a rede neural referente à AOM1 indicou corretamente 100% dos casos de defeitos dentro da AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 74,9% de acertos nas detecções dos defeitos e na AOM3 100%. Na Tabela 27 são mostrados os resultados detalhados obtidos.




Figura 85 - IEEE13 / PMU / Carga Variável / Nada no primário / 3 Medidores - Resultados

Tabela 27 - IEEE13 / PMU / Carga Variável / Nada no primário / 3 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	710	710	100	1290	100
2	1035	835	74,89	734	82,94
3	175	175	100	1825	100

- **7 Medidores**

A Figura 86 e a Figura 87 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de sete medidores do tipo PMU. A Figura 86 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 86 - IEEE13 / PMU / Carga Variável / Nada no primário - AOM 7 Medidores

O valor da função aptidão neste cenário foi 0,4745 (ou EMA = 0,1). O gráfico da Figura 77 mostra que a rede neural referente à AOM1 indicou corretamente 23,49% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 98,57% de acertos nas detecções dos defeitos e para AOM6 99,45%. As demais áreas – AOM3, AOM4, AOM5, AOM7 – apresentaram 100% de acertos nas detecções. Na Tabela 28 são mostrados os resultados detalhados obtidos.




Figura 87 - IEEE13 / PMU / Carga Variável / Nada no primário / 7 Medidores - Resultados

Tabela 28 - IEEE13 / PMU / Carga Variável / Nada no primário / 7 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	166	39	23,49	1832	99,89
2	349	344	98,57	1651	100
3	357	357	100	1643	100
4	187	187	100	1813	100
5	376	376	100	1624	100
6	385	374	97,14	1615	100
7	180	180	100	1820	100

- **Conclusões Parciais: Carga Variável e Medidores PMU**

Nota-se que neste cenário as redes neurais também apresentaram um ótimo desempenho, com assertividade total mínima de 91,95% em todos os casos. Este valor corresponde ao percentual de todos os acertos – dentro e fora de todas as AOMs, tal valor está apresentado na, Tabela 35, na coluna assertividade total. Tal valor é o menor valor de assertividade para tais condições – carga variável, medidores PMU, nada no primário. Ressalta-se que diferentemente do esperado, a utilização da informação angular explícita não resultou em uma maior eficácia. Este comportamento não foi analisado detalhadamente e é uma indicação de trabalho futuro.

4.4.2 IEEE13 – Fasorial (PMU) - Topologia (ii)

Esta topologia considera que os capacitores de distribuição e as capacitâncias parasitas são conectadas ao primário e as cargas são conectadas através de transformadores do tipo delta-estrela;

4.4.2.1 IEEE13 – Fasorial (PMU) - Topologia (ii) – Carga Fixa

Para essa condição de contorno não foram apresentados os resultados dos testes, pois o método proposto apresentou uma taxa de assertividade igual a 100% neste caso.

4.4.2.2 IEEE13 – Fasorial (PMU) - Topologia (ii) – Carga Variável

- 2 Medidores

A Figura 88 e a Figura 89 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de dois medidores do tipo PMU. A Figura 88 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 88 - IEEE13 / PMU / Carga Variável / Capacitor no primário - AOM 2 Medidores

O valor da função aptidão neste cenário foi 1532,8307 (ou EMA = 19,58). O gráfico da Figura 88 mostra que a rede neural referente à AOM1 indicou corretamente 80,09% dos casos de defeitos dentro da AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 100% de acertos nas detecções dos defeitos. Na Tabela 29 são mostrados os resultados detalhados obtidos.




Figura 89 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 2 Medidores - Resultados

Tabela 29 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 2 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1813	1452	80,09	151	80,75
2	187	187	100	1813	100

- **3 Medidores**

A Figura 90 e a Figura 91 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de três medidores do tipo PMU. A Figura 90 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.




Figura 90 - IEEE13 / PMU / Carga Variável / Capacitor no primário - AOM 2 Medidores

O valor da função aptidão neste cenário foi 652,1691 (ou EMA = 8,52). O gráfico da Figura 91 mostra que a rede neural referente à AOM1 indicou corretamente 99,8% dos casos de defeitos dentro da AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 69,01% de acertos nas detecções dos defeitos. Já a área AOM3 apresentou 100% de acertos nas detecções. Na Tabela 30 são mostrados os resultados detalhados obtidos.




Figura 91 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 3 Medidores - Resultados

Tabela 30 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 3 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	503	502	99,8	1497	100
2	1307	902	69,01	425	61,33
3	190	190	100	1810	100

- **7 Medidores**

A Figura 92 e a Figura 93 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de sete medidores do tipo PMU. A Figura 92 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.

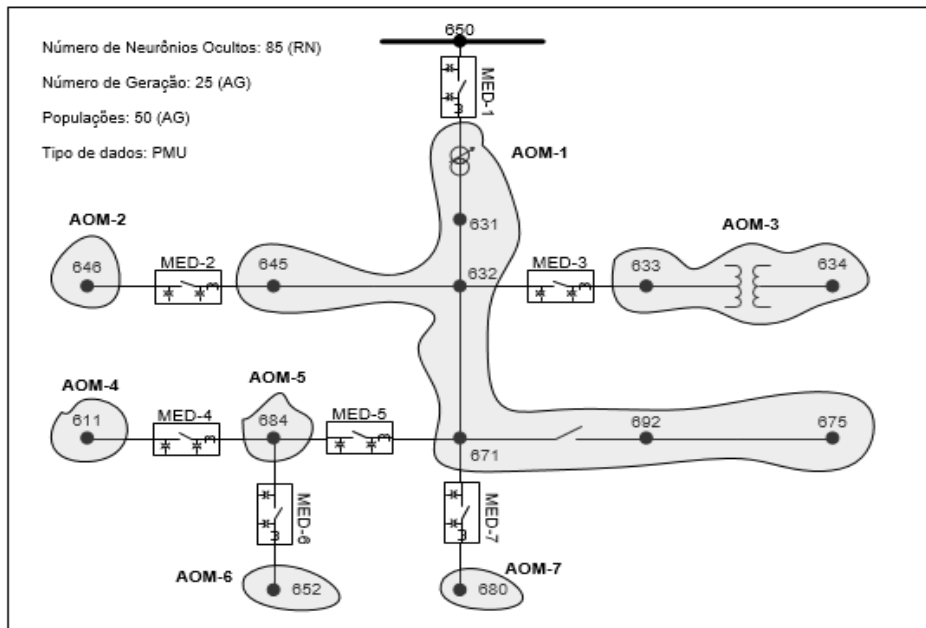


Figura 92 - IEEE13 / PMU / Carga Variável / Capacitor no primário – AOM 7 Medidores

O valor da função aptidão neste cenário foi 599,4774 (ou EMA = 3,50). O gráfico da Figura 77 mostra que a rede neural referente à AOM1 indicou corretamente 34,66% dos casos de defeitos dentro da AOM1 (azul). Para as áreas AOM2, AOM6 e AOM7, foram observados que as redes apresentaram 68,05%, 28,32% e 54,08% de acertos nas detecções dos defeitos. As demais áreas AOM3, AOM4 e AOM5 apresentaram 100% de acertos nas detecções. Na Tabela 31 são mostrados os resultados detalhados obtidos.




