



**INSTITUTO FEDERAL DE CIÊNCIA E TECNOLOGIA DE PERNAMBUCO**

**Campus Garanhuns**

**Curso de Bacharelado em Engenharia Elétrica**

**EDUARDO FELIPE LAURINDO VIEIRA**

**LOCALIZADOR DE FALTAS UTILIZANDO MEDIÇÃO EM REGIME PERMANENTE  
E REDES NEURAIAS ARTIFICIAIS**

**Garanhuns**

**2022**

EDUARDO FELIPE LAURINDO VIEIRA

**LOCALIZADOR DE FALTAS UTILIZANDO MEDIÇÃO EM REGIME PERMANENTE  
E REDES NEURAIAS ARTIFICIAIS**

Trabalho de conclusão de curso apresentado à Coordenação de Graduação em Engenharia Elétrica do Instituto Federal de Ciência e Tecnologia de Pernambuco – Campus Garanhuns, como requisito para obtenção do título de Engenheiro Eletricista.

Orientador: Prof. Dr. Rafael Mendonça Rocha Barros.

Garanhuns

2022

V6581

Vieira, Eduardo Felipe Laurindo.

Localizador de faltas utilizando medição em regime permanente e redes neurais artificiais / Eduardo Felipe Laurindo Vieira ; orientador Rafael Mendonça Rocha Barros, 2022.

72 f. : il.

Orientador: Rafael Mendonça Rocha Barros.

Trabalho de Conclusão de Curso (Graduação) – Instituto Federal de Pernambuco. Pró-Reitoria de Ensino. Diretoria de Ensino. Campus Garanhuns. Coordenação do Curso Superior em Engenharia. Curso de Bacharelado em Engenharia Elétrica, 2022.

1. Energia elétrica – Distribuição. 2. Falhas de energia elétrica. 3. Sistemas de energia elétrica 4. Inteligência artificial. 5. Redes neurais (Computação). I. Título.

CDD 621.31

Andréa Maria Lidington Lins –CRB4/868

EDUARDO FELIPE LAURINDO VIEIRA

**LOCALIZADOR DE FALTAS UTILIZANDO MEDIÇÃO EM REGIME PERMANENTE  
E REDES NEURAIS ARTIFICIAIS**

Trabalho Aprovado em: / / .

---

Prof. Dr. Rafael Mendonça Rocha Barros

Orientador

---

Prof. Dr. Diego Soares Lopes

Avaliador Interno

---

Prof. Dr. Marcus Túlius Barros Florentino

Avaliador Externo

## **AGRADECIMENTOS**

Primeiramente agradeço a Deus que me ajudou a escrever este trabalho e a minha família que sempre me apoiou em toda minha jornada durante este curso, queria agradecer também aos meus colegas de curso pois me ajudaram bastante durante o período da graduação.

Agradeço também ao meu orientador Rafael Mendonça Roca Barros que me guiou ao decorrer deste processo e ao Instituto Federal de Pernambuco - Campus Garanhuns que me proporcionou todo meu conhecimento na área de Engenharia Elétrica.

## RESUMO

O sistema de distribuição cresce continuamente elevando assim cada vez mais a probabilidade do surgimento de faltas em suas linhas. Com o intuito de resolver essa problemática foi desenvolvido um programa que consegue, através dos valores eficazes das grandezas elétricas da barra principal de um sistema de distribuição indicar possíveis previsões do local da ocorrência de uma falta do sistema. Para a implementação do programa foi utilizado um software de simulação de faltas, o OpenDSS, um para programação em Python, o Pycharm e um software de redes neurais artificiais, o KNIME, para previsão de dados. Com a aplicação de faltas em todos barramentos e o uso de inteligência artificial, foi possível adquirir grandezas elétricas como tensão, corrente, potência, fator de potência e criar Redes Neurais Artificiais. Como resultados obteve-se as previsões dos locais da falta, seus erros que foram próximos a zero e então foi possível concluir que a RNA consegue determinar de forma eficiente a localização da falta, se tornando um projeto atrativo para concessionárias de energia, visto que, pode-se reduzir com os localizadores de faltas custos energéticos, custos com deslocamentos e o tempo sem energia elétrica, aumentando então os índices de satisfação do cliente.

Palavras-chave: Localizador de Faltas. Sistema de Distribuição de Energia. Redes Neurais Artificiais.

## **ABSTRACT**

The distribution system grows continuously thus increasing the probability of the emergence of faults in its lines. In order to solve this problem was developed a program that can, through the RMS values of the electrical quantities of the main bar of a distribution system indicate possible predictions of the location of the occurrence of a system fault. For the implementation of the program was used three softwares: simulation of faults, programming in Python, and a software of artificial neural nets, the KNIME, for data prediction. With the application of faults in all buses and the use of artificial intelligence it was possible to acquire electrical quantities such as voltage, current, power and power factor and create Artificial Neural Networks. As results we obtained the predictions of the fault sites and their errors and then it was possible to conclude that the RNA can efficiently determine the location of the fault, becoming an attractive project for since, one can reduce with fault locators, energy costs, travel costs and time without electricity, thus increasing customer satisfaction rates.

**Keywords:** Fault Locator. Power Distribution System. Artificial Neural Networks.

## LISTA DE ABREVIATURAS

ABNT	Associação Brasileira de Normas Técnicas
ABRADEE	Associação Brasileira de Distribuidores de Energia Elétrica
ANSI	American National Standards Institute
BT	Baixa Tensão
CPFL	Companhia Paulista de Força e Luz
CENS	Custo Social de Energia Não Suprida
DEC	Duração Equivalente de Interrupções por Unidade Consumidora
EA	Erro Absoluto
EMQ	Erro Médio Quadrático
FEC	Frequência Equivalente de Interrupções por Unidade Consumidora
SF6	Hexafluoreto de Enxofre
IEEE	Institute of Electrical and Electronics Engineers
IEEEES	Institute of Electrical and Electronics Engineers Spectrum
IEC	International Electrotechnical Commission
MME	Ministério de Minas e Energia
MT	Média Tensão
GN	Gauss-Newton
GD	Gradiente Descendente
PRODIST	Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
REMQ	Raiz do Erro Médio Quadrático
RNA	Redes Neurais Artificiais



