

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA**  
**FACULDADE DE ENGENHARIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**João Pedro Brito da Silva**

**Detecção e Localização de Falhas Monofásicas em Sistema de Distribuição Baseadas em  
Redes Neurais Artificiais com uso de Algoritmo Genético para Alocação de Medidores**

Juiz de Fora

2024

**João Pedro Brito da Silva**

**Detecção e Localização de Falhas Monofásicas em Sistema de Distribuição Baseadas em Redes Neurais Artificiais com uso de Algoritmo Genético para Alocação de Medidores**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, na área de concentração em Sistemas de Energia Elétrica, como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica.

Orientadora: Profa. Dra. Débora Rosana Ribeiro Penido Araujo

Coorientador: Prof. Dr. Leandro Ramos de Araujo

Juiz de Fora

2024

Ficha catalográfica Elaborado através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Silva, João Pedro Brito da.

Detecção e Localização de Falhas Monofásicas em Sistema de Distribuição Baseadas em Redes Neurais Artificiais com uso de Algoritmo Genético para Alocação de Medidores / João Pedro Brito da Silva. -- 2024.

126 f. : il.

Orientadora: Débora Rosana Ribeiro Penido Araujo

Coorientador: Leandro Ramos de Araujo

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2024.

1. Sistemas de distribuição. 2. Falhas de alta impedância. 3. Detecção e localização de faltas. 4. Redes neurais artificiais. 5. Algoritmo genético. I. Araujo, Débora Rosana Ribeiro Penido, orient. II. Araujo, Leandro Ramos de, coorient. III. Título.

**João Pedro Brito da Silva**

**Detecção e Localização de Falhas Monofásicas em Sistema de Distribuição Baseadas em Redes Neurais Artificiais com uso de Algoritmo Genético para Alocação de Medidores**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, na área de concentração em Sistemas de Energia Elétrica, como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica.

Aprovado em 13 de setembro de 2024.

**BANCA EXAMINADORA**

---

Profª. Dra. Débora Rosana Ribeiro Penido Araujo – Orientadora  
Universidade Federal de Juiz de Fora

---

Prof. Dr. Leandro Ramos de Araujo – Coorientador  
Universidade Federal de Juiz de Fora

---

Prof. Dr. Leonardo Willer de Oliveira  
Universidade Federal de Juiz de Fora

---

Prof. Dr. Oswaldo Hideo Ando Junior  
Universidade Federal Rural de Pernambuco

Juiz de Fora, 19/08/2024.



Documento assinado eletronicamente por **Debora Rosana Ribeiro Penido Araujo, Professor(a)**, em 16/09/2024, às 14:46, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Leandro Ramos de Araujo, Professor(a)**, em 16/09/2024, às 14:48, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Leonardo Willer de Oliveira, Professor(a)**, em 16/09/2024, às 14:56, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **OSWALDO HIDEO ANDO JUNIOR, Usuário Externo**, em 16/09/2024, às 15:07, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf ([www2.ufjf.br/SEI](http://www2.ufjf.br/SEI)) através do ícone Conferência de Documentos, informando o código verificador **1930485** e o código CRC **2B50155A**.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus, pois é Ele quem me sustenta e me capacita. Agradeço pelas oportunidades concedidas até aqui, e também pelas que virão. Toda honra e toda glória sejam dadas a Ele.

Agradeço especialmente à minha esposa Maria Eduarda, com quem divido minha vida e está sempre presente ao meu lado, me dando todo amor, suporte e confiança necessários para que possamos alcançar nossas conquistas e sonhos.

Agradeço aos meus pais, Adriana e Sandro, que sempre me deram todo apoio necessário para que eu pudesse trilhar minha caminhada de vida. Agradeço também aos meus sogros, Daniele e Marino, que me orientam e ajudam em diversas ocasiões.

Agradeço a todos os demais familiares que sempre demonstraram apoio e entendimento nos momentos de distância devido aos estudos. Agradeço a todos meus amigos que compartilharam comigo momentos de estudo e de alguma forma contribuíram para que eu chegasse até aqui.

Agradeço aos meus orientadores Débora e Leandro que me impulsionaram ao caminho das pesquisas e transmitiram seus conhecimentos.

Agradeço também ao Programa de Pós-Graduação em Engenharia Elétrica pelos conhecimentos acadêmicos ensinados pelos professores responsáveis pela minha formação e pela oportunidade de realizar um curso de mestrado de excelente qualidade.

Por fim, agradeço a Universidade Federal de Juiz de Fora, CAPES, CNPQ, FAPEMIG e INERGE pelo suporte financeiro e estruturas que contribuíram para que eu tivesse as condições necessárias para estudar e pudesse desenvolver minhas habilidades e aprendizados.

*“Porque o Senhor dá a sabedoria, e da sua boca vem a inteligência e o entendimento.”*

*(Provérbios 2:6)*

## RESUMO

Neste trabalho, foi proposto um método que utiliza redes neurais artificiais (RNAs) para detectar e localizar faltas de alta impedância em sistemas de distribuição de energia elétrica. Para a realização deste estudo, foram utilizadas medições de corrente como dados de entrada das RNAs, e como forma de avaliar o desempenho, foram usados três tipos de medições: não fasoriais, de sequência e fasoriais. Além disso, foi utilizado o algoritmo genético para otimizar a alocação dos medidores. A implementação do método se deu pelo desenvolvimento de dois conjuntos de RNAs: um composto por redes neurais associadas a cada um dos barramentos do sistema de distribuição e outro formado por três RNAs, sendo cada uma exclusiva a uma fase do circuito, e dessa maneira, a detecção das faltas e a localização das barras e fases defeituosas puderam ser determinadas. Os testes para validação do método foram conduzidos em três sistemas: IEEE 13 barras, IEEE 34 barras e IEEE 123 barras. Os resultados mostraram que, apesar das dificuldades impostas, o método foi eficaz na maioria dos cenários propostos. As RNAs se mostraram robustas na detecção de faltas e na localização da fase com defeito, apresentando eficiências acima de 90% na maioria dos casos testados. A localização do barramento com falta foi indicada por um grupo de barras prováveis, o que reduziu o campo de busca e mostrou eficiência superior a 90% quando a otimização foi usada. Os locais onde os medidores foram instalados foram cruciais para o desempenho do método, e o algoritmo genético provou ser uma ferramenta eficaz para essa otimização. Para implementação computacional do método, foram utilizados os softwares OpenDSS® e Matlab®.

**Palavras-chave:** Sistemas de distribuição; Faltas de alta impedância; Detecção e localização de faltas; Redes neurais artificiais; Algoritmo genético.



## ABSTRACT

In this work, a method utilizing artificial neural networks (ANNs) was proposed to detect and locate high-impedance faults in power distribution systems. Current measurements were used as input data for the ANNs, and to evaluate performance, three types of measurements were used: non-phasor, sequence, and phasor. Additionally, the genetic algorithm was employed to optimize the placement of the meters. The method was implemented by developing two sets of ANNs: one composed of neural networks associated with each bus of the distribution system, and another formed by three ANNs, each exclusive to a phase of the circuit, and this allowed for the detection of faults and the identification of defective buses and phases. The validation tests for the method were conducted on three systems: IEEE 13-bus, IEEE 34-bus, and IEEE 123-bus. The results showed that, despite the challenges imposed, the method was effective in most proposed scenarios. The ANNs proved to be robust in fault detection and defective phase localization, achieving efficiencies above 90% in most tested cases. The faulty bus location was indicated by a group of probable buses, which reduced the search field and showed efficiency above 90% when optimization was used. The placement of the meters was crucial for the method's performance, and the genetic algorithm proved to be an effective tool for this optimization. For the computational implementation of the method, the software OpenDSS® and Matlab® were used.

**Keywords:** Distribution systems; High-impedance faults; Fault detection and location; Artificial neural networks; Genetic algorithm.

## LISTA DE FIGURAS

Figura 1 – Diagrama de blocos representativo de um sistema elétrico de potência.....	16
Figura 2 – Redes Aéreas de Distribuição: (a) Convencional, (b) Compacta e (c) Isolada.....	19
Figura 3 – Modelo de falta monofásica em barramento na fase A.....	32
Figura 4 – Fluxograma básico do desenvolvimento da metodologia.....	34
Figura 5 – Fluxograma da etapa de construção da base de dados de treinamento.....	35
Figura 6 – Fluxograma da etapa de construção da base de dados de teste.....	39
Figura 7 – Fluxograma da etapa de desenvolvimento de RNAs para localização de faltas.....	41
Figura 8 – Arquitetura padrão das RNAs criadas.....	45
Figura 9 – Novo fluxograma básico do desenvolvimento da metodologia.....	49
Figura 10 – Fluxograma da etapa de otimização da localização de medidores por AG.....	50
Figura 11 – Exemplo de codificação de um indivíduo.....	51
Figura 12 – IEEE 13 barras.....	56
Figura 13 – IEEE 34 barras.....	65
Figura 14 – IEEE 123 barras.....	80
Figura 15 – Esquemático de uma subestação de distribuição simples.....	102
Figura 16 – Esquemático de um SMFS.....	108
Figura 17 – Modelo simplificado do neurônio biológico.....	112
Figura 18 – Arquitetura de um neurônio artificial.....	113
Figura 19 – Esquemático da arquitetura de uma RNA.....	115
Figura 20 – Fluxograma simplificado do algoritmo genético.....	119
Figura 21 – Exemplo de seleção pelo método de Torneio.....	121
Figura 22 – Exemplo de seleção pelo método de Classificação por Ranking.....	121
Figura 23 – Exemplo de seleção pelo método da Roleta.....	122
Figura 24 – Exemplo de cruzamento de um ponto.....	123
Figura 25 – Exemplo de cruzamento por múltiplos pontos.....	123
Figura 26 – Exemplo de cruzamento uniforme.....	124
Figura 27 – Exemplos de mutação em um indivíduo.....	125

## LISTA DE TABELAS

Tabela 1 – Resumo dos trabalhos revisados.....	27
Tabela 2 – Parâmetros internos das RNAs desenvolvidas .....	44
Tabela 3 – Parâmetros genéticos adotados .....	53
Tabela 4 – Níveis de corrente de falta – IEEE 13 barras.....	57
Tabela 5 – Resultados obtidos pelas RNAs relativas às barras – IEEE 13 barras.....	58
Tabela 6 – Resultados obtidos pelas RNAs relativas às fases – IEEE 13 barras .....	58
Tabela 7 – Detalhamento de resultados com medidor fasorial – IEEE 13 barras .....	59
Tabela 8 – Detalhamento de resultados da posição relativa da barra indicada como a mais provável de estar com defeito – IEEE 13 barras.....	62
Tabela 9 – Níveis de corrente de falta – IEEE 34 barras.....	66
Tabela 10 – Detalhamento de resultados – IEEE 34 barras .....	68
Tabela 11 – Detalhamento de resultados da posição relativa da barra indicada como a mais provável de estar com defeito – IEEE 34 barras.....	70
Tabela 12 – Detalhamento de resultados obtidos com uso de AG (medição não fasorial) – IEEE 34 barras.....	72
Tabela 13 – Detalhamento de resultados obtidos com uso de AG (medição de sequência) – IEEE 34 barras .....	72
Tabela 14 – Detalhamento de resultados obtidos com uso de AG (medição fasorial) – IEEE 34 barras.....	72
Tabela 15 – Detalhamento de resultados obtidos para localização das fases com uso de AG – IEEE 34 barras .....	73
Tabela 16 – Detalhamento de resultados, com uso de AG, da posição relativa da barra indicada como a mais provável de estar com defeito – IEEE 34 barras .....	76
Tabela 17 – Níveis de corrente de falta – IEEE 123 barras.....	81
Tabela 18 – Detalhamento de resultados – IEEE 123 barras .....	83
Tabela 19 – Detalhamento de resultados da posição relativa da barra indicada como a mais provável de estar com defeito – IEEE 123 barras.....	85
Tabela 20 – Desempenho do método em relação ao local de falta - IEEE 123 barras.....	86
Tabela 21 – Detalhamento de resultados – IEEE 123 barras .....	87
Tabela 22 – Detalhamento de resultados da alocação dos medidores – IEEE 123 barras .....	87

Tabela 23 – Detalhamento de resultados, com uso de AG, da posição relativa da barra indicada como a mais provável de estar com defeito – IEEE 123 barras .....	90
Tabela 24 – Intensidade das correntes de FAI em diferentes superfícies.....	106
Tabela 25 – Principais funções de ativação.....	114

## LISTA DE GRÁFICOS

Gráfico 1 – Resultados obtidos para detecção de faltas - IEEE 13 barras.....	59
Gráfico 2 – Resultados obtidos para localização das barras com faltas - IEEE 13 barras .....	60
Gráfico 3 – Resultados obtidos para localização das fases com faltas - IEEE 13 barras .....	60
Gráfico 4 – Desempenho das RNAs dedicadas às barras com variação de neurônios na camada oculta - IEEE 13 barras.....	61
Gráfico 5 – Resultados das posições relativas da primeira barra indicada com defeito - IEEE 13 barras.....	63
Gráfico 6 – Resultados obtidos para detecção de faltas - IEEE 34 barras.....	67
Gráfico 7 – Resultados obtidos para localização da barra com falta - IEEE 34 barras .....	67
Gráfico 8 – Resultados obtidos para localização da fase com falta - IEEE 34 barras.....	68
Gráfico 9 – Desempenho das RNAs dedicadas às barras com variação de neurônios na camada oculta - IEEE 34 barras.....	69
Gráfico 10 – Resultados das posições relativas da primeira barra indicada com defeito – IEEE 34 barras.....	71
Gráfico 11 – Resultados obtidos para detecção de faltas com uso de AG - IEEE 34 barras....	73
Gráfico 12 – Resultados obtidos para localização da barra com falta com uso de AG - IEEE 34 barras.....	74
Gráfico 13 – Resultados obtidos para localização da fase com falta com uso de AG - IEEE 34 barras.....	74
Gráfico 14 – Desempenho, com uso de AG, das RNAs dedicadas às barras com variação de neurônios na camada oculta - IEEE 34 barras .....	75
Gráfico 15 – Resultados das posições relativas da primeira barra indicada com defeito com uso de AG – IEEE 34 barras .....	76
Gráfico 16 – Comparativo de resultados - IEEE 34 barras .....	78
Gráfico 17 – Comparativo de resultados para posições relativas – IEEE 34 barras .....	79
Gráfico 18 – Resultados obtidos para detecção de faltas - IEEE 123 barras.....	82
Gráfico 19 – Resultados obtidos para localização da barra com falta - IEEE 123 barras .....	82
Gráfico 20 – Resultados obtidos para localização da fase com falta - IEEE 123 barras.....	83
Gráfico 21 – Desempenho das RNAs dedicadas às barras com variação de neurônios na camada oculta - IEEE 123 barras.....	84

Gráfico 22 – Resultados das posições relativas da primeira barra indicada com defeito – IEEE 34 barras.....	85
Gráfico 23 – Resultados obtidos para detecção de faltas com uso de AG - IEEE 123 barras..	88
Gráfico 24 – Resultados obtidos para localização da barra com falta com uso de AG - IEEE 123 barras.....	88
Gráfico 25 – Resultados obtidos para localização da fase com falta com uso de AG - IEEE 123 barras.....	89
Gráfico 26 – Resultados das posições relativas da primeira barra indicada com defeito com uso de AG – IEEE 123 barras .....	90
Gráfico 27 – Comparativo de resultados - IEEE 123 barras .....	92
Gráfico 28 – Comparativo de resultados para posições relativas – IEEE 123 barras .....	93

## LISTA DE ABREVIATURAS E SIGLAS

AG	Algoritmo Genético
AM	Aprendizado de Máquina
ANEEL	Agência Nacional de Energia Elétrica
ANFIS	Sistema de Inferência Neuro-Fuzzy Adaptativo
AT	Alta Tensão
BT	Baixa Tensão
FAI	Falta de Alta Impedância
GD	Geração Distribuída
GPS	<i>Global Positioning System</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
Matlab	<i>Matrix Laboratory</i>
MQL	Mínimos Quadrados Lineares
MT	Média Tensão
ONS	Operador Nacional do Sistema
OpenDSS	<i>Open Distribution System Simulator</i>
PDC	<i>Phasor Data Concentrator</i>
PMU	<i>Phasor Measurement Units</i>
PRODIST	Procedimentos de Distribuição
PSO	<i>Particle Swarm Optimization</i>
RNA	Rede Neural Artificial
RPG	Regressão por Processo Gaussiano
SD	Sistema de Distribuição

SE	Subestação
SEP	Sistema Elétrico de Potência
SIN	Sistema Interligado Nacional
SMFS	Sistema de Medição Fasorial Sincronizado
TC	Transformador de Corrente
TDW	Transformada Discreta de Wavelet
TP	Transformador de Potencial
TW	Transformada de Wavelet
UFJF	Universidade Federal de Juiz de Fora



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>16</b>
1.1	CONSIDERAÇÕES INICIAIS .....	16
1.2	MOTIVAÇÃO .....	18
1.3	REVISÃO BIBLIOGRÁFICA .....	20
1.4	OBJETIVOS .....	28
1.5	PUBLICAÇÕES DECORRENTES.....	29
1.6	ESTRUTURA DO TRABALHO .....	29
<b>2</b>	<b>METODOLOGIA PROPOSTA .....</b>	<b>31</b>
2.1	CONSIDERAÇÕES INICIAIS .....	31
2.2	PROBLEMA ESTUDADO .....	31
<b>2.2.1</b>	<b>Modelagem das faltas .....</b>	<b>32</b>
<b>2.2.2</b>	<b>Medidores .....</b>	<b>32</b>
2.3	MÉTODO PROPOSTO PARA DETECÇÃO E LOCALIZAÇÃO DE FALTAS..	33
<b>2.3.1</b>	<b>Etapa de construção da base de dados de treino.....</b>	<b>34</b>
<b>2.3.2</b>	<b>Etapa de construção da base de dados de teste .....</b>	<b>38</b>
<b>2.3.3</b>	<b>Etapa de desenvolvimento de RNAs para localização de faltas.....</b>	<b>40</b>
<b>3</b>	<b>ALOCAÇÃO ÓTIMA DE MEDIDORES .....</b>	<b>48</b>
<b>4</b>	<b>RESULTADOS.....</b>	<b>55</b>
4.1	INTRODUÇÃO .....	55
4.2	IEEE 13 BARRAS.....	55
<b>4.2.1</b>	<b>Análise parcial dos resultados – IEEE 13 barras.....</b>	<b>63</b>
4.3	IEEE 34 BARRAS .....	65
<b>4.3.1</b>	<b>Análise parcial dos resultados – IEEE 34 barras.....</b>	<b>77</b>
4.4	IEEE 123 BARRAS.....	79

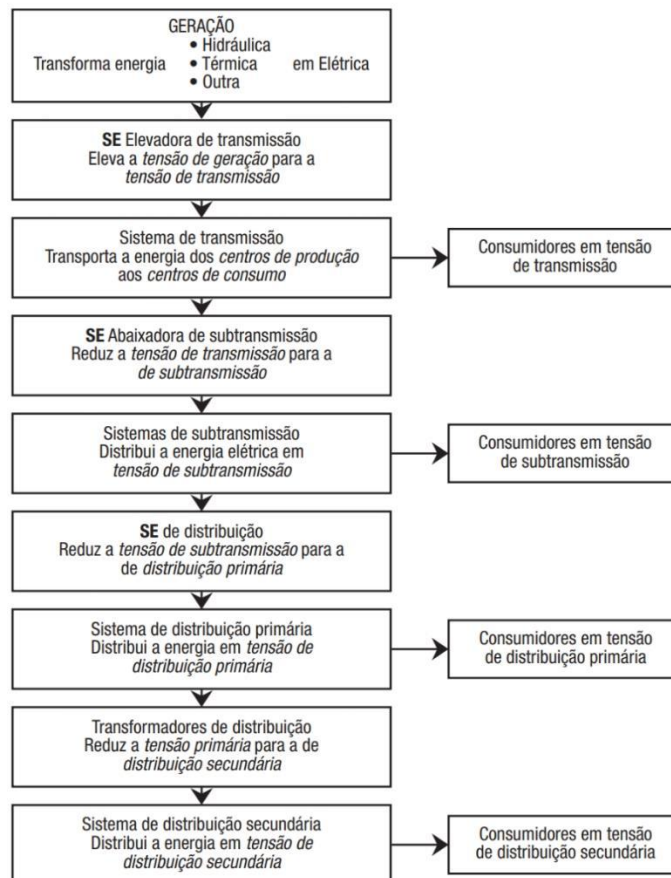
4.4.1	Análise parcial dos resultados – IEEE 123 barras.....	91
5	CONSIDERAÇÕES FINAIS .....	94
5.1	CONCLUSÕES GERAIS .....	94
5.2	SUGESTÕES DE TRABALHOS FUTUROS .....	95
	REFERÊNCIAS .....	97
	APÊNDICE A – SISTEMAS DE DISTRIBUIÇÃO .....	101
	APÊNDICE B – TIPOS DE MEDIÇÕES.....	107
	APÊNDICE C – REDES NEURAIAS ARTIFICIAIS .....	111
	APÊNDICE D – ALGORITMO GENÉTICO.....	117

# 1 INTRODUÇÃO

## 1.1 CONSIDERAÇÕES INICIAIS

Um sistema elétrico de potência (SEP) é responsável por produzir, transportar e distribuir energia elétrica dos centros de geração até os consumidores finais, tendo como principal objetivo atender a demanda dos clientes com qualidade. Sua estrutura é composta por uma rede de componentes elétricos interligados, como geradores, linhas de transmissão, subestações e sistemas de distribuição, que trabalham juntos para suprir o consumo de eletricidade de maneira eficiente e segura (KAGAN, OLIVEIRA e ROBBA, 2000). A Figura 1 ilustra um diagrama de blocos representativo de um sistema elétrico de potência.

Figura 1 – Diagrama de blocos representativo de um sistema elétrico de potência



Fonte: Kagan, Oliveira e Robba (2000).

No Brasil, o Sistema Interligado Nacional (SIN) é a rede de grande porte encarregada pela maior parte da geração e transmissão de energia elétrica em, praticamente, todo o país. O Operador Nacional do Sistema Elétrico (ONS) é responsável por coordenar e controlar a operação dessas instalações, junto às transmissoras, atuando com a finalidade de: promover a otimização dos procedimentos do sistema, visando a redução de custos; assegurar que todos os agentes do setor elétrico possam utilizar a rede de transmissão de forma justa e igualitária; colaborar, conforme suas atividades, para que a expansão do SIN ocorra com menor custo e tenha como foco a perspectiva de melhores condições operacionais (ONS, 2024).

Em relação ao Sistema de Distribuição (SD), tem-se um sistema composto por subestações, transformadores, cabos e equipamentos de controle e proteção, sendo projetado para operar em diferentes níveis de tensão e fornecer energia elétrica diretamente aos consumidores finais, em uma topologia caracterizada por diversas ramificações ao longo da zona urbana e rural de uma cidade. Para assegurar o funcionamento adequado desse tipo de sistema, os agentes do setor elétrico destinados a realizar a operação do SD são as concessionárias de energia de elétrica.

A garantia do abastecimento contínuo, seguro e confiável, é crucial no desenvolvimento econômico e social de uma sociedade, assim, a presença um órgão regulador faz-se necessária para implementar políticas e diretrizes federais, fiscalizar e regular as atividades de geração, transmissão, distribuição e comercialização de energia elétrica, estabelecer tarifas, etc. No setor elétrico brasileiro, a ANEEL (Agência Nacional de Energia Elétrica) cumpre este papel de executar tais atividades, a fim de proporcionar condições favoráveis para que o mercado de energia elétrica se desenvolva com equilíbrio entre os agentes e em benefício da população. (ANEEL, 2023).

Ainda no âmbito de qualidade de fornecimento de eletricidade, é importante pontuar que o SD é uma rede suscetível a defeitos, acidentes e interrupções, devido a causas naturais, falhas de equipamentos ou erros humanos. Diante desse cenário, o sistema de proteção desempenha uma função fundamental ao propiciar a confiabilidade e a segurança da distribuição, promovendo a detecção e o isolamento das faltas elétricas, uma vez que os riscos associados podem comprometer a infraestrutura, os equipamentos, os consumidores e a segurança pública. Além disso, a mitigação dos efeitos adversos produzidos por tais faltas minimiza os custos da distribuidora com manutenções, reparos, troca de equipamentos e multas (NASCIMENTO, 2020).

## 1.2 MOTIVAÇÃO

O Sistema de Distribuição (SD) atualmente é composto em sua grande maioria por redes aéreas, as quais são divididas em três tipos: convencional, compacta e isolada.


Dentre esses tipos, a Rede Aérea Convencional se destaca pela alta adesão por parte das concessionárias, motivada pelo baixo custo e facilidade de instalação, sendo caracterizada por cabos nus, apoiados sobre isoladores de vidro ou porcelana, fixados horizontalmente sobre cruzetas de madeira, nos circuitos de média tensão e, verticalmente, nos de baixa tensão (INBRAEP, 2022). O grande desafio enfrentado por essa rede é a alta taxa de faltas, em razão dos condutores estarem expostos sem qualquer tipo de isolamento, favorecendo, por exemplo, o contato com galhos de árvores, o rompimento dos cabos, os contatos indiretos devido à proximidade com edificações, incidência de descargas atmosféricas, acidentes com animais, entre outros. Ou seja, há uma considerável possibilidade de falhas neste tipo de rede.

Desse modo, embora com um custo maior, as redes compactas têm ganhado popularidade, por ser um tipo de alimentador que ocupa menos espaço e apresenta proteção nos cabos, proporcionando uma alternativa à melhoria da confiabilidade do sistema elétrico por diminuir as incidências de contato nas partes vivas da rede (RIBEIRO, 2008). Porém, também há falhas nessas redes.

Existem também as redes aéreas isoladas que consistem em condutores isolados eletricamente e trançados ao redor de um cabo mensageiro de sustentação. Nesse sentido, esse tipo de rede também apresenta como vantagem a prevenção contra contatos acidentais devido ao isolamento das partes vivas, e diferentemente dos demais tipos, a presença do cabo mensageiro pode evitar o rompimento dos cabos eletrificados ao proporcionar maior resistência mecânica. Entretanto, a rede isolada requer maiores investimentos e, dessa forma, sua aplicação é recomendada em projetos específicos nos quais as redes convencionais e compactas podem ser consideradas perigosas ou suscetíveis a maior incidência de falhas (RIBEIRO, 2008). É importante destacar que, apesar de apresentar taxas reduzidas, as redes isoladas também estão sujeitas aos defeitos, como a queda de postes.

Exemplos da rede aérea convencional, da rede aérea compacta e da rede aérea isolada são apresentados na Figura 2.

Figura 2 – Redes Aéreas de Distribuição: (a) Convencional, (b) Compacta e (c) Isolada



Fonte: (a) Caetfest (2016), (b) VGS Group([s.d.]) e (c) Adaptado de Adeel (2017).

Assim, independentemente do tipo de rede empregado, as linhas de distribuição estão sujeitas a falhas, especialmente nas aéreas que são mais expostas.

Nesse contexto, torna-se essencial o investimento em tecnologias que aprimorem a continuidade do fornecimento de energia elétrica, permitindo o atendimento dos padrões de abastecimento e aumentando a qualidade do serviço. A rápida e precisa localização de faltas é crucial para viabilizar a solução dos problemas, otimizando todo o processo de reparo e restauração da rede. Isso não apenas ajuda a reduzir o tempo de interrupção dos clientes e a diminuir multas perante a ANEEL, mas também contribui para o aumento dos lucros das concessionárias e promove maior segurança aos equipamentos e, acima de tudo, à vida humana (NASCIMENTO, 2020).