Figura 93 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 7 Medidores - Resultados

Tabela 31 - IEEE13 / PMU / Carga Variável / Capacitor no primário / 7 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	336	113	34,66	1670	99,76
2	751	511	68,05	1198	95,92
3	177	100	100	1823	100
4	190	190	100	1810	100
5	187	187	100	1813	100
6	173	49	28,32	1825	99,89
7	196	106	54,08	1801	99,83

- **Conclusões Parciais: Carga Variável e Medidores PMU**

Nota-se que neste cenário as redes neurais também apresentaram um bom desempenho, com assertividade total mínima de 88,76%. Este valor corresponde ao percentual de todos os acertos – dentro e fora de todas as AOMs, tal valor está apresentado na, Tabela 35, na coluna assertividade total. Tal valor é o menor valor de assertividade para tais condições – carga variável, medidores PMU, capacitor no primário.

4.4.3 IEEE13 – Fasorial (PMU) - Topologia (iii)

A presente topologia considera que todos os equipamentos e cargas são conectados diretamente ao primário conforme disposto originalmente nos casos base do IEEE.

4.4.3.1 IEEE13 – Fasorial (PMU) - Topologia (iii) – Carga Fixa

Para essa condição de contorno não foi apresentado os resultados dos testes, pois o método proposto apresentou uma taxa de assertividade igual a 100% neste caso.

4.4.3.2 IEEE13 – Fasorial (PMU) - Topologia (iii) – Carga Variável

- **2 Medidores**

A Figura 94 e a Figura 95 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de dois medidores do tipo PMU. A Figura 94 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta e cada rede neural.




Figura 94 - IEEE13 / PMU / Carga Variável / Tudo no primário - AOM 2 Medidores

O valor da função aptidão neste cenário foi 2193,04 (ou EMA = 23,41). O gráfico da Figura 63 mostra que a rede neural referente à AOM1 indicou corretamente 79,97% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 100% de acertos nas detecções dos defeitos. Na Tabela 32 são mostrados os resultados detalhados obtidos.




Figura 95 - IEEE13 / PMU / Carga Variável / Tudo no primário / 2 Medidores - Resultados

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1807	1445	79,97	167	86,53
2	193	193	100	1807	100

Tabela 32 - IEEE13 / PMU / Carga Variável / Tudo no primário / 2 Medidores - Resultados por área

- **3 Medidores**

A Figura 96 e a Figura 97 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de três medidores do tipo PMU. A Figura 96 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.

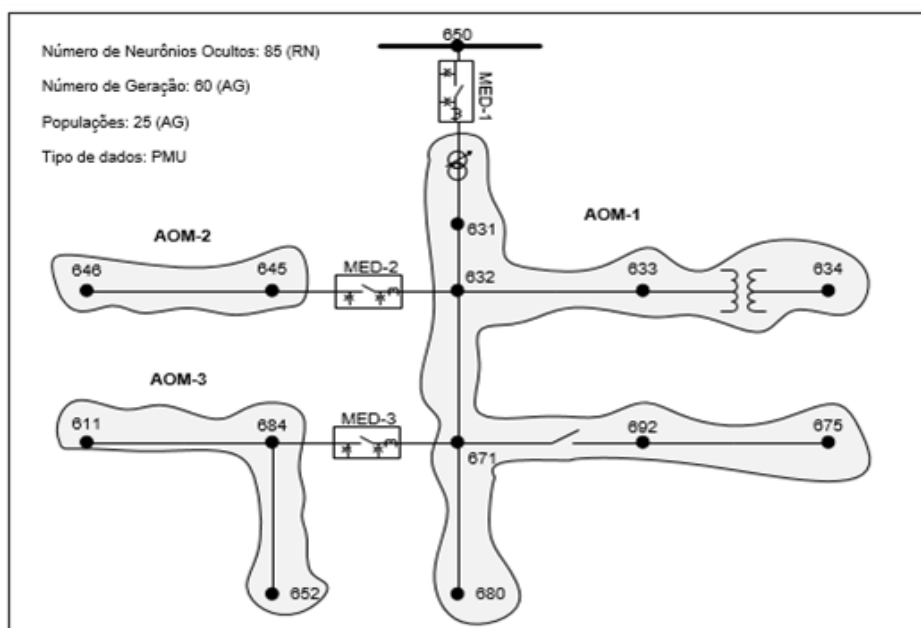


Figura 96 - IEEE13 / PMU / Carga Variável / Tudo no primário - AOM 3 Medidores

O valor da função aptidão neste cenário foi 845,12 (ou EMA = 9,69). O gráfico da Figura 63 mostra que a rede neural referente à AOM1 indicou corretamente 99,73% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 23,59% de acertos nas detecções dos defeitos. Já a AOM3 apresentou 100% de acertos na detecção, a AOM4 100% de acertos. Na Tabela 33 são mostrados os resultados detalhados obtidos.




Figura 97 - IEEE13 / PMU / Carga Variável / Tudo no primário / 3 Medidores - Resultados

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	1633	1297	79,42	311	84,74
2	174	174	100	1826	100
3	193	193	100	1807	100

Tabela 33 - IEEE13 / PMU / Carga Variável / Tudo no primário / 3 Medidores - Resultados por área

- **7 Medidores**

A Figura 98 e a Figura 99 representam os resultados das simulações do sistema com o cenário de carga variável com a instalação de sete medidores do tipo PMU. A Figura 98 mostra o local indicado para a instalação e as AOMs. Neste caso, o melhor resultado foi obtido com 85 neurônios na camada oculta de cada rede neural.