## LISTAS DE FIGURAS

Figura 1 – Exemplo de Chave Fusível .....	17
Figura 2 – Exemplo de disjuntor ABB .....	18
Figura 3 – Exemplo de religador automático .....	20
Figura 4 – Representação de um curto circuito fase-terra .....	22
Figura 5 – Representação de um curto circuito bifásico .....	24
Figura 6 – Representação do circuito de sequência positiva em curtos-circuitos trifásicos. ....	25
Figura 7 - Modelo de um neurônio artificial .....	27
Figura 8 – Rede com uma camada.....	29
Figura 9 – RNA de múltiplas camadas .....	30
Figura 10 - RNA de múltiplas camadas retroalimentadas.....	30
Figura 11 - Cálculo da distância de falta .....	33
Figura 12 - Técnicas de Localização e Classificação de Faltas .....	40
Figura 13 - Fluxograma para utilização de RNA's em Localizadores de Faltas .....	43
Figura 14 - Rede Neural Artificial Feita no KNIME.....	52
Figura 15 - Cross Validation da RNA.....	53
Figura 16 – Gráfico da Rede de Distribuição em coordenadas de latitude e longitude .....	54
Figura 17 - Correlação das variáveis com o target em faltas monofásicas .....	57
Figura 18 - Correlação das variáveis com o target em faltas bifásicas .....	57
Figura 19 - Correlação das variáveis com o target em faltas trifásicas .....	58
Figura 20 - Distância vs Previsão em faltas monofásicas .....	60
Figura 21 - Distância vs Previsão em faltas bifásicas.....	61
Figura 22 - Distância vs Previsão em faltas trifásicas .....	61
Figura 23 - Gráfico da porcentagem dos erros entre a distância e previsão quando aplicadas faltas nas barras.....	63
Figura 24 - Correlação das variáveis com a distância em faltas no lado de baixa .....	64
Figura 25 - Tensão na barra inicial da rede quando ocorrem faltas na BT e MT.....	65

## LISTA DE TABELAS

<b>Tabela 1 – Principais funções de proteção utilizadas em subestações de distribuição .....</b>	<b>19</b>
<b>Tabela 2 - Análise dos dados de entrada de localizadores de falta.....</b>	<b>42</b>
<b>Tabela 3 - Configurações da Rede.....</b>	<b>44</b>
<b>Tabela 4 - Matriz de correlação de variáveis com a distância na fase A .....</b>	<b>55</b>
<b>Tabela 5 - Matriz de correlação de variáveis com a distância na fase B .....</b>	<b>55</b>
<b>Tabela 6 - Matriz de correlação de variáveis com a distância na fase C .....</b>	<b>56</b>
<b>Tabela 7 - Camadas ocultas e neurônios por camada ocultas.....</b>	<b>59</b>
<b>Tabela 8 - Métricas de erros .....</b>	<b>62</b>

## SUMÁRIO

1 INTRODUÇÃO	12
1.1 Motivação	13
1.2 Objetivos	15
2 FUNDAMENTAÇÃO TEÓRICA	16
2.1 Proteção do Sistema de Distribuição	16
2.1.1 Chaves / Elos fusíveis	16
2.1.2 Disjuntores	17
2.1.3 Relés de sobrecorrente	18
2.1.4 Religador	19
2.2 Faltas e Curtos-Circuitos	20
2.2.1 Faltas Temporárias	20
2.2.2 Faltas Permanentes	21
2.2.3 Curto-Circuito	21
2.3 Redes Neurais Artificiais	26
2.3.1 Componentes das Redes Neurais Artificiais	26
2.3.2 Tipos de redes	29
2.3.3 Aprendizado da rede	31
3 REVISÃO BIBLIOGRÁFICA	33
3.1 Método Takagi et al. (1982)	33
3.2 Método Girgis e Fallon (1992)	35
3.3 Método de Lee et al. (2004)	36
3.4 Método de aprendizagem de máquinas	37
4 METODOLOGIA	40
4.1 Etapa 1: Seleção da técnica de localização de faltas mais adequada para o cenário	40
4.2 Etapa 2: Seleção dos dados de entradas utilizados nos localizadores de faltas	41
4.3 Etapa 3: Criação de um fluxograma para desenvolvimento de localizadores de faltas	43
4.4 Etapa 4: Seleção da Rede de Distribuição	44

4.5 Etapa 5: Seleção das ferramentas matemáticas utilizadas para aplicação de curto-circuitos e suas utilizações ao longo do processo	44
4.6 Etapa 6: Construção da rotina computacional para simulações de curto-circuito	46
4.7 Etapa 7: Subdivisão e seleção dos dados elétricos para início do treinamento da rede	49
4.8 Etapa 8: Seleção da rede e do algoritmo de treinamento	50
4.9 Etapa 9: Otimização dos hiperparâmetros da rede e validação cruzada	51
4.10 Esquema de como foi feita a construção da Rede Neural Artificial	51
5 RESULTADOS E ANÁLISES	54
6 CONCLUSÕES	66
REFERÊNCIAS	68

## 1 INTRODUÇÃO

O sistema de distribuição é a parte do sistema elétrico de potência responsável por fornecer energia elétrica para áreas urbanas como centros comerciais, indústrias, residências e também para áreas rurais como sítios, fazendas e residências distantes dos centros das cidades. O sistema de distribuição é operado pelas distribuidoras de energia, que são empresas que recebem a concessão do poder público para distribuir energia elétrica em uma determinada área. As concessionárias adequam os níveis de tensão do sistema de potência para as redes de distribuição nas subestações abaixadoras reduzindo tensões acima de 138 kV para níveis de subtransmissão como 69 kV e de distribuição primária, como 34,5 kV ou 13,8 kV. Em seguida reduzem para níveis de tensões de distribuição secundária de 220/127 V ou 380/220 V - definição adotada pela ABRADEE (Associação Brasileira de Distribuidores de Energia Elétrica).

O sistema de distribuição pode ser constituído por dois tipos de redes, as aéreas e as subterrâneas. As redes aéreas são formadas por interligações de cabos ligados a postes de energia. As redes se iniciam em alimentadores que estão localizados em subestações das concessionárias, terminam nos pontos de consumo dos clientes e são compostas por cabos nus. Existem algumas configurações que são instaladas as redes aéreas, por exemplo, a radial simples, radial com recurso e sistema de anéis.

Cada configuração é construída visando o melhor abastecimento de uma região. Também existem as redes subterrâneas, em que as interligações dos cabos são feitas sob o solo compostas por cabos isolados. Isso se dá quando a densidade de carga é acima de 28MVA/km<sup>2</sup> e suas configurações são radiais, em anel, primário seletivo, reticulado e spot-network (MAMEDE; MAMEDE FILHO, 2013). Com relação à incidência de faltas, a rede aérea está mais exposta o que leva as concessionárias elaborarem ferramentas para solucionar problemas.

Um dos problemas mais graves, e ao mesmo tempo mais frequentes no sistema de distribuição, é a interrupção do fornecimento de energia elétrica quando ocorrem faltas não programadas. Faltas não programadas (LEME *et al.*, 2013) são quedas de energia ocasionadas por acidentes na rede elétrica, fazendo com que os clientes de uma região fiquem sem poder usufruir da eletricidade em seus estabelecimentos. Essas quedas podem tanto atingir pequenos blocos municipais como grandes blocos regionais no país.