No que diz respeito aos sistemas de proteção convencionais, o cenário mais geral é que eles são capazes de identificar com eficácia sobrecorrentes nos ramais de alimentação, através da atuação conjunta de disjuntores e relés, e o emprego de fusíveis, desde que estejam bem dimensionados e coordenados. Porém, nos SD, ainda existem dificuldades para detectar e localizar a ocorrência de uma falta, especialmente se for uma Falta de Alta Impedância (FAI), a qual é definida por uma baixa corrente de defeito quando comparada com as correntes normais solicitadas pelas cargas do SD (GHADERI, GINN e MOHAMMADPOUR, 2017). Na distribuição há uma enorme variação de cargas durante os dias, desequilíbrios acentuados entre as fases, muitas ramificações nos circuitos e poucos equipamentos de proteção com elementos de medição, comparativamente com outras partes dos SEP.

No atual momento, muitos casos de localização de faltas são realizados pela comunicação dos consumidores à ouvidoria da concessionária, ou pela inspeção visual feita pelas equipes de manutenção (CAVALARI, 2023), sendo que essas maneiras não são as mais eficientes para a tarefa e podem gerar transtornos à população e custos adicionais para a concessionária. Dessa forma, diversas pesquisas se propõem a colaborar com o desenvolvimento de métodos que auxiliem o processo de identificação de faltas e proporcionem que os sistemas de proteção se tornem mais sofisticados, utilizando algoritmos de detecção mais precisos e comunicação em tempo real. Além disso, a automação e a integração dos sistemas de proteção com outros dispositivos de monitoramento e controle estão progredindo para se tornarem cada vez mais comuns, permitindo uma gestão mais eficiente e coordenada do sistema de distribuição em situações de falta (ALJOHANI e HABIBALLAH, 2020).

### 1.3 REVISÃO BIBLIOGRÁFICA

A revisão bibliográfica neste trabalho se fundamentou em outros trabalhos que contribuíram para o desenvolvimento de métodos de localização de faltas em sistemas de distribuição.

Em Aljohani e Habiballah (2020) é feita uma revisão das metodologias de detecção, classificação e localização de faltas de alta impedância. Além disso, técnicas de diagnóstico são categorizadas, avaliadas e comparadas entre si. Dentre os métodos analisados tem-se: tradicionais, que utilizam as componentes simétricas das correntes para atuação dos relés de proteção; modelo em tempo real, o qual simula condições reais de falta em laboratório; técnicas de processamento de sinais, como a análise de harmônicos por meio da transformada de Fourier e a decomposição dos sinais pela transformada de Wavelet; aproximações matemáticas, que envolvem estimação da localização precisa das faltas por meio de equações que modelam o comportamento da rede; e inteligências artificiais, que são métodos formados por três processos principais: aquisição de dados, extração das características de faltas e aprendizado de máquina. Por fim, são discutidas as desvantagens das abordagens atuais e uma visão para o futuro do diagnóstico de faltas.

O trabalho de Oliveira *et al.* (2016) desenvolveu uma metodologia para a detecção e classificação de faltas em sistemas de distribuição de energia elétrica, utilizando redes neurais

artificiais. Como dados para a camada de entrada das RNAs, a técnica propõe módulos de tensão, fasores de corrente e um fator de sequência negativa, o qual é um índice de sensibilidade desenvolvido a partir das correntes de sequência negativa e zero, em condições de pré-defeito e defeito, e normalizadas pela corrente de pré-defeito de sequência positiva. Dessa forma, os resultados obtidos mostraram que a utilização do novo fator, associado aos ângulos de corrente de falta, permitiu que as RNAs fossem altamente eficazes na identificação de faltas e capazes de diferenciar faltas em derivação, série e simultâneas, com cabo caído do lado da fonte ou da carga. Além disso, os resultados indicam que modificações na rede de distribuição, tais como níveis de carregamento, desequilíbrio, valor da impedância de defeito ou local do defeito, não afetaram a eficácia do método proposto.

A técnica desenvolvida por Daisy e Dashti (2016) propõe um método combinado para localizar faltas monofásicas para a terra em redes de distribuição de energia. Nessa metodologia, inicialmente, são registradas as tensões e correntes no início do alimentador no momento da falta, e assim com esses dados executa-se um algoritmo de localização de faltas baseado em impedância, o qual fornece uma estimativa da distância e da resistência de faltas. Como esse algoritmo pode estimar a mesma distância em ramais diferentes da rede, um novo algoritmo é necessário para determinar a localização exata do trecho defeituoso. Assim, o mesmo tipo de falta é simulado na seção de possíveis locais de falta com incrementos de 0,1 km e a variação do ângulo de fase e a diferença de magnitude das tensões no início do alimentador são calculadas em relação à distância da falta e posteriormente armazenadas para a formação de um banco de dados online. Ao final, a localização real da falta é especificada pelo valor correspondente ao banco de dados que indica os possíveis locais.

Os autores de Santos *et al.* (2017) apresentam um algoritmo de detecção de faltas de alta impedância em redes de distribuição utilizando a técnica da transformada discreta de Wavelet para analisar as diferentes componentes de tensão em várias frequências ao longo do sistema. Isso permite identificar a área mais provável em que a falta ocorreu, sem a necessidade de sincronização de dados ou informações detalhadas sobre os parâmetros do sistema. O método proposto foi testado através de simulações utilizando programas de transientes eletromagnéticos em um sistema de 13,8 kV, modelado com base em dados reais da rede de distribuição brasileira. Além das faltas de alta impedância, o estudo também considerou a simulação de outros eventos, como o chaveamento de bancos de capacitores e a energização do alimentador, considerando o sistema com e sem geração distribuída. Os resultados



demonstraram que o algoritmo é eficaz em reduzir consideravelmente a área de busca das faltas de alta impedância, diferenciando-as de outras perturbações com precisão.

O estudo de Aziz, Hassan e Zahab (2012) apresenta uma metodologia capaz de detectar, localizar e classificar faltas de alta impedância em sistemas de distribuição utilizando um Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS). Nesse método, três conjuntos diferentes de dados podem ser utilizados como entrada para o treinamento e teste do ANFIS, os quais são obtidos no início do alimentador nos momentos de falta, ou não, e aplicados na transformada discreta de Fourier. Os conjuntos de entrada podem ser fasores das componentes fundamentais das correntes trifásicas, magnitudes das componentes fundamentais e terceiras harmônicas das correntes trifásicas ou fasores das componentes de terceira harmônica das correntes trifásicas. As faltas aplicadas no sistema teste tiveram seus valores de resistência variando de 100 a 2000 ohms e todos os tipos de falta foram testados (fase-terra, fase-fase, fase-fase-terra e fase-fase-fase-terra). No processo de treinamento, o ANFIS é ajustado para identificar os padrões das correntes de falta e de operação normal, e assim, quando testados, são capazes de determinar a localização e a classificação das faltas na rede de distribuição. Os resultados mostraram que as componentes de terceira harmônica desempenham um papel essencial na detecção e localização de FAI, ao passo que as componentes fundamentais são importantes para a classificação.

A metodologia desenvolvida por Moloji, Jordaan e Hamam (2018) propõe uma técnica para diagnóstico de faltas de alta impedância em uma rede de distribuição de energia. Um segmento de um sistema de energia real de 22 kV é testado para vários casos, incluindo operação normal, faltas de alta impedância e chaveamentos de carga e de capacitores. O método utiliza dois ciclos da corrente de falta medida no início do alimentador, e faz uso da Transformada Discreta de Wavelet (TDW) como técnica de extração de características de falta. As características extraídas são posteriormente inseridas em uma Rede Neural Artificial (RNA) e em esquemas de Regressão por Processo Gaussiano (RPG) para diagnosticar efetivamente as FAIs. A RNA é usada para classificação e detecção de faltas em outras condições do sistema de energia. Além disso, o esquema RPG é usado para estimar a localização da falta. Assim, uma técnica híbrida composta por TDW-RNA-RPG é proposta para diagnóstico das faltas. Os resultados obtidos mostram que o esquema é bastante preciso e tem erro mínimo de estimativa para a localização da falta.

Em Trindade, Freitas e Vieira (2014) é desenvolvida uma abordagem para localização de defeitos baseada em medidores inteligentes com capacidade de monitoramento de variações

de tensão. A ideia principal é explorar as aferições de tensão de medidores colocados em diferentes pontos de conexão de sistemas de distribuição para estimar onde ocorreu o defeito. A estimativa é obtida relacionando a mudança de tensão medida por cada medidor à corrente de defeito calculada com base na matriz de impedância do sistema, considerando o defeito em várias localizações. Para aprimorar a precisão do método, as cargas são modeladas como impedâncias constantes e incluídas na matriz de impedância. A eficácia do método é demonstrada em um ambiente de distribuição real, com a ocorrência de faltas monofásicas e trifásicas. Os resultados dos estudos de sensibilidade indicam que o método é robusto, apresentando desempenho satisfatório para diferentes valores de resistência do defeito e para várias quantidades e posições dos medidores inteligentes.

No trabalho de Chakraborty e Das (2019) as FAIs são identificadas com base na presença de harmônicos pares nas formas de onda de tensão obtidas por medidores inteligentes. Além disso, o método foi aplicado em um medidor de energia comercial para demonstrar sua viabilidade. A avaliação do desempenho do método também levou em consideração a presença de flutuações de tensão, comutação de capacitores/cargas, energização de transformadores, alimentação de circuitos, cargas eletrônicas de potência, cargas de forno a arco e geração distribuída (GD), apresentando desempenho satisfatório.

O método proposto por Fanucchi (2014) utilizou transformadas Wavelet (TW) e redes neurais artificiais para detecção e localização de faltas de alta impedância em sistemas de distribuição. Um sistema de distribuição real foi modelado para possibilitar análise do método proposto e validar os resultados obtidos. A metodologia proposta se dividiu em três módulos para o processo de identificação das faltas. O Módulo 1 foi designado para monitorar de forma contínua os sinais de corrente e, através da utilização da transformada de Wavelet, detectar uma possível ocorrência de falta devido a uma descontinuidade. O Módulo 2, por sua vez, foi desenvolvido para ser ativado na ocorrência de um evento de descontinuidade e ser capaz de diferenciar, por meio de RNAs, as FAIs dos demais eventos. Por fim, com a verificação positiva de falta no módulo anterior, inicializava-se o Módulo 3, o qual foi responsável por estimar a localização das FAIs através de RNAs diferentes das anteriores.

Os autores de Iurinic *et al.* (2016) apresentam uma formulação analítica para a detecção de faltas de alta impedância em redes elétricas de distribuição. O método é desenvolvido no domínio do tempo, utilizando um modelo de falta composto por dois diodos em antiparalelo. Através deste modelo, logo nos ciclos iniciais do defeito e através de um único sinal de tensão e corrente, a distância e os parâmetros da falta são determinados por intermédio de um problema

de otimização. A técnica possibilita a inclusão ou não da capacitância da linha. Se a capacitância não for considerada, um conjunto linear de equações é resolvido utilizando uma abordagem de Mínimos Quadrados Lineares (MQL). Já se a capacitância for levada em conta, um conjunto não linear de equações deve ser solucionado. Para validar o método, foram realizadas simulações utilizando o sistema IEEE 13 barras.

O estudo de Ledesma *et al.* (2020) propõe um método para localizar e identificar as faltas de alta impedância em redes de média tensão de sistemas de distribuição desbalanceados, o qual utiliza medições sincronizadas e dois conjuntos de redes neurais artificiais para esse fim. O sistema elétrico é dividido em áreas de observação através da posição dos medidores, e a primeira RNA é empregada para determinar se há uma falta nas possíveis áreas, enquanto a segunda RNA é responsável por calcular a distância da falta até o primeiro medidor da área de observação. Essa abordagem leva em consideração diversas características das redes de distribuição, tais como a variação de carga, reconfiguração, presença de geração distribuída, variação da resistência da falta, imprecisão nos dados dos alimentadores e operações dos dispositivos de proteção. Para validar o método proposto, foram realizados testes utilizando como sistema teste o IEEE 123 barras, que foi modificado para incluir gerações distribuídas. Ao utilizar dados de unidades de medição sincronizadas e duas redes neurais artificiais, o método proposto demonstrou ser eficaz na localização de faltas de alta impedância, mesmo em redes de distribuição desbalanceadas e com diversas condições variáveis.

A metodologia desenvolvida por Acácio (2017) aborda a influência da alocação de medidores em sistemas de distribuição para detecção e localização de faltas monofásicas. O estudo empregou algoritmos genéticos (AG) para otimizar o posicionamento dos medidores, formando áreas de observação para detecção de defeitos, ao passo que redes neurais artificiais foram utilizadas como rotina interna para calcular a eficiência do processo de identificação das faltas em cada área. As entradas das RNAs consistiram em dados de tensões e correntes obtidas por cada medidor alocado, podendo ser medições fasoriais ou apenas medições das magnitudes das grandezas. Para validação da metodologia foram utilizados como sistemas teste o IEEE 13 barras e o IEEE 123 barras. Os resultados obtidos demonstraram uma boa precisão e robustez para a localização das faltas, mesmo considerando diferentes condições operativas, como variações na carga e presença de capacitores e reguladores de tensão.

No trabalho de Nascimento (2020) foram implementados métodos para detecção e identificação de faltas em sistemas de distribuição baseados em redes neurais artificiais. Diversos tipos de faltas monofásicas foram examinados, como defeitos de contato com alta

resistência, abertura de condutores e faltas simultâneas. Para atingir esse objetivo, o método foi dividido em duas abordagens distintas. Na primeira, foram utilizadas informações de corrente provenientes de medidores instalados no sistema, como entrada para as redes neurais, visando detectar e identificar cada tipo de falta. Já na segunda categoria, as medições de tensão nas barras terminais foram empregadas como entrada para as redes neurais, com o propósito de detectar faltas de abertura ou simultâneas em áreas específicas. Por meio da alocação dos medidores, a rede elétrica foi segmentada em áreas de detecção para simplificar o processo de localização, reduzindo a área de busca. Além disso, a detecção das faltas foi realizada de forma independente para cada fase do sistema, ou seja, cada rede neural identificava faltas em uma área específica de uma determinada fase do sistema utilizado. O estudo também incluiu simulações em tempo real para testes mais precisos das redes neurais, cujos resultados demonstraram eficácia e viabilidade prática da abordagem empregada.

Em Ghaderi, Ginn e Mohammadpour (2017) foi realizada uma análise abrangente das técnicas de detecção de faltas de alta impedância, e propõe que a detecção de FAIs é semelhante a uma tarefa de classificação de padrões, dividida em três etapas distintas: medição dos sinais do sistema, extração das características desses sinais e classificação das condições operacionais. O estudo visa categorizar, avaliar e comparar os métodos existentes na literatura sobre localização de faltas. Quanto à aquisição dos sinais, as metodologias utilizam as medições de corrente, tensão e intensidade do campo magnético. Na etapa de extração de características, destacam-se técnicas como sinais em coordenadas de fase ou de sequência, valor eficaz, transformada de Fourier e transformadas Wavelet. Na fase de classificação, são utilizados métodos como redes neurais artificiais, lógica Fuzzy, máquinas de vetores de suporte, árvores de decisão, algoritmos genéticos, entre outros. Por fim, o estudo aborda perspectivas futuras para o desenvolvimento dessas técnicas, considerando avanços na tecnologia da informação e aumento na capacidade de processamento como impulsionadores do campo de proteção e medição de sistemas de energia.

O artigo elaborado por Lopes, Silva e Vieira (2023) apresenta uma análise comparativa entre métodos baseados em aprendizado de máquina para detectar Faltas de Alta Impedância em sistemas de distribuição, considerando ruídos e a influência de geradores distribuídos. Para o desenvolvimento do estudo, foram utilizados como dados de entrada os harmônicos extraídos dos sinais de corrente aplicando-se a Transformada de Fourier. A partir desse conjunto de dados, os seguintes algoritmos de aprendizado de máquina foram treinados e testados: Árvore de Decisão (*Decision Tree*), Árvore de Conjunto (*Ensemble Tree*), Floresta Aleatória (*Random*

*Forest*), Vizinho Mais Próximo (*Nearest Neighbor*), Máquina de Vetores de Suporte e Redes Neurais Artificiais. Além disso, os métodos foram treinados utilizando-se uma simulação de um modelo de FAI, porém, foram testados com sinais reais de FAIs. O problema estudado neste trabalho se resume na detecção de faltas ocasionadas pelo rompimento de um condutor e seu subsequente contato com uma superfície de alta impedância, e na classificação de eventos em SDs, como energização de equipamentos e chaveamento de cargas e ramais laterais. O trabalho apresentou resultados, considerados pelos autores, com altas taxas de sucesso, e dentre suas principais contribuições destaca-se a comprovação de que algoritmos baseados em aprendizado de máquinas são adequados para o processo de detecção de faltas, além da categorização de eventos.

O método proposto em Diefenthaler *et al.* (2023) utiliza redes neurais artificiais para realizar o processo de detecção de faltas de alta impedância, abordando uma análise comparativa entre dois tipos de RNAs, Perceptron de Múltiplas Camadas e Convolutacional. A realização dos testes das RNAs é feita a partir de diferentes cenários simulados baseados em um sistema de distribuição real de média tensão localizado no País Basco, Espanha. Para avaliação dos resultados, são utilizados critérios de precisão, confiabilidade, segurança, proteção e sensibilidade através dos valores obtidos pela matriz de confusão. Por fim, tais resultados evidenciaram que as RNAs Convolutacionais demonstraram desempenhos superiores às redes Perceptron de Múltiplas Camadas.

Os autores de Pessoa e Oleskovicz (2023) desenvolveram um algoritmo capaz de estimar a distância e a resistência de falta baseado em impedância e métodos meta-heurísticos, a partir da utilização de medidores presentes no sistema de distribuição. Para validação do método, foram utilizados como teste o sistema IEEE 34 barras e o sistema CIGRÉ, considerando a presença de geradores distribuídos, e foram feitas análises de sensibilidade em relação ao tipo e a posição dos medidores, à resistência de falta, variação na quantidade e na alocação dos geradores distribuídos, e a falta de sincronismo entre os medidores empregados para localização das faltas. A respeito das meta-heurísticas utilizadas para otimização do algoritmo desenvolvido, têm-se as seguintes técnicas empregadas: Algoritmo Genético, Otimização por Enxame de Partículas (*Particle Swarm Optimization - PSO*) e Recozimento Simulado (*Simulated Annealing*). Os resultados obtidos pelo trabalho revelaram uma correlação significativa da distância estimada com a distância real para uma faixa específica de valores de resistência de falta, além disso, foram observados que o desempenho do algoritmo pode ser

afetado de acordo com a quantidade e a disposição dos geradores distribuídos e que o sincronismo entre os medidores é essencial para a aplicação da metodologia proposta.

A partir de uma análise geral dos trabalhos revisados, é possível observar que alguns se propõem em detectar ou classificar eventos que sejam considerados faltas nos sistemas de distribuição, algo bastante relevante no processo de localização dos defeitos. Outros trabalhos possuem o objetivo de estimar a localização das faltas, inclusive as de alta impedância. Dessa maneira, a Tabela 1 apresenta um resumo das principais características dos trabalhos revisados.

Tabela 1 – Resumo dos trabalhos revisados.

<b>Trabalho</b>	<b>Detecção</b>	<b>Localização</b>	<b>FAI</b>	<b>Medição</b>	<b>Técnica Empregada</b>
<b>Oliveira et al. (2016)</b>	Sim	Não	Não	Tensão e Corrente	Componentes Simétricas e RNA
<b>Daisy e Dashti (2016)</b>	Sim	Sim	Não	Tensão e Corrente	Enumeração Exaustiva
<b>Santos et al. (2017)</b>	Sim	Não	Sim	Tensão	TDW
<b>Aziz, Hassan e Zahab (2012)</b>	Sim	Sim	Sim	Corrente	Fuzzy
<b>Moloi, Jordaan e Hamam (2018)</b>	Sim	Sim	Sim	Corrente	TDW, RNA e RPG
<b>Trindade, Freitas e Vieira (2014)</b>	Sim	Sim	Não	Tensão	Monitoramento de queda de tensão
<b>Chakraborty e Das (2019)</b>	Sim	Não	Sim	Tensão	Distorções Harmônicas
<b>Fanucchi (2014)</b>	Sim	Sim	Sim	Corrente	TW e RNA
<b>Iurinic et al. (2016)</b>	Sim	Sim	Sim	Tensão e Corrente	MQL
<b>Ledesma et al. (2020)</b>	Sim	Sim	Sim	Corrente	RNA

<b>Acácio (2017)</b>	Sim	Sim	Sim	Corrente	RNA e AG
<b>Nascimento (2020)</b>	Sim	Sim	Sim	Tensão e Corrente	RNA
<b>Diefenthaler et al. (2023)</b>	Sim	Não	Sim	Tensão e Corrente	RNA
<b>Pessoa e Oleskovicz (2023)</b>	Sim	Sim	Não	Tensão e Corrente	AG, PSO e <i>Simulated Annealing</i>

Fonte: Elaborado pelo autor (2024).

Os demais trabalhos revisados, os quais realizaram revisões bibliográficas, e os trabalhos resumidos na tabela anterior evidenciam que as RNAs são amplamente utilizadas durante a etapa de processamento de dados extraídos dos sistemas de distribuição, demonstrando a eficácia dessa ferramenta em diferentes métodos empregados para solução do problema de localização de faltas

Além disso, pode-se observar que há muitos trabalhos na área de detecção e localização de defeitos, cada um com características específicas, mas não esgotando a necessidade de pesquisas na área, devido às muitas situações diferentes de faltas, de tipos de sistemas, de metodologias de solução, dentre outras variações interessantes de serem estudadas buscando maior rapidez, robustez e precisão nos resultados.

#### 1.4 OBJETIVOS

Na busca por melhores resultados nos quesitos de detecção e localização de faltas, e verificando que a questão da alocação de medidores pode impactar consideravelmente nestas tarefas, tem-se o desenvolvimento da metodologia proposta neste trabalho. Sendo que o objetivo principal deste trabalho é a implementação de um método de detecção e localização de faltas monofásicas de alta impedância em sistemas de distribuição considerando a instalação otimizada de medidores de correntes.

A implementação será feita através de simulações computacionais, considerando medições de correntes, do desenvolvimento de redes neurais para a correta identificação das

barras com faltas e de um algoritmo genético para alocar os medidores de maneira que se obtenha soluções de boa qualidade para a eficiência do método. Serão desenvolvidas RNAs para cada uma das barras do sistema a ser testado, contribuindo assim com um método diferente em relação aos demais trabalhos revisados.

Nesse trabalho, com a finalidade de representar a realidade das redes de distribuição de energia elétrica, serão consideradas as variações de carga, variações de resistência de falta e o uso de poucos medidores em relação a quantidade de barras do sistema. Estas considerações são importantes para aplicações reais, e alguns métodos apresentados na bibliografia não consideram todos estes pontos, gerando limitações em sua utilização em análises reais. Assim, neste trabalho busca-se uma metodologia simples e eficiente para aplicação em sistemas reais.

## 1.5 PUBLICAÇÕES DECORRENTES

Este trabalho resultou na seguinte publicação:

- “Aplicação de Redes Neurais Artificiais para a Localização de Faltas por Área em Sistemas de Distribuição Considerando Geração Distribuída”. Artigo apresentado no Simpósio Brasileiro de Sistemas Elétricos – SBSE. Manaus, AM, outubro de 2023.

## 1.6 ESTRUTURA DO TRABALHO

O capítulo 1 apresentou uma ideia ampla sobre o assunto a ser tratado neste trabalho, como também a motivação, uma revisão bibliográfica e o objetivo.

No capítulo 2, apresenta-se a metodologia elaborada para a detecção e localização de faltas de alta impedância.

No capítulo 3, descreve-se o processo de alocação ótima de medidores.

No capítulo 4, são demonstrados os resultados obtidos com a metodologia desenvolvida.



No capítulo 5, são mostradas as conclusões em relação ao método e aos resultados e as sugestões para trabalhos futuros.

Nos apêndices A, B, C e D, são descritas as fundamentações teóricas sobre o sistema de distribuição e faltas que podem ocorrer na rede elétrica, um detalhamento sucinto dos tipos de medidores e uma explicação sobre redes neurais artificiais e algoritmo genético.

## 2 METODOLOGIA PROPOSTA

### 2.1 CONSIDERAÇÕES INICIAIS

Este capítulo descreve a metodologia proposta para a elaboração do método de detecção e localização de falta de alta impedância em sistema de distribuição baseado em redes neurais artificiais. Em um primeiro momento, o problema estudado é detalhado de modo a apresentar as características dos sistemas de distribuição que serão simuladas, a modelagem das faltas e os tipos de medidores que serão utilizados. Em seguida, é descrito o método desenvolvido, exibindo-se a sequência de todos os passos elaborados para o desenvolvimento das redes neurais.

Para a implementação computacional do problema, utiliza-se o *software* OpenDSS®, responsável pela simulação dos sistemas de distribuição de energia elétrica. E para o desenvolvimento do algoritmo proposto, faz-se o uso do *software* Matlab®, o qual permite a utilização das redes neurais através de suas ferramentas de programação.

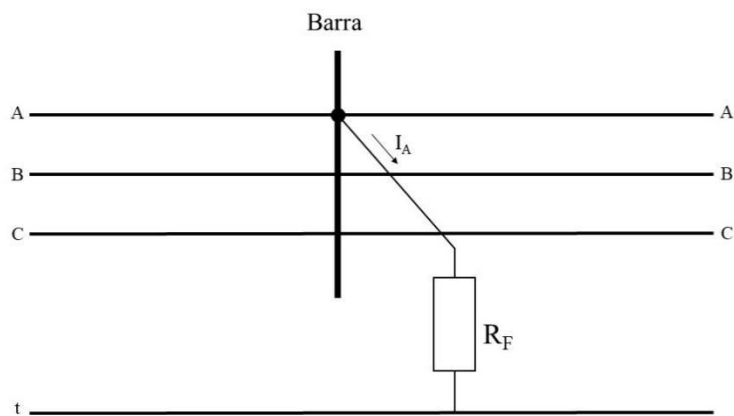
### 2.2 PROBLEMA ESTUDADO

Recapitulando o que foi descrito no capítulo de introdução, neste trabalho será estudado o problema de localização de faltas em barramentos de sistemas de distribuição. Em relação as faltas analisadas, serão analisadas apenas as monofásicas que envolvem a terra, visto que representam o maior quantitativo de defeitos nos SDs. Será dada ênfase a análise de faltas de alta impedância que são mais difíceis de serem detectadas na prática. No que se refere aos sistemas de distribuição simulados, serão consideradas redes trifásicas radiais que representem os desequilíbrios das cargas conectadas e os principais equipamentos existentes nas redes, inclusive a atuação de transformadores, reguladores e capacitores nos sistemas.

### 2.2.1 Modelagem das faltas

Para a representação das faltas será utilizado um modelo de resistência simples de valor constante, uma vez que o arco formado pelo contato das fases energizadas com o solo tem uma característica predominantemente resistiva. Além disso, o uso de medições de valores eficazes das correntes permite filtrar o período transitório em que pode haver outros comportamentos. Dessa forma, o modelo proposto torna-se adequado para a análise em regime permanente do sistema de distribuição. A Figura 3 ilustra o modelo de falta utilizado.

Figura 3 – Modelo de falta monofásica em barramento na fase A



Fonte: Elaborado pelo autor (2024).

### 2.2.2 Medidores

A respeito dos medidores utilizados para fornecer as medidas de corrente, este trabalho considera como quantidade ideal a menor possível que garanta uma boa eficiência da metodologia aplicada. Essa consideração busca representar outra especificidade dos SDs reais, a pouca disponibilidade desses equipamentos, ou seja, não é adequado considerar um grande número de medidores no desenvolvimento dos métodos quando na realidade estes quantitativos de medidores não estão disponíveis na prática.