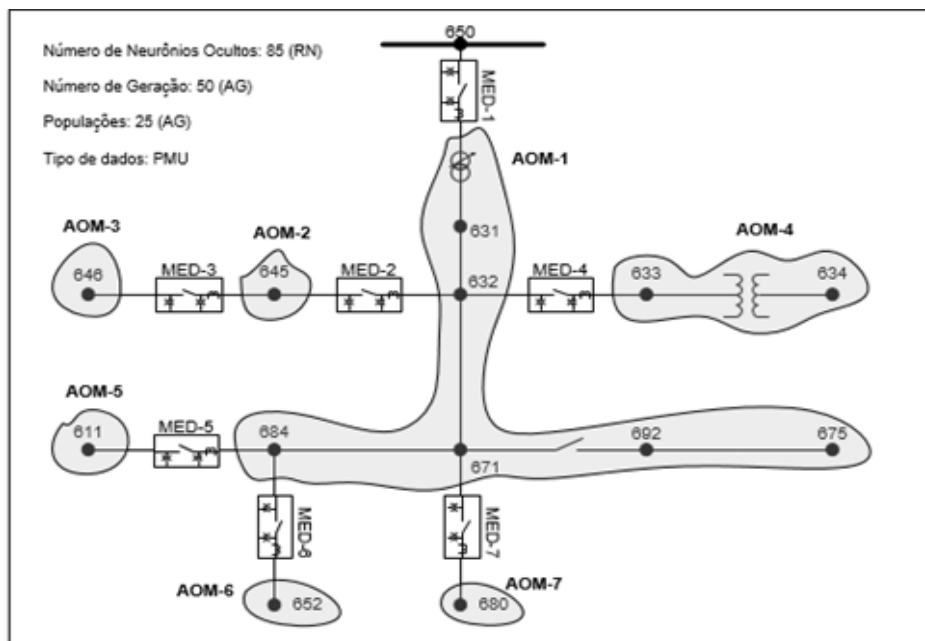


Figura 98 - IEEE13 / PMU / Carga Variável / Tudo no primário - AOM 7 Medidores

O valor da função aptidão neste cenário foi 886,71 (ou EMA = 4,25). O gráfico da Figura 63 mostra que a rede neural referente à AOM1 indicou corretamente 99,73% dos casos de defeitos dentro a AOM1 (azul). Para a AOM2, foi observado que a rede apresentou 23,59% de acertos nas detecções dos defeitos. Já a AOM3 apresentou 100% de acertos na detecção, a AOM4 100% de acertos. Já as AOM5, AOM6 e AOM7 apresentaram, respectivamente, 100%, 44,85% e 89,38% de acertos. Na Tabela 34 são mostrados os resultados detalhados obtidos.

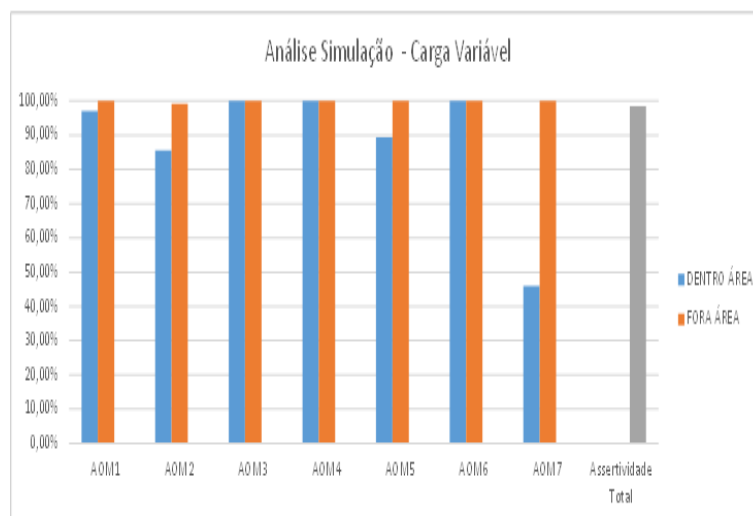


Figura 99 - IEEE13 / PMU / Carga Variável / Tudo no primário / 7 Medidores - Resultados

Tabela 34 - IEEE13 / PMU / Carga Variável / Tudo no primário / 7 Medidores - Resultados por área

AOM	Defeito na AOM	Acertos Defeitos	Acertos(%) Defeitos	Acertos Fora	Acertos(%) Fora
1	370	359	97,03	1629	99,94
2	569	487	85,59	1418	99,09
3	356	356	100	1644	100
4	175	174	100	1825	100
5	160	143	89,38	1839	99,95
6	174	174	100	1926	100
7	196	90	45,92	1803	99,94

- **Conclusões Parciais: Carga Variável e Medidores Fasorial (PMU)**

Nestes casos, atendendo as expectativas, notou-se que o método apresentou os melhores resultados com os dados de entrada informados em coordenadas de fase em módulo e ângulo. Assim como em cenários anteriores, o aumento do número de medidores aumentou a assertividade total do método.

4.5 Constatações pelas comparações entre as situações analisadas do sistema IEEE13

Na Tabela 35 é apresentado o resumo dos resultados dos testes realizados no sistema IEEE13. As cores indicam os grupamentos com mesma topologia de rede, mas com tipos de medições distintas. As seguintes constatações são apresentadas:

a) Caso a representação da variação da carga não seja considerada, o problema torna-se de fácil solução para o método proposto (considerando a alocação ótima de medidores e as redes neurais propostas) e os resultados apresentaram eficácia de 100%. Todavia, esta consideração não reflete a operação real do sistema e estes resultados só devem ser considerados em termos de pesquisa. Ressalta-se que uma considerável quantidade de trabalhos pesquisados na literatura não representa a variação da carga e com isto apresentam ótimos resultados, mas que não podem ser obtidos em aplicações práticas.

b) Nota-se que na maioria absoluta dos casos, o aumento do número de pontos de medição impactou diretamente no aumento da eficácia total do método. Duas questões devem ser esclarecidas neste tópico. O aumento de medidores reduz a área de procura para a localização do defeito, em contrapartida existe o aumento de custos de instalação de medidores. O segundo ponto consiste que mesmo com poucos medidores é possível

detectar a existência de falta de alta resistência com considerável eficácia, alocando bem os medidores e com redes neurais adequadas.

c) Na condição topológica (i), as redes neurais utilizando entrada de dados com informações em coordenadas de sequência apresentaram desempenho superior considerando a assertividade total.

d) Na condição topológica (ii), as redes neurais utilizando entrada de dados com informações em coordenadas de fase, oriundas de PMUs (módulo e ângulo), apresentaram desempenho ligeiramente superior considerando a assertividade total.

e) Na condição topológica (iii), as redes neurais utilizando entrada de dados com informações em coordenadas de sequência e em coordenadas de fase, oriundas de PMUs, apresentaram desempenho semelhantes considerando a assertividade total.

f) Atualmente os medidores nos sistemas de distribuição são todos RMS. Nas análises realizadas, apesar de a utilização de dados oriundos deste tipo de medidores não apresentar o melhor desempenho em nenhum caso, sua eficácia é interessante. Como pode ser observado esta ficou acima de 85% em todas as condições simuladas, desta forma sua implementação prática, apenas para alertar sobre possíveis falta de alta resistência pode ser interessante.

g) Não foi identificado nenhum padrão em relação ao número de neurônios na camada oculta das redes neurais.

h) Um ponto que não foi considerado é o erro associado aos medidores. Em sistemas de distribuição, o valor tolerável de erro medição é 4%, logo uma sugestão de estudo futuro é verificar como impactam estes erros na eficácia do método proposto.