As faltas de energia podem ocorrer devido a fenômenos da natureza – relâmpagos, chuvas e ventos – que atingem a rede, árvores que atingem os cabos dos postes, colisões de veículos em estruturas que sustentam as redes de transmissão ou distribuição, queima de equipamentos dessas redes por falta de manutenção ou intervenções naturais ou até mesmo ligações inadequadas nas próprias instalações dos estabelecimentos (LEE, 2004). Após a ocorrência de uma falta, é objetivo das concessionárias reestabelecer o fornecimento do sistema o mais rápido possível. Contudo, para o reestabelecimento, é necessário identificar o local exato da falta na rede e prover os reparos necessários, o que em muitas situações não é uma tarefa trivial.

Uma das formas das concessionárias estabelecerem de maneira mais rápida o funcionamento adequado de um sistema de energia em falta é com a utilização de *SmartGrids* que são redes que contêm pontos de medição ao longo das suas linhas. Essas medições são fundamentais para identificação do local da falta e diminuem o tempo dos contratantes de energia sem o serviço. Todavia não é toda rede que é *SmartGrid*, principalmente as redes que estão funcionando a um longo período, então surgiram estudos para utilização de algoritmos computacionais que são implementados para facilitar a localização de faltas. O foco deste trabalho é desenvolver um algoritmo que seja capaz de auxiliar a identificação do local de faltas em sistemas de distribuição de energia.

## **1.1 Motivação**

Interrupções inesperadas de energia no sistema podem afetar diretamente a qualidade da energia elétrica, que pode ser definida como as condições ideais de conformidade de energia para atender a demanda de um determinado contratante de maneira com que ele possa realizar suas atividades com eficiência. A não conformidade do sistema e a má qualidade da energia podem ocasionar diversos malefícios, como a falta de segurança para as pessoas, a redução na produtividade de indústrias e estabelecimentos comerciais impactando diretamente na economia de uma região e queima de aparelhos elétricos conectados à rede. É válido ressaltar que a depender do segmento, os custos pela falta de energia podem custar milhares de reais em apenas um minuto de interrupção.

Foi feito um estudo pela Institute of Electrical and Electronics Engineers Spetrum (IEEEES) que o prejuízo causado pela indústria manufatureira americana é de US\$ 10 bilhões de dólares por ano devido ao crescente número de faltas e interrupções no fornecimento de energia elétrica. Um estudo publicado pela Eurelectric, que é a associação do setor que representa os interesses comuns da indústria elétrica a nível europeu, estima que o valor de prejuízo é ocasionado pela má qualidade da energia elétrica gira em torno de 1,5% de todo o PIB da Europa afetando diretamente em sua economia (MARTINHO, 2013).

As concessionárias enfrentam muitos problemas para encontrar o local exato onde ocorreu a falta, porque, muitas delas acontecem, em rodovias muito extensas, ou locais de difícil acesso. E quando não há um restabelecimento em curto espaço de tempo pode ocorrer a monetização do Custo Social de Energia não Suprida (CENS), fazendo então que a sociedade receba um quantitativo para o tempo que não houve energia elétrica suprida. O valor unitário das interrupções não programados por setor no Brasil é de 13,9 R\$/kWh para indústria, 18,1 R\$/kWh para o comércio e 19,7 R\$/kWh para residências. No Brasil o custo médio de energia não suprida é de 4,48 US\$/kWh (MME, 2016).

A inconformidade em quaisquer que sejam os pontos da rede, tanto nas proteções quanto nas ramificações ou equipamentos, precisa ser solucionada o mais rápido possível. Existem métodos que são utilizados para resolver esse problema, um deles é a automação de redes. Todavia, esse processo de automatização pode ser bastante oneroso, mas existe outra forma de obter o restabelecimento da rede de maneira mais eficaz que é com o uso dos localizadores de faltas, que são ferramentas computacionais capazes de estimar o local aproximado onde a falta ocorreu.

Duração Equivalente de Interrupções por Unidade Consumidora (DEC) é um índice de quantificação do tempo das interrupções no sistema elétrico que é analisado pelas concessionárias. Para que este índice se mantenha em patamares adequados, de acordo com o PRODIST (Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional) - Módulo 8, se faz necessário reestabelecer o fornecimento do sistema o mais rápido possível, o que implica conhecer o local de ocorrência das faltas. Neste contexto, a utilização de ferramentas de localização de faltas é de grande valor para as concessionárias.

## 1.2 Objetivos

O principal objetivo deste trabalho é desenvolver um localizador de faltas baseado na aplicação de Redes Neurais Artificiais, capaz de localizar faltas em redes de média tensão do sistema de distribuição, a partir da medição de valores eficazes de corrente e tensão no início da rede. A metodologia é baseada na construção de redes neurais. Para alcançar objetivo principal, os seguintes objetivos específicos precisam ser alcançados:

- Desenvolver um algoritmo para realização de faltas em toda a rede para obtenção dos valores eficazes de tensão, corrente, potência e fator de potência.
- Realizar a criação de um banco de dados que possa armazenar os dados de cada falta realizada ao longo dos barramentos
- Utilizar os bancos de dados para criação e aprendizagem de uma Rede Neural.
- Validar os valores retornados pela Rede Neural.
- Realizar análises dos resultados e identificar os potenciais locais do local da falta.

Com a criação do localizador será possível melhorar o índice de qualidade do serviço DEC de uma região, fazendo assim com que haja cada vez mais eficiência na distribuição de energia elétrica.



## **2 FUNDAMENTAÇÃO TEÓRICA**

### **2.1 Proteção do Sistema de Distribuição**

Para a proteção do sistema de distribuição é preciso instalar equipamentos com a finalidade de garantir maior segurança para os componentes da rede. A proteção tem como função extinguir o curto-circuito em determinado ponto do sistema. Alguns equipamentos podem ser utilizados para auxiliar na localização de faltas em situações diversas, mas por si só não é fator preponderante para determinação do tipo ou local da falta. Existem alguns equipamentos que são comumente utilizados nos sistemas de proteção, como por exemplo: chaves/elos fusíveis, disjuntores, relés e religadores.

#### **2.1.1 Chaves / Elos fusíveis**


Chave fusível é um equipamento composto por um isolador de porcelana, cartucho, terminal de carga e fonte, barra de fixação, articulação e dentro do cartucho tem o elo fusível (MAMEDE; MAMEDE FILHO, 2013). A sua principal função é interromper a corrente quando esta esteja acima dos valores nominais suportados pelo elo fusível, a interrupção é feita quando o elo fusível é fundido porque flui por ele correntes acima dos valores nominais logo haverá temperaturas acima do nominal. Os elementos que podem estar contidos dentro do elo são estanho ou chumbo, atingindo suas temperaturas de fundição eles liberam gases de ionizantes fazendo com que haja a extinção de arcos elétricos que podem surgir quando a chave é seccionada.