Com relação ao tipo de medidor empregado serão consideradas as medições não-fasoriais, fasoriais e de sequência nos testes, dado que, atualmente, as empresas de distribuição


de energia adotam amplamente os medidores não-fasoriais em seus sistemas, porém, com o avanço tecnológico das redes de distribuição, a implementação das PMUs (*Phasor Measurement Units*) está se tornando uma realidade próxima, o que naturalmente substituirá os medidores convencionais e permitirá a utilização de dados fasoriais. Portanto, neste trabalho, os testes serão conduzidos com esses três tipos de medição para se obter uma análise de sensibilidade do método no que se refere ao tipo de entrada fornecida às RNAs.

### 2.3 MÉTODO PROPOSTO PARA DETECÇÃO E LOCALIZAÇÃO DE FALTAS

A metodologia desenvolvida na construção do método é baseada inicialmente na simulação de variados casos operativos no sistema de distribuição a ser avaliado, consistindo em variações dos níveis de carregamento, das localizações dos defeitos e dos valores das resistências de falta, de maneira a formar duas bases de dados, uma para treinamento e outra para teste das redes neurais artificiais, compostas pelos fasores das correntes das linhas da rede de distribuição para cada caso simulado. Utilizando-se estes dados são definidas RNAs para serem utilizadas na posterior análise de faltas deste sistema.

Posteriormente, o conjunto desenvolvido de RNAs para um sistema específico, ao receber as informações provenientes de uma simulação de um caso operacional neste sistema, deverá ser capaz de indicar corretamente o barramento e a fase em que ocorreu a falta ou indicar que não existe falta. É importante ressaltar que a detecção de faltas é feita simultaneamente com a localização, já que as RNAs indicarão para cada barramento se existe ou não uma falta, e posteriormente é feito um agrupamento das respostas de saída para identificar qual barramento está com defeito ou se todos não apresentam defeito. Nesse contexto, a metodologia para o desenvolvimento do método proposto foi dividida em três etapas, apresentadas no fluxograma da Figura 4.

Figura 4 – Fluxograma básico do desenvolvimento da metodologia

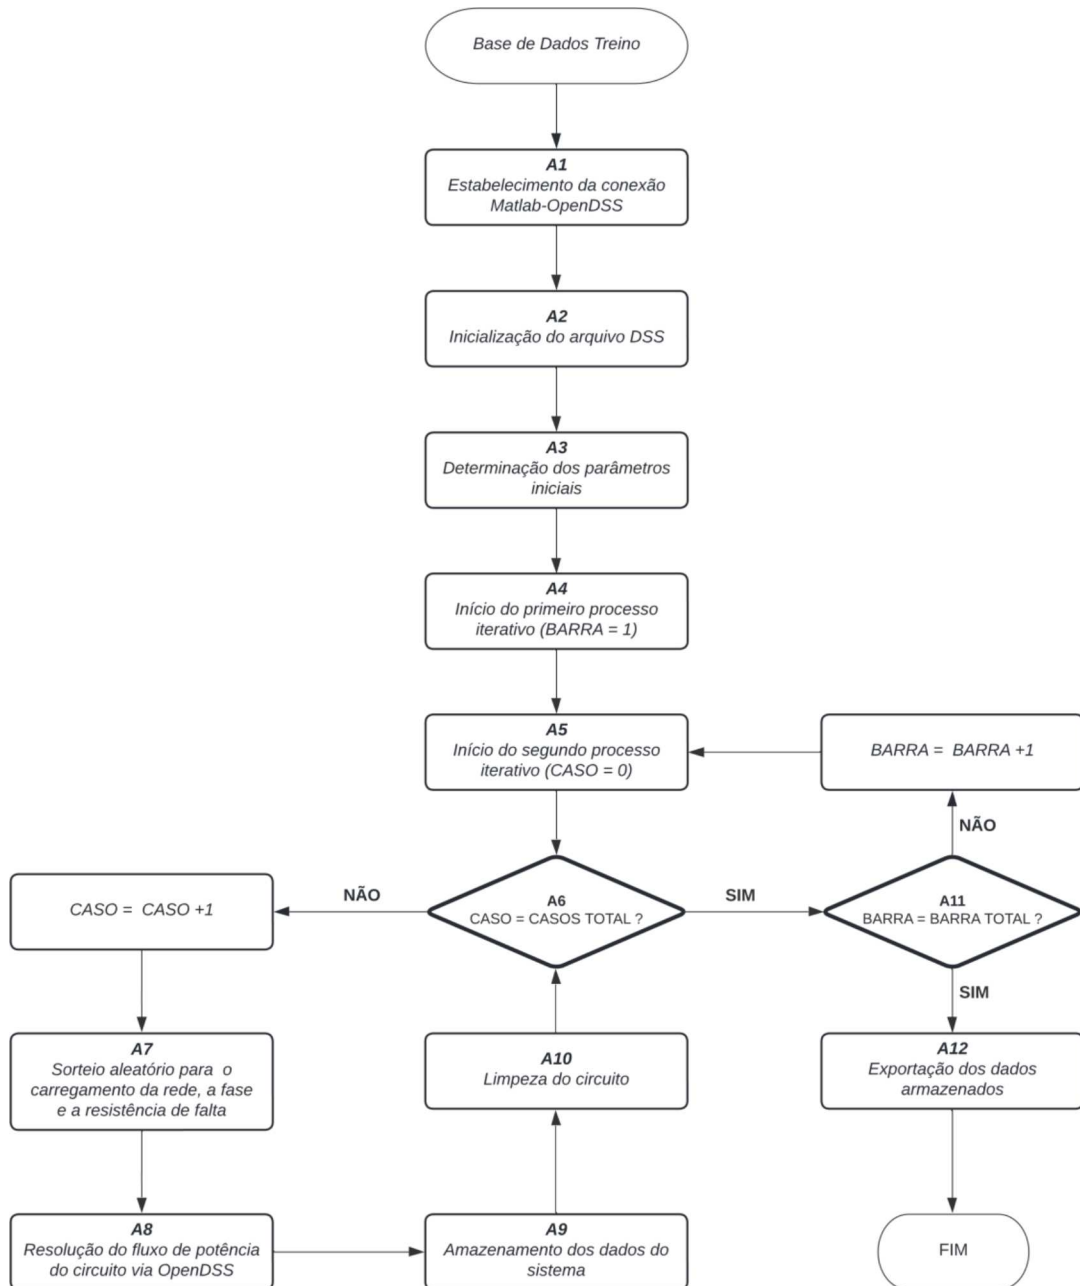


Fonte: Elaborado pelo autor (2024).

### 2.3.1 Etapa de construção da base de dados de treino

Nesta etapa foi desenvolvida uma base de dados responsável pelo treinamento das RNAs, sendo composta por simulações diversificadas que possuem o objetivo de representar diferentes condições operacionais da rede de distribuição. O funcionamento dessa etapa é ilustrado através do fluxograma da Figura 5.

Figura 5 – Fluxograma da etapa de construção da base de dados de treinamento



Fonte: Elaborado pelo autor (2024).

**A1** - Estabelecimento da conexão Matlab-OpenDSS: neste passo, há a inicialização do programa em Matlab® que permite executar o OpenDSS® através das linhas de comando (isso é realizado por meio de códigos que possibilitam a comunicação entre ambos softwares, permitindo que as instruções do *software* de simulação de sistemas de distribuição sejam utilizadas no *script* do Matlab® durante todo o processo).

**A2** - Inicialização do arquivo DSS: neste passo, o arquivo de extensão “.dss”, que representa a modelagem computacional do sistema de distribuição que será simulado, é lido pelo Matlab® para executá-lo através da comunicação realizada no passo anterior.

**A3** - Determinação dos parâmetros iniciais: neste passo determina-se os valores de alguns parâmetros que serão essenciais para a construção da base de dados, sendo eles:

- a) Número de casos que serão simulados de condições de falta em cada barra (define-se a variável CASOS TOTAL);
- b) Limite de variação da carga;
- c) Valores mínimos e máximos da resistência de falta;
- d) Número de barras em que serão simuladas as faltas (define-se a variável BARRAS TOTAL).

A variável CASOS TOTAL é definida pelo usuário com um valor que seja suficiente para que a base de dados de treino contenha uma quantidade ampla de casos simulados, permitindo que seja construído, na etapa C, a partir de uma única base de dados, um conjunto de dados de treino exclusivo para cada uma das RNAs que serão desenvolvidas, melhorando assim a eficiência das mesmas. Neste trabalho, o valor adotado para a variável CASOS TOTAL foi de 1500.

Os valores limites de variação de carga e de resistência de falta são determinados de acordo com o sistema de distribuição em que o método será testado, em virtude das especificidades de cada um. Assim, no capítulo de resultados serão apresentados os valores utilizados neste trabalho para essas variáveis.

Além disso, é importante salientar que os elementos que compõem a variável BARRAS TOTAL são exatamente todos os barramentos do sistema acrescidos de mais um barramento de valor zero, o qual irá representar a simulação dos casos que não possuem defeito aplicado, sendo exclusivamente um recurso de programação utilizado para facilitar a simulação de casos operativos que possuem apenas variações de carregamento, mas não têm falta.

**A4** - Início do primeiro processo iterativo: neste passo, o processo se torna iterativo, percorrendo todas as barras do sistema. A variável BARRA, com valor inicial ‘1’, se refere a cada uma das barras que terão seus casos de falta simulados, sendo incrementada em cada ciclo iterativo para que se tenha a simulação para todas as barras. Isso se faz necessário para simular uma quantidade igual de casos de falta aplicados em todos os barramentos, inclusive o mesmo

número de casos sem falta (representados na programação pelo barramento de valor zero), garantindo-se uma base de dados generalista que permita análises de sensibilidade em relação à quantidade de casos simulados a serem fornecidos às RNAs durante seus treinamentos.

**A5** - Início do segundo processo iterativo: neste passo, o processo iterativo é responsável por simular um número de casos pré-determinado para cada barra. Inicialmente a variável CASO tem seu valor '0' e é incrementada a cada ciclo iterativo até atingir o valor máximo CASOS TOTAL.

**A6** - CASO = CASOS TOTAL ?: neste passo, é feita a verificação se o número de casos definido para cada barra já foi simulado. A cada iteração, a variável CASO é comparada à variável CASOS TOTAL. Dessa forma, no momento que as duas variáveis se igualarem, o processo avançará para o passo A11. Caso contrário, a variável CASO será incrementada em uma unidade e o processo iterativo prossegue.

**A7** - Sorteio aleatório para o carregamento da rede, a fase e a resistência de falta: neste passo, é feito o sorteio, de forma aleatória, para determinar o quanto a carga da rede irá variar neste caso em relação ao caso base, a fase em que será aplicada a falta neste caso e o valor da resistência de falta a ser considerado neste caso, respeitando os respectivos limites para estas variáveis (que podem ser definidos pelo usuário da ferramenta). Esse procedimento é fundamental para tornar as simulações mais representativas em relação ao sistema de distribuição real, o qual está sujeito a variações em suas cargas e apresenta faltas com resistências diversas em diferentes fases, sendo estes fatores considerados como complicadores no que se refere ao processo de localização das faltas.

Neste passo, é relevante destacar que o sorteio aleatório da fase em que será aplicada a falta adequa-se aos barramentos em cada caso, e desse modo, torna-se impossível realizar a simulação de uma falta em uma fase que não exista em uma barra monofásica ou bifásica.

Ademais, a aleatoriedade dos sorteios é definida pela função "*randi*" do Matlab®, a qual realiza o sorteio de números inteiros pseudoaleatórios uniformemente distribuídos em um intervalo pré-determinado.

**A8** - Resolução do fluxo de potência do circuito via OpenDSS®: neste passo, o sistema a ser simulado é o caso original com as modificações definidas para o caso específico, e este caso é resolvido por meio das linhas de código do Matlab® através da comunicação com o OpenDSS®



**A9** – Armazenamento dos dados do sistema: neste passo, os dados relativos à simulação de cada caso simulado são armazenados a fim de que, ao término de todos os processos iterativos, seja formada a base de dados de treinamento com todas as simulações.

**A10** – Limpeza do circuito: neste passo, ocorre apenas um artifício de programação, onde os elementos acrescentados ao sistema original para representar a falta aplicada no caso são eliminados via OpenDSS® para que na iteração seguinte não ocorra sobreposição de faltas aplicadas.

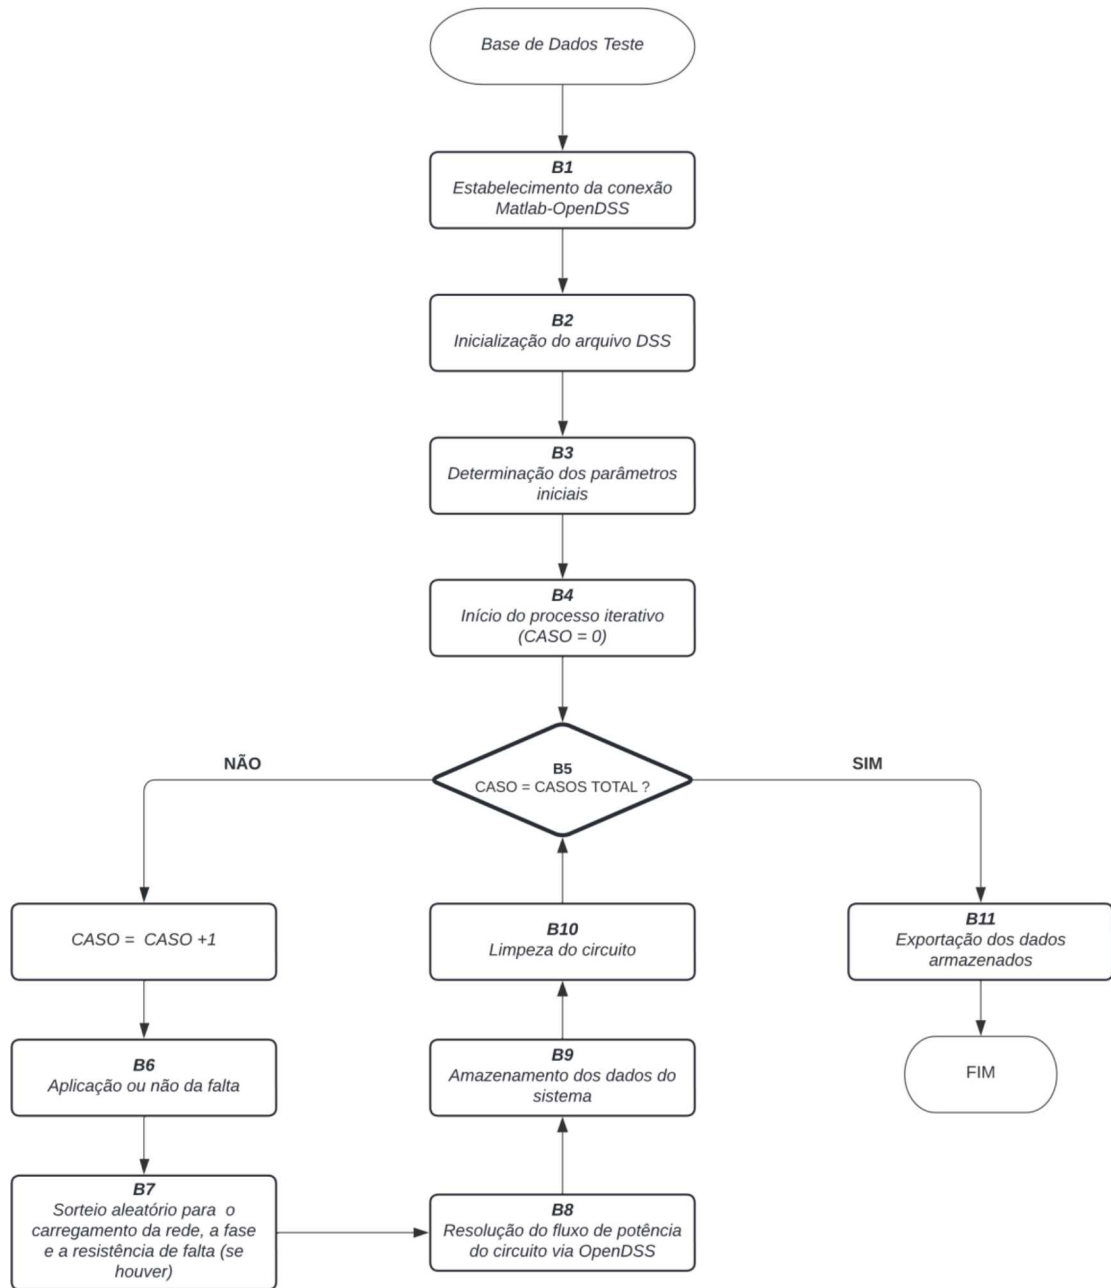
**A11** – BARRA = BARRA TOTAL?: neste passo, é feita a verificação se todas as barras tiveram seus casos simulados. A cada iteração, a variável BARRA é comparada à variável BARRAS TOTAL. Dessa forma, no momento que as duas variáveis se igualarem, o processo avançará para o passo A12. Caso contrário, a variável BARRA será incrementada em uma unidade e o processo iterativo prossegue.

**A12** – Exportação dos dados armazenados: neste passo, os dados armazenados são exportados em formato de planilhas com extensão “.xlsx”, tipo de arquivo que pode ser lido pelo *software* Excel®. Esta medida é importante para que a base de dados de treinamento esteja salva no armazenamento do computador e seja acessível para o processo de localização de faltas.

### **2.3.2 Etapa de construção da base de dados de teste**

Nesta etapa será desenvolvida uma base de dados responsável pelo teste das RNAs, sendo composta por simulações diversificadas, porém, estas devem possuir valores diferentes da base de dados de treinamento, já que o intuito é avaliar a capacidade das RNAs em localizar diferentes faltas. O funcionamento dessa etapa é ilustrado através do fluxograma da Figura 6.

Figura 6 – Fluxograma da etapa de construção da base de dados de teste



Fonte: Elaborado pelo autor (2024).

Ao analisar o fluxograma, pode-se observar que este se assemelha ao fluxograma da etapa anterior. A principal diferença está na ausência do processo iterativo que realiza a simulação exaustiva de casos de falta em todos os barramentos do sistema, algo que se fez necessário apenas para se construir a base de dados de treino. Dessa maneira, serão explicados de forma mais detalhada apenas os passos que se diferem da etapa de treinamento.

**B3** - Determinação dos parâmetros iniciais: neste passo, os valores de alguns parâmetros que serão essenciais para a construção da base de dados são determinados, sendo eles:

- a) Número de casos que serão simulados (define-se a variável CASOS TOTAL);
- b) Limite de variação da carga;
- c) Valores mínimos e máximos da resistência de falta;
- d) Porcentagem da quantidade de faltas que serão aplicadas.

O valor da variável CASOS TOTAL é definido pelo mesmo conceito da etapa de base de dados de treino, assim o valor adotado será de 3000, e a diferença nesse passo se dá pelo item 'd'. A porcentagem da quantidade de faltas que serão aplicadas é um importante parâmetro a ser determinado para a construção da base de dados de teste, já que, dentre todos os casos simulados para testar as RNAs, uma parcela significativa deve ser de casos operacionais que não contenham faltas aplicadas, a fim de que se possa avaliar a eficiência do método em detectar a ocorrência, ou não, de um defeito. Assim, neste trabalho será adotado um valor de 85% para a porcentagem de casos simulados com falta para o teste das RNAs, e dessa maneira, 450 casos testados não terão falta. Essa divisão de 85/15 permite avaliar se as RNAs foram calibradas para serem especialistas em detectar falta, mas também possibilita observar se as mesmas não se tornaram 'cegas' para os casos em que não ocorreram faltas.

**B6** – Aplicação ou não da falta: neste passo, primeiramente é feito um sorteio para determinar se o caso a ser simulado terá aplicação, ou não, de falta, respeitando-se a porcentagem da quantidade de faltas em relação ao número total de casos definida no passo B3. Se for determinado que ocorra aplicação da falta, um novo sorteio é feito para que seja definida a barra defeituosa, caso contrário, é escolhido o barramento de valor zero para representar os casos operativos que não possuem falta. Assim como na etapa anterior, a aleatoriedade dos sorteios é definida pela função "*randi*" do Matlab®.

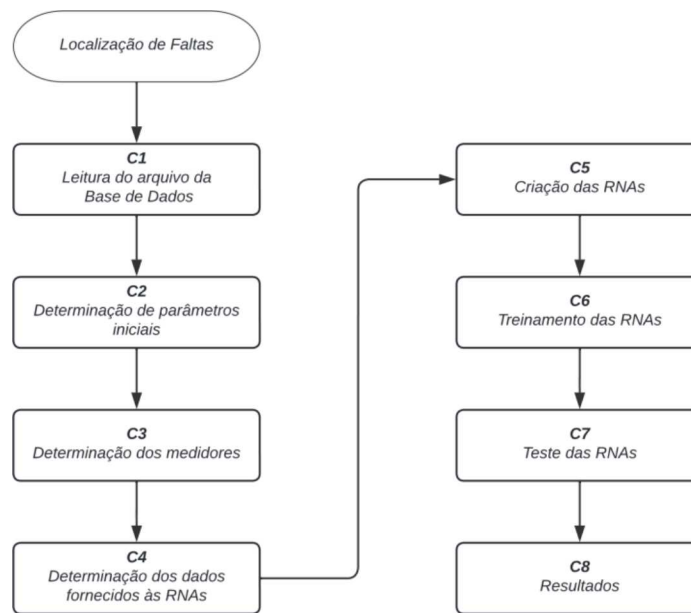
### 2.3.3 Etapa de desenvolvimento de RNAs para localização de faltas

Esta etapa corresponde especificamente à ferramenta com o método proposto para a detecção e localização de faltas em sistemas de distribuição. Ela se baseia na criação de um conjunto de RNAs que sejam capazes de, ao receberem as informações de grandezas elétricas

de medidores, indicar se houve falta, e se for o caso o barramento e a fase em que a falta ocorreu. Para cumprir esse objetivo, o conjunto de RNAs proposto é composto por uma RNA dedicada a cada barramento do sistema de distribuição e por uma RNA exclusiva para cada fase da rede elétrica.

Para um melhor entendimento dessa etapa, o processo para o desenvolvimento da ferramenta para localização das faltas é explicado através do fluxograma da Figura 7.

Figura 7 – Fluxograma da etapa de desenvolvimento de RNAs para localização de faltas



Fonte: Elaborado pelo autor (2024).

**C1** - Leitura do arquivo da Base de Dados: neste passo, a leitura das planilhas relativas às bases de dados já montadas (treino e teste) é feita a partir de um novo *script* no Matlab®. De posse das informações contidas para cada caso simulado em cada uma das barras do sistema, é possível determinar pelo usuário quais dados deverão ser utilizados no processo de treinamento e teste das RNAs. Dentre as informações presentes nessas bases de dados têm-se os fasores das correntes (módulo e ângulo) em todas as linhas para cada caso, que serão associados à localização de cada falta (ou situação sem falta), aos valores de carregamento do sistema, à fase e à resistência da falta para cada caso simulado.

**C2** - Determinação dos parâmetros iniciais: neste passo, os valores de alguns parâmetros que serão importantes para a formulação dos dados utilizados como *input* e *target* das RNAs são especificados, sendo eles:

- a) Quantidade de barras que o sistema de distribuição analisado possui;
- b) Número de casos de falta que foram simulados para cada barra na base de dados de treino;
- c) Quantidade de neurônios que irão compor a camada oculta das RNAs;
- d) Quantidade dos tipos de casos que irão compor o conjunto de dados de treinamento exclusivo de cada RNA responsável pela indicação da barra com falta;
- e) Quantidade de casos que irão compor o conjunto de dados de treinamento exclusivo de cada RNA responsável pela indicação da fase com falta.

A respeito do item 'c', neste trabalho será adotado um conjunto de valores com o objetivo de analisar uma sensibilidade do método em relação a quantidade de neurônios na camada oculta. Assim, os valores definidos foram de 1, 5, 10, 20, 30 e 50 neurônios na camada oculta.

Em relação às RNAs destinadas a localizar a barra defeituosa, tem-se que cada RNA estará associada a um, e somente um, barramento da rede de distribuição, e sua responsabilidade será detectar, exclusivamente, faltas em seu barramento de análise. Logo, a determinação dos parâmetros indicados nos itens 'd' influencia no processo de treinamento dessas RNAs em virtude da composição do conjunto exclusivo de dados considerado como *input* para cada RNA. O *input* das RNAs será formado por medições de correntes de três tipos de casos simulados: casos relativos às faltas que ocorrem nas barras referentes a própria RNA; casos de faltas em outros barramentos; casos sem faltas aplicadas.

Essa divisão entre os três tipos de casos irá contribuir para que as RNAs tenham a capacidade de indicar, de maneira correta, os casos que ocorrem e os que não ocorrem falta em sua barra de interesse. É importante ressaltar que a proporção entre a quantidade de casos de falta para a barra específica daquela RNA, a quantidade de casos de falta para outras barras e a quantidade de casos sem falta é determinada pelo usuário de modo que seja suficiente a representação dos três cenários de casos no processo de treinamento das RNAs. Além disso, a quantidade adotada para cada um dos tipos de casos é definida de acordo com o sistema de distribuição em que o método será testado, em virtude das especificidades de cada um. Assim, no capítulo de resultados serão apresentados os valores utilizados neste trabalho, de acordo com os casos testados, para essas variáveis.

Já em relação ao item ‘e’, tem-se a determinação da quantidade de casos que serão utilizados para treinar as RNAs responsáveis por detectar faltas em cada fase do sistema de distribuição. Como estas RNAs devem indicar a fase com defeito para os casos que o método detectar uma falta, apenas casos de falta serão utilizados para o treinamento. Como os valores adotados para a quantidade de casos que irão treinar as RNAs específicas das fases dependem do sistema de distribuição que será testado, no capítulo de resultados serão apresentados os valores utilizados neste trabalho para essas variáveis.

**C3** – Determinação dos medidores: neste passo, os medidores são escolhidos pelo usuário que irá determinar a quantidade, a localização de cada um, e o tipo de medida que será utilizada (não fasorial, fasorial ou sequência). Caso seja escolhida a medição não fasorial, basta utilizar apenas os módulos das correntes da base de dados, e caso seja a de sequência, é preciso calcular as componentes simétricas a partir das medições fasoriais.

**C4** – Determinação dos dados fornecidos às RNAs: neste passo, a formação dos conjuntos de dados de *input* e *target* é realizada, tanto para os dados de treino quanto para os de teste das RNAs. Assim, para a composição do *input* de cada RNA utiliza-se as medições de corrente de cada medidor escolhido no passo anterior, considerando apenas as medições relativas aos casos simulados determinados no passo C2 (d) e C2 (e). A respeito do *target* das RNAs, utiliza-se como informação a ocorrência ou não da falta em relação a barra ou a fase de interesse de cada RNA.

Além disso, é essencial destacar que esse passo ainda inclui a normalização dos dados fornecidos às RNAs, *input* e *target*, visto que essas ferramentas computacionais possuem um melhor desempenho com valores compreendidos no intervalo de 0 a 1. Portanto, para os dados de *input*, a normalização transforma o menor valor referente ao módulo das correntes em 0 e o maior valor em 1, e o restante assume valores entre 0 e 1. O mesmo procedimento deve ser aplicado para os ângulos das correntes caso sejam utilizadas as medições fasoriais ou de sequência. Já para os dados de *target* basta considerar como 1 os casos em que há falta aplicada na barra ou fase de interesse da respectiva RNA ou como 0 os casos em que não ocorre falta.