Tabela 35 - Resumo dos Resultados

Sistema	Cenário	Topologia	Assertividade Total	EMA	Quantidade e de Medidores	Variação da carga	Entrada	Neurônios Ocultos
IEEE13	1	(i) Nada no primário	100	0	2	Não	RMS	20
	2	(i) Nada no primário	100	0	3	Não	RMS	20
	3	(i) Nada no primário	100	0	7	Não	RMS	20
	4	(i) Nada no primário	90	22,65	2	Sim	RMS	85
	5	(i) Nada no primário	89,68	13,26	3	Sim	RMS	85

6	(i) Nada no primário	93,15	11,02	7	Sim	RMS	50
7	(ii) Capacitor no primário	100	0	2	Não	RMS	20
8	(ii) Capacitor no primário	100	0	3	Não	RMS	20
9	(ii) Capacitor no primário	100	0	7	Não	RMS	20
10	(ii) Capacitor no primário	89,35	25,4	2	Sim	RMS	85
11	(ii) Capacitor no primário	89,35	20,2	3	Sim	RMS	50
12	(ii) Capacitor no primário	88,53	12,18	7	Sim	RMS	50
13	(iii) Tudo no primário	83,93	34,45	2	Sim	RMS	85
14	(iii) Tudo no primário	83,93	20,74	3	Sim	RMS	50
15	(iii) Tudo no primário	92,78	9,76	7	Sim	RMS	50
16	(i) Nada no primário	91,95	13,96	2	Sim	PMU	85
17	(i) Nada no primário	92,82	2,66	3	Sim	PMU	85
18	(i) Nada no primário	98,96	0,10	7	Sim	PMU	85
19	(ii) Capacitor no primário	90,08	19,58	2	Sim	PMU	85
20	(ii) Capacitor no primário	88,76	8,51	3	Sim	PMU	85
21	(ii) Capacitor no primário	94,81	3,50	7	Sim	PMU	85
22	(iii) Tudo no primário	90,30	23,41	2	Sim	PMU	85
23	(iii) Tudo no primário	93,74	9,69	3	Sim	PMU	85
24	(iii) Tudo no primário	98,34	4,25	7	Sim	PMU	85
25	(i) Nada no primário	100	0	2	Sim	SEQ	85

26	(i) Nada no primário	100	0	3	Sim	SEQ	85
27	(i) Nada no primário	100	0	7	Sim	SEQ	85
28	(ii) Capacitor no primário	90,35	17,57	2	Sim	SEQ	85
29	(ii) Capacitor no primário	92,11	8,60	3	Sim	SEQ	85
30	(ii) Capacitor no primário	96,81	3,33	7	Sim	SEQ	85
31	(iii) Tudo no primário	90,35	23,30	2	Sim	SEQ	85
32	(iii) Tudo no primário	92,87	22,78	3	Sim	SEQ	85
33	(iii) Tudo no primário	97,08	4,15	7	Sim	SEQ	85

4.6 Testes com o Sistema IEEE123

Nesta seção serão apresentados os resultados obtidos com a aplicação do método proposto no sistema IEEE123. Tal sistema foi escolhido visto que o mesmo é um sistema consideravelmente desequilibrado, tanto no carregamento quanto na rede física, que possui diversos ramais bifásicos e monofásicos em sua estrutura, sendo assim um sistema desafiador para avaliar o desempenho da metodologia. A seguir, na Figura 100 apresenta-se o unifilar do sistema. O sistema está com as barras numeradas e tal numeração será importante para visualizar as posições indicadas para alocar os medidores em cada um dos cenários.




Figura 100 - Sistema IEEE123

Conforme apresentado em seção anterior, três considerações de topologia sistêmica foram testadas nos testes da metodologia: (i) Nenhum equipamento com conexão direta para a terra está alocado nos alimentadores de média tensão (primário) e as cargas são conectadas através de transformadores do tipo delta-estrela, esta topologia referente aos sistemas de distribuição brasileiros com nenhum equipamento conectado ao primário; (ii) Os capacitores de distribuição e as capacitâncias parasitas são conectadas na média tensão e as cargas são conectadas através de transformadores do tipo delta-estrela, esta topologia é referente a maioria dos sistemas brasileiros reais e (iii) todos os equipamentos e cargas são conectados na média tensão através de transformadores monofásicos conforme disposto originalmente nos casos base do IEEE (os transformadores monofásicos não são representados no caso IEEE123), esta topologia é semelhante aos sistemas de distribuição norte-americanos.

A fim de avaliar a influência do processo de aprendizagem (treinamento) da rede neural na eficiência da metodologia, foram criados para este sistema, dois conjuntos de

banco de dados, sendo que o primeiro banco de dados contém 2000 casos para cada cenário e o segundo contém 5000 casos para cada cenário.

Para cada um dos conjuntos de dados (2000 e 5000) foram feitas simulações considerando a alocação na rede de distribuição de 6 e 11 medidores. Lembrando que um dos medidores é sempre instalado no alimentador que deixa a subestação de distribuição, ou seja, a otimização da alocação dos medidores realizada pelo módulo de otimização 3.3.2, considera um medidor a menos do total alocado na rede de distribuição.

Apesar de todas as topologias terem sido testadas, a seguir serão apresentados somente os resultados dos testes realizados considerando como condição sistêmica todos as cargas conectadas através de transformadores delta-estrela aterrada e equipamentos, como os capacitores, conectados diretamente na média tensão - Topologia *iii*. Decidiu-se por não apresentar todos os resultados, visto que esta condição sistêmica é a mais comum nos sistemas nacionais e o trabalho ficaria por demais extenso.

Para todos os casos simulados para o sistema IEEE123, foram considerados 50 neurônios ocultos para cada rede neural, 20 gerações e 20 populações. Esta consideração foi realizada devido ao alto tempo de simulação. Para cada cenário são necessárias 6 horas de simulações em um i7 4790k, Windows 10, 16Gb, MatLab® 2015. Uma sugestão de trabalho futuro é comparar os resultados obtidos com simulações com maiores populações, gerações e número distinto de neurônios.

Na Figura 101 são apresentados os resultados das simulações considerando 2000 casos e na Figura 102 os resultados das simulações considerando 5000 casos.