Uma característica importante a ser analisada para a escolha de um elo fusível é o seu tempo de atuação que está intimamente relacionado com a corrente que passa por ele, com o elemento capaz de extinguir o arco elétrico e tempo de uso. Os elos fusíveis são fabricados de acordo com suas características tempo versus corrente havendo as tipologias H, K e T cada uma se diferenciando em relação ao seu tempo de atuação e que possuem aplicações distintas, sendo esses de velocidade de fusão rápida, lenta e de alto surto. Caso seja necessária a obtenção de parâmetros de

valores pré-falta é importante levar em conta o tempo e velocidade de fusão dos fusíveis, pois a captura de um dado errôneo pode comprometer a localização de faltas.

Quando ocorre uma falta na rede de distribuição o fusível é um dos dispositivos que indicam a inconformidade do sistema, esse elemento é essencial para quando se quer realizar buscas do local onde ocorreu as faltas. Normalmente o indicativo da sua queima é identificado por moradores da região que podem informar a concessionária o incidente, podendo assim realizar uma busca mais refinada e assertiva para encontrar uma falta. É válido conhecer sua estrutura para identificação de possíveis falhas no sistema de distribuição, a Figura 1 mostra um fusível e sua chave.

**Figura 1 – Exemplo de Chave Fusível**



Fonte: MORETO (2005)

### **2.1.2 Disjuntores**

O disjuntor é um equipamento fundamental para o funcionamento dos alimentadores de distribuição, pois são responsáveis por suas proteções e também é utilizado para manobras de abertura e fechamento do sistema sob carga. Essa proteção deve ser instalada em conjunto com relés de sobrecorrentes. Eles atuam quando recebem informações dos relés de sobrecorrentes que é um dispositivo capaz de identificar se a corrente que está no circuito está acima da nominal, fechando assim seus contatos e enviando informações para o disjuntor fazendo então com que ele abra seus contatos protegendo a rede ou algum equipamento. A Figura 2 representa um disjuntor a vácuo.

**Figura 2 – Exemplo de disjuntor ABB**



Fonte: ABB Inc (2004)

O disjuntor possui três polos conectados a cada uma das fases do sistema podendo ser denominados R, S e T. Todavia, para identificação de faltas é preciso saber quais dessas fases não estão operando com valores nominais, então isso é definido pela abertura monopolar desse disjuntor. Usualmente são utilizados em algoritmos de localização dois ciclos de rotina pós faltas para compatibilizar o atraso de um sistema de proteção na abertura dos disjuntores com o momento exato da falta podendo então realizar as leituras de transitórios e de valores permanentes em um programa com mais exatidão.

### **2.1.3 Relés de sobrecorrente**

Relés de sobrecorrente são equipamentos que monitoram constantemente as grandezas elétricas da rede, como tensão, corrente, frequências e potência. No caso de detecção de anomalias, que são definidas a partir de parâmetros pré-estabelecidos, os relés enviam informações para o disjuntor fazendo com que ele opere a manobra de abertura. Para a medição de altas tensões e altas correntes, são utilizados transformadores de instrumentos, estes dispositivos fazem a conversão de grandezas de alta magnitude para grandezas compatíveis para leituras nos relés.

Os relés têm as suas funções de proteção identificadas por números, de acordo com as normas IEEE (*Institute of Electrical and Electronics Engineers*), ANSI (*American National Standards Institute*) e IEC (*International Electrotechnical*

*Commission*). Na Tabela 1 são apresentadas as principais funções de proteção aplicadas em subestações de distribuição de acordo com os padrões IEEE/ANSI.

**Tabela 1 – Principais funções de proteção utilizadas em subestações de distribuição**

<b>Função</b>	<b>Descrição</b>
50	Função de sobrecorrente instantânea de fase
51	Função de sobrecorrente temporizada de fase
50N	Função de sobrecorrente instantânea de neutro
50/51NS	Função de sobrecorrente neutro sensível
51BF	Função de falha de disjuntor
46	Função de sequência negativa
67	Função de sobrecorrente direcional de fase
67N	Função de sobrecorrente direcional de fase
21	Função de proteção de distância
27	Função de subtensão
59	Função de sobretensão
79	Função de religamento
50BF	Função de falha do disjuntor
51G	Função de sobrecorrente de terra
87	Função de diferencial
61	Função de desequilíbrio de corrente
25	Função de sincronismo
26	Função de temperatura do óleo
49	Função de temperatura do enrolamento
63	Função de pressão do gás do transformador de potência
71	Função de nível do óleo
98	Função de oscilografia
43	Função de transferência da proteção
86	Função de bloqueio

Fonte: Leme (2013).

#### **2.1.4 Religador**

É um equipamento eletrônico com um sistema de controle em que após a ocorrência de uma falta tenta restabelecer o sistema realizando o fechamento do circuito de acordo com parâmetros pré-definidos de tempo e números de tentativas de reestabelecimento. A troca de equipamentos com manobras não automáticas por religadores automáticos têm impacto direto na redução de indicadores de DEC, podendo haver variações entre 32,05% a 89,36% em um sistema de fluxo de potência de 69 kVA variando de acordo com o local da falta e as cargas do sistema

(WITKOVSKI, 2019). Para algoritmos localizadores esse equipamento é bastante útil principalmente quando esses dispositivos conseguem enviar informações em tempo real para as unidades de medição, porém a maior parte das redes não comportam esse tipo de comunicação de informação, dificultando o processo.

Os religadores automáticos são componentes que reduzem o tempo na solução de problemas na rede, diminuem a necessidade de manutenção *in loco* na rede e reduzem os danos nos demais equipamentos do circuito. Mesmo sendo um aparelho altamente funcional em uma rede de distribuição pode não conseguir extinguir a falha na rede. Porém, este estado de não extinção pode ser útil para a concessionária identificar o lugar específico de uma falta caso haja um monitoramento ao longo de toda a rede, ou inspeção visual pela linha. A Figura 3 mostra um exemplo de religador automático.

**Figura 3 – Exemplo de religador automático**



Fonte: ABB Inc (2004)

## **2.2 Falhas e Curtos-Circuitos**

### **2.2.1 Falhas Temporárias**

A falta temporária é definida como uma falta auto instigável, ou seja, a causa que originou a falta desaparece espontaneamente em um curto intervalo de tempo. De acordo a CPFL (2016) 80% das faltas nas redes de distribuição são do tipo transitórias e sempre são eliminadas em um período curto de tempo. Os principais fatores que as ocasionam são:

- Contato acidental dos cabos causando um curto-circuito;
- Eventos climáticos interagindo com os cabos;
- Rompimento da rigidez dielétrica criando arcos elétricos;
- Falta de manutenção dos componentes da rede.

### **2.2.2 Faltas Permanentes**

As faltas permanentes são definidas como danos que ocorrem na rede por um tempo indeterminado, ou seja, não há possibilidade de reestabelecimento do fornecimento sem que haja uma intervenção corretiva na rede. Os religadores automáticos não são capazes de resolver esse tipo de falta, logo é necessário que equipes de manutenção atuem *in loco* para investigar quais são as causas dessa falta para que seja solucionada e o sistema volte a funcionar em suas condições normais.