A normalização dos valores dos módulos e ângulos das correntes é realizado através da Equação (1).

$$z_n = \frac{x_n - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Onde:

- $z_n$  : n-ésimo valor normalizado do conjunto de dados
- $x_n$  : n-ésimo valor do conjunto de dados
- $\min(x)$  : menor valor do conjunto de dados
- $\max(x)$  : maior valor do conjunto de dados

**C5** – Criação das RNAs: neste passo, as redes neurais são criadas, a partir da *toolbox* disponibilizada pelo Matlab®, para cada barra e para cada fase do sistema de distribuição. Serão definidos os seguintes parâmetros internos:

- a) o número de camadas ocultas e seus respectivos neurônios;
- b) algoritmo de treinamento;
- c) função de ativação;
- d) critérios de parada.

Durante o desenvolvimento das RNAs, foram observadas, através de alguns testes realizados previamente, quais características seriam adequadas ao método proposto, considerando principalmente a qualidade dos resultados e o tempo computacional. Assim, neste trabalho os parâmetros internos das RNAs serão adotados conforme o descrito na Tabela 2.

Tabela 2 – Parâmetros internos das RNAs desenvolvidas


<b>Parâmetro</b>	<b>Descrição</b>
Tipo de rede	<i>Feedforward backpropagation</i>
Neurônios camada oculta	[1 5 10 20 30 50]
Camadas ocultas	1
Função de ativação	Tangente sigmoide
Método de Treinamento	<i>Levenberg-Marquardt</i>

Fonte: Elaborado pelo autor (2024).

Em relação aos critérios de parada, foram utilizados os valores padrões da toolbox do Matlab®.

Além da escolha dessas características, a arquitetura das RNAs criadas seguirá o padrão apresentado na Figura 8.

Figura 8 – Arquitetura padrão das RNAs criadas



Fonte: Elaborado pelo autor (2024).

**C6** – Treinamento das RNAs: neste passo, as redes neurais são treinadas a partir do conjunto de dados de *input* e *target* destinado ao treino. Através desse treinamento, os parâmetros internos das RNAs, como peso e bias, são determinados. Ressalta-se que cada RNA possui um conjunto de dados de treino específico, já que existe uma RNA para cada barra e cada fase.

**C7** – Teste das RNAs: neste passo, todas as redes neurais que foram treinadas no passo anterior são testadas a partir de um único conjunto de dados de *input* destinado ao teste. A partir desse teste, para cada caso de falta presente no conjunto de dados de input, será possível aferir simultaneamente a capacidade de todas as RNAs em detectar falta em seus respectivos barramentos.

**C8** – Resultados: nesse passo, os resultados relacionados ao teste das RNAs, realizado no passo anterior, são fornecidos. Para avaliação da saída de todas as RNAs, os resultados poderão ser classificados da seguinte forma:

- a) Verdadeiros Positivos ( $V_P$ ): resposta que indica que há falta e de fato existe;
- b) Verdadeiros Negativos ( $V_N$ ): resposta que indica que não há falta e de fato não existe;
- c) Falsos Positivos ( $F_P$ ): resposta que indica que há falta, mas de fato não existe;
- d) Falsos Negativos ( $F_N$ ): resposta que indica que não há falta, mas de fato existe.



E ainda, pelo fato de existir um conjunto de RNAs dedicado a cada barra, e outro conjunto dedicado a cada fase, este trabalho possui diferentes maneiras de mensurar a eficiência das respostas obtidas a partir das classificações das saídas.

Primeiramente, como existe apenas uma falta aplicada para cada caso simulado, somente as RNAs associadas a barra e a fase em que ocorreu o defeito terão que detectar a falta, ao passo que o restante das RNAs terá que fornecer uma saída de valor nulo ou próximo de zero. Dessa forma, sabendo-se quais RNAs exibiram como saída um valor mais próximo a 1, é possível localizar a barra e a fase que ocorreu o defeito.

A respeito da indicação da barra defeituosa, em alguns momentos o conjunto de RNAs destinados a essa função poderá apresentar para um mesmo caso simulado algumas saídas com valores nulos, outras com valores intermediários e outras com valores próximos a 1, e assim pode ocorrer de a RNA com o maior valor de saída não estar relacionada com a barra que a falta foi aplicada. Dessa forma, para essa situação, os resultados serão exibidos da seguinte forma:

- a) Para um caso de falta, o conjunto de RNAs deverá indicar um grupo formado pelas prováveis barras em que a falta possa ter ocorrido, e na hipótese de um caso sem falta aplicada, o grupo das barras prováveis se tornará vazio. Assim, será avaliada a eficiência das RNAs quanto à detecção de falta caso seja formado o grupo com barras que possam estar com defeito e aos acertos em relação à presença da barra correta dentro desse grupo;
- b) O grupo de barras prováveis também será utilizado para se avaliar a eficiência das RNAs quanto à indicação da barra classificada como a de maior probabilidade de estar com falta.

Assim, as eficiências do item 'a' podem ser calculadas por meio das equações (2) e (3), as quais representam a eficiência de detecção da falta e localização da falta, respectivamente:

$$E_{falta}(\%) = \frac{V_{P_{falta}} + V_{N_{falta}}}{Casos_{teste}} \times 100 \quad (2)$$

$$E_{barra}(\%) = \frac{V_{P_{barra}}}{V_{P_{falta}}} \times 100 \quad (3)$$

Nessas equações a variável  $V_{P_{falta}}$  representa a quantidade de casos que as faltas foram detectadas corretamente, ou seja, casos em que houve a formação do grupo com as prováveis barras em que a falta possa ter ocorrido para ocasiões que verdadeiramente aconteceu uma falta. A variável  $V_{N_{falta}}$  representa a quantidade de casos que, de maneira correta, não houve a detecção de falta, ou seja, casos que o grupo de barras prováveis permaneceu vazio para ocasiões que de fato não ocorreu uma falta. Já  $Casos_{teste}$  representa a quantidade de casos simulados na base de dados de teste. Por fim,  $V_{P_{barra}}$  representa a quantidade de casos em que o barramento correto foi indicado dentro grupo de barras prováveis, ou seja, representa a parcela de  $V_{P_{falta}}$  em que houve a correta localização da barra com falta.

Por outro lado, a qualidade dos resultados relativos ao item ‘b’ será observada a partir da análise da posição relativa de cada barramento indicado como o mais provável de estar com defeito em comparação com a barra em que a falta foi aplicada em cada caso simulado. Desse modo, serão definidas sete categorias para essa posição relativa, sendo elas: posição correta, indicando exatamente a barra com defeito; primeira, segunda ou terceira barra com posição a montante da barra com defeito; primeira, segunda ou terceira barra com posição a jusante da barra com defeito.

Em relação localização da fase defeituosa, as RNAs responsáveis por essa função irão considerar apenas os casos indicados com falta pelo conjunto de RNAs de barras, já que seria uma inconsistência detectar uma fase com falta em um caso no qual não houve detecção de defeito. Logo, a eficiência dos resultados pode ser calculada pela Equação (4).

$$E_{fases}(\%) = \frac{V_{P_{fase A}} + V_{P_{fase B}} + V_{P_{fase C}}}{V_{P_{falta}}} \times 100 \quad (4)$$

Onde  $V_{P_{fase A}}$ ,  $V_{P_{fase B}}$  e  $V_{P_{fase C}}$  representa a quantidade de casos verdadeiros positivos que as RNAs indicaram para as fases A, B e C, respectivamente.

No próximo capítulo será apresentada a metodologia utilizada para melhorar a alocação de medidores para otimizar a localização de faltas utilizando esta metodologia desenvolvida.

### 3 ALOCAÇÃO ÓTIMA DE MEDIDORES

Analisando o método desenvolvido para localização de faltas em sistemas de distribuição, é possível observar que diferentes posições dos medidores fornecerão às RNAs dados de entrada com diferentes valores de corrente, dependendo de suas posições de medição. Isso faz com que o processo de treinamento das RNAs seja influenciado pelos locais nos quais os medidores estejam alocados, impactando diretamente na eficiência das redes em sua posterior aplicação na localização das faltas.

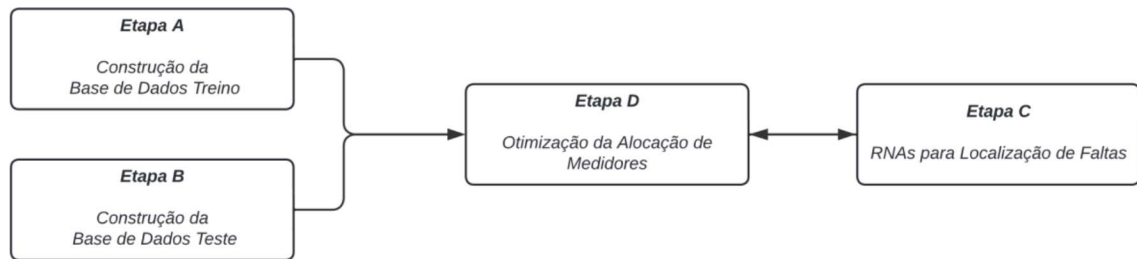
Além disso, por questões práticas, de economia da concessionária, é importante utilizar a menor quantidade possível de medidores que leve a resultados adequados. Assim, é interessante empregar um método que proporcione uma alocação inteligente e bem distribuída ao longo do sistema, do número de medidores que se tem disponíveis, a fim de se obter melhores resultados.

Um método que garantiria a otimalidade da alocação de medidores é a enumeração exaustiva, que permite a verificação de todas as possíveis maneiras de se alocar os medidores ao longo do sistema de distribuição. Entretanto, o que pode ocorrer na aplicação deste método é uma explosão combinatória, sendo que seu processamento iria requerer um elevado desempenho e tempo computacional, devido ao tamanho da rede elétrica. Por essa razão, um método meta-heurístico se apresenta como um recurso viável durante a busca por uma solução factível e de boa qualidade para esta situação, já que é um tipo de método empregado para problemas de otimização combinatória pelo fato de utilizar um subconjunto de um grande conjunto de soluções para fornecer resultados satisfatórios e com menor tempo computacional.

Logo, para potencializar a ferramenta proposta, com o foco em uma maior eficiência na utilização dos medidores, o uso de algoritmo genético é proposto como solução para alocá-los de maneira ótima neste trabalho, obtendo-se resultados com melhores eficiências para o processo de localização das faltas quando comparados aos resultados do método desenvolvido que não possui otimização da alocação de medidores.

Assim, com a utilização de algoritmo genético para otimizar a alocação dos medidores, é necessário adicionar mais uma etapa à metodologia proposta. O esquemático do novo fluxograma da metodologia desenvolvida neste trabalho é apresentado na Figura 9.

Figura 9 – Novo fluxograma básico do desenvolvimento da metodologia

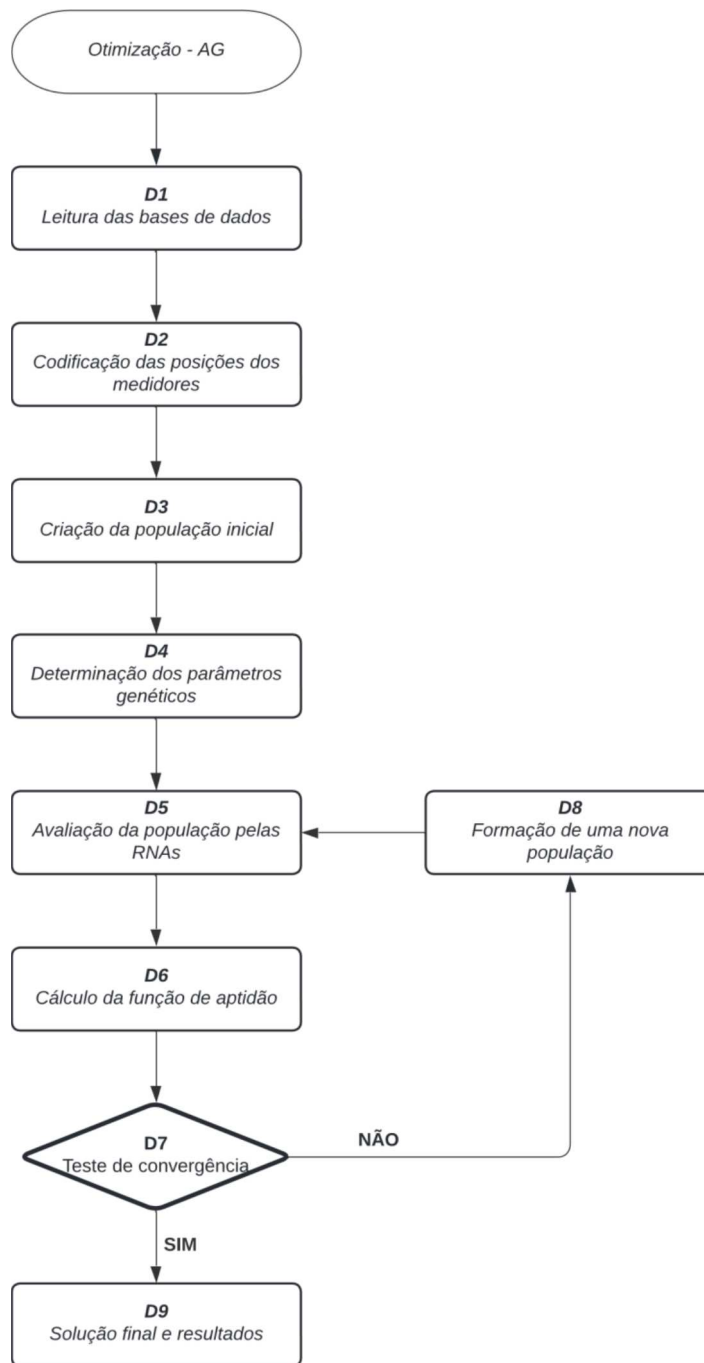


Fonte: Elaborado pelo autor (2024).

Nesta nova etapa do desenvolvimento da metodologia, um processo iterativo conduzido pelo algoritmo genético irá realizar a busca por diversas soluções factíveis de alocação de medidores e determinará uma que forneça um resultado de melhor qualidade dentre todas as gerações reproduzidas, de acordo com a função de aptidão (*fitness*) estabelecida.

Para o entendimento da aplicação do algoritmo genético para a otimização da alocação de medidores para localização de faltas, um fluxograma é mostrado na Figura 10.

Figura 10 – Fluxograma da etapa de otimização da localização de medidores por AG

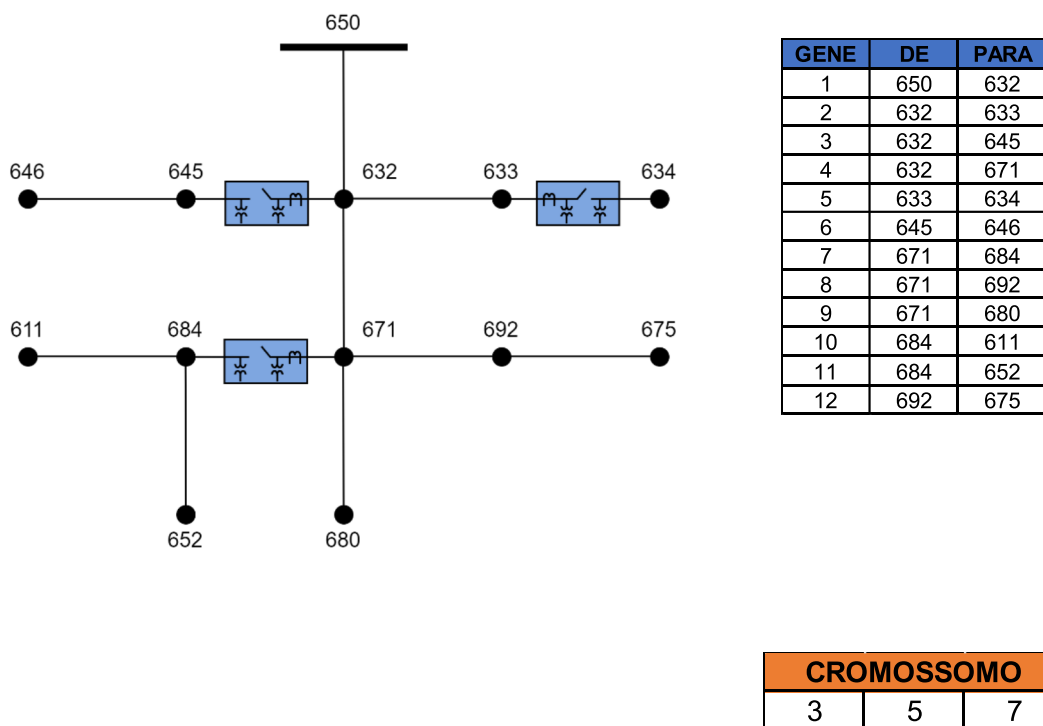


Fonte: Elaborado pelo autor (2024).

**D1** - Leitura do arquivo da Base de Dados: neste passo, a leitura das planilhas relativas às bases de dados (treino e teste) é feita a partir de um novo *script* no Matlab®.

**D2** – Codificação das posições dos medidores: neste passo, a posição que cada medidor poderá assumir será codificada para ser representada pelos genes de cada cromossomo (indivíduo) que compõe uma população. O tamanho de um cromossomo será definido pela quantidade de medidores que será utilizada, sendo cada gene relativo a um medidor. Os valores que os genes poderão assumir estarão correlacionados com as linhas (barras DE e PARA) do sistema de distribuição nas quais os medidores poderão ser instalados. Dessa maneira, um indivíduo que representa um possível candidato a solução da otimização composto por três medidores, por exemplo, será um cromossomo de três genes, e a linha em que cada medidor será alocado será definida pelo valor de seu respectivo gene. A Figura 11 ilustra um exemplo de codificação de um indivíduo.

Figura 11 – Exemplo de codificação de um indivíduo



Fonte: Elaborado pelo autor (2024).

**D3** – Criação da população inicial: neste passo, utiliza-se a definição da quantidade de medidores que serão utilizados, decide-se o tamanho da população e, em seguida, são definidos os valores dos genes de cada cromossomo, sorteados de maneira aleatória.

Neste trabalho, o tamanho da população foi definido para 20 indivíduos e o sorteio dos genes de cada indivíduo foi realizado através da função “*randi*” do Matlab®. É importante

ressaltar que valores maiores para o tamanho da população não contribuíram com ganhos significativos para os resultados, e foram implementadas restrições no sorteio dos genes para que apenas linhas trifásicas fossem sorteadas, evitando assim que os medidores fossem alocados em linhas bifásicas e monofásicas.

**D4** – Determinação dos parâmetros genéticos: neste passo, os parâmetros genéticos que irão influenciar nos operadores evolutivos e nos critérios de parada do AG são determinados pelo usuário. Tais parâmetros são:

- a) Limites inferiores e superiores dos valores dos genes;
- b) Índice das variáveis inteiras;
- c) Número de variáveis;
- d) Número máximo de gerações (critério de parada);
- e) Estagnação da população (critério de parada);
- f) Seleção;
- g) Cruzamento;
- h) Elitismo;
- i) Mutação.

Os limites inferiores e superiores dos valores são definidos pelo valor mínimo e o valor máximo que os genes podem assumir. O índice de variáveis inteiras é um parâmetro que é importante ser definido para que nenhum gene assumira um valor que não seja inteiro durante o processo de otimização. Já o número de variáveis é definido pela quantidade de medidores que serão alocados, ou seja, o tamanho da sequência genética do indivíduo.

Ao longo do desenvolvimento do algoritmo genético, foram conduzidos testes preliminares que permitiram identificar as especificações apropriadas dos demais parâmetros, avaliando-se principalmente a qualidade dos resultados e o tempo computacional. Portanto, neste trabalho, os parâmetros genéticos utilizados foram definidos de acordo com o apresentado na Tabela 3.

Tabela 3 – Parâmetros genéticos adotados

Parâmetros	Descrição
Número Máximo de gerações	10
Estagnação da população	5
Seleção	Roleta
Cruzamento	Ponto Duplo
Elitismo	2
Mutação	5%

Fonte: Elaborado pelo autor (2024).

**D5** – Avaliação da população pelas RNAs: neste passo, a população é avaliada por meio das RNAs responsáveis pela etapa de localização de faltas. Assim, a Etapa C do fluxograma apresentado na Figura 9 se apresenta como um passo da Etapa D, já que, a cada iteração do processo de otimização, as RNAs são treinadas e testadas para cada um dos indivíduos (medidores alocados) da população a ser avaliada, além de fornecer os valores para o cálculo da função de aptidão. É importante ressaltar que, durante esse passo, os indivíduos devem ter seus genes decodificados para se obter as localizações exatas dos medidores a fim de que sejam fornecidos às RNAs seus respectivos valores de correntes presentes na base de dados.

**D6** – Cálculo da função aptidão: neste passo, através dos resultados de saída das RNAs responsáveis pela localização das faltas, calcula-se para cada indivíduo a sua aptidão de acordo com uma função *fitness*. Neste trabalho, essa função será definida pela maximização da eficiência das RNAs quanto à indicação da barra classificada como a de maior probabilidade de estar com falta, conforme apresentado na Equação (5).

$$FOB = \max \left( \frac{V_{P\ 1^{a}Barra}}{Casos_{Falta}} \right) \quad (5)$$

Onde  $V_{P\ 1^{a}Barra}$  representa a quantidade de casos em que as RNAs indicaram de forma correta a barra classificada como a de maior probabilidade de estar com falta e  $Casos_{Falta}$  representa a quantidade de casos simulados na base de dados de teste que possuem falta.



**D7** – Teste de convergência: neste passo, a convergência do método é avaliada pelos critérios de parada definidos no passo D4, número de gerações ou estagnação da população. Ao atingir sua convergência, o método de otimização avança para o passo D9, caso contrário, o processo iterativo do AG continua, prosseguido para o passo D8.

**D8** – Formação de uma nova população: neste passo, pelo fato de ainda não haver convergência do processo de otimização, a população é novamente codificada para que sejam empregados os devidos operadores evolutivos (seleção, reprodução, mutação) formando-se uma nova população de indivíduos para a próxima geração.

**D9** – Solução final e resultados: neste passo, o algoritmo genético apresentará como solução final o conjunto de medidores que terá a melhor aptidão entre todas as gerações desenvolvidas, promovendo uma otimização do método inicialmente proposto para localização de faltas em sistemas de distribuição. Assim, de posse de uma solução de boa qualidade, realiza-se novamente o teste das RNAs para que sejam exibidos os resultados do indivíduo determinado pelo AG e possam ser realizadas as devidas análises, principalmente a comparação com o método não otimizado.

No próximo capítulo serão apresentados resultados alcançados utilizando a ferramenta proposta, que combina a técnica de algoritmos genéticos para alocação otimizada de medidores com as redes neurais artificiais para a tarefa de localização de faltas.

## 4 RESULTADOS

### 4.1 INTRODUÇÃO

Neste trabalho, a análise do problema de detecção e localização de faltas de alta impedância é feita em três sistemas teste: IEEE 13 barras, IEEE 34 barras e IEEE 123 barras. Tais sistemas de distribuição são caracterizados por um carregamento desbalanceado e pela presença de reguladores de tensão, transformadores e capacitores, os quais são elementos que podem interferir no comportamento operativo da rede de distribuição, causando dificuldades para as RNAs detectarem e localizarem as faltas.


Para cada um dos sistemas teste foram realizadas simulações de diferentes cenários com a finalidade de verificar a eficácia do método proposto em relação a utilização de diferentes tipos de medidores, e considerando diferentes níveis de carregamento e resistências de falta.

Os mesmos cenários foram simulados sem a otimização da alocação de medidores, utilizando apenas as redes neurais, e também utilizando o algoritmo genético fazendo a otimização da alocação de medidores, com o intuito de verificar a se a otimização do posicionamento dos medidores implica em melhoria nos resultados de localização de faltas.

### 4.2 IEEE 13 BARRAS

Este sistema opera a uma tensão nominal de 4,16 kV e possui um circuito pequeno, sendo principalmente utilizado para teste de recursos de metodologias de análise de distribuição. Possui um único regulador de tensão, linhas aéreas e subterrâneas, capacitores em derivação, um transformador (4,16 kV – 480 V) e carregamento desequilibrado (IEEE, [s.d.]). O diagrama unifilar desse sistema é ilustrado na Figura 12.

Figura 12 – IEEE 13 barras



Fonte: IEEE ([s.d.]).

Para realizar a detecção e localização das faltas neste sistema foi utilizado um conjunto de dois medidores. Dessa maneira, em virtude de serem consideradas apenas as linhas trifásicas para alocação de medidores, o sistema IEEE 13 barras possui somente sete opções disponíveis para o segundo medidor, já que o primeiro será instalado na saída da subestação.

Devido a essas circunstâncias, pode-se inferir que em um sistema de distribuição com poucas opções para alocação de medidores, o uso do algoritmo genético é dispensável, pois é possível realizar a avaliação de todos os indivíduos com um tempo computacional baixo através da busca exaustiva. Assim, especificamente para esse sistema teste, optou-se por realizar as simulações sem o uso do algoritmo genético.

Em relação à quantidade dos tipos de casos que irão compor o conjunto de dados de treinamento exclusivo de cada RNA responsável pela indicação da barra com falta, foram adotados os seguintes valores: 1500 para casos relativos às faltas que ocorrem nas barras referentes a própria RNA; 1300 para casos de faltas em outros barramentos; 500 casos sem faltas aplicadas.

Além disso, a respeito da quantidade de casos que irão compor o conjunto de dados de treinamento exclusivo de cada RNA responsável pela indicação da fase com falta foi adotada uma quantidade de 5000 casos, os quais serão distribuídos entre cada uma das barras e fases.

Para este sistema teste, foram propostos os seguintes cenários de simulação de falta:

- a) Cenário 1: variação de carga nominal entre 80 a 120% e variação da resistência de falta entre 200 e 300 ohms;
- b) Cenário 2: variação de carga nominal entre 80 a 120% e variação da resistência de falta entre 300 e 600 ohms;
- c) Cenário 3: variação de carga nominal entre 70 a 130% e variação da resistência de falta entre 600 e 800 ohms.
- d) Cenário 4: variação de carga nominal entre 60 a 140% e variação da resistência de falta entre 800 e 1000 ohms.

A Tabela 4 apresenta os valores estimados das correntes de falta em cada cenário. O cálculo dessas correntes é feito através da divisão da tensão de fase do sistema pela resistência de falta.

Tabela 4 – Níveis de corrente de falta – IEEE 13 barras

<b>Resistência de Falta</b>	<b>Corrente</b>
200-300 $\Omega$	8 – 12 A
300-600 $\Omega$	4 - 8 A
600-800 $\Omega$	3 - 4 A
800-1000 $\Omega$	2,4 - 3 A

Fonte: Elaborado pelo autor (2024).

Como exemplificação da busca exaustiva, as tabelas a seguir apresentam um comparativo entre os resultados obtidos para cada posição dos medidores. É importante ressaltar que os resultados exibidos são relativos às simulações do cenário 1, com 20 neurônios na camada oculta das RNAs. Acerca da Tabela 5 são apresentados os resultados das eficiências atingidas no processo de detecção de faltas e localização das barras defeituosas, calculadas de acordo com as equações (2) e (3). A primeira coluna é referente à posição do segundo medidor alocado, identificada pelas barras DE e PARA, e as colunas subsequentes são relativas às eficiências obtidas com cada tipo de medidor (não fasorial, sequência e fasorial). Pelo fato do sistema IEEE 13 barras ser pequeno, foram considerados até 3 barramentos para formar o grupo de barras prováveis com falta. Além disso, a Tabela 6 apresenta as eficiências alcançadas pelas RNAs exclusivas das fases, calculadas por meio da equação (4).