Sistema	Cenário	Quantidade de casos	Quantidade de Medidores	Variação de Carga	Topologia	Função de aptidão	EMA	Assertividade Total (%)	Rmos Indicados (Alocar Medidores)	Eficiência da Área (%)
IEEE123	1	2000	5	Não	RMS	3499,09	9,859	91,93%	150 - 49	A1: 85,94 D / 66,27 F
									72 - 76	A2: 100,00 D / 100,00 F
									52 - 53	A3: 100,00 D / 100,00 F
									18 - 21	A4: 100,00 D / 100,00 F
									49 - 50	A5: 18,75 D / 100,00 F
									57 - 60	A6: 66,86 D / 100,00 F
					PMU	3115,2	9,302	97,53%	150 - 49	A1: 100,00 D / 100,00 F
									197 - 101	A2: 100,00 D / 100,00 F
									13 - 152	A3: 97,71 D / 100,00 F
									18 - 21	A4: 100,00 D / 100,00 F
									152 - 52	A5: 18,75 D / 100,00 F
									135 - 35	A6: 37,43 D / 100,00 F
	SEQ			1680,88	6,833	95,91%	150 - 49	A1: 100,00 D / 100,00 F		
							54 - 57	A2: 96,68 D / 100,00 F		
							21 - 23	A3: 100,00 D / 100,00 F		
							197 - 101	A4: 100,00 D / 100,00 F		
							47 - 48	A5: 18,75 D / 100,00 F		
							53 - 54	A6: 54,75 D / 100,00 F		
	4			RMS	11469,06	17,85	91,30%	150 - 49	A1: 73,17 D / 98,97 F	
								76 - 77	A2: 33,23 D / 93,93 F	
								77 - 78	A3: 83,33 D / 98,92 F	
								67 - 97	A4: 100,00 D / 100,00 F	
								86 - 87	A5: 20,97 D / 100,00 F	
								152 - 52	A6: 38,26 D / 100,00 F	
				PMU	6681,63	13,62	92,75%	150 - 49	A1: 96,00 D / 100,00 F	
								60 - 62	A2: 85,78 D / 98,03 F	
								42 - 44	A3: 29,82 D / 98,77 F	
								25 - 28	A4: 100,00 D / 100,00 F	
								152 - 52	A5: 20,97 D / 100,00 F	
								53 - 54	A6: 38,26 D / 100,00 F	
	6			SEQ	4718,9	11,45	91,68%	150 - 49	A1: 70,03 D / 75,43 F	
								149 - 1	A2: 100,00 D / 100,00 F	
								54 - 57	A3: 100,00 D / 100,00 F	
								21 - 23	A4: 100,00 D / 100,00 F	
								35 - 40	A5: 20,97 D / 100,00 F	
								53 - 54	A6: 39,14 D / 100,00 F	
	7			RMS	12709,03	10,25	97,35%	150 - 49	A1: 100,00 D / 100,00 F	
								35 - 40	A2: 100,00 D / 100,00 F	
								140 - 145	A3: 100,00 D / 100,00 F	
								76 - 86	A4: 100,00 D / 100,00 F	
								54 - 55	A5: 35,51 D / 100,00 F	
								93 - 95	A6: 72,49 D / 93,14 F	
				PMU	11733,4	9,847	97,23%	01 - 07	A7: 100,00 D / 100,00 F	
								18 - 21	A8: 100,00 D / 100,00 F	
								07 - 08	A9: 100,00 D / 100,00 F	
								54 - 57	A10: 25,00 D / 100,00 F	
								260 - 67	A11: 70,45 D / 100,00 F	
								150 - 49	A1: 100,00 D / 100,00 F	
8	SEQ	12743,14	10,26	97,45%	13 - 18	A2: 100,00 D / 100,00 F				
					54 - 57	A3: 20,97 D / 100,00 F				
					135 - 35	A4: 100,00 D / 100,00 F				
					60 - 61	A5: 31,20 D / 100,00 F				
					50 - 51	A6: 48,15 D / 100,00 F				
					60 - 160	A7: 100,00 D / 100,00 F				
	RMS	21626,78	13,37	95,03%	07 - 08	A8: 100,00 D / 100,00 F				
					01 - 07	A9: 100,00 D / 100,00 F				
					35 - 40	A10: 25,00 D / 100,00 F				
					18 - 135	A11: 85,87 D / 100,00 F				
					150 - 49	A1: 100,00 D / 100,00 F				
					53 - 54	A2: 100,00 D / 100,00 F				
10	PMU	17087,56	11,88	94,26%	108 - 300	A3: 100,00 D / 100,00 F				
					135 - 35	A4: 100,00 D / 100,00 F				
					13 - 18	A5: 50,30 D / 100,00 F				
					08 - 13	A6: 47,79 D / 100,00 F				
					55 - 56	A7: 100,00 D / 100,00 F				
					93 - 95	A8: 100,00 D / 100,00 F				
	SEQ	14614,38	10,99	95,01%	13 - 152	A9: 100,00 D / 100,00 F				
					25 - 28	A10: 25,00 D / 100,00 F				
					18 - 21	A11: 89,08 D / 100,00 F				
					150 - 49	A1: 100,00 D / 100,00 F				
					97 - 98	A2: 63,08 D / 80,43 F				
					63 - 62	A3: 100,00 D / 100,00 F				
11	RMS	21626,78	13,37	95,03%	54 - 57	A4: 100,00 D / 100,00 F				
					57 - 60	A5: 54,03 D / 100,00 F				
					55 - 56	A6: 22,83 D / 100,00 F				
					89 - 91	A7: 100,00 D / 100,00 F				
					18 - 135	A8: 100,00 D / 100,00 F				
					76 - 77	A9: 100,00 D / 100,00 F				
	PMU	17087,56	11,88	94,26%	13 - 152	A10: 18,18 D / 100,00 F				
					150 - 49	A1: 100,00 D / 100,00 F				
					60 - 61	A2: 95,65 D / 100,00 F				
					54 - 55	A3: 52,12 D / 78,45 F				
					67 - 97	A4: 100,00 D / 100,00 F				
					67 - 72	A5: 50,40 D / 100,00 F				
12	SEQ	14614,38	10,99	95,01%	62 - 63	A6: 22,83 D / 100,00 F				
					260 - 67	A7: 100,00 D / 100,00 F				
					54 - 57	A8: 100,00 D / 100,00 F				
					40 - 42	A9: 100,00 D / 100,00 F				
					135 - 35	A10: 18,18 D / 100,00 F				
					13 - 152	A11: 52,58 D / 100,00 F				
12	RMS	21626,78	13,37	95,03%	150 - 49	A1: 100,00 D / 100,00 F				
					60 - 160	A2: 72,36 D / 100,00 F				
					18 - 135	A3: 20,00 D / 100,00 F				
					67 - 97	A4: 92,11 D / 100,00 F				
					197 - 101	A5: 51,22 D / 98,13 F				
					64 - 65	A6: 47,68 D / 100,00 F				
	PMU	17087,56	11,88	94,26%	101 - 105	A7: 100,00 D / 100,00 F				
					97 - 98	A8: 100,00 D / 100,00 F				
					01 - 07	A9: 100,00 D / 100,00 F				
					18 - 21	A10: 18,18 D / 100,00 F				
					25 - 28	A11: 64,29 D / 100,00 F				
					150 - 49	A1: 100,00 D / 100,00 F				
SEQ	14614,38	10,99	95,01%	60 - 61	A2: 95,65 D / 100,00 F					
				54 - 55	A3: 52,12 D / 78,45 F					
				67 - 97	A4: 100,00 D / 100,00 F					
				67 - 72	A5: 50,40 D / 100,00 F					
				62 - 63	A6: 22,83 D / 100,00 F					
				260 - 67	A7: 100,00 D / 100,00 F					