De acordo com MME (2016) os fatores que podem ocasionar as faltas permanentes são:

- Objetos que entram em contato com a rede danificando sua isolação;
- Colisões de automóveis em postes de energia elétrica;
- Vandalismo.

### **2.2.3 Curto-Circuito**

Curto-circuito é o encurtamento de um circuito elétrico que faz com que a corrente siga um percurso não projetado. Com o encurtamento do circuito, a impedância reduz e a corrente elétrica pode aumentar de intensidade danificando os componentes que foram dimensionados para funcionar em suas condições nominais. O aumento excessivo de corrente também gera dissipação exacerbada de energia podendo gerar arcos elétricos, explosões e faíscas.

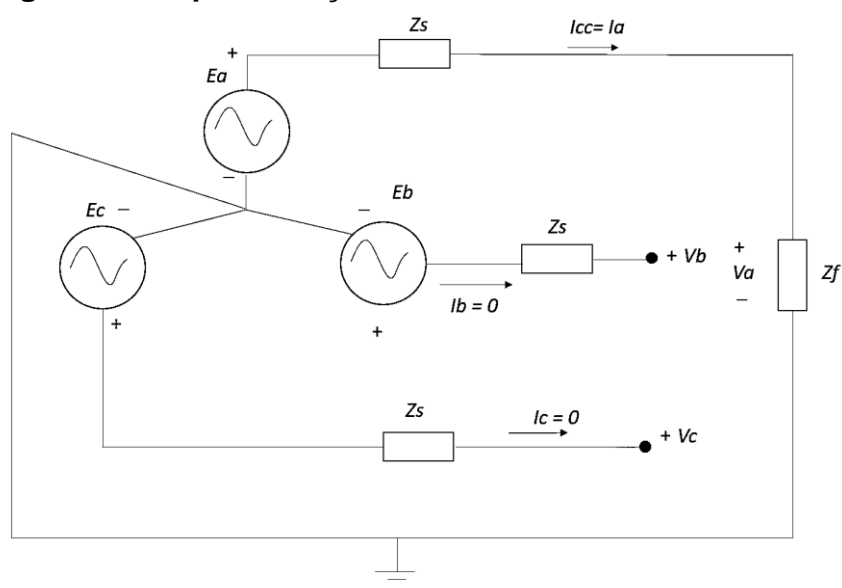
De acordo com MARTINHO (2013) os curtos-circuitos podem ser classificados de acordo com a quantidade de fases envolvidas no evento, em monofásico, bifásico e trifásico. Análises estatísticas mostram que as probabilidades de ocorrências em cada um dos casos são:

- Curtos-circuitos trifásicos: 5%

- Curtos-circuitos bifásicos: 35%
- Curtos-circuitos monofásicos: 70%

O curto monofásico ocorre quando um dos condutores entra em contato com algum outro objeto aterrado. Para se calcular o curto entre uma das fases e o condutor terra em um sistema de distribuição pode se utilizar ferramentas matemáticas como as componentes simétrica do teorema de Fortescue que decompõe a tensão e corrente que estão em um circuito desequilibrado em três sistemas equilibrados: o de sequência positiva, negativa e zero. O cálculo da corrente de curto circuito monofásico pode ser realizado de acordo com os procedimentos a seguir, partindo da representação elétrica apresentada na Figura 4.

**Figura 4 – Representação de um curto circuito fase-terra**



Fonte: Autor

Em que:

$I_{cc}$  = Corrente de curto circuito

$a$  = Operador que representa uma rotação de  $120^\circ$  entre fasores

$Z_1$  = Conjunto de impedâncias de sequência positiva do gerador até o curto-circuito

$Z_f$  = Impedância de falta

$I_a^0$  = Corrente de sequência negativa da fase a

$I_a^1$  = Corrente de sequência positiva da fase a

$I_a^2$  = Corrente de sequência negativa da fase a

$I_b$  = Corrente da fase b

$I_c$  = Corrente da fase c

$V_a$  = Tensão da fase a

$V_b$  = Tensão da fase b

$V_c$  = Tensão da fase c

$E$  = Tensão no gerador

(0), (1), (2)= Índices de sequência zero, positiva e negativa respectivamente

Sabendo que:

$$V_a = Z_f I_a \quad (1)$$

$$I_b = I_c = 0 \quad (2)$$

Levando em consideração a matriz de Fortescue:

$$\begin{bmatrix} I_a \\ I_b \\ I_c \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & 1 & 1 \\ 1 & a^2 & a \\ 1 & a & a^2 \end{bmatrix} \begin{bmatrix} I_{a0} \\ 0 \\ 0 \end{bmatrix} \quad (3)$$

$$I_a^0 = I_a^1 = I_a^2 = \frac{I_a}{3} \quad (4)$$

$$V_a = V_a^0 + V_a^1 + V_a^2 \quad (5)$$

$$V_a = Z_f I_a = E_a - \frac{I_a}{3} (Z_s^1 - Z_s^2 - Z_s^0) \quad (6)$$

Logo, tem se que:

$$I_a = 3I_a^0 \quad (7)$$

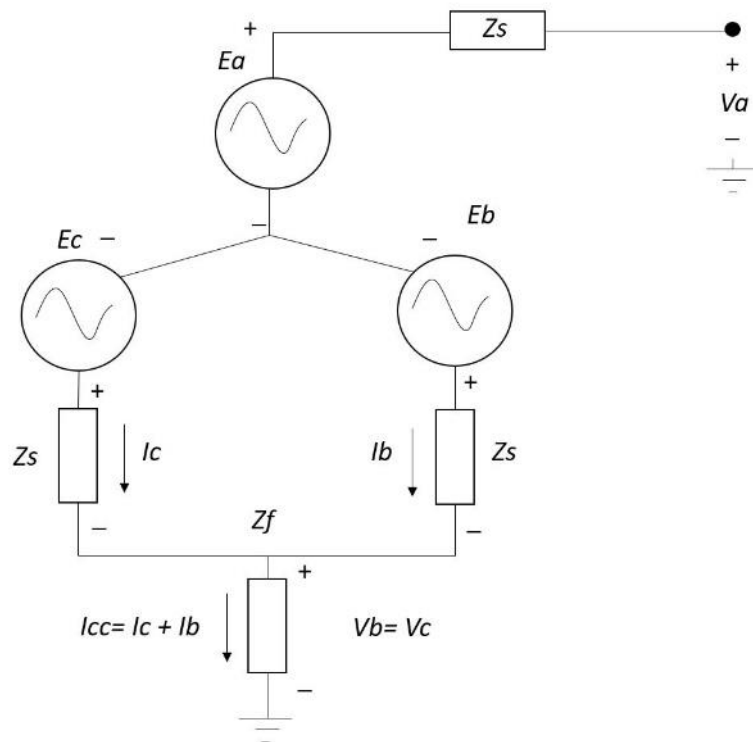
E por fim tem-se que a corrente de curto-circuito é:



$$I_{cc} = \frac{3Ea}{Z_s^1 + Z_s^2 + Z_s^0 + 3Z_f} \quad (8)$$

Em curtos-circuitos bifásicos ocorre o contato entre duas fases, podendo haver contato com o condutor terra do sistema ou não. A Figura 5 apresenta uma representação elétrica para este tipo de curto.