Tabela 5 – Resultados obtidos pelas RNAs relativas às barras – IEEE 13 barras

<b>Posição</b>	<b>Não Fasorial</b>		<b>Sequência</b>		<b>Fasorial</b>		
	<b>DE-PARA</b>	<b>Deteção</b>	<b>Localização</b>	<b>Deteção</b>	<b>Localização</b>	<b>Deteção</b>	<b>Localização</b>
<b>650-632</b>		96,73%	71,37%	98,37%	88,64%	98,07%	88,88%
<b>632-670</b>		95,00%	79,37%	96,80%	89,43%	95,20%	90,47%
<b>670-671</b>		95,80%	80,67%	95,03%	91,28%	95,57%	91,26%
<b>632-633</b>		99,77%	68,41%	99,87%	88,11%	99,73%	89,19%
<b>633-634</b>		99,27%	71,63%	99,77%	88,79%	99,90%	90,03%
<b>671-692</b>		97,53%	85,85%	98,33%	93,10%	99,43%	94,56%
<b>692-675</b>		96,37%	78,30%	92,23%	84,90%	96,70%	90,39%

Fonte: Elaborado pelo autor (2024).

Tabela 6 – Resultados obtidos pelas RNAs relativas às fases – IEEE 13 barras

<b>Posição</b>	<b>Não Fasorial</b>	<b>Sequência</b>	<b>Fasorial</b>
<b>DE-PARA</b>			
<b>650-632</b>	99,64%	99,61%	99,96%
<b>632-670</b>	98,86%	99,76%	99,49%
<b>670-671</b>	98,93%	99,44%	99,68%
<b>632-633</b>	99,45%	99,45%	99,92%
<b>633-634</b>	99,33%	99,76%	99,84%
<b>671-692</b>	99,92%	99,60%	99,88%
<b>692-675</b>	99,48%	98,42%	99,49%

Fonte: Elaborado pelo autor (2024).

Para um melhor entendimento dos cálculos das eficiências apresentadas anteriormente, a Tabela 7 apresenta de forma detalhada os resultados obtidos com o medidor fasorial. A primeira coluna é relativa à posição do medidor, já a segunda e a terceira colunas apresentam a quantidade de casos verdadeiros positivos e negativos no processo de detecção das faltas, respectivamente. A quarta coluna exibe a quantidade de casos verdadeiros positivos para a presença do barramento correto dentro do grupo de barras indicadas como prováveis de estarem com defeito, e assim a quinta, a sexta e a sétima colunas detalham em qual posição o barramento

correto foi indicado dentro do grupo. Por fim, é mostrada a soma da quantidade de casos verdadeiros positivos obtidos durante o processo de identificação das fases com falta.

Tabela 7 – Detalhamento de resultados com medidor fasorial – IEEE 13 barras


Posição	$V_{P_{falta}}$	$V_{N_{falta}}$	$V_{P_{barra}}$	1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	$V_{P_{fase A}} + V_{P_{fase B}} + V_{P_{fase C}}$
650-632	2528	414	2247	1411	555	281	2527
632-670	2529	327	2288	1486	546	256	2516
670-671	2528	339	2307	1561	505	241	2520
632-633	2544	448	2269	1501	488	280	2542
633-634	2547	450	2293	1558	485	250	2543
671-692	2537	446	2399	1748	470	181	2534
692-675	2528	373	2285	1448	547	290	2515

Fonte: Elaborado pelo autor (2024).

A fim de observar o desempenho do método em outros cenários, o Gráfico 1 e o


Gráfico 2 apresentam os resultados de eficiência obtidos pelas RNAs dedicadas à localização das barras com falta, enquanto o Gráfico 3 exibe os resultados de eficiência para a localização das fases. É relevante pontuar que para os resultados exibidos a seguir o medidor foi alocado entre as barras 671 e 692, e foram utilizados 20 neurônios na camada oculta das RNAs.

Gráfico 1 – Resultados obtidos para detecção de faltas - IEEE 13 barras




Fonte: Elaborado pelo autor (2024).

Gráfico 2 – Resultados obtidos para localização das barras com faltas - IEEE 13 barras



Fonte: Elaborado pelo autor (2024).

Gráfico 3 – Resultados obtidos para localização das fases com faltas - IEEE 13 barras




Fonte: Elaborado pelo autor (2024).

Além disso, outra forma de observar o desempenho do método proposto é através da variação dos neurônios na camada oculta das RNAs. Dessa forma, o Gráfico 4 apresenta os resultados de eficiência obtidos para cada quantidade de neurônios na camada oculta, para cada

tipo de medidor, considerando os testes realizados no cenário 1 e com o medidor alocado na posição 671-692.

Gráfico 4 – Desempenho das RNAs dedicadas às barras com variação de neurônios na camada oculta - IEEE 13 barras



Fonte: Elaborado pelo autor (2024).

Por meio dessa comparação entre a quantidade de neurônios na camada oculta e uma avaliação feita para todos os cenários, optou-se pela apresentação dos resultados com 20 neurônios na camada oculta dos RNAs, já que para a maioria dos casos essa configuração forneceu os melhores resultados com tempo computacional razoável.

Outra forma de analisar o desempenho do método é através da avaliação das respostas obtidas para a primeira barra indicada como a mais provável de estar com defeito. Assim, a Tabela 8 apresenta os resultados acerca das posições relativas dos barramentos indicados como os mais prováveis de estarem com defeito em comparação com a barra em que a falta foi aplicada em cada caso simulado. A composição dessa tabela será feita pelas seguintes colunas:

- **1ª Coluna:** referência ao tipo de medição;
- **2ª Coluna:** referência ao cenário;
- **3ª a 9ª Coluna:** categorização dos barramentos indicados como os mais prováveis de estarem com defeito em relação às sete categorias de posição relativa;




Tabela 8 – Detalhamento de resultados da posição relativa da barra indicada como a mais provável de estar com defeito – IEEE 13 barras

<b>Medição</b>	<b>Cenário</b>	<b>-3</b>	<b>-2</b>	<b>-1</b>	<b>0</b>	<b>+1</b>	<b>+2</b>	<b>+3</b>
<b>Não Fasorial</b>	<b>1</b>	1	44	265	1190	446	162	23
	<b>2</b>	3	41	279	1082	459	205	51
	<b>3</b>	22	78	237	804	389	201	83
	<b>4</b>	44	80	215	679	341	170	132
<b>Sequência</b>	<b>1</b>	1	31	262	1604	312	77	0
	<b>2</b>	2	41	274	1418	342	104	3
	<b>3</b>	4	69	423	1092	349	117	7
	<b>4</b>	4	57	355	1035	360	137	23
<b>Fasorial</b>	<b>1</b>	0	29	237	1748	284	59	0
	<b>2</b>	4	31	245	1503	369	91	0
	<b>3</b>	3	45	298	1239	386	120	4
	<b>4</b>	4	58	330	994	419	128	16

Fonte: Elaborado pelo autor (2024).

Para uma melhor visualização e análise do desempenho do método, o Gráfico 5 apresenta os mesmos resultados apresentados anteriormente para a medição fasorial, porém em formato de figura.

Gráfico 5 – Resultados das posições relativas da primeira barra indicada com defeito - IEEE 13 barras



Fonte: Elaborado pelo autor (2024).

#### 4.2.1 Análise parcial dos resultados – IEEE 13 barras

As simulações realizadas no sistema IEEE 13 barras foram utilizadas para avaliar a eficácia do método proposto em localizar FAIs em um sistema de distribuição pequeno, mas que apresenta desbalanceamento de carga, com ramais monofásicos, bifásicos e trifásicos, além de equipamentos que alteram os níveis de tensão da rede como os transformadores e reguladores.

Por meio dos resultados obtidos é possível observar que a busca exaustiva para alocação de medidor é possível de ser implementada em um contexto que existem poucas possibilidades de combinação do conjunto de medidores. Dessa maneira, para os testes conduzidos neste trabalho, observou-se que na grande maioria dos casos a melhor posição para se instalar um segundo medidor são as linhas 670-671 e 671-692, já que contribuíram com as maiores eficiências para o processo de localização das faltas.

Em relação às simulações dos cenários propostos, torna-se evidente que quanto maior a resistência de falta e a variação de carregamento, maiores dificuldades são impostas para as RNAs detectarem e localizarem as faltas. O aumento dos limites de variação de carregamento faz com que uma grande carga possa ser confundida pelas RNAs devido à corrente de falta e sejam detectadas faltas inexistentes. Por outro lado, a ocorrência de uma FAI em uma ocasião que o circuito esteja com baixo carregamento, as RNAs podem não detectar a falta devido à baixa corrente, a qual pode ser similar a uma de operação normal do sistema. Dessa forma, como já previsto, o cenário 4 apresentou menores eficiências, enquanto o cenário 1 as melhores.

A respeito das eficiências obtidas para localização, constata-se que as medições fasoriais apresentaram os melhores resultados, seguidas das medições de sequência e posteriormente das não fasoriais. Além disso, a quantidade de neurônios na camada oculta das RNAs também provoca variações no desempenho do método, demonstrando que maiores quantidades não estão necessariamente relacionadas às maiores eficiências. Ao se analisar os resultados obtidos, nota-se que as eficiências para detecção de falta e localização da fase com defeito são superiores a 90%. Já em relação a localização da barra com falta apenas os cenários 1 e 2 apresentaram bons resultados, demonstrando que existe uma limitação quanto a capacidade das RNAs ao indicar corretamente o barramento defeituoso dentro do grupo de barras prováveis para casos em que a variação de carregamento do circuito é alta e as correntes de falta muito baixas.

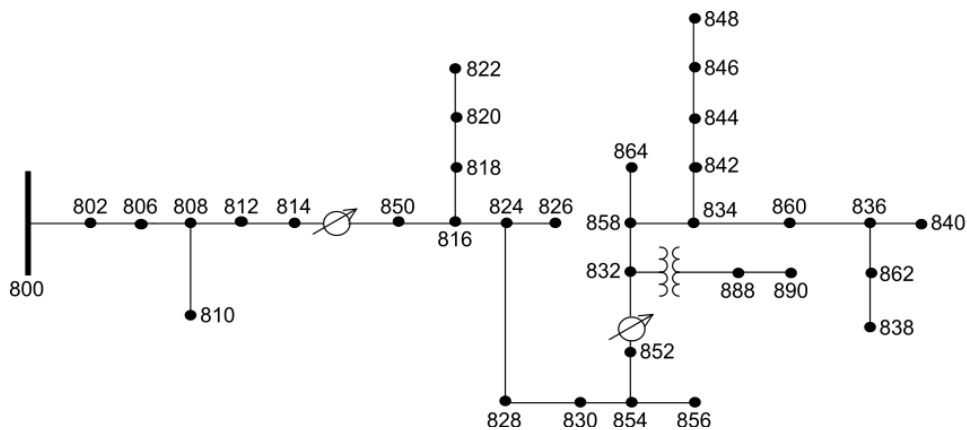
Através dos testes conduzidos, observou-se também que a maior dificuldade imposta pelo sistema IEEE 13 barras foi o alto carregamento do circuito, algo que influenciou diretamente no processo de localização das barras com defeito, já que as RNAs foram induzidas em alguns momentos a indicarem barramentos errados devido às maiores correntes.

Além disso, ao se avaliar as posições relativas, tem-se que, para maioria dos cenários, mais de 80% dos barramentos indicados como o de maior chance de apresentar falta se adequaram às posições à montante e à jusante da barra correta com falta, contribuindo para direcionar a localização do defeito para os barramentos próximos.

### 4.3 IEEE 34 BARRAS

Este sistema teste é um sistema de distribuição real localizado no Arizona, com uma tensão nominal de 24,9 kV. É caracterizado por um alimentador longo e levemente carregado, carga desequilibrada, presença de dois reguladores de tensão, um transformador (24,9 kV - 4,16 kV) e capacitores em derivação (IEEE [s.d.]). O diagrama unifilar desse sistema é ilustrado na Figura 13.

Figura 13 – IEEE 34 barras



Fonte: IEEE ([s.d.]).

Para realizar a detecção e localização das faltas foi utilizado um conjunto de 3 medidores. Dessa maneira, considerando que um medidor será instalado na saída da subestação e apenas as linhas trifásicas serão utilizadas para alocação, o sistema IEEE 34 barras possui exatamente 300 combinações diferentes para alocar os outros dois medidores. Dessa maneira, os locais dos medidores, primeiramente, foram escolhidos de maneira arbitrária para que posteriormente, com o uso do algoritmo genético, se compare os resultados obtidos com os medidores colocados aleatoriamente com os resultados obtidos com medidores alocados de maneira otimizada a fim de analisar a eficácia da metodologia de otimização desenvolvida.

Em relação à quantidade dos tipos de casos que irão compor o conjunto de dados de treinamento exclusivo de cada RNA responsável pela indicação da barra com falta, serão adotados os seguintes valores: 1500 para casos relativos às faltas que ocorrem nas barras

referentes a própria RNA; 1188 para casos de faltas em outros barramentos; 300 casos sem faltas aplicadas.

Além disso, a respeito da quantidade de casos que irão compor o conjunto de dados de treinamento exclusivo de cada RNA responsável pela indicação da fase com falta será adotada uma quantidade de 3000 casos, os quais serão distribuídos entre cada uma das barras e fases.

Para este sistema teste, foram propostos os seguintes cenários de simulação de falta:

- a) Cenário 1: variação de carga nominal entre 80 a 120% e variação da resistência de falta entre 800 e 1000 ohms;
- b) Cenário 2: variação de carga nominal entre 80 a 120% e variação da resistência de falta entre 1000 e 1500 ohms.
- c) Cenário 3: variação de carga nominal entre 70 a 130% e variação da resistência de falta entre 1500 e 2000 ohms.
- d) Cenário 4: variação de carga nominal entre 70 a 130% e variação da resistência de falta entre 2000 e 3000 ohms.

A Tabela 9 apresenta os valores estimados das correntes de falta em cada cenário. O cálculo dessas correntes é feito através da divisão da tensão de fase do sistema pela resistência de falta.

Tabela 9 – Níveis de corrente de falta – IEEE 34 barras

<b>Resistência de Falta</b>	<b>Corrente</b>
800-1000 $\Omega$	14,38 – 17,97 A
1000-1500 $\Omega$	9,58 – 14,38 A
1500-2000 $\Omega$	7,19 – 9,58 A
2000-3000 $\Omega$	4,79 – 7,19 A


Fonte: Elaborado pelo autor (2024).

Nesse sentido, os medidores, inicialmente, foram alocados de maneira bem distribuída no circuito, sendo um medidor instalado no início do alimentador (saída da subestação), outro entre as barras 816 e 824 e o último entre as barras 858 e 834. Os gráficos a seguir apresentam alguns resultados obtidos com esta configuração de medidores.

O Gráfico 6 mostra as eficiências alcançadas pelas RNAs relacionadas à detecção de faltas, além de um comparativo entre os tipos de medição. A respeito dos resultados obtidos


para a localização de falta, o Gráfico 7 e o Gráfico 8 apresentam os valores de eficiências do processo de localização da barra e da fase com falta, respectivamente. Ressalta-se que para obtenção desses resultados foram utilizados 20 neurônios na camada oculta das RNAs.

Gráfico 6 – Resultados obtidos para detecção de faltas - IEEE 34 barras




Fonte: Elaborado pelo autor (2024).

Gráfico 7 – Resultados obtidos para localização da barra com falta - IEEE 34 barras



Fonte: Elaborado pelo autor (2024).

Gráfico 8 – Resultados obtidos para localização da fase com falta - IEEE 34 barras



Fonte: Elaborado pelo autor (2024).

Para um melhor entendimento do cálculo desses resultados, a Tabela 10 mostra os valores detalhados obtidos por cada tipo de medição em todos os cenários, sendo importante pontuar que para a formação do grupo de barras prováveis com defeito foram considerados até cinco barramentos para serem indicados como os mais possíveis de apresentar falta.


Tabela 10 – Detalhamento de resultados – IEEE 34 barras

Medição	Cenário	$V_{P_{falta}}$	$V_{N_{falta}}$	$V_{P_{barra}}$	1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	4 <sup>a</sup>	5 <sup>a</sup>
Não Fasorial	1	2548	404	2367	1165	687	291	138	86
	2	2542	386	2271	998	687	340	157	89
	3	2539	380	2217	940	623	353	187	114
	4	2538	298	2195	906	618	349	198	124
Sequência	1	2550	448	2473	1575	547	178	91	82
	2	2543	442	2451	1396	610	283	110	52
	3	2534	435	2316	1122	623	344	139	88
	4	2528	416	2227	1107	549	348	134	89
Fasorial	1	2550	450	2497	1693	536	166	65	37
	2	2548	450	2488	1529	594	213	117	35
	3	2549	450	2403	1206	681	341	111	64
	4	2524	447	2280	1130	652	279	124	95

Fonte: Elaborado pelo autor (2024).

Além disso, é possível observar também a influência exercida pela quantidade de neurônios na camada oculta das RNAs nos valores de eficiência obtidos, assim, o Gráfico 9 apresenta um comparativo, para o cenário 1, dos resultados de localização da barra com defeito.

Gráfico 9 – Desempenho das RNAs dedicadas às barras com variação de neurônios na camada oculta - IEEE 34 barras



Fonte: Elaborado pelo autor (2024).

Apesar de 10 e 30 neurônios na camada oculta das RNAs apresentarem eficiências maiores em determinados casos, o motivo pelo qual se optou pela apresentação dos resultados com 20 neurônios na camada oculta das RNAs se deu pelo fato dessa configuração fornecer na maioria das vezes os melhores resultados com tempo computacional razoável nos diferentes cenários testados.

Outra forma de analisar o desempenho do método é através da avaliação das respostas obtidas para a primeira barra indicada como a mais provável de estar com defeito. Assim, a Tabela 11 apresenta os resultados acerca das posições relativas dos barramentos indicados como os mais prováveis de estarem com defeito em comparação com a barra em que a falta foi aplicada em cada caso simulado.




Tabela 11 – Detalhamento de resultados da posição relativa da barra indicada como a mais provável de estar com defeito – IEEE 34 barras

<b>Medição</b>	<b>Cenário</b>	<b>-3</b>	<b>-2</b>	<b>-1</b>	<b>0</b>	<b>+1</b>	<b>+2</b>	<b>+3</b>
<b>Não Fasorial</b>	<b>1</b>	56	145	398	1165	438	129	39
	<b>2</b>	96	178	367	998	405	174	65
	<b>3</b>	57	171	365	940	424	206	84
	<b>4</b>	118	169	284	845	393	201	126
<b>Sequência</b>	<b>1</b>	32	83	354	1575	283	30	7
	<b>2</b>	42	137	320	1396	364	74	18
	<b>3</b>	52	156	337	1122	411	175	44
	<b>4</b>	89	148	300	1107	365	137	64
<b>Fasorial</b>	<b>1</b>	20	96	239	1693	289	47	3
	<b>2</b>	21	109	294	1529	360	59	15
	<b>3</b>	63	154	346	1206	433	128	29
	<b>4</b>	68	135	340	1130	386	120	60

Fonte: Elaborado pelo autor (2024).

Para uma melhor visualização e análise do desempenho do método, o Gráfico 10 apresenta os mesmos resultados apresentados anteriormente para a medição fasorial, porém em formato de figura.

Gráfico 10 – Resultados das posições relativas da primeira barra indicada com defeito – IEEE 34 barras



Fonte: Elaborado pelo autor (2024).

Após a realização das simulações sem o uso de técnicas de otimização na alocação de medidores, o Algoritmo Genético foi utilizado para realizar a alocação dos medidores com o intuito de melhorar os resultados obtidos com o método proposto. Logo, para realizar essa tarefa, também foram utilizados três medidores, sendo um instalado no início do alimentador (saída da subestação), e os outros dois livres para serem alocados de acordo com a indicação do processo de otimização. A seguir são apresentados os valores de eficiências alcançados com o AG.

A Tabela 12, a Tabela 13 e a Tabela 14 mostram os valores detalhados obtidos por cada tipo de medição em todos os cenários, com 20 neurônios na camada oculta das RNAs, com as duas últimas colunas exibindo as linhas em que os medidores foram alocados. Além disso, a Tabela 15 exhibe os acertos para o processo de localização das fases defeituosas.

Tabela 12 – Detalhamento de resultados obtidos com uso de AG (medição não fasorial) – IEEE 34 barras

<b>Cenário</b>	$V_{P_{falta}}$	$V_{N_{falta}}$	$V_{P_{barra}}$	1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	4 <sup>a</sup>	5 <sup>a</sup>	<b>Medidores</b>	
<b>1</b>	2550	450	2451	1386	619	221	127	98	852-832	834-842
<b>2</b>	2549	450	2402	1233	624	283	149	113	852-832	834-842
<b>3</b>	2548	450	2378	1165	610	300	165	138	852-832	858-834
<b>4</b>	2550	449	2340	994	625	359	216	146	852-832	860-836

Fonte: Elaborado pelo autor (2024).

Tabela 13 – Detalhamento de resultados obtidos com uso de AG (medição de sequência) – IEEE 34 barras

<b>Cenário</b>	$V_{P_{falta}}$	$V_{N_{falta}}$	$V_{P_{barra}}$	1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	4 <sup>a</sup>	5 <sup>a</sup>	<b>Medidores</b>	
<b>1</b>	2549	449	2528	1694	572	180	67	15	832-888	834-860
<b>2</b>	2548	450	2479	1502	594	254	85	44	824-828	858-834
<b>3</b>	2550	446	2348	1254	645	317	75	57	824-828	888-890
<b>4</b>	2542	446	2335	1171	672	344	85	63	888-890	834-860

Fonte: Elaborado pelo autor (2024).

Tabela 14 – Detalhamento de resultados obtidos com uso de AG (medição fasorial) – IEEE 34 barras

<b>Cenário</b>	$V_{P_{falta}}$	$V_{N_{falta}}$	$V_{P_{barra}}$	1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	4 <sup>a</sup>	5 <sup>a</sup>	<b>Medidores</b>	
<b>1</b>	2550	450	2546	1782	601	153	10	0	824-828	834-860
<b>2</b>	2549	448	2535	1606	564	177	111	77	854-852	834-842
<b>3</b>	2546	450	2418	1345	578	279	125	91	850-816	888-890
<b>4</b>	2548	449	2362	1134	641	270	193	124	858-834	834-842

Fonte: Elaborado pelo autor (2024).


Tabela 15 – Detalhamento de resultados obtidos para localização das fases com uso de AG – IEEE 34 barras

Cenário	$V_{P_{fase A}} + V_{P_{fase B}} + V_{P_{fase C}}$		
	Não Fasorial	Sequência	Fasorial
1	2550	2547	2550
2	2546	2545	2547
3	2548	2544	2545
4	2549	2542	2543

Fonte: Elaborado pelo autor (2024).


A partir dos resultados apresentados anteriormente, o Gráfico 11 mostra as eficiências alcançadas pelas RNAs relacionadas à detecção de faltas. A respeito dos resultados obtidos para a localização de falta, o Gráfico 12 e o Gráfico 13 apresentam os valores de eficiências do processo de localização da barra e da fase com falta, respectivamente.

Gráfico 11 – Resultados obtidos para detecção de faltas com uso de AG - IEEE 34 barras




Fonte: Elaborado pelo autor (2024).

Gráfico 12 – Resultados obtidos para localização da barra com falta com uso de AG - IEEE 34 barras



Fonte: Elaborado pelo autor (2024).

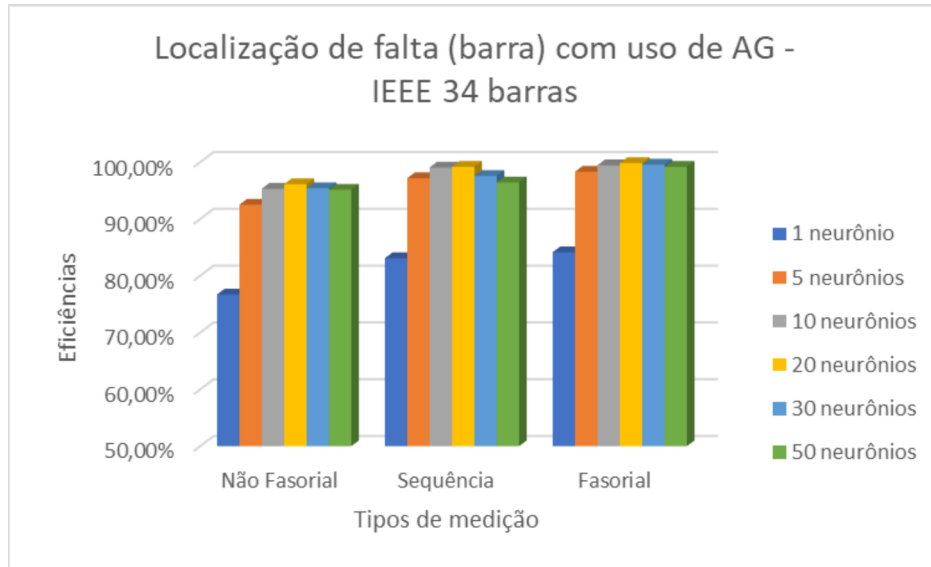
Gráfico 13 – Resultados obtidos para localização da fase com falta com uso de AG - IEEE 34 barras



Fonte: Elaborado pelo autor (2024).

O Gráfico 14 apresenta uma comparação de resultados obtidos com diferentes neurônios na camada oculta das RNAS em simulações do cenário 1 para a localização da barra defeituosa.

Gráfico 14 – Desempenho, com uso de AG, das RNAs dedicadas às barras com variação de neurônios na camada oculta - IEEE 34 barras



Fonte: Elaborado pelo autor (2024).


E ainda, com o intuito de avaliar a qualidade dos resultados relacionados à indicação da barra de maior probabilidade de estar com defeito, a Tabela 16 apresenta os resultados acerca das posições relativas para cada cenário, com 20 neurônios na camada oculta das RNAs, e o Gráfico 15 apresenta os mesmos resultados para medição fasorial, mas em formato de figura para melhor visualização.

Tabela 16 – Detalhamento de resultados, com uso de AG, da posição relativa da barra indicada como a mais provável de estar com defeito – IEEE 34 barras

Medição	Cenário	-3	-2	-1	0	+1	+2	+3
<b>Não Fasorial</b>	1	72	146	368	1386	327	97	38
	2	86	141	335	1233	349	148	71
	3	97	170	340	1165	362	138	60
	4	105	178	281	994	446	180	95
<b>Sequência</b>	1	36	77	314	1694	300	68	8
	2	38	132	351	1502	342	84	28
	3	59	170	319	1254	423	168	30
	4	85	238	387	1171	394	111	35
<b>Fasorial</b>	1	9	80	331	1782	284	45	3
	2	29	96	269	1606	325	68	36
	3	54	126	239	1386	391	112	43
	4	81	222	322	1134	358	141	73

Fonte: Elaborado pelo autor (2024).

Gráfico 15 – Resultados das posições relativas da primeira barra indicada com defeito com uso de AG – IEEE 34 barras



Fonte: Elaborado pelo autor (2024).

### 4.3.1 Análise parcial dos resultados – IEEE 34 barras

A partir dos resultados obtidos para o sistema IEEE 34 barras, é possível observar que a método desenvolvido, mesmo sem a utilização de AG para otimizar a alocação de medidores, se mostrou eficiente ao detectar as FAIs para os diferentes cenários e tipos de medição, apresentando todos os resultados com acertos acima de 90%. Além disso, também apresentou boas eficiências em relação a localização de faltas, ao indicar um grupo de até 5 barras prováveis que possam estar com falta, algo que pode reduzir o campo de busca para menos de 15% da quantidade de barramentos do sistema.

A cada cenário simulado, lembrando que os cenários foram definidos num crescente de dificuldade, constata-se que as eficiências mensuradas diminuem, independentemente do tipo de medição utilizada, já que, para as RNAs, torna-se mais difícil identificar um defeito pelo fato do incremento da corrente de falta se tornar baixo o suficiente para ser confundido como um caso de operação normal do sistema com determinada variação do carregamento.

Já em relação aos neurônios utilizados na camada oculta das RNAs, a variação da quantidade demonstrou que, para a grande maioria dos casos, os melhores resultados foram obtidos pelas RNAs com 10, 20 ou 30 neurônios em sua camada oculta, revelando que não necessariamente mais neurônios colaboram com resultados superiores e que uma quantidade menor pode não ser suficiente para a aplicação do método, como no caso de 1 neurônio, que apresentou eficiências ruins.