Figura 101 - Simulações Sistemas IEEE123 - 2000 Casos

Sistema	Cenário	Quantidade de casos	Quantidade de Medidores	Varição de Carga	Topologia	Função de aptidão	EMA	Assertividade Total (%)	Rmos Indicados (Alocar Medidores)	Eficiência da Área (%)		
IEEE123	13	5000	5	NÃO	RMS	2591,82	8,485	93,17%	150 - 49 07 - 08 54 - 57 52 - 53 18 - 135 40 - 42	A1: 100,00 D / 100,00 F A2: 27,46 D / 97,10 F A3: 100,00 D / 100,00 F A4: 100,00 D / 100,00 F A5: 19,77 D / 100,00 F A6: 38,54 D / 100,00 F		
	14				PMU	1723,97	6,92	96,04%	150 - 49 260 - 67 152 - 52 72 - 76 97 - 98 149 - 1	A1: 98,22 D / 100,00 F A2: 100,00 D / 100,00 F A3: 100,00 D / 100,00 F A4: 100,00 D / 100,00 F A5: 19,77 D / 100,00 F A6: 38,23 D / 100,00 F		
	15				SEQ	1032,05	5,354	96,22%	150 - 49 67 - 72 101 - 105 93 - 95 08 - 13 89 - 91	A1: 100,00 D / 100,00 F A2: 100,00 D / 100,00 F A3: 100,00 D / 100,00 F A4: 100,00 D / 100,00 F A5: 19,77 D / 100,00 F A6: 58,21 D / 100,00 F		
	16				SIM	RMS	13011,26	19,01	93,52%	150 - 49 260 - 67 135 - 35 63 - 64 60 - 160 98 - 99	A1: 79,76 D / 95,42 F A2: 100,00 D / 100,00 F A3: 97,13 D / 99,98 F A4: 100,00 D / 100,00 F A5: 18,60 D / 100,00 F A6: 56,25 D / 98,09 F	
	17					PMU	3718,36	10,16	93,71%	150 - 49 57 - 60 21 - 23 135 - 35 54 - 57 42 - 44	A1: 89,96 D / 98,89 F A2: 26,43 D / 99,12 F A3: 100,00 D / 100,00 F A4: 100,00 D / 100,00 F A5: 26,80 D / 100,00 F A6: 21,85 D / 99,91 F	
	18					SEQ	2598	8,495	92,71%	150 - 49 135 - 35 53 - 54 35 - 40 57 - 60 54 - 55	A1: 100,00 D / 100,00 F A2: 100,00 D / 100,00 F A3: 46,17 D / 91,91 F A4: 100,00 D / 100,00 F A5: 18,60 D / 100,00 F A6: 51,05 D / 100,00 F	
	19					NÃO	RMS	6016,1	7,051	96,20%	150 - 49 64 - 65 47 - 49 54 - 57 57 - 60 18 - 135 47 - 48 28 - 29 135 - 35 18 - 21 21 - 23	A1: 100,00 D / 100,00 F A2: 100,00 D / 100,00 F A3: 100,00 D / 100,00 F A4: 21,52 D / 100,00 F A5: 27,78 D / 100,00 F A6: 27,91 D / 100,00 F A7: 100,00 D / 100,00 F A8: 100,00 D / 100,00 F A9: 100,00 D / 100,00 F A10: 20,63 D / 100,00 F A11: 73,61 D / 100,00 F
	20						PMU	7087,83	7,654	97,53%	150 - 49 52 - 53 35 - 40 135 - 35 54 - 57 60 - 61 63 - 64 64 - 65 40 - 42 18 - 21 01 - 07	A1: 100,00 D / 100,00 F A2: 100,00 D / 100,00 F A3: 100,00 D / 100,00 F A4: 100,00 D / 100,00 F A5: 50,27 D / 100,00 F A6: 50,05 D / 100,00 F A7: 100,00 D / 100,00 F A8: 100,00 D / 100,00 F A9: 100,00 D / 100,00 F A10: 20,63 D / 100,00 F A11: 86,81 D / 100,00 F
	21						SEQ	6182,15	7,148	97,53%	150 - 49 55 - 56 60 - 160 63 - 64 18 - 135 42 - 44 18 - 21 152 - 52 13 - 18 57 - 60 49 - 50	A1: 100,00 D / 100,00 F A2: 100,00 D / 100,00 F A3: 100,00 D / 100,00 F A4: 100,00 D / 100,00 F A5: 19,77 D / 100,00 F A6: 17,74 D / 100,00 F A7: 100,00 D / 100,00 F A8: 100,00 D / 100,00 F A9: 100,00 D / 100,00 F A10: 20,63 D / 100,00 F A11: 84,10 D / 100,00 F
	22				SIM		RMS	18985,27	12,53	95,82%	150 - 49 100 - 450 67 - 72 35 - 40 77 - 78 25 - 28 23 - 25 140 - 145 53 - 54 57 - 60 40 - 42	A1: 100,00 D / 100,00 F A2: 74,78 D / 100,00 F A3: 76,83 D / 93,89 F A4: 100,00 D / 100,00 F A5: 74,79 D / 98,46 F A6: 30,10 D / 100 F A7: 100,00 D / 100,00 F A8: 100,00 D / 100,00 F A9: 100,00 D / 100,00 F A10: 21,84 D / 100,00 F A11: 22,11 D / 100,00 F
	23						PMU	13366,73	10,51	95,38%	150 - 49 54 - 57 52 - 53 50 - 51 135 - 35 49 - 50 25 - 28 13 - 18 21 - 23 60 - 160 65 - 66	A1: 44,48 D / 91,65 F A2: 100,00 D / 100,00 F A3: 100,00 D / 100,00 F A4: 100,00 D / 100,00 F A5: 42,54 D / 100,00 F A6: 21,70 D / 100,00 F A7: 100,00 D / 100,00 F A8: 100,00 D / 100,00 F A9: 100,00 D / 100,00 F A10: 21,84 D / 100,00 F A11: 58,19 D / 100,00 F
	24						SEQ	11679,62	9,825	97,03%	150 - 49 63 - 64 40 - 42 08 - 13 50 - 51 47 - 49 13 - 18 52 - 53 54 - 37 18 - 135 30 - 250	A1: 100,00 D / 100,00 F A2: 100,00 D / 100,00 F A3: 100,00 D / 100,00 F A4: 100,00 D / 100,00 F A5: 83,76 D / 82,17 F A6: 21,70 D / 100,00 F A7: 100,00 D / 100,00 F A8: 100,00 D / 100,00 F A9: 100,00 D / 100,00 F A10: 21,84 D / 100,00 F A11: 60,84 D / 100,00 F