**Figura 5 – Representação de um curto circuito bifásico**



Fonte: Autor

A partir da análise do circuito, é possível concluir que a tensão em  $V_b$  é dada por:

$$V_b = V_c = Z_f(I_b + I_c) \quad (9)$$

$$I_{cc} = I_b + I_c \quad (10)$$

$$V_b = Z_f[2I_a^0 + (a^2 - a)I_a^1 + (a - a^2)I_a^2] \quad (11)$$

Sabendo que  $a^2 + a^0 = -1$

$$V_b = Z_f(2I_a^0 - I_a^1 - I_a^2) \quad (12)$$


$$I_a^0 + I_a^1 + I_a^2 = 0 \quad (13)$$

$$3Z_f I_a^0 = Z_s^0 I_a^0 - E_a + Z_s^1 I_a^1 \quad (14)$$

$$I_{cc} = 3I_a^0 \quad (15)$$

O curto-circuito trifásico ocorre quando há o contato entre as três fases. Uma característica desse curto é que as correntes acabam sendo balanceadas entre as fases e nos cálculos leva-se em consideração apenas a de sequência positiva. É válido salientar que para encontrar a corrente de curto considera-se que o circuito é modelado com uma impedância de Thévenin, que é o conjunto de todas as impedâncias do circuito a partir de um ponto de análise como apresentado na Figura 6.

**Figura 6 – Representação do circuito de sequência positiva em curtos-circuitos trifásicos.**



Fonte: Autor

Também através da matriz de Fortescue temos que:

$$I_{a1} = \frac{1}{Z_1} \quad (16)$$

Logo:

$$I_a^0 + I_a^1 + I_a^2 = I_a \quad (17)$$

$$I_a^0 = 0 \quad (18)$$

$$I_a^2 = 0 \quad (19)$$

Portanto a corrente de curto-circuito é:

$$I_a = I_a^1 = \frac{1}{Z_1} \quad (20)$$

$$I_a = \frac{1}{|Z_1|} = I_{cc} \quad (21)$$

### 2.3 Redes Neurais Artificiais

As RNA's são modelos matemáticos utilizados para auxílio à tomada de decisões. Elas são compostas por várias funções matemáticas que são conectadas e processadas mediante a uma ponderação previamente definida. As funções estão contidas dentro de camadas que também estão conectadas de formas paralelas e a cada resolução de uma função, há a passagem para uma nova camada até atingir o resultado (BRAGA; CARVALHO; LUDERMIR, 2000).

#### 2.3.1 Componentes das Redes Neurais Artificiais

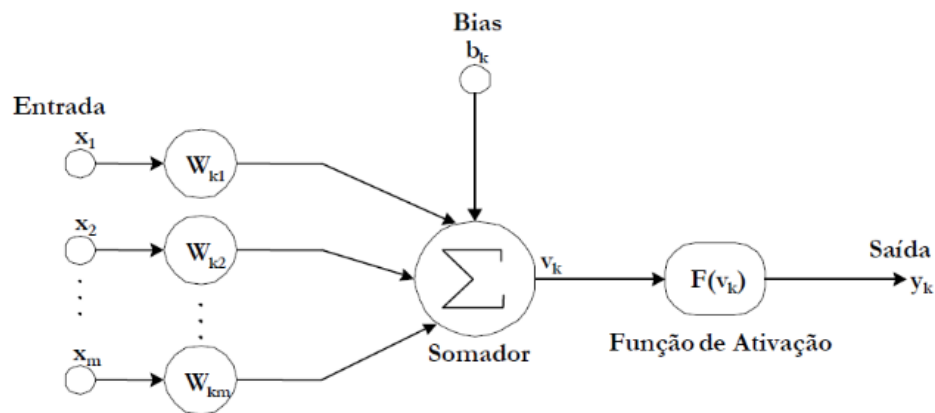
Assim como um cérebro humano as RNA's também contêm neurônios, que neste caso são as unidades de processamento das funções matemáticas, esses neurônios são interligados por estruturas de conexões chamadas axônios, como há muitos neurônios nas redes neurais há muitas conexões. O conjunto de determinados neurônios é chamado de camadas. Um neurônio pode ser composto por sinapses, pesos sinápticos, função de soma, *bias*, função de ativação e saídas, conforme descrições a seguir (CRISTÓVÃO, 2018).

- Sinapses: É a interface entre o humano e a máquina, mais precisamente são os valores que serão adicionados à rede neural, tais quais os sinais que chegam aos dendritos no cérebro que é parte do neurônio humano que recebe sinais de entrada.

- Pesos sinápticos: São pesos que têm como função designar qual a relevância de uma determinada sinapse dentro de um neurônio, também são responsáveis por caracterizar sinapses, o que ocorre quando as sinapses são multiplicadas pelos seus pesos.
- Somadores: São a funções matemáticas que recebem os dados da entrada e realizam o processo de soma no neurônio, essas funções só são ativadas após multiplicação das sinapses com seus respectivos pesos.
- *Bias*: São valores numéricos capazes de auxiliar na velocidade de convergência das RNA's.
- Função de ativação: É a função capaz de fazer a análise de um neurônio, se o seu valor é o esperado ou não. É responsável também por normalizar os dados que ficam usualmente entre (-1, 1) ou (0, 1).

É mostrado na Figura 7 quais são os componentes de um neurônio artificial:

**Figura 7 - Modelo de um neurônio artificial**



Fonte: Cristóvão (2018).

As equações 22 e 23 definem um neurônio matematicamente (MORETO, 2005):

$$v_k = \sum_{j=1}^m w_{kj} * x_j + b_k \quad (22)$$

$$y_k = \varphi(v_k) \quad (23)$$

Em que:

$v_k$  = valor que o somador retorna

$y_k$  = resposta do neurônio

$w_{kj}$  = pesos sinápticos

$b_k$  = *bias*

$x_j$  = entrada

$\varphi$  = função de ativação

$j$  = índice

$m$  = número de entradas

As funções de ativação devem se aproximar ao máximo da disposição dos dados em um plano cartesiano para maior velocidade na resposta de saída, podendo ter características lineares como a equação 24:

$$\varphi(v) = \begin{cases} 1, & v < 0 \\ 0, & v \geq 0 \end{cases} \quad (24)$$

Linear por partes como na equação 25:

$$\varphi(v) = \begin{cases} 1 & v \geq \frac{1}{2} \\ v & \frac{1}{2} > v > -\frac{1}{2} \\ 0 & v \leq -\frac{1}{2} \end{cases} \quad (25)$$

A função sigmoide é uma das funções de ativação mais comuns porque contém um bom balanceamento entre uma função linear e não linear.