Ao se avaliar as posições relativas, tem-se que, para todos os cenários, mais de 80% dos barramentos indicados como o de maior chance de apresentar falta se adequaram às posições a montante e a jusante da barra correta com falta, contribuindo para direcionar a localização do defeito para os barramentos próximos.

A respeito dos tipos de medidores utilizados, as medições fasoriais foram as que contribuíram para os melhores resultados para a presença do barramento correto dentro do grupo de barras prováveis, exibindo eficiências acima de 90% em todos os cenários. Por outro lado, o tipo de medição não causou tanta influência nos resultados de detecção de falta e identificação da fase defeituosa, já que para todos os tipos foi possível obter altas eficiências.

Além disso, acerca dos resultados obtidos através da utilização da otimização para a alocação dos medidores, considera-se que o AG se apresentou como uma excelente ferramenta

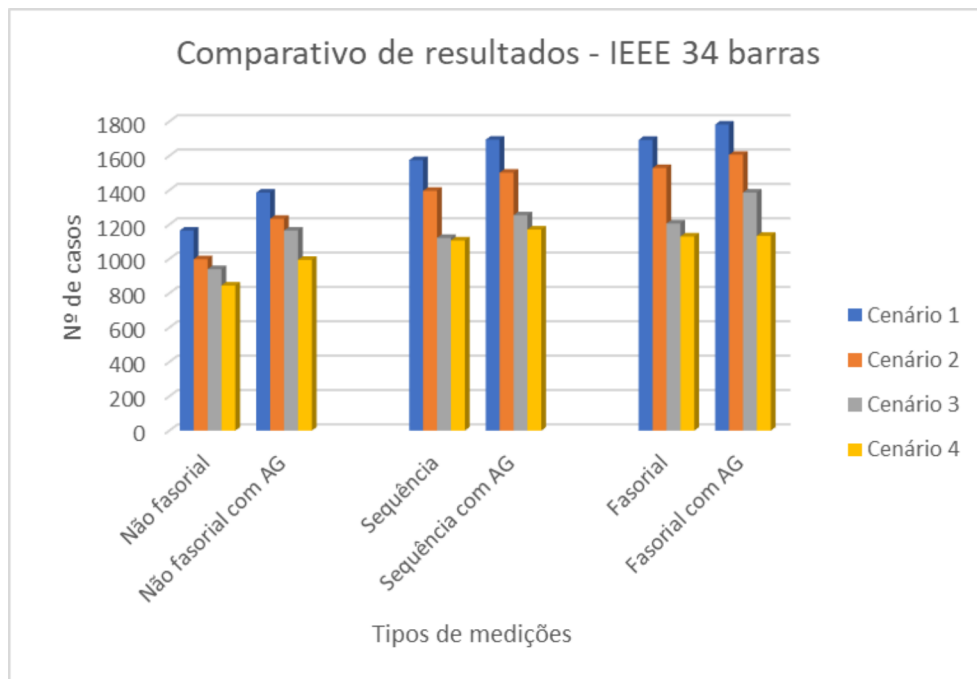


para o problema proposto. Em todos os cenários e para todas as circunstâncias a qualidade dos resultados alcançados foi superior ao ser comparada com a qualidade dos resultados anteriores, comprovando que o local onde o medidor é instalado é um fator extremamente importante para a aplicação do método.

Outro fato relevante a ser mencionado é que o AG indicou localizações diferentes para os medidores para cada simulação, revelando que o tipo de entrada fornecida às RNAs e suas arquiteturas influenciam nos melhores locais para a instalação dos medidores. De maneira geral, foi possível observar que os medidores foram alocados, principalmente, no ramal compreendido pelas barras 824 e 860, com o foco em torno dos barramentos 832 e 834. Além disso, o fator mais determinante no posicionamento dos medidores é o tipo de medição, pois ao se analisar a mudança de cenário em que os casos são simulados, para um mesmo tipo de medição, os resultados convergiram de maneira parcial para determinados locais.

A fim de se avaliar melhor os resultados entre as simulações com e sem otimização, o Gráfico 16 apresenta um comparativo dos acertos da indicação da barra com maior possibilidade de estar com defeito no grupo formado pelas barras prováveis, acertos os quais foram maximizados pelo AG.


Gráfico 16 – Comparativo de resultados - IEEE 34 barras



Fonte: Elaborado pelo autor (2024).

Além disso, o Gráfico 17 apresenta um comparativo de resultados obtidos com as medições fasoriais para as posições relativas da barra indicada com maior possibilidade de estar com defeito no grupo formado pelas barras prováveis.

Gráfico 17 – Comparativo de resultados para posições relativas – IEEE 34 barras




Fonte: Elaborado pelo autor (2024).

#### 4.4 IEEE 123 BARRAS

Este sistema teste opera a uma tensão nominal de 4,16 kV e possui um circuito caracterizado por linhas aéreas e subterrâneas bastante ramificadas, cargas desequilibradas, quatro reguladores de tensão, bancos de capacitores em derivação e várias chaves (IEEE, [s.d.]). O diagrama unifilar desse sistema é ilustrado na Figura 14.

Figura 14 – IEEE 123 barras



Fonte: IEEE ([s.d.]).

Para realizar a detecção e localização das faltas foi utilizado um conjunto de 10 medidores. Dessa maneira, considerando que um medidor será instalado na saída da subestação e apenas as linhas trifásicas serão utilizadas para alocação, o sistema IEEE 123 barras possui mais de 37 bilhões de combinações diferentes para alocar os outros nove medidores. Dessa maneira, os locais dos medidores, primeiramente, foram escolhidos de maneira arbitrária para que posteriormente, com o uso do algoritmo genético sejam alocados na otimização, e que se compare os resultados a fim de analisar a eficácia da metodologia de otimização desenvolvida.

Em relação à quantidade dos tipos de casos que irão compor o conjunto de dados de treinamento exclusivo de cada RNA responsável pela indicação da barra com falta, serão adotados os seguintes valores: 2000 para casos relativos às faltas que ocorrem nas barras referentes a própria RNA; 3690 para casos de faltas em outros barramentos; 600 casos sem faltas aplicadas.

Além disso, a respeito da quantidade de casos que irão compor o conjunto de dados de treinamento exclusivo de cada RNA responsável pela indicação da fase com falta será adotada uma quantidade de 6000 casos, os quais serão distribuídos entre cada uma das barras e fases.

Para este sistema teste, foram propostos os seguintes cenários de simulação de falta:

- a) Cenário 1: variação de carga nominal entre 80 a 120% e variação da resistência de falta entre 200 e 300 ohms
- b) Cenário 2: variação de carga nominal entre 80 a 120% e variação da resistência de falta entre 300 e 600 ohms;
- c) Cenário 3: variação de carga nominal entre 70 a 130% e variação da resistência de falta entre 600 e 800 ohms.
- d) Cenário 4: variação de carga nominal entre 60 a 140% e variação da resistência de falta entre 800 e 1000 ohms.

A Tabela 17 apresenta os valores estimados das correntes de falta em cada cenário. O cálculo dessas correntes é feito através da divisão da tensão de fase do sistema pela resistência de falta.

Tabela 17 – Níveis de corrente de falta – IEEE 123 barras


<b>Resistência de Falta</b>	<b>Corrente</b>
200-300 $\Omega$	8 – 12 A
300-600 $\Omega$	4 - 8 A
600-800 $\Omega$	3 - 4 A
800-1000 $\Omega$	2,4 - 3 A

Fonte: Elaborado pelo autor (2024).

Nesse sentido, os medidores, inicialmente, foram alocados de maneira bem distribuída no circuito, sendo um medidor instalado no início do alimentador (saída da subestação) e os outros nas linhas entre as barras 8-13, 13-152, 18-135, 23-25, 44-47, 60-160, 67-72, 67-97 e 86-87. Os gráficos a seguir apresentam alguns resultados obtidos com esta configuração de medidores.


O Gráfico 18 mostra as eficiências alcançadas pelas RNAs relacionadas à detecção de faltas, além de um comparativo entre os tipos de medição. A respeito dos resultados obtidos para a localização de falta, o Gráfico 19 e o Gráfico 20 apresentam os valores de eficiências do processo de localização da barra e da fase com falta, respectivamente. Ressalta-se que para obtenção desses resultados foram utilizados 20 neurônios na camada oculta das RNAs.

Gráfico 18 – Resultados obtidos para detecção de faltas - IEEE 123 barras




Fonte: Elaborado pelo autor (2024).

Gráfico 19 – Resultados obtidos para localização da barra com falta - IEEE 123 barras



Fonte: Elaborado pelo autor (2024).

Gráfico 20 – Resultados obtidos para localização da fase com falta - IEEE 123 barras



Fonte: Elaborado pelo autor (2024).

Para um melhor entendimento do cálculo desses resultados, a Tabela 18 mostra os valores detalhados obtidos por cada tipo de medição em todos os cenários, sendo importante pontuar que para a formação do grupo de barras prováveis com defeito foram considerados até cinco barramentos para serem indicados como os mais possíveis de apresentar falta.


Tabela 18 – Detalhamento de resultados – IEEE 123 barras

Medição	Cenário	$V_{P_{falta}}$	$V_{N_{falta}}$	$V_{P_{barra}}$	$V_{P_{fase A}} + V_{P_{fase B}} + V_{P_{fase C}}$
Não Fasorial	1	2509	361	2330	2499
	2	2524	311	2223	2516
	3	2529	300	2202	2514
	4	2524	255	2044	2515
Sequência	1	2507	437	2450	2505
	2	2518	407	2371	2516
	3	2498	396	2277	2494
	4	2487	369	2059	2483
Fasorial	1	2508	447	2448	2507
	2	2523	426	2408	2519
	3	2515	405	2308	2506
	4	2508	374	2142	2501

Fonte: Elaborado pelo autor (2024).

Além desses resultados, é possível observar também a influência exercida pela quantidade de neurônios na camada oculta das RNAs nos valores de eficiência obtidos, assim, o Gráfico 21 apresenta um comparativo, para o cenário 2, dos resultados de localização da barra com defeito.

Gráfico 21 – Desempenho das RNAs dedicadas às barras com variação de neurônios na camada oculta - IEEE 123 barras



Fonte: Elaborado pelo autor (2024).

Ao analisar o comparativo de resultados para diferentes neurônios na camada oculta, é possível observar que 20 neurônios nem sempre fornece a maior eficiência, porém de maneira geral, entre todos os cenários, essa configuração de arquitetura das RNAs se mostra como a mais adequada para fornecer bons resultados com tempo computacional razoável, e assim foi escolhida para apresentar os resultados nos testes do sistema IEEE 123 barras.

Outra forma de analisar o desempenho do método é através da avaliação das respostas obtidas para a primeira barra indicada como a mais provável de estar com defeito. Dessa forma, a Tabela 19 apresenta os resultados acerca das posições relativas dos barramentos indicados como os mais prováveis de estarem com defeito em comparação com a barra em que a falta foi aplicada em cada caso simulado.


Tabela 19 – Detalhamento de resultados da posição relativa da barra indicada como a mais provável de estar com defeito – IEEE 123 barras

Medição	Cenário	-3	-2	-1	0	+1	+2	+3
<b>Não Fatorial</b>	1	51	142	382	866	355	176	45
	2	60	165	394	796	358	160	68
	3	80	153	343	707	361	194	116
	4	65	132	333	634	366	222	117
<b>Sequência</b>	1	40	112	411	1079	386	124	46
	2	48	160	382	958	357	173	59
	3	55	169	385	811	379	175	88
	4	66	124	295	656	373	217	102
<b>Fatorial</b>	1	28	120	407	1132	348	126	49
	2	47	150	406	1015	372	153	37
	3	51	143	390	847	392	181	69
	4	62	147	295	711	394	240	99

Fonte: Elaborado pelo autor (2024).

Para uma melhor visualização e análise do desempenho do método, o Gráfico 22 apresenta os mesmos resultados apresentados anteriormente para a medição fatorial, porém em formato de figura.

Gráfico 22 – Resultados das posições relativas da primeira barra indicada com defeito – IEEE 34 barras



Fonte: Elaborado pelo autor (2024).



Pelo fato do sistema IEEE 123 barras ter muitos barramentos em comparação com os demais apresentados, outro resultado interessante de ser exibido é a eficácia do método de acordo com o local em que a falta ocorre. Assim, para fins de análise, os locais de ocorrência de falta foram agrupados em 10 áreas, sendo cada uma delimitada de acordo com a posição dos medidores. A Tabela 20 exibe os medidores delimitadores de cada área e as eficiências obtidas para a localização de faltas que ocorrem dentro de cada área em simulações do cenário 1.

Tabela 20 – Desempenho do método em relação ao local de falta - IEEE 123 barras

Área	Medidores delimitadores	Medição		
		Não Fasorial	Sequência	Fasorial
1	150; 8-13	97,84%	99,63%	99,63%
2	8-13; 13-152; 18-135; 23-25	98,39%	100,00%	99,60%
3	23-25	73,97%	84,47%	90,29%
4	18-135; 44-47	98,80%	99,55%	100,00%
5	44-47	80,56%	94,44%	100,00%
6	13-152; 60-160	99,32%	95,06%	93,00%
7	60-160; 67-72; 67-97	100,00%	100,00%	100,00%
8	67-72; 86-87	81,17%	77,60%	92,21%
9	86-87	96,77%	98,00%	100,00%
10	67-97	77,72%	91,08%	97,03%

Fonte: Elaborado pelo autor (2024).

Após a realização das simulações sem o uso de técnicas de otimização, o Algoritmo Genético foi utilizado para realizar a alocação dos medidores com o intuito de melhorar os resultados obtidos com o método proposto. Logo, para realizar essa tarefa, também foram utilizados três medidores, sendo um instalado entre as barras (saída da subestação), e os outros nove livres para serem alocados de acordo com a indicação do processo de otimização. A seguir são apresentados os valores de eficiências alcançados com o AG.

A Tabela 21 mostra os valores detalhados de detecção e localização de falta obtidos por cada tipo de medição em todos os cenários, com 20 neurônios na camada oculta das RNAs, e a Tabela 22 os resultados da alocação dos medidores, indicando a posição em que cada um foi instalado.

Tabela 21 – Detalhamento de resultados – IEEE 123 barras

Medição	Cenário	$V_{P_{falta}}$	$V_{N_{falta}}$	$V_{P_{barra}}$	$V_{P_{fase A}} + V_{P_{fase B}} + V_{P_{fase C}}$
Não Fatorial	1	2528	389	2401	2520
	2	2531	377	2345	2522
	3	2530	342	2349	2515
	4	2527	295	2195	2518
Sequência	1	2530	441	2482	2525
	2	2529	425	2458	2520
	3	2525	409	2371	2519
	4	2519	397	2219	2510
Fatorial	1	2540	448	2517	2533
	2	2534	432	2472	2524
	3	2530	419	2424	2523
	4	2528	402	2213	2520

Fonte: Elaborado pelo autor (2024).


Tabela 22 – Detalhamento de resultados da alocação dos medidores – IEEE 123 barras

Medição	Cenário	Medidores								
Não Fatorial	1	13-18	25-28	18-135	44-47	152-52	57-60	160-67	76-86	197-101
	2	8-13	13-18	21-23	25-28	42-44	54-57	60-62	72-76	67-97
	3	13-18	18-21	25-28	40-42	13-152	62-63	60-160	76-86	97-197
	4	7-8	13-18	23-25	42-44	53-54	62-63	160-67	86-87	67-97
Sequência	1	18-21	28-29	18-135	47-49	52-53	57-60	67-72	87-89	105-108
	2	13-18	29-30	135-35	49-50	13-152	60-62	160-67	76-77	97-98
	3	13-18	25-28	35-40	152-52	57-60	60-62	67-72	89-91	197-101
	4	18-21	30-250	44-47	13-152	54-57	60-160	87-89	98-99	105-108
Fatorial	1	25-28	18-135	44-47	52-53	57-60	67-72	76-77	99-100	108-300
	2	8-13	28-29	135-35	13-152	60-62	60-160	67-97	86-87	101-105
	3	7-8	13-18	23-25	49-50	152-52	60-61	60-160	72-76	197-101
	4	13-152	18-135	29-30	49-50	57-60	62-63	67-72	89-91	101-105

Fonte: Elaborado pelo autor (2024).

A partir dos resultados apresentados anteriormente, o Gráfico 23 mostra as eficiências alcançadas pelas RNAs relacionadas à detecção de faltas.


Gráfico 23 – Resultados obtidos para detecção de faltas com uso de AG - IEEE 123 barras



Fonte: Elaborado pelo autor (2024).


A respeito dos resultados obtidos para a localização de falta, o Gráfico 24 e o Gráfico 25 apresentam os valores de eficiências do processo de localização da barra e da fase com falta, respectivamente.

Gráfico 24 – Resultados obtidos para localização da barra com falta com uso de AG - IEEE 123 barras



Fonte: Elaborado pelo autor (2024).

Gráfico 25 – Resultados obtidos para localização da fase com falta com uso de AG - IEEE 123 barras



Fonte: Elaborado pelo autor (2024).


Ademais, com o intuito de avaliar a qualidade dos resultados relacionados à indicação da barra de maior probabilidade de estar com defeito, a Tabela 23 apresenta os resultados acerca das posições relativas para cada cenário, com 20 neurônios na camada oculta das RNAs, e o Gráfico 26 apresenta os mesmos resultados para medição fasorial, mas em formato de figura para melhor visualização.

Tabela 23 – Detalhamento de resultados, com uso de AG, da posição relativa da barra indicada como a mais provável de estar com defeito – IEEE 123 barras

Medição	Cenário	-3	-2	-1	0	+1	+2	+3
<b>Não Fasorial</b>	<b>1</b>	58	144	410	1034	331	171	49
	<b>2</b>	47	133	396	905	391	162	90
	<b>3</b>	64	172	406	843	391	166	67
	<b>4</b>	60	147	350	732	400	211	97
<b>Sequência</b>	<b>1</b>	27	123	381	1194	369	120	39
	<b>2</b>	28	130	397	1047	348	168	76
	<b>3</b>	62	146	350	938	414	191	89
	<b>4</b>	119	174	333	831	368	190	112
<b>Fasorial</b>	<b>1</b>	84	110	331	1310	366	129	35
	<b>2</b>	30	138	390	1121	341	112	53
	<b>3</b>	72	158	368	1077	393	127	52
	<b>4</b>	76	168	343	907	444	178	78

Fonte: Elaborado pelo autor (2024).

Gráfico 26 – Resultados das posições relativas da primeira barra indicada com defeito com uso de AG – IEEE 123 barras



Fonte: Elaborado pelo autor (2024).

#### 4.4.1 Análise parcial dos resultados – IEEE 123 barras

A partir dos resultados obtidos para o sistema IEEE 123 barras, é possível observar que a método desenvolvido, mesmo sem a utilização de AG para otimizar a alocação de medidores, se mostrou eficiente ao detectar as FAIs para os diferentes cenários e tipos de medição, apresentado todos os resultados acima de 90%. Além disso, também apresentou eficiências acima de 80% em relação a localização de faltas e alguns casos acima de 90%. Ao indicar um grupo de até 5 barras prováveis que possam estar com falta, o campo de busca da barra defeituosa se reduz para menos de 5% da quantidade de barramentos do sistema, algo que pode contribuir com maior rapidez no reparo da rede elétrica.

Novamente, a cada cenário simulado, uma vez que foram definidos em uma sequência de características que dificulta a localização, todos os valores de eficiência se reduzem, devido aos maiores desafios relacionados aos processos de identificação das FAIs. Além disso, constata-se também que os medidores fasoriais contribuem para maior eficácia de implementação do método, apresentando eficiências sempre próximas ou acima de 90% para localização das faltas. Já em relação a detecção de FAI e localização da fase com defeito, o tipo de medição fornecida às RNAs não apresentou diferenças relevantes em virtude de ter sido possível obter altas eficiências independentemente do tipo de medidor.

Outro fato que também se repetiu foi a influência da quantidade de neurônios na camada oculta das RNAs no processo de localização de faltas. Os melhores resultados foram atingidos com a quantidade variando entre 20 e 30 neurônios, e novamente, os testes demonstraram que poucos neurônios não apresentam bons resultados e muitos podem não ser significado de melhor eficiência.

A respeito das posições relativas dos barramentos indicados como o de maior possibilidade de apresentar falta, tem-se que, para todos os cenários, mais de 70% se adequaram às posições a montante e a jusante da barra correta com falta, e em determinados casos essa porcentagem superou os 80%. Esses dados evidenciam que as respostas fornecidas pelas RNAs direcionam o processo de localização da falta para barramentos próximos ou iguais ao real local em que a falta ocorreu.


Outra análise a respeito da localização das FAIs é sobre o agrupamento dos barramentos do sistema em áreas delimitadas pelos medidores. Os dados mostram que a área 7 é o local onde

ocorrem os maiores acertos, e ao inspecionar o sistema, torna-se claro que a explicação para isso é o fato dessa área ser a menor e ainda possuir três medidores delimitando-a. Por outro lado, a área 3 se apresenta como a de maior dificuldade de se localizar faltas, e uma das razões para esse fato é tal área possuir apenas um medidor delimitador. Além disso, outras áreas apresentaram altas eficiências para localização de falta, como as áreas 1,2,4 e 9.

Ao se tratar do uso do algoritmo genético, tem-se que sua utilização novamente se mostrou bastante útil para otimizar os resultados obtidos pelo método proposto. Em todos os aspectos de análise foi possível obter melhores eficiências, demonstrando que a localização do medidor impacta diretamente na eficácia das RNAs desenvolvidas. Além do mais, para cada simulação, o AG indicou localizações diferentes para os medidores, comprovando que o cenário, o tipo de medição e a quantidade de neurônios interfere na composição do conjunto de medidores, mas sendo mais convergente para determinadas regiões do sistema ao se comparar com os resultados obtidos para o sistema IEEE 34 barras, e assim, não é possível indicar qual fator é mais relevante para o direcionamento dos medidores, o cenário ou o tipo de entrada.

Com o intuito de se avaliar os resultados entre as simulações com e sem otimização, o Gráfico 27 apresenta um comparativo dos acertos da indicação da barra com maior possibilidade de estar com defeito no grupo formado pelas barras prováveis, acertos os quais foram maximizados pelo AG.


Gráfico 27 – Comparativo de resultados - IEEE 123 barras



Fonte: Elaborado pelo autor (2024).

Além disso, o Gráfico 28 apresenta um comparativo de resultados obtidos com as medições fasoriais para as posições relativas da barra indicada com maior possibilidade de estar com defeito no grupo formado pelas barras prováveis.

Gráfico 28 – Comparativo de resultados para posições relativas – IEEE 123 barras



Fonte: Elaborado pelo autor (2024).



## 5 CONSIDERAÇÕES FINAIS

### 5.1 CONCLUSÕES GERAIS

Neste trabalho foi proposto um método baseado em redes neurais artificiais para a detecção e localização de faltas de alta impedância em sistemas desequilibrados de distribuição. Além disso, desenvolveu-se a aplicação de algoritmo genético para realizar a alocação ótima de medidores de corrente para melhorar a localização de faltas.

Para cada barramento do sistema de distribuição, uma RNA foi desenvolvida para realizar o processo de identificação das faltas. Dessa maneira, cada RNA foi responsável por indicar se o seu barramento associado apresentou falta em uma simulação. Além disso, também foi desenvolvida uma RNA exclusiva para cada uma das três fases do circuito, com o objetivo de localizar a fase defeituosa.

Para avaliar a capacidade das RNAs em relação ao tipo de entrada fornecido, foram utilizados três tipos diferentes de medições: não fasoriais, de sequência e fasoriais. Essa abordagem foi realizada para mostrar a eficiência do método desde com a utilização de medições mais simples, que são a maioria na distribuição atualmente, até a melhor eficiência com a utilização de medições com mais informações como as fasoriais, que se espera que possam ser cada vez mais utilizadas em sistemas de distribuição. Em todos os testes conduzidos, nota-se que a medição fasorial contribui com as melhores eficiências do método.

E de acordo com os resultados apresentados, conclui-se que uma grande quantidade de neurônios não está relacionada com melhores resultados, mas contribui de maneira expressiva com maiores tempos computacionais de simulação.

Com o intuito de avaliar a eficácia do método em diferentes sistemas de distribuição, utilizou-se os sistemas IEEE 13 barras, IEEE 34 barras e IEEE 123 barras. Todos são sistemas que possuem diferentes equipamentos e representações de características importantes de sistemas de distribuição.

Além disso, com o objetivo de averiguar a eficácia das RNAs, foram propostos diferentes cenários de simulação que apresentaram aumento progressivo da resistência de falta

e da variação de carregamento, características que dificultam o processo de identificação das faltas. A ideia foi estressar os casos para verificar a robustez do método.

De maneira geral, o método apresentou bons resultados, visto as dificuldades impostas nos testes realizados. A cada cenário proposto é possível observar que as eficiências diminuem, conforme esperado, entretanto, as RNAs ainda assim se mostraram robustas quanto a detecção de faltas e localização da fase com defeito, apresentando eficiências acima de 90% na maioria dos casos testados.

Já em relação a localização do barramento com falta, foi proposta a indicação de um grupo de barras prováveis que podem estar com defeito, e assim, reduzir o campo de busca pela falta. Dessa maneira, a eficiência de localização do barramento com falta se deu pela presença do barramento correto dentro desse grupo indicado. Os resultados obtidos pelas RNAs para localização da barra defeituosa também podem ser considerados bons, já que o método atingiu eficiências acima de 90% para todos os cenários quando considerado o uso de otimização para alocação dos medidores.

A partir da comparação dos resultados obtidos com e sem a utilização de otimização, é possível constatar também que outro fator que impacta diretamente o desempenho do método é a melhor localização dos medidores, sendo algo primordial para se obter bons resultados. Assim, o algoritmo genético para a alocação de medidores se mostrou como uma ferramenta que contribuiu satisfatoriamente com o método proposto para localização de faltas.

## 5.2 SUGESTÕES DE TRABALHOS FUTUROS

No decorrer da elaboração deste trabalho foram identificados alguns aspectos que podem ser explorados com o intuito de melhorar a representação do sistema elétrico de distribuição e o desempenho do método proposto. A seguir são apresentadas as sugestões que podem ser implementadas em trabalhos futuros:

- a) Desenvolvimento do método para detectar e localizar outros tipos de defeitos, como por exemplo faltas bifásicas e trifásicas, ocorrência de faltas simultâneas e defeitos de abertura de cabos;

- b) Representação de Recursos Energéticos Distribuídos (RED), como geração distribuída, armazenamento de energia e veículos elétricos, os quais são realidade nos sistemas de distribuição e implicam em maior incerteza em relação a demanda de energia, podendo influenciar nas correntes de falta;
- c) Avaliação do método proposto em simulações em tempo real;
- d) Consideração de erros de medição, os quais podem impactar negativamente na eficácia do método;
- e) Avaliação da quantidade ótima de medidores para cada sistema de distribuição simulado;
- f) Utilização de outros tipos de dados de entrada para as RNAs, como medições de tensão;
- g) Utilização de outras técnicas e formas de otimização para alocação dos medidores, a fim de se encontrar uma boa alocação global, evitando a aleatoriedade de acordo com o tipo de entrada, arquitetura das RNAs e os cenários.