Figura 102 - - Simulações Sistemas IEEE123 - 5000 Casos

4.7 Constatações pelas comparações entre as situações analisadas do sistema IEEE123

Com base na Figura 101 e na Figura 102 pode-se aferir as seguintes constatações:

a) Similar ao sistema IEEE13, caso a representação da variação da carga não seja considerada, o problema torna-se de fácil solução para o método proposto (considerando a alocação ótima de medidores e as redes neurais propostas). Entretanto, para o presente sistema não foram alcançadas assertividades de 100%. Vale ressaltar, que esta consideração de carga fixa não reflete a operação real do sistema e estes resultados só devem ser considerados em termos de pesquisa.

b) Nota-se que na maioria absoluta dos casos, o aumento do número de pontos de medição impactou diretamente no aumento da eficácia total do método. Duas questões devem ser esclarecidas neste tópico. O aumento de medidores reduz a área de procura para a localização do defeito, em contrapartida existe o aumento de custos de instalação de medidores. O segundo ponto consiste que mesmo com poucos medidores é possível detectar a existência de falta de alta resistência com considerável eficácia, alocando bem os medidores e com redes neurais adequadas.

c) Na condição topológica (iii), percebe-se que para todas as entradas de dados – RMS, PMU, Sequência – a metodologia apresentou um excelente desempenho. Entretanto é visível que a entrada de dados em RMS foi a que teve, entre as demais, o menor desempenho. Em relação às entradas de dados em PMU e Sequência, não foi identificado um padrão para definir qual destas entradas garante o melhor desempenho à metodologia.

d) Atualmente os medidores nos sistemas de distribuição são todos RMS. Nas análises realizadas, apesar de a utilização de dados oriundos deste tipo de medidores não apresentar o melhor desempenho em nenhum caso, sua eficácia é interessante. Como pode ser observado esta ficou acima de 90% em todas as condições simuladas, desta forma sua implementação prática, apenas para alertar sobre possíveis falta de alta resistência pode ser interessante.

e) Nota-se a influência do processo de aprendizado (treinamento) na identificação dos defeitos. Para os cenários simulados, a partir de 5000 casos, notou-se um melhor desempenho, quando comparado com os cenários simulados considerando 2000 casos.

f) Assim como no sistema IEEE13, um ponto que não foi considerado é o erro associado aos medidores.

Capítulo 5 Conclusões

5.1 Considerações Finais

Neste trabalho foi desenvolvido um método utilizando algoritmos genéticos e redes neurais para a alocação ótima de medidores de corrente para a detecção de defeitos monofásicos na média tensão envolvendo o solo, com alta resistência de contato (100- 200 ohms), em sistemas de distribuição.

Foram analisadas três configurações de redes neurais para a detecção de defeitos monofásicos de alta resistência: redes neurais com entradas de correntes do tipo não-fasoriais, fasoriais em coordenadas de fase e em coordenadas de sequência. Cada rede neural indica se determinada área do sistema de distribuição possui ou não possui defeitos, assim, é feita uma localização de defeito por área.

Visto que a alocação dos medidores no sistema de distribuição, trata de um problema de otimização combinatória foi necessária à utilização de uma técnica heurística de algoritmos genéticos para definir posições otimizadas dos medidores. O cromossomo possui dimensão igual ao número de medidores que se deseja alocar e cada posição indica o ramo do sistema onde deve ser instalado o medidor.

Além disto, também foi considerada a variação da carga, o que é uma realidade em sistemas de distribuição. No caso, para cada caso testado, cada carga, individualmente, é multiplicada por um valor entre 0,75 e 1,25. Notou-se que esta consideração reduziu sensivelmente a eficácia do método proposto, mas retrata com mais fidelidade os sistemas de distribuição reais.

Os resultados demonstram uma considerável precisão e robustez para a locação de equipamentos de medição visando a detecção e localização por áreas de faltas de alta resistência, considerando várias condições operativas do sistema de distribuição, incluindo os capacitores e reguladores do sistema de distribuição, bem como a variação da carga. No que diz respeito às redes neurais artificiais, estas foram capazes de detectar, identificar e localizar a área com defeito com eficácia maior que 90% na maioria dos casos testados.

5.2 Sugestões de Trabalhos Futuros

Pode-se pensar em melhorias para os métodos propostos e, além disso, existem análises relativas à detecção de defeitos que podem também ser mais exploradas utilizando o método proposto e estratégias diferenciadas de simulação de redes neurais e dos algoritmos genéticos. Assim, ficam como sugestões para trabalhos futuros:

- ✓ Consideração da geração distribuída;
- ✓ Consideração dos esquemas de chaveamentos dos sistemas de distribuição;
- ✓ Desenvolvimento de método para detecção de outros tipos de defeitos, como fase-fase ou abertura de cabos;
- ✓ Verificação aprofundada da questão do número de gerações, população e neurônios na eficácia do método;
- ✓ Pesquisa de métodos adicionais para a redução do tempo de simulação como a implementação em supercomputadores utilizando programação paralela ou utilização de cluster de PCs;
- ✓ Analisar o impacto da quantidade de amostras em defeitos em cada área na eficácia da área;
- ✓ Utilização do método proposto em um sistema de distribuição real.

Bibliografia

ABB,. **ABB no Brasil - Líder em tecnologias digitais para industria**. Disponível em: <<http://new.abb.com/br>>. Acesso em: 7 set. 2017.

ANEEL. **Agência Nacional de Energia Elétrica - ANEEL**. Disponível em: <<http://www.aneel.gov.br/>>. Acesso em: 9 jul. 2017.

BI, T. S. et al. **A novel ANN fault diagnosis system for power systems using dual GA loops in ANN training**. Power Engineering Society Summer Meeting, 2000. IEEE, 2000

BRAHMA, S. M.; GIRGIS, A. A. Development of adaptive protection scheme for distribution systems with high penetration of distributed generation. **IEEE Transactions on power delivery**, v. 19, n. 1, p. 56–63, 2004.

BUTLER, K. L.; MOMOH, J. A. **Detection and classification of line faults on power distribution systems using neural networks**. Circuits and Systems, 1993., Proceedings of the 36th Midwest Symposium on, 1993

CASTILHO, V. DE. **Otimização de componentes de concreto pré-moldado protendidos mediante algoritmos genéticos**. Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, 2003.