$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (26)$$

Em que  $a$  é suavização da função sigmoide.

### 2.3.2 Tipos de redes

- I. **Redes neurais com uma camada** – Possui apenas uma camada de saída de neurônios, em que as sinapses percorrem o caminho da entrada para a saída apenas, não havendo inversão de percurso, como mostrado na Figura 8. A camada processa todas as informações e toma todas as decisões da rede podendo apenas solucionar problemas lineares.


**Figura 8 – Rede com uma camada**



Fonte: Moreto (2005)

- II. **Redes neurais com múltiplas camadas** – Podem possuir várias camadas entre a camada de saída e a camada de entrada, conseqüentemente podendo haver um maior número de neurônios, dando assim uma maior robustez a rede como mostrado na Figura 9. O sinal de entrada da camada de entrada fornece informações que serão utilizadas pela segunda camada, que pode ser intitulada como camada oculta, que nada mais é do que uma camada intermediária entre a entrada e a saída. A segunda camada ou primeira camada oculta fornece informações para as camadas ocultas seguintes até que todo o processo chegue ao fim na camada final. Esse tipo de rede neural é interessante porque ao contrário das redes de camadas únicas podem ser usadas para resolver problemas não lineares.

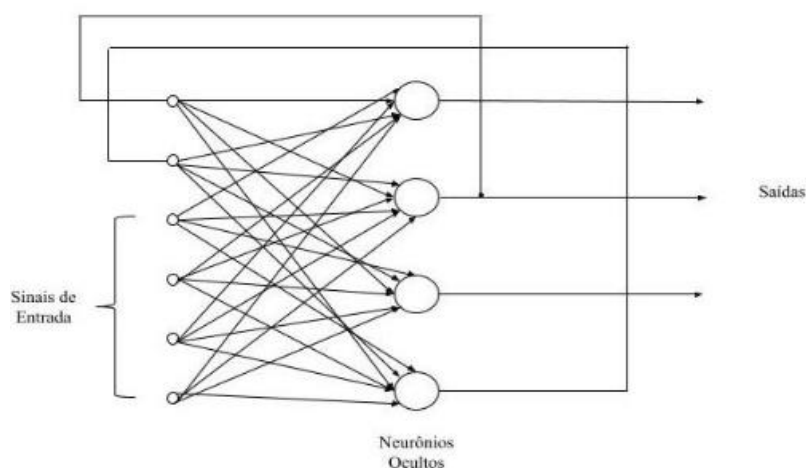
**Figura 9 – RNA de múltiplas camadas**



Fonte: Moreto (2005)

- III. **Redes neurais recorrentes** - É uma rede neural que contém um processo de realimentação ligando os nós da entrada com a saída como mostrado na Figura 10. Esse processo é interessante porque proporciona uma maior velocidade de aprendizagem à rede.

**Figura 10 - RNA de múltiplas camadas retroalimentadas**



Fonte: Moreto (2005)

### 2.3.3 Aprendizado da rede

A aprendizagem é essencial para que a rede consiga retornar valores próximos do esperado, consiga solucionar questões de alto nível de complexidade, se adequar a possíveis alterações que ocorram com a entrada de sinapses novas no banco de dados e aumente a velocidade de saída. O fator preponderante para o aprendizado é o peso correlacionado a cada sinapse o qual deve ser ajustado para atingir o máximo aproveitamento da rede, porém para que haja uma evolução na rede é preciso que se encontre uma solução genérica para um conjunto de dados.

A princípio um algoritmo é exposto a diversos cenários, com a finalização de cada cenário é possível averiguar quais serão os parâmetros que serão alterados e quais pesos serão adicionados. Quando feitas as novas alterações pode-se concluir se o procedimento retornou a resposta esperada, esse processo ocorre inúmeras vezes em um *loop* e cada *loop* a rede adiciona em seu banco de dados soluções para cada diferente cenário. Logo é preciso que sejam separados dados para que a rede seja treinada e dados que possam conferir se a rede está funcionando de maneira correta, é indicado que sejam separados de 50% a 90% dos dados para o treinamento da rede (CRISTÓVÃO, 2018).

Um dos algoritmos mais utilizados para treinamento das RNA's é o Levenberg-Marquardt, o qual se mostra eficaz para treinar a rede antes de sua execução completa. Este algoritmo usa o artifício de separar classes iterativamente, em que os pesos sinápticos permanecem em uma classe até que a rede seja treinada completamente, e então após uma iteração finalizada os pesos são atualizados indo para outra classe e esse procedimento acontece até encontrar um bom estado da rede. A formulação matemática por trás do algoritmo são os métodos matemáticos de Gauss-Newton (GN) e Gradiente Descendente (GD) que têm como função estimar raízes de uma função de forma iterativa.

O Levenberg-Marquardt usa as principais características de cada um dos dois modelos matemáticos: como o GD que tem a rapidez para encontrar valores iniciais adequados para convergência do sistema e sendo mais completo que o método GN, porém o método de Gauss-Newton tem maior capacidade de convergência em redes com maior quantitativo de neurônios (ROCHA, 2017). O algoritmo consegue abarcar problemas com muitos parâmetros porque se utiliza de uma matriz Jacobiana utilizada



no método GN, em contrapartida por haver vários parâmetros o esforço que máquina precisa para realizar as operações é maior.

Para finalizar a aprendizagem é preciso que ocorra uma validação dos dados, visto que, se quando o treinamento da rede for finalizado for mostrado que houve uma adaptação para apenas os dados do banco de informações e não para qualquer tipo de dado inserido na entrada, toda a aprendizagem não será válida. Existe uma técnica chamada *cross validation* essa técnica pode indicar se seus resultados têm uma boa performance.

O que acontece na *cross validation* é que dentre um conjunto de dados uma parte é selecionada para teste e outra normalmente maior para treino, os dados de treino representam os dados em que a máquina usa para aprender, já a parte de teste é a que é realmente a máquina usa para simular o processo, isso ocorre de forma cíclica uma vez que os grupos de teste se tornam os grupos de treinamento e vice-versa até que todos os dados sejam testados e treinados (TRIBA *et al.*, 2018). Quando toda essa etapa é concluída a RNA está pronta para fazer previsões e proporcionar resultados condizentes com os sinais de entradas.