## REFERÊNCIAS

- ACÁCIO, Luciana C. Alocação ótima de medidores para fins de detecção de falhas. **Dissertação (Mestrado)**, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora, Juiz de Fora, 2017.
- ADEEL. Rede Compacta VS Rede Convencional. **Adeel**, 2017. Disponível em: <https://adeel.com.br/rede-compacta-vs-convencional/>. Acesso em: 27 maio 2024.
- AHN, Chang W.; RAMAKRISHNA, R. S. Elitism-Based Compact Genetic Algorithms. **IEEE Transactions on Evolutionary Computation**, v.7, n. 4, ago 2003. p.367-385.
- ALJOHANI, Abdulaziz; HABIBALLAH, Ibrahim. High-Impedance Fault Diagnosis: A Review. **Energies**, v. 13, 5 dez 2020. 6447.
- ANEEL. A ANEEL, 2023. Disponível em: <https://www.gov.br/aneel/pt-br/aceso-a-informacao/institucional/a-aneel>. Acesso em: 06 março 2024.
- AZIZ, M.S. A.; HASSAN, M.A. M.; ZAHAB, E.A. High-impedance Faults Analysis in Distribution Networks Using an Adaptive Neuro Fuzzy Inference System. **Electric Power Components and Systems**, v. 40, 01 ago 2012. p. 1300-1318.
- BARROS, Benjamin F. D.; BORELLI, Reinaldo; GEDRA, Ricardo L. **Geração, Transmissão, Distribuição e Consumo de Energia Elétrica**. 1ª. ed. São Paulo: Érica, 2014.
- CAETFEST. Notícias. **CaetFest**, 2016. Disponível em: <https://www.caetfest.com.br/noticias/5855-coelba-informa-desligamento-de-energia-eletrica-dia-10-em-caetite>. Acesso em: 08 março 2024.
- CAVALARI, Carla F. Localização de faltas de alta impedância monofásicas por minimização de erros em sistemas de distribuição. **Dissertação (Mestrado)**, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora, Juiz de Fora, 2023.
- CHAKRABORTY, Soham; DAS, Sarasij. Application of Smart Meters in High Impedance Fault Detection on Distribution Systems. **IEEE Transactions on Smart Grid**, v. 10, mai 2019. p. 3465-3473.
- COPEL. Redes Subterrâneas. **Copel**, 2023. Disponível em: <https://www.copel.com/site/copel-distribuicao/poder-publico/redes-de-distribuicao-subterraneas/>. Acesso em: 29 junho 2024.

DAISY, Mohammad ; DASHTI, Rahman. Single phase fault location in electrical distribution feeder using hybrid method. **Energy**, v. 103, 15 mai 2016. p. 356-368.

DATA SCIENCE ACADEMY. **Deep Learning Book**, 2022. Disponível em: <https://www.deeplearningbook.com.br/>. Acesso em: 04 julho 2024.

DIEFENTHÄLER, Andressa T. *et al.* Artificial Neural Networks: Modeling and Comparison to Detect High Impedance Faults. **IEEE Access**, v. 11, 2023. p. 124499-124508.

DINIZ, Tamara O. Avaliação do impacto dos tipos de equipamentos de medição no desempenho da detecção de defeitos em sistemas de distribuição utilizando redes neurais. **Dissertação (Mestrado)**, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora, Juiz de Fora, 2015.

EHRENSPERGER, Juliana G. Sistemas de Medição Fasorial: Estudo e Análise do Estado da Arte. **Relatório Técnico Interno**, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, 2003.

FANUCCHI, Rodrigo Z. A Detecção e a Localização de Faltas de Alta Impedância em Sistemas de Distribuição Utilizando Transformadas Wavelets e Redes Neurais Artificiais. **Dissertação (Mestrado)**, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2014.

GHADERI, Amin; GINN, Herbet L.; MOHAMMADPOUR, Hossein A. High impedance fault detection: A review. **Electric Power Systems Research**, v. 143, fev 2017. p. 376-388.

GOLDBARG, Elizabeth ; LUNA, Henrique P. L.; GOLDBARG, Marco. **Otimização combinatória e meta-heurísticas**: algoritmos e aplicações. 1ª. ed. Rio de Janeiro: Grupo GEN, 2015.

HAYKIN, Simon. **Redes Neurais**: Princípios e prática. 2ª. ed. Porto Alegre: Bookman, 2007.

IEEE. **IEEE PES Test Feeder**. Disponível em: <https://cmte.ieee.org/pes-testfeeders/resources/>. Acesso em: 19 junho 2024.

INBRAEP. Tipos de Redes de Distribuição. **INBRAEP**, 2022. Disponível em: <https://inbraep.com.br/publicacoes/tipos-de-redes-de-distribuicao/>. Acesso em: 08 março 2024.

IURINIC, Leonardo U. *et al.* Distribution Systems High-Impedance Fault Location: A Parameter Estimation Approach. **IEEE Transactions on Power Delivery**, v. 31, n. n. 4, ago 2016. p. 1806-1814.

KAGAN, Nelson; OLIVEIRA, Carlos César B. D.; ROBBA, Ernesto J. **Introdução aos sistemas de distribuição de energia elétrica**. 2<sup>a</sup>. ed. São Paulo: Blucher, 2000.

LEDESMA, Jorge J. G. *et al.* A two-level ANN-based method using synchronized measurements to locate high-impedance fault in distribution systems. **Electric Power Systems Research**, v. 188, nov 2020. p. 106576.

LOPES, Gabriela N.; SILVA, Maurício P. D.; VIEIRA, José Carlos M. Comparison of Machine Learning-Based Methods for High Impedance Fault Detection in Distribution Systems. **2023 IEEE PES Innovative Smart Grid Technologies Europe (ISGT EUROPE)**, out 2023. p. 1-5.

LUDERMIR, Teresa B. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, v.35, abr 2021. p.85-94.

LUZIA, Leandro F.; RODRIGUES, Maurício C. **Estudo sobre as Metaheurísticas**. Instituto de Matemática e Estatística, Departamento de Ciências da Computação, Universidade de São Paulo. São Paulo. 2009.

MAMEDE FILHO, João. **Manual de Equipamentos Elétricos**. 5<sup>a</sup>. ed. Rio de Janeiro: Grupo GEN, 2019.

MAMEDE FILHO, João. **Proteção de Sistemas Elétricos de Potência**. 2<sup>a</sup>. ed. Rio de Janeiro: Grupo GEN, 2020.

MATHWORKS. What Is a Neural Network? **MathWorks**, 2018. Disponível em: <https://www.mathworks.com/discovery/neural-network.html>. Acesso em: 04 julho 2024.

MOLOI, Katleho; JORDAAN, Jacobus A.; HAMAM, Yskandar. High Impedance Fault Classification and Localization Method for Power Distribution Network. **2018 IEEE PES/IAS PowerAfrica**, Cape Town, South Africa, 2018. p. 84-89.

NASCIMENTO, Kelvin B. D. Aplicações de redes neurais artificiais na detecção e identificação de faltas monofásicas em sistemas de distribuição. **Dissertação (Mestrado)**, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora, Juiz de Fora, 2020.

OLIVEIRA, A. R. *et al.* Fault Classification in Distribution Systems Based on Fault Current Angles. **IEEE Latin America Transactions**, v.1 4, n. n. 1, jan 2016. p. 199-205.

ONS. O que é ONS. **ONS**, 2024. Disponível em: <https://www.ons.org.br/paginas/sobre-ons/o-que-e-ons>. Acesso em: 05 março 2024.

PESSOA, André Luiz D. S.; OLESKOVICZ, Mário. Fault location algorithm for distribution systems with distributed generation based on impedance and metaheuristic methods. **Electric Power Systems Research**, v. 225, dez 2023. 109871.

RIBEIRO, André L. Benefícios da rede de distribuição aérea compacta 15kV. **Trabalho de conclusão de curso**, Engenharia Elétrica, Universidade São Francisco, Itatiba, nov 2008.

SANTOS, W.C. *et al.* High-Impedance Fault Identification on Distribution Networks. **IEEE Transactions on Power Delivery**, v. 32, fev 2017. p. 23-32.

SILVA, Lucas N. M. Tipos de aprendizado de máquina e algumas aplicações. **TerraLAB**, 2021. Disponível em: <https://www2.decom.ufop.br/terralab/tipos-de-aprendizado-de-maquina-e-algumas-aplicacoes/>. Acesso em: 04 julho 2024.

SOUZA, Antônio Carlos Z. D.; ALVEZ, Cristian A.; MOURA, Renan S. **Sistemas de Distribuição de Energia Elétrica: Conceitos Básicos e Modelagem**. 1ª. ed. Rio de Janeiro: Interciência, 2024.

SOUZA, Fabiano A. D. Detecção de Falhas em Sistema de Distribuição de Energia. **Dissertação (Mestrado)**, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Estadual Paulista, Ilha Solteira, 2008.

TRINDADE, Fernanda C. L.; FREITAS, Walmir; VIEIRA, José Carlos M. Fault Location in Distribution Systems Based on Smart Feeder Meters. **IEEE Transactions on Power Delivery**, v. 29, n. 1, fev 2014. p. 251-260.

VGS GROUP. Produtos. **VGS Energia**. Disponível em: <https://www.vgsenergia.com.br/produtos/performados-e-acessorios-para-rede-compacta/braco-anti-balanco-15-kv/>. Acesso em: 08 março 202.

ZAPELINI, Christiane Z. **Um Estudo Abrangente sobre Metaheurística, incluindo um Histórico**. Instituto de Matemática e Estatística, Departamento de Ciências da Computação, Universidade de São Paulo. [S.l.]. 2009.

## APÊNDICE A – SISTEMAS DE DISTRIBUIÇÃO

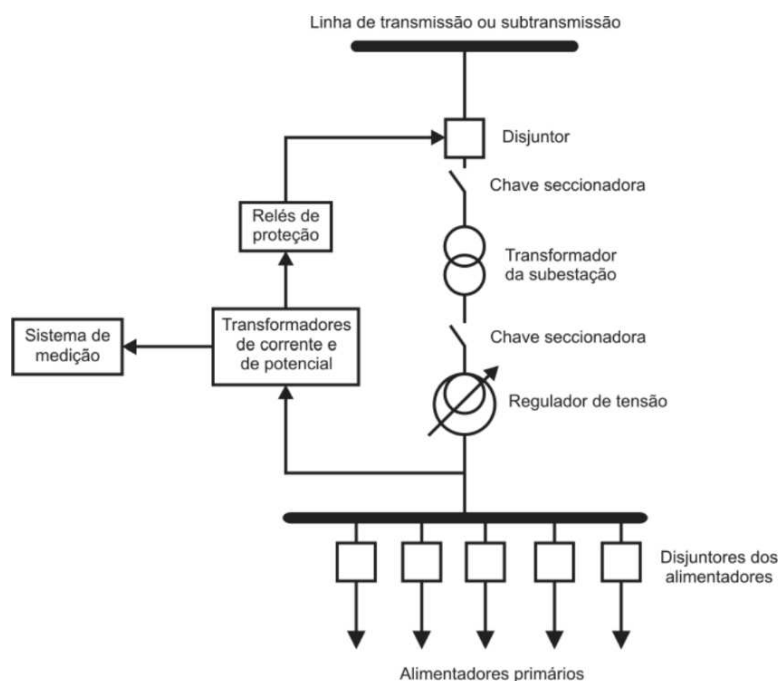
O Sistema de Distribuição (SD) é alimentado em sua maior parte através de subestações (SEs), que recebem a energia elétrica que foi gerada e transmitida muitas vezes por uma longa distância, e possui a função de fornecer eletricidade aos consumidores finais com níveis de tensão reduzidos.

As SEs são caracterizadas por receberem as linhas, de alta tensão (AT), da transmissão ou subtransmissão, normalmente, com tensões de níveis entre 69 kV e 138 kV, e distribuírem a energia elétrica, através de alimentadores primários, com valores de média tensão (MT), em sua grande maioria entre 2,3 kV e 44 kV. Esse tipo de instalação elétrica compreende equipamentos destinados à medição, proteção e transformação de energia, e dessa forma, possuem o objetivo de permitir a flexibilidade de manobras e adequação dos valores de tensão e corrente para o fornecimento de energia elétrica em condições seguras e confiáveis (BARROS, BORELLI e GEDRA, 2014). A Figura 15 ilustra um esquemático de uma subestação de distribuição simples e seus principais equipamentos presentes.

As redes de distribuição primária, localizados na saída das SEs, são responsáveis por atender os consumidores primários e os transformadores de distribuição da rede secundária. Dentre os consumidores atendidos diretamente pelos alimentadores primários têm-se as indústrias de médio porte e os *shopping centers*. Já as redes secundárias se estabelecem a partir do secundário dos transformadores, e são encarregadas de abastecer os consumidores de baixa tensão (BT), com valores entre 127 V e 440 V, como por exemplo as residências e pequenos comércios (BARROS, BORELLI e GEDRA, 2014).



Figura 15 – Esquemático de uma subestação de distribuição simples



Fonte: Souza, Alvez e Moura (2024).

Em relação à estrutura das redes de distribuição, é possível elencar quatro tipos específicos, sendo eles: aérea convencional, aérea compacta, aérea isolada e subterrânea. As redes aéreas são as redes mais utilizadas, e são caracterizadas por condutores dispostos em postes e sujeitas à maior ocorrência de defeitos, principalmente as redes convencionais com cabos nus, mas inclusive as que possuem condutores com camadas de proteção contra contatos indiretos e perturbações estão sujeitas a defeitos.

Por outro lado, as redes subterrâneas apresentam os maiores níveis de confiabilidade, por terem seus componentes enterrados no solo. Acerca dos benefícios provenientes desse tipo de rede tem-se a proteção dos cabos contra tempestades e contato indiretos com galhos de árvores e animais, menores custos de operação e valorização visual de empreendimentos (COPEL, 2023). No entanto, os investimentos necessários para se implementar as redes subterrâneas são altos quando comparados aos das redes aéreas, e assim, sua utilização se restringe, na maioria dos casos, em áreas muito densas, locais com restrições urbanísticas e projetos arquitetônicos que prezam pelo resultado estético (BARROS, BORELLI e GEDRA, 2014).

Os conjuntos de equipamentos que compõem os SDs são classificados de acordo com suas funções, e com isso, podem ser divididos entre os sistemas de medição, proteção e controle.

O sistema de medição desempenha um papel fundamental no monitoramento e gestão do fornecimento da energia elétrica, além de se integrar ao sistema de proteção, alimentando-o, por exemplo, com as medições de corrente e tensão. Seus principais equipamentos são os transformadores de corrente (TC) e potencial (TP), os quais possibilitam que os dispositivos de medição e proteção funcionem corretamente sem a necessidade de altas correntes e tensões do circuito principal.

Devido ao fato de surgirem defeitos de maneira regular nos SDs, os sistemas de proteção são implementados com a finalidade de diminuir a ocorrência de interrupções no fornecimento de energia aos consumidores, e assim, melhorar a qualidade do serviço oferecido. A função principal dos equipamentos de proteção é garantir a desconexão do trecho com falha, e de forma secundária, auxiliar na localização dos defeitos e seus respectivos reparos (MAMEDE FILHO, 2020).

Para que o sistema de proteção tenha uma boa performance, é necessário que sejam atendidos alguns critérios essenciais, como por exemplo a seletividade, a qual garante que apenas o elemento de proteção mais próximo atue na interrupção da falha. Já a sensibilidade é o critério que define a capacidade dos elementos de proteção em reconhecer com precisão suas faixas de atuação. Outro critério importante é a velocidade, a qual se refere à rapidez do tempo de atuação dos dispositivos de proteção. A confiabilidade por sua vez é o critério do sistema de proteção relacionado ao cumprimento de funções de maneira segura e exata. E por fim, a automação é uma característica fundamental que permite que os elementos de proteção operem de forma autônoma quando solicitados e retornem às suas posições sem intervenções. A seguir são apresentados os principais equipamentos que integram os sistemas de proteção e suas funções (MAMEDE FILHO, 2020).:

- Relés microprocessados: dispositivos que processam e analisam sinais elétricos em tempo real, permitindo uma detecção rápida e precisa de falhas. Eles são capazes de serem ajustados, através de programação, para atuarem de maneira integrada com sistemas de controle e comunicação, melhorando assim a seletividade e a velocidade de resposta às condições adversas. Suas funções de proteção são sobrecorrente instantânea e temporizada, subtensão, sobretensão, frequência, distância, entre outros;
- Chaves fusíveis: dispositivos de maior utilização na proteção das redes de distribuição, devido ao baixo custo e ótimo desempenho. São caracterizados por

um elo fusível que se rompe com a circulação de sobrecorrentes, interrompendo a passagem de energia elétrica.

- Disjuntores: dispositivos responsáveis por interromper a circulação de correntes de defeito em um circuito. Seu acionamento é realizado por um comando enviado pelos relés de proteção, e suas características construtivas permitem que o arco elétrico formado na abertura de circuitos energizados seja extinto de maneira segura e rápida. Caso a instalação de um disjuntor não seja feita acompanhada por um relé, o equipamento se torna apenas uma excelente chave de manobra, sem qualquer função de proteção;
- Chaves seccionadoras: dispositivos mecânicos de manobra encarregados de realizar o chaveamento dos circuitos alimentadores. Entretanto, diferentemente dos disjuntores, as chaves seccionadoras devem ser operadas sem carga, já que podem abrir arcos elétricos com a passagem de altas correntes. Sua principal função é seccionar trechos da rede de distribuição para que sejam feitos trabalhos de manutenção, reparo e reconfiguração de conexões;
- Religadores automáticos: dispositivos capazes de repetir operações de abertura e fechamento do circuito durante a ocorrência de uma falha, e dessa forma, são destinados ao reestabelecimento das redes de distribuição em ocorrências de faltas transitórias, as quais podem ser cessadas apenas pelo desligamento momentâneo do sistema.

Além dos equipamentos citados, o regulador de tensão e os capacitores são outros dispositivos que compõem o sistema de distribuição que merecem destaque. O uso desses equipamentos se dá pela necessidade de manter a tensão dos barramentos dentro dos limites especificados definidos pelo PRODIST (Procedimentos de Distribuição), para que os consumidores recebam uma energia de qualidade. Logo, a instalação desses equipamentos é bastante difundida ao longo dos alimentadores, visto que compensam as variações de carga, corrigem quedas de tensão devido aos defeitos na rede e protegem os demais equipamentos conectados ao realizarem o controle da tensão respeitando os limites definidos em norma (MAMEDE FILHO, 2019).

No que diz respeito aos consumidores abastecidos pelo sistema de distribuição é importante destacar que seus perfis de consumo são variados e estão diretamente relacionados aos tipos de carga instalada. Uma indústria de grande porte pode ter uma curva de consumo de energia constante ao longo do dia com uma carga pesada, já que o funcionamento de seu

maquinário é contínuo. Um comércio por sua vez não terá uso de energia durante o horário noturno, e uma residência apresenta seus picos de energia nos momentos em que as pessoas retornam para suas casas após o trabalho. Assim, a energia fornecida pelo sistema de distribuição deve atender cada carga de acordo com sua especificidade de potência instalada, prezando sempre pela segurança e confiabilidade, tornando a operação da rede elétrica bastante complexa e crucial para funcionamento de uma sociedade. Nesse sentido, os SDs devem possuir todo o tipo de equipamento necessário para manter a rede a pleno funcionamento, inclusive em momentos de falhas.

### A.1 FALTAS EM SISTEMAS DE DISTRIBUIÇÃO

Os sistemas de distribuição de energia elétrica estão sujeitos à ocorrência de defeitos, já que estão vulneráveis a incidentes como colisões de veículos, roubos de cabos, galhos de árvores tocando os cabos, queda de árvores, objetos lançados ou caídos de construções, pipas, entre outros (MAMEDE FILHO, 2020).

Os defeitos que podem ocorrer nos SDs podem ser caracterizados primeiramente pelo tempo de duração das faltas, sendo elas temporárias ou permanentes. As primeiras são aquelas que ocorrem de forma momentânea, geralmente devido a uma condição transitória, como o contato breve entre fases ou entre uma fase e o solo. Essas falhas são frequentemente causadas por eventos como quedas de galhos, contato com animais ou descargas atmosféricas. Já as faltas permanentes englobam todas as interrupções que não são classificadas como temporárias ou programadas. Um dos tipos mais comuns de faltas em um sistema elétrico é o curto-circuito, o qual resulta em uma sobrecorrente e um desbalanceamento da tensão (SOUZA, 2008).

Um tipo específico de defeito que ocorre na rede de distribuição primária são as chamadas Faltas de Alta Impedância (FAI), que são definidas pelo contato dos condutores energizados com uma superfície de alta resistência, algo que resulta em níveis de corrente semelhantes aos observados durante a operação normal da rede, sendo baixos o suficiente para que não haja a atuação do sistema de proteção convencional. Desse modo, esse tipo de defeito se torna difícil de ser identificado de forma autônoma pelos equipamentos instalados nos SDs, acarretando em riscos de choque elétrico à população e atrasos na recuperação do sistema (SANTOS, LOPES, *et al.*, 2017).

A intensidade da corrente de uma FAI varia conforme o tipo de superfície com a qual o cabo rompido faz contato. Para exemplificar essa característica, a Tabela 24 apresenta valores de corrente de falta para diferentes superfícies de contato em uma rede primária de 20kV.

Tabela 24 – Intensidade das correntes de FAI em diferentes superfícies

Superfície	Corrente (A)
Concreto armado	75
Gramma molhada	50
Terra molhado	40
Gramma seca	25
Terra seca	20
Areia molhada	15
Asfalto molhado	< 1
Areia seca	< 1

Fonte: Aljohani e Habiballah (2020).

Os principais aspectos que definem um curto-circuito como uma FAI, além da baixa variação da corrente de falta, são apresentados a seguir (ALJOHANI e HABIBALLAH, 2020):

- Intermittência de contato com o solo: arcos elétricos instáveis, harmônicos e ruídos nas medições;
- Assimetria e aleatoriedade: a intermitência provoca mudança da magnitude da corrente a cada ciclo;
- Não linearidade: a relação entre os sinais senoidais de corrente e tensão se torna não linear;
- *Build-up* e *shoulder*: a magnitude da corrente aumenta durante alguns ciclos (*Build-up*) até atingir um estado estacionário (*shoulder*).

## APÊNDICE B – TIPOS DE MEDIÇÕES

O monitoramento da rede de distribuição é essencial para assegurar a eficiência e a confiabilidade do sistema elétrico. Através de uma supervisão contínua, é possível identificar e mitigar problemas como falhas técnicas, perdas de energia e oscilações de tensão, antes que se tornem defeitos significativos. Devido à grande extensão e ramificação dos SDs, as concessionárias realizam as medições em locais estratégicos dos alimentadores primários (preferencialmente), a fim de que os custos com a instalação de equipamentos sejam reduzidos ao passo que as normas estabelecidas pela ANEEL sejam respeitadas. Dentre os locais de alocação de medidores, destacam-se a saída dos alimentadores da subestação de distribuição, os transformadores de distribuição e religadores e/ou equipamentos do sistema de proteção (NASCIMENTO, 2020).

Os tipos de medições realizadas pelos dispositivos de monitoramento podem ser não fasoriais ou fasoriais, sendo a primeira categoria a mais utilizada pelas distribuidoras em virtude dos valores econômicos, e os tipos de grandezas medidas são corrente, tensão, potência, frequência, etc. (DINIZ, 2015).

### B.1 MEDIDORES NÃO-FASORIAIS

Os medidores não-fasoriais são definidos por medir exclusivamente os módulos das grandezas de interesse. Como a medição é feita na rede de média tensão, são usados transformadores de instrumentos para auxiliar no processo de conversão de altas tensões ou correntes em valores adequados para os relés de medição, bem como para os medidores. Uma das principais vantagens desses equipamentos é o isolamento do sistema de medição em relação ao circuito primário de MT. Os transformadores de instrumentos dividem-se em duas categorias, Transformador de Corrente (TC) e Transformador de Potencial (TP).

Os TCs utilizados nos sistemas de medição são equipamentos instalados em série com os alimentadores primários e transformam as correntes de carga em um nível padronizado, na maioria dos casos, de 5 amperes, para que sejam compatíveis com as correntes nominais dos demais equipamentos (MAMEDE FILHO, 2019).

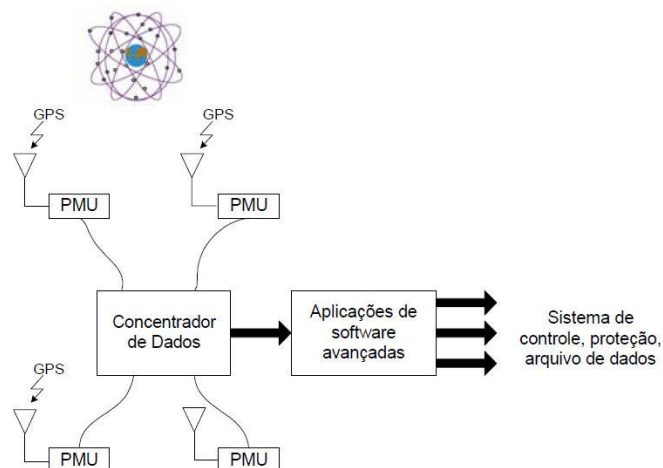
Os TPs, por sua vez, são instalados em paralelo com os alimentadores primários e são utilizados nos sistemas de medição para abaixarem os níveis de tensão para os demais equipamentos medidores. A construção desses equipamentos é baseada em um enrolamento primário de muitas espiras e um enrolamento secundário que proporciona uma relação de transformação normalmente padronizada em 115 V ou  $115/\sqrt{3}$  V (MAMEDE FILHO, 2019).

## B.2 MEDIDORES FASORIAIS

Os medidores fasoriais são equipamentos capazes de medir, além dos módulos, os ângulos e frequências das grandezas de interesse. Atualmente, um dos dispositivos que possibilita a realização desse tipo de medição em sistemas de distribuição são unidades de medição fasorial, conhecidas como PMU (*Phasor Measurement Units*). As PMUs, juntamente com o concentrador de dados fasoriais, conhecido como PDC (*Phasor Data Concentrator*), integram o que é chamado de Sistemas de Medição Fasorial Sincronizados (SMFS) (EHRENSPERGER, 2003).

O funcionamento de um SMFS é baseado na aquisição, feita pelas PMUs, dos fasores de corrente e/ou tensão, os quais posteriormente são enviados via satélite aos PDCs de forma sincronizada por GPS (*Global Positioning System*) para que seja feito o monitoramento da rede em tempo real (EHRENSPERGER, 2003). O esquemático de um SMFS é exibido na Figura 16.

Figura 16 – Esquemático de um SMFS



Fonte: Ehrensperger (2003).

Apesar das vantagens proporcionadas pelo uso de um SMFS, como por exemplo a minimização de erros de convergência e de estimação de estados, e maior confiabilidade na detecção de defeitos nos mais diversos sistemas, sua adoção ainda é baixa, devido ao alto investimento necessário para a aquisição dos equipamentos utilizados (NASCIMENTO, 2020). No entanto, muitos trabalhos vêm sendo desenvolvidos considerando o emprego dos SMFS, já que em um futuro próximo, a tendência é que as concessionárias realizem a substituição dos equipamentos instalados por PMUs.

### B.3 MEDIDORES DE SEQUÊNCIA

Os medidores de sequência são definidos pela aquisição das componentes simétricas das grandezas de interesse, obtidas por meio das medições fasoriais, através da aplicação do Teorema de Fortescue. A transformação dos fasores em componentes simétricas normalmente é feita em sistemas elétricos polifásicos que possuem tensões e correntes desequilibradas, e quando aplicado o teorema em circuitos trifásicos, os fasores são decompostos em três sistemas equilibrados, sendo estes formados por componentes de sequência positiva, negativa e zero. A equação (6) demonstra a aplicação do Teorema de Fortescue para a obtenção das componentes de sequência dos fasores de corrente.

$$\begin{bmatrix} I_0 \\ I_1 \\ I_2 \end{bmatrix} = \frac{1}{3} \cdot \begin{bmatrix} 1 & 1 & 1 \\ 1 & \alpha & \alpha^2 \\ 1 & \alpha^2 & \alpha \end{bmatrix} \cdot \begin{bmatrix} I_A \\ I_B \\ I_C \end{bmatrix} \quad (6)$$

Onde:

- $I_0$ ,  $I_1$  e  $I_2$  são as componentes de sequência zero, positiva e negativa, respectivamente, dos fasores das correntes;
- $\alpha = 1 \angle 120^\circ$ ;
- $\alpha^2 = 1 \angle -120^\circ$ ;
- $I_A$ ,  $I_B$  e  $I_C$  são os fasores das correntes das fases A, B e C, respectivamente;

A corrente de sequência zero ( $I_0$ ) se decompõe em três fasores de mesmo módulo e ângulo de defasagem, e está relacionada com as correntes que fluem para a terra no sistema original. Já a corrente de sequência positiva ( $I_1$ ) se decompõe em três fasores de mesmo módulo e com ângulo de defasagem igual a  $120^\circ$ , ou seja, na mesma sequência de fase do sistema



original, e está relacionada com as correntes de operação normal do sistema original. Por fim, a corrente de sequência negativa ( $I_2$ ) se decompõe em três fasores de mesmo módulo e com ângulo de defasagem igual a  $-120^\circ$ , ou seja, na sequência de fase inversa do sistema original, e está relacionada com o desequilíbrio das correntes do sistema original.