DA SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **REDES NEURAIAS ARTIFICIAIS PARA ENGENHARIA E: CIENCIAS APLICADAS - CURSO PRATICO**. [s.l.] ARTLIBER, [s.d.].

DA SILVA RAYBOLT, A. C. **LOCALIZAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO EM CIRCUITO DUPLO UTILIZANDO REDES NEURAIAS ARTIFICIAIS**. [s.l.] Tese de Doutorado, Universidade Federal do Rio de Janeiro, 2011.

DECANINI, J. G. M. S. **Detecção, classificação e localização de faltas de curto-circuito em sistemas de distribuição de energia elétrica usando sistemas inteligentes**, Artigo de Periódico, 2012.

DINIZ, T. O. **Avaliação do impacto dos tipos de equipamentos de medição no desempenho da detecção de defeitos em sistemas de distribuição utilizando redes neurais**, Dissertação de Mestrado, Universidade Federal de Juiz de Fora, 2015.

GARCÍA, J. C.; GARCÍA, V. V.; KAGAN, N. **Detection of high impedance faults in overhead multi grounded networks**. Industry Applications (INDUSCON), 2014 11th IEEE/IAS International Conference on, 2014

GIMENEZ, J. J. G. **Metodologia para Detecção, Identificação e Localização de Defeitos de Alta Impedância com a presença de Geração Distribuída**. Tese de Doutorado, Universidade Federal de Juiz de Fora, 2016.

- GÖNEN, T. **Electric power distribution system engineering**. [s.l.] McGraw-Hill New York, 1986.
- HAYKIN, S. **Redes Neurais Princípios e Aplicações. Segunda Edição. Porto Alegre**, 2001.
- HOLLAND, J. H. **Adaptation in natural and artificial systems**. 1975. **Ann Arbor, MI: University of Michigan Press and**, 1992.
- HUANG, Y.-C.; YANG, H.-T.; HUANG, C.-L. A new intelligent hierarchical fault diagnosis system [for power networks]. **IEEE transactions on power systems**, v. 12, n. 1, p. 349–356, 1997.
- IURINIC, L. U. et al. Distribution Systems High-Impedance Fault Location: A Parameter Estimation Approach. **IEEE Transactions on Power Delivery**, v. 31, n. 4, p. 1806–1814, 2016.
- KEZUNOVIC, M. **Intelligent applications in substations disturbance analysis**. Power Engineering Society General Meeting, 2004. IEEE. **Anais...IEEE**, 2004
- LAI, W.-T. et al. **Development of the Short-Circuit Capacities Curves for Distribution Systems Planning Using Matlab**. Cybernetics and Intelligent Systems, 2006 IEEE Conference on, 2006
- LEDESMA, J. J. G. **Uma metodologia para análise da coordenação e seletividade da proteção de sistemas de distribuição**, Artigo de Periódico, 2012.
- LEDESMA, J. J. G.; ARAUJO, L. R.; PENIDO, D. R. R. A method for evaluation of overcurrent protection in unbalanced distribution systems. **International Transactions on Electrical Energy Systems**, v. 26, n. 2, p. 412–428, 2016.
- NASCIMENTO, H. **Sistemas de Energia - Cap. 7 - Prof. Helton do Nascimento - Sistemas de Energia -...** Disponível em: <<http://www.ebah.com.br/content/ABAAABpIIAL/sistemas-energia-cap-7-prof-helton-nascimento>>. Acesso em: 10 jul. 2017.
- NIKOOFEKR, I.; SARLAK, M.; SHAHRTASH, S. M. **Detection and classification of high impedance faults in power distribution networks using ART neural networks**. Electrical Engineering (ICEE), 2013 21st Iranian Conference on. IEEE, 2013
- PENIDO, D. R. R. et al. A new tool for multiphase electrical systems analysis based on current injection method. **International Journal of Electrical Power & Energy Systems**, v. 44, n. 1, p. 410–420, 2013.
- PENIDO, D. R. R.; DE ARAUJO, L. R.; DE CARVALHO FILHO, M. A fault analysis algorithm for unbalanced distribution systems. **IEEE Latin America Transactions**, v. 13, n. 1, p. 107–115, 2015.
- PIRES, R.; BORBA, S. **Vantagens da instalação para as empresas de transmissão e para o operador nacional do sistema de PMU/SPMS (unidade de medição fasorial/sistemas de medição fasorial sincronizada)**". . In: X SIMPÓSIO DE

ESPECIALISTAS EM PLANEJAMENTO DA OPERAÇÃO E EXPANSÃO ELÉTRICA. Florianópolis, Brasil: 2006

RIANI, L. M. et al. **Análise de defeitos em coordenadas de fase utilizando modelagem a quatro fios e fluxo de potência continuado.** CONGRESSO BRASILEIRO DE AUTOMÁTICA, 2008

SALIM, R. H. et al. Hybrid fault diagnosis scheme implementation for power distribution systems automation. **IEEE Transactions on Power Delivery**, v. 23, n. 4, p. 1846–1856, 2008.

SARLAK, M.; SHAHRTASH, S. M. High impedance fault detection using combination of multi-layer perceptron neural networks based on multi-resolution morphological gradient features of current waveform. **IET generation, transmission & distribution**, v. 5, n. 5, p. 588–595, 2011.

SCHNEIDER. **Especialista Global em Gestão de Energia | Schneider Electric.** Disponível em: <<http://www.schneider-electric.com.br/pt/>>. Acesso em: 9 jul. 2017.

SEL. **IEDs e Relés de Proteção SEL - Schweitzer Engineering Laboratories.** Disponível em: <<https://selinc.com/pt/>>. Acesso em: 9 jul. 2017.

SENGER, E. C. et al. Automated fault location system for primary distribution networks. **IEEE Transactions on Power Delivery**, v. 20, n. 2, p. 1332–1340, 2005.

SIEMENS. **Siemens Website.** newton_home. Disponível em: <<https://www.siemens.com/br/pt/home.html>>. Acesso em: 9 jul. 2017.

VON ZUBEN, F.; N. DE CASTRO, L. **Redes Neurais Artificiais para Reconhecimento e Classificação de Padrões**, 2000. Disponível em: <ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia353_03/revisao/docs/tema16.doc>

WEG. **Motores, Automação, Energia, T&D e Tintas - WEG Brasil.** Disponível em: <<http://old.weg.net/br/>>. Acesso em: 9 jul. 2017.

WESTPHAL, H. **Algoritmo genético aplicado à Otimização multiobjetivo em redes de distribuição de petróleo e derivados.** [s.l.] Dissertação de Mestrado Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná, Curitiba, Paraná, Brasil, 2006.

ZAMBONI, L. et al. Fault detection in power distribution systems using automated integration of computational intelligence tools. **IEEE Latin America Transactions**, v. 9, n. 4, p. 522–527, 2011.