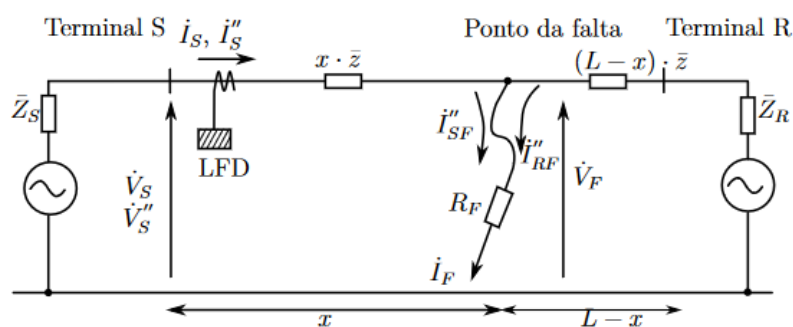
### 3 REVISÃO BIBLIOGRÁFICA

#### 3.1 Método Takagi et al. (1982)

Um dos métodos pioneiros para localização de falta foi o método de Takagi, que se iniciou sendo utilizado para linhas de transmissão e posteriormente foi aderido para linhas de distribuição. O método se utiliza de grandezas fasoriais analisadas por um relé de proteção instalado nos terminais da linha. Como os valores obtidos contêm parte real e parte imaginária e uma resistência de falta desconhecida utiliza-se uma rotina baseada na transformada de Fourier para facilitar a produção dos componentes fundamentais dos sinais e por seguinte obter os dados de corrente. Os valores são adquiridos no momento que ocorre o defeito e instantes antes da ocorrência do defeito e então é calculada a distância da falta vista na equação 27.

O circuito na Figura 11 mostra como se comporta a linha quando acontece a falta:

**Figura 11 - Cálculo da distância de falta**



Fonte: Takagi et al. (1982)

Em que:

$I_S$  = Corrente do terminal s

$Z_S$  = Impedância do terminal s

$V_S$  = Tensão do terminal s

$z$  = Impedância por quilômetro

$x$  = Distância da falta

$I_{sf}$  = Corrente da falta que vem do terminal S

$I_{rf}$  = Corrente da falta que vem do terminal R

$R_f$  = Resistência da falta

$L$  = Comprimento da linha

$Z_r$  = Impedância do terminal R

$V_f$  = Tensão do terminal f

$I_m$  = Parte imaginária da corrente

" = É o valor da grandeza subtraído pelo seu valor pré-falta

A modelagem matemática que descreve a localização das faltas avalia os terminais que estão presentes no circuito, R e S. São levados em conta os dados adquiridos pelo relé, a impedância da linha e a resistência de falta, fazendo uma superposição entre os dados na ocorrência da falta e pré-falta, as equações 28 e 30 demonstram como chegar à equação 27 da distância.

$$x = \frac{\text{Im}(V_s I_s''^*)}{\text{Im}(Z * I_s''^* I_s)} \quad (27)$$

Em que  $x$  é a distância da falta com relação ao terminal S e  $V_s$  é a tensão obtida no terminal S indicada por:

$$V_s = x * Z * I_s + R_f * I_f \quad (28)$$

Em que  $R_f$  é a resistência de falta,  $I_f$  é a corrente da falta,  $x * z$  é a impedância pelo comprimento e  $I_s''$  é a diferença entre a corrente do terminal S e a corrente de pré-falta:

$$I_s'' = I_s - I_{pré} \quad (29)$$

Manipulando matematicamente a equação 28, utilizando a multiplicação do conjugado de  $I_s''^*$  e considerando que está em fase com a corrente de falta  $I_f$  obtêm-se a equação 30 que decorre a distância da falta na equação 27.

$$Im(V_s I_s''^*) = x Im(Z * I_s''^* I_s) + R_f Im(I_f I_s''^*) \quad (30)$$

A localização é feita utilizando a formulação monofásica e pode ser utilizada para linhas curtas de transmissão com comprimento de 100 km. Para as análises a capacitância dos condutores é desprezada. Na formulação do método é imposto que a linha seja composta por um único cabo, que não haja cargas ao longo do seu comprimento, a resistência de falta tem que ser de baixos valores e a reatância da linha é o ponto chave dos cálculos (Takagi *et al.*, 1982). Essas limitações impossibilitam o seu uso em linhas de distribuições pois existem variados tipos de cargas ao longo da linha e há casos em que na linha não é composta por um único cabo.

### 3.2 Método Girgis e Fallon (1992)

O método de Girgis e Fallon utiliza modelos matemáticos baseados em fasores de frequência fundamental das tensões e das correntes que são obtidas por oscilógrafos dispostos nos dois terminais da linha tanto no início quanto no fim. Além de utilizar os gráficos de tensão e corrente se faz necessário também o cálculo da impedância aparente para determinar o local da falta. É pressuposto que a linha é transposta e não considera as correntes em geração distribuída.

Na bibliografia de 1992 foi utilizado dois sistemas para comprovar a veracidade do método, um sistema de transmissão de 115 kV com dados disponíveis em dois terminais e um sistema de transmissão radial de 69 kV com dados disponíveis em um terminal. Primeiramente foi feita a conversão dos dados dos gráficos obtidos por equipamentos de medição em arquivos que pudessem ser implementados na rotina computacional. Os oscilógrafos que obtinham as grandezas elétricas são os monitores de registro de falhas, os quais são constituídos por um sistema digital de registro de falhas e perturbações que utiliza comunicações via IEC61850 para registrar eventos

do momento das faltas que são indicados pelos relés de proteção distribuídos em uma subestação.

No método é realizada uma varredura em todo o sistema verificando a distância da falta em comparação aos valores registrados no monitor de registro de faltas. Toda a linha é percorrida em um *loop* e a cada *loop* é feito o cálculo da distância da falta, esse cálculo é feito utilizando a tensão e corrente de um ponto conhecido e por meio do teorema de Fortescue em que um sistema desequilibrado, pode ser convertido em sistemas equilibrados de fasores, chamados componentes simétricas pôde-se iniciar o processo. Então no cálculo o autor utiliza a tensão de sequência da falta, a corrente de sequência tanto a barra anterior quanto da barra seguinte e as impedâncias dessas linhas conhecidas para encontrar as impedâncias da falta. Com o valor das impedâncias de faltas e com os valores da corrente é possível determinar a distância das faltas.

### **3.3 Método de Lee et al. (2004)**

O método de Lee se baseia na modelagem matemática dos métodos de Takagi e Girgis, que são métodos desenvolvidos para linhas de transmissão e circuitos monofásicos. No método de Lee foi realizado adaptações para abarcar também sistemas de distribuição, os quais diferentemente dos de transmissão não podem ser considerados com um único tipo de condutor, têm comprimentos menores, têm variadas cargas conectadas ao longo da rede e são trifásicos desequilibrados, o que impossibilita o uso direto das metodologias de Takagi e Girgis.

O método consiste em cálculos da impedância em diferentes momentos de ocorrência da falta. Inicialmente é averiguado como se comporta o sistema em plena carga efetuando os cálculos mediante as equações 31, 32 e 27, na sequência é realizada a análise quando uma ramificação é desenergizada por um disjuntor. Assim como no método de Girgis para o uso da metodologia é preciso o uso de oscilógrafos das