Para realizar os cálculos das componentes simétricas são utilizados os relés microprocessados, já que são capazes de realizar tal processamento de dados e possuem funções de proteção que incluem as correntes em medições de sequência.

## APÊNDICE C – REDES NEURAIAS ARTIFICIAIS

Os métodos computacionais baseados em técnicas de inteligência artificial (IA) frequentemente se inspiram em comportamentos inteligentes observados na natureza para solucionar problemas complexos. Essas técnicas proporcionam soluções eficientes para tarefas relacionadas a reconhecimento de padrões, tomadas de decisão, execução de tarefas repetitivas, análise preditiva, as quais podem ser aplicadas em diferentes áreas como transporte, finanças, engenharia, medicina e linguagem (LUDERMIR, 2021).

O Aprendizado de Máquina (AM), conhecido também como *Machine Learning*, é uma técnica de IA que se baseia no desenvolvimento de algoritmos que possibilitem as máquinas aprenderem a partir de dados fornecidos a elas, melhorando seus desempenhos ao longo do tempo sem serem explicitamente programadas para cada tarefa. Existem três tipos de AM: supervisionado, não supervisionado e por reforço (SILVA, 2021).

O aprendizado supervisionado consiste no treinamento da máquina através de dados de entrada e saída de um sistema. Dessa maneira, a máquina aprende a fornecer a resposta adequada diante de novos dados de entrada, baseando-se no ensinamento prévio que lhe foi dado.

O aprendizado não supervisionado, por outro lado, oferece à máquina apenas os dados de entrada para treinamento, na expectativa de que as respostas sejam classificadas de acordo com padrões observados pela própria máquina.

O aprendizado por reforço se baseia em um algoritmo de treinamento que oferece um sinal de reforço à medida que a máquina responde aos dados de entrada. Esse sinal de reforço pode ser uma recompensa ou uma punição, e dessa forma, a máquina aprende a exibir saídas que sejam consideradas boas.


Dentre as técnicas de AM desenvolvidas, destacam-se as Redes Neurais Artificiais (RNA), as quais se baseiam no funcionamento do cérebro humano. Esse método bioinspirado permite que os neurônios, unidades básicas do sistema nervoso biológico, sejam emulados a fim de processar as informações de entrada e se adaptarem de acordo com o treinamento recebido para proporcionar respostas desejadas. A seguir apresentadas os princípios básicos das RNAs.

## C1. NEURÔNIO ARTIFICIAL

O neurônio é a principal célula do cérebro humano, sendo especializado na transmissão de informações através de propriedades de excitabilidade e condução de mensagens nervosas. Ele é composto por três partes principais: soma (ou corpo celular), dendritos (ramificações que recebem sinais de outros neurônios) e axônio (ramificação que transmite sinais para outros neurônios).

A comunicação entre neurônios ocorre nas sinapses, momento em que as terminações axônicas de um neurônio encontram dendritos de outro. Os sinais processados pelo corpo celular são enviados através do axônio, e se o sinal for superior a um certo limiar, ele continua; caso contrário, é bloqueado. Esse processo permite que os neurônios formem redes neurais complexas que processam informações de maneira paralela e adaptativa, com variações na quantidade de neurônios, sinapses e pesos sinápticos em diferentes regiões do cérebro, amplificando e atenuando os sinais processados. Essas redes inspiraram o desenvolvimento de modelos matemáticos de neurônios, base da inteligência artificial (DATA SCIENCE ACADEMY, 2022). A Figura 17 apresenta um modelo simplificado do neurônio biológico.

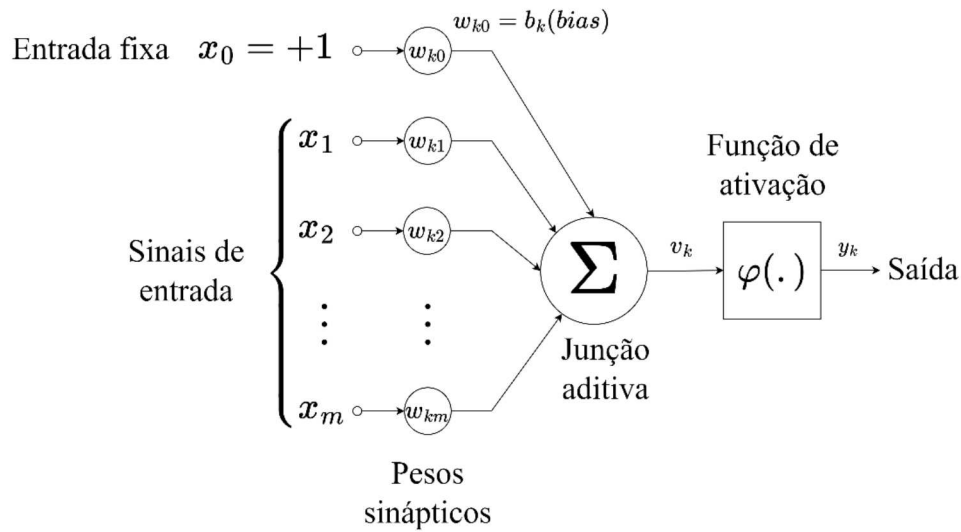
Figura 17 – Modelo simplificado do neurônio biológico



Fonte: Data Science Academy (2022).

Os modelos matemáticos de neurônios tiveram início em 1943, a partir do trabalho de Warren McCulloch e Walter Pitts, o qual implementou de maneira simplificada o funcionamento de um neurônio. Posteriormente, o trabalho realizado por Frank Rosenblatt em 1957 foi responsável por desenvolver o *Perceptron*, um neurônio artificial com capacidade de aprendizado para classificar resultados de forma linear (HAYKIN, 2007). A Figura 18 ilustra a arquitetura de um *Perceptron*.

Figura 18 – Arquitetura de um neurônio artificial

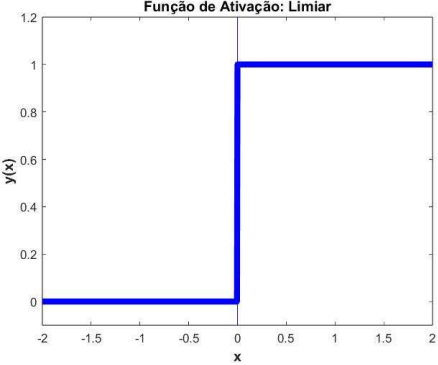
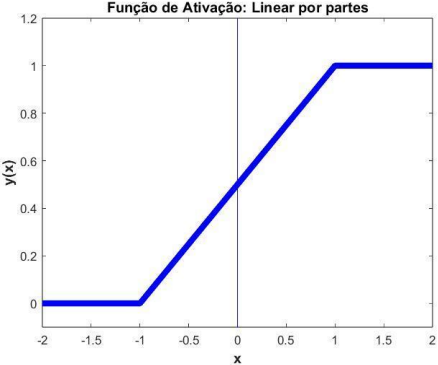
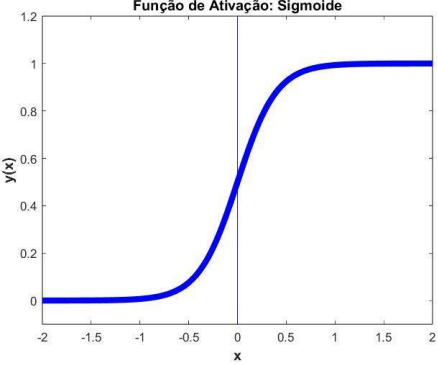
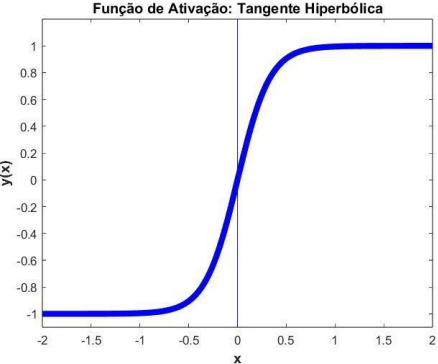


Fonte: Adaptado de Haykin (2007).

Por meio do esquemático apresentado é possível observar que o neurônio recebe múltiplos sinais de entrada ( $x_0, x_1, x_2, \dots, x_m$ ) e produz um único sinal de saída ( $y_k$ ), que pode ser usado como entrada para outros neurônios em uma rede neural artificial. As entradas são multiplicadas por pesos sinápticos ( $w_{k0}, w_{k1}, w_{k2}, \dots, w_{km}$ ), e esses produtos são somados formando um sinal intermediário ( $v_k$ ). O resultado dessa soma ponderada é aplicado em uma função de ativação ( $\varphi(\cdot)$ ) que restringe a amplitude do sinal de saída. A inclusão do parâmetro bias ( $b_k$ ) se torna importante para que aproximação da saída da rede seja melhor ajustada, já que esse sinal permite que saídas não nulas sejam obtidas mesmo com entradas nulas.

As funções de ativação normalmente restringem as saídas dos neurônios no intervalo  $[0,1]$  ou  $[-1,1]$ , e assim, as principais funções de ativação utilizadas são a limiar, linear por partes, sigmoide e tangente hiperbólica (HAYKIN, 2007). A Tabela 25 apresenta as principais funções de ativação, suas equações e exemplos de gráficos.

Tabela 25 – Principais funções de ativação

Função de Ativação	Equação	Gráfico
Limiar	$y(x) = \begin{cases} 1, & \text{se } x \geq x_0 \\ 0, & \text{se } x < x_0 \end{cases}$	 <p>Função de Ativação: Limiar</p>
Linear por partes	$y(x) = \begin{cases} 0, & \text{se } x \leq x_1 \\ ax + b, & \text{se } x_1 < x < x_2 \\ 1, & \text{se } x \geq x_2 \end{cases}$	 <p>Função de Ativação: Linear por partes</p>
Sigmoide	$y(x) = \frac{1}{1 + e^{-ax}}$	 <p>Função de Ativação: Sigmoide</p>
Tangente hiperbólica	$y(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	 <p>Função de Ativação: Tangente Hiperbólica</p>


Fonte: Elaborado pelo autor (2024).

## C2. ARQUITETURA DAS RNAS

As redes neurais artificiais são basicamente o agrupamento de vários neurônios em camadas com características específicas para o processamento de dados. Tais camadas são divididas em três categorias, entrada, oculta e saída.

A camada de entrada é responsável por receber os sinais para processamento e a de saída por expressar os resultados obtidos após o treinamento das RNAs. Entre essas duas camadas podem ser inseridas uma ou mais camadas, as quais serão nomeadas de camadas ocultas, caracterizando as redes *perceptrons* de múltiplas camadas. A Figura 19 mostra um esquemático da arquitetura de uma RNA de múltiplas camadas.

Figura 19 – Esquemático da arquitetura de uma RNA



Fonte: Adaptado de Data Science Academy (2022).

De acordo com a quantidade de camadas e a forma como se comunicam, as RNAs podem ser classificadas da seguinte forma (MATHWORKS, 2018):

- *Feed-Forward*: típica RNA em que o fluxo de dados segue da entrada para a saída, ou seja, as atividades dos neurônios em cada camada são influenciadas apenas pelos processamentos realizados na camada anterior;
- Recorrente: RNA em que a saída de algumas camadas pode realimentar entradas de camadas anteriores, existindo assim uma retropropagação de dados. Essas RNAs são muito utilizadas em tarefas que possuem dados sequenciais, como por exemplo a previsão de séries temporais;

- Convolutacional: RNA especializada no reconhecimento de objetos e classificação de imagens.

### C.3 TREINAMENTO DAS RNAS

O treinamento das redes neurais artificiais (RNAs) é essencial para ajustar os pesos sinápticos, permitindo que a rede aprenda a mapear corretamente as entradas para as saídas desejadas. Além disso, o treinamento contínuo com novos dados melhora a precisão e adaptabilidade do modelo. Assim, a etapa o treinamento das RNAs é crucial para seu desempenho, eficiência e aplicação prática em diversas tarefas.

Como mencionado anteriormente, métodos caracterizados como Aprendizado de Máquina possuem três tipos de treinamentos, e desse modo, os mais utilizados em RNAs são os supervisionados e os não supervisionados. Além disso, uma consideração importante a ser feita sobre o processo de treinamento é a utilização do algoritmo de retropropagação de erro, conhecido como *back-propagation*. Esse algoritmo é amplamente empregado e se baseia na correção das saídas das RNAs por meio de uma retropropagação do erro através das camadas para que os pesos sinápticos sejam ajustados, fazendo com que as respostas reais das redes neurais se adequem às respostas esperadas (HAYKIN, 2007).

## APÊNDICE D – ALGORITMO GENÉTICO

Métodos de otimização são técnicas desenvolvidas para realizar a busca da melhor solução dentro de um conjunto de restrições de um determinado problema. A implementação dessas técnicas destina-se a minimizar ou maximizar uma função objetivo, a qual representa de forma matemática o problema a ser solucionado. Atualmente, existem diferentes categorias de métodos de otimização, e dessa forma, a técnica a ser utilizada é escolhida de acordo com a natureza do problema, o tamanho do espaço de soluções, as restrições impostas e os recursos computacionais disponíveis.

Ao se tratar de problemas complexos em que a busca pela solução exata seja inviável devido a grande quantidade de soluções possíveis, as metaheurísticas se destacam. Esse método de otimização, apesar de não garantir a otimalidade da solução encontrada, fornece uma resposta de boa qualidade ao aplicar estratégias que guiam o processo de busca de maneira eficiente ao diminuir o espaço de soluções, proporcionando um melhor desempenho computacional (ZAPELINI, 2009). As principais técnicas que compõe essa categoria são Algoritmo Genético, Colônia de Formigas, *Particle Swarm Optimization*, *Bat Algorithm*, entre outros.

O Algoritmo Genético (AG) é um método de otimização baseado na Teoria da Evolução de Charles Darwin. O algoritmo desenvolvido utiliza um modelo evolucionário que aplica três princípios de Darwin: variação genética, hereditariedade e seleção natural. O primeiro princípio está relacionado às mutações e recombinações de genes em um indivíduo. A hereditariedade se refere às características genéticas da população, sendo preservadas pelos indivíduos e transmitidas dos pais para os filhos. Por fim, a seleção natural é responsável por selecionar os indivíduos que possuam as melhores características genéticas (GOLDBARG, LUNA e GOLDBARG, 2015).

Assim, para que seja implementado esse comportamento biológico através de algoritmos computacionais, algumas considerações e adaptações devem ser feitas para que a otimização simule o processo de evolução de uma população a fim de fornecer como resposta final uma solução de boa qualidade. A codificação do problema é fundamental para que as variáveis de processo, como os genes de cada indivíduo, possam ser manipuladas pelo algoritmo através de operadores genéticos.

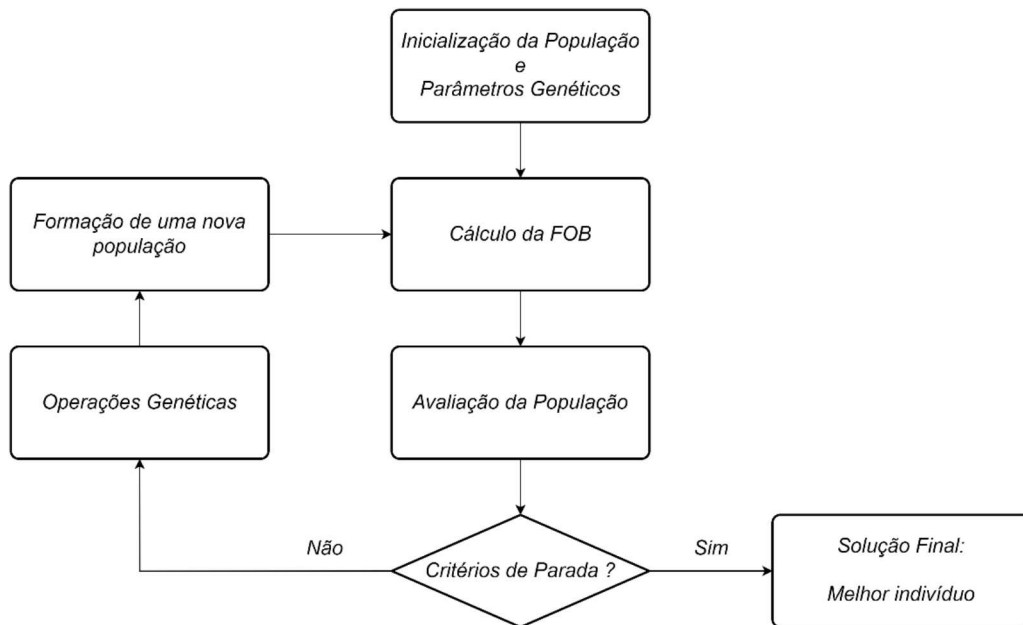


A implementação de um algoritmo genético pode ser realizada pelas seguintes etapas (LUZIA e RODRIGUES, 2009):

- Criação da população inicial: nesta etapa são determinados os indivíduos que irão compor a primeira população. Essa população representa o conjunto inicial de soluções possíveis para o problema. O tamanho da população não deve ser muito grande, pois o tempo computacional gasto durante a busca pela melhor solução seria afetado. No entanto, uma população pequena pode não ser suficiente para explorar de maneira eficiente o espaço de busca. Além disso, na maioria dos casos a criação dos indivíduos é feita de maneira aleatória, porém existem alguns trabalhos que estudam técnicas que permitam a escolha de uma solução inicial melhor, influenciando todo o processo evolucionário do algoritmo;
- Cálculo da função objetivo (FOB): nesta etapa os indivíduos são classificados por meio de uma função objetivo, conhecida também como função de aptidão (*fitness function*). Em muitos casos, a função de aptidão é única ligação verdadeira do algoritmo com o problema real, já que essa função irá atribuir valores a cada indivíduo para que posteriormente para que a população possa ser avaliada e os melhores indivíduos sejam identificados;
- Operações genéticas: a cada iteração do método, casos os critérios de parada não sejam atingidos, uma nova população é reproduzida para a próxima geração através dos operadores genéticos (seleção, cruzamento e mutação) com o intuito de obter melhores indivíduos para solucionar o problema;
- Critérios de parada: para que o processo iterativo do método não seja infinito, é necessário impor alguns limites para que ocorra a parada do método. Os principais critérios utilizados são: número máximo de gerações, tempo de execução e estagnação dos indivíduos.

Para um melhor entendimento, um fluxograma do funcionamento simplificado do algoritmo genético é apresentado na Figura 20.

Figura 20 – Fluxograma simplificado do algoritmo genético



Fonte: Elaborado pelo autor (2024).

#### D.1 NOMENCLATURAS

Para que se tenha uma melhor compreensão do funcionamento do AG, a seguir são apresentadas as nomenclaturas utilizadas na biologia e o que representam no processo de otimização:

- a) Indivíduo ou cromossomo: representação de uma solução, a qual é composta por uma sequência de caracteres;
- b) Gene: representação de cada um dos caracteres que compõe um cromossomo, ou seja, características que definem uma solução;
- c) População: representa um conjunto de soluções;
- d) Geração: representa a evolução da população, ou seja, está relacionada ao novo conjunto de soluções formado a cada iteração;
- e) Genótipo: representa a codificação da solução por meio de uma sequência de genes para implementar o problema real através do AG;
- f) Fenótipo: representa a decodificação da solução para retorná-la ao problema real.
- g) Seleção: representa a escolha dos melhores indivíduos para serem reproduzidos e formar a nova população, ou seja, a escolha das melhores soluções para formar um novo conjunto de soluções;

- h) Cruzamento: operador genético que representa a forma como novas soluções são geradas;
- i) Mutação: operador genético que proporciona aleatoriedade genética na reprodução de um indivíduo, ou seja, proporciona diversidade na geração de uma nova solução.

## D.2 OPERADORES GENÉTICOS

Os operadores genéticos são ferramentas utilizadas pelo AG para que ocorra a implementação da teoria da evolução na busca da melhor resposta possível para o problema a ser otimizado. Através desses operadores, o espaço de busca é explorado de maneira eficiente e as soluções encontradas tendem a ser melhores que as anteriores. A seguir são apresentados os principais operadores genéticos.


### D.2.1 SELEÇÃO

O processo evolutivo artificial, para que seja implementado, necessita do estabelecimento de critérios que manipularão o processo reprodutivo dos indivíduos. Com o intuito de simular a teoria de Darwin, o operador genético de seleção deve priorizar indivíduos de maior aptidão, mas não deve excluir indivíduos que são considerados inferiores, pois os mesmos podem conter genes que sejam favoráveis à criação de um indivíduo de boa aptidão (GOLDBARG, LUNA e GOLDBARG, 2015).

Dentre as formas de realizar a seleção artificial dos indivíduos, destacam-se os seguintes métodos: Torneio, Classificação por Ranking, Roleta, Sorteio Universal.

O método de Torneio se baseia no modelo de *play-off*, similar ao de campeonatos esportivos. Os indivíduos da população são escolhidos dois a dois para se ‘enfrentarem’, sendo o vencedor determinado pela maior aptidão. A cada fase de enfrentamento, metade da população é eliminada, e o número de fases é determinado pela quantidade de indivíduos que serão utilizados para se reproduzirem e formar a nova população. A Figura 21 exemplifica a seleção dos indivíduos pelo método de Torneio.


Figura 21 – Exemplo de seleção pelo método de Torneio



Fonte: Adaptado de Goldberg, Luna e Goldberg (2015).

O método da Classificação por Ranking faz o ordenamento dos indivíduos da população através de um ranking decrescente, ou seja, do indivíduo de maior aptidão para o de menor aptidão. Dessa maneira, são selecionados os indivíduos de melhor aptidão de acordo com a quantidade estabelecida para reprodução. A Figura 22 exemplifica a seleção dos indivíduos pelo método de Classificação por Ranking.


Figura 22 – Exemplo de seleção pelo método de Classificação por Ranking



Fonte: Adaptado de Goldberg, Luna e Goldberg (2015).

O método da Roleta consiste na representação de cada indivíduo através de uma parcela de uma roleta fictícia. A parcela relativa a cada indivíduo é diretamente proporcional a sua aptidão. Dessa maneira, ao realizar o ‘giro’ dessa roleta, os indivíduos de maior aptidão terão maior probabilidade de serem sorteados. A quantidade de sorteios é definida pelo número de indivíduos que serão utilizados na reprodução.

Figura 23 – Exemplo de seleção pelo método da Roleta



Fonte: Adaptado de Goldberg, Luna e Goldberg (2015).

O método de Sorteio Universal é similar ao da Roleta, no entanto, os indivíduos são sorteados com igual probabilidade, sem distinção. Apesar de ser prático, esse método pode não ser eficiente para selecionar os melhores indivíduos, já que não existe diferença entre os de maiores e os de menores aptidão.

#### *D.2.2 CRUZAMENTO*


O processo de cruzamento é um operador genético que se inicia após a operação de seleção. O cruzamento é responsável pela reprodução de novo indivíduos, realizar a mistura do genético dos pais para a criação dos filhos que irão compor a população da próxima geração. Além disso, como normalmente o tamanho da população é mantido constante, durante a etapa de reprodução deve-se determinar se alguns indivíduos irão permanecer ‘vivos’ para a próxima geração ou se todos os pais serão substituídos por seus filhos.

Denomina-se elitismo a técnica de garantir que os melhores indivíduos sejam preservados para que o bom material genético não se perca durante os procedimentos de reprodução. Assim, a cada geração, uma parcela da população é mantida para a próxima, visando melhorar o desempenho do método de otimização. Entretanto, o elitismo deve ser utilizado com moderação, pois pode provocar convergência prematura devido a pouca diversidade genética caso a fração considerada elite seja grande. Normalmente, são escolhidos de 1 a 10% dos indivíduos da população como elite (AHN e RAMAKRISHNA, 2003).

O processo de cruzamento pode ser feito através de formas: cruzamento de um ponto, cruzamento por múltiplos pontos e cruzamento uniforme.

O cruzamento de um ponto é definido pela escolha de um ponto de corte na sequência de genes dos pais. A partir desse ponto, uma combinação é feita com as parcelas cortadas de cada pai para a formação de dois filhos. A Figura 24 apresenta um exemplo de cruzamento de um ponto.


Figura 24 – Exemplo de cruzamento de um ponto



Fonte: Adaptado de Goldberg, Luna e Goldberg (2015).

O cruzamento por múltiplos pontos é a técnica de reprodução que apresenta mais de um ponto de corte, aumentando a diversidade da combinação genética para a criação de filhos. A Figura 25 apresenta um exemplo de cruzamento por múltiplos pontos.

Figura 25 – Exemplo de cruzamento por múltiplos pontos



Fonte: Adaptado de Goldberg, Luna e Goldberg (2015).

O cruzamento uniforme é caracterizado por não possuir pontos de corte. A combinação dos genes dos pais é feita através de uma distribuição de probabilidade uniforme. A Figura 26 apresenta um exemplo de cruzamento uniforme, sendo possível observar que a sequência genética dos filhos é dividida igualmente entre os pais.

Figura 26 – Exemplo de cruzamento uniforme

<i>PAI 1</i>	4	1	6	3	9	8	1	2
<i>PAI 2</i>	5	8	1	2	4	7	6	3
<i>FILHO 1</i>	4	8	6	2	9	7	1	3
<i>FILHO 2</i>	5	1	1	3	4	8	6	2

Fonte: Adaptado de Goldberg, Luna e Goldberg (2015).


### D.2.3 MUTAÇÃO

A mutação é o operador genético responsável pela mudança aleatória dos genes dos indivíduos. A função desse operador é aumentar a diversidade genética das soluções para que o espaço de busca seja explorado da melhor forma. Sua aplicação é feita após a etapa de reprodução, fazendo com que os filhos gerados tenham a possibilidade de ter suas características alteradas por meio de genes que não poderiam ser herdados de seus pais.

É importante ressaltar que no contexto do algoritmo genético, as taxas de mutação adotadas, quando comparadas com a biologia, são relativamente altas, podendo ser até irrealistas, já que esse operador é utilizado com fins de diversificação genética para melhoria do desempenho do método de otimização. Ademais, o valor escolhido para as taxas de mutação também deve ser moderado, pois uma alta taxa de mutação pode tornar o processo de criação de uma nova população muito aleatório, porém baixas taxas podem causar estagnação do algoritmo, restringindo o espaço de busca de soluções a ótimos locais. Na literatura, a recomendação geral é que o indivíduo sofra mutação em apenas um gene, ou, caso a sequência genética seja grande, alguns autores recomendam uma taxa de  $1/n$ , onde  $n$  representa a

quantidade de genes do indivíduo (GOLDBARG, LUNA e GOLDBARG, 2015). A Figura 27 ilustra exemplos de mutação em um indivíduo.

Figura 27 – Exemplos de mutação em um indivíduo



Fonte: Adaptado de Goldberg, Luna e Goldberg (2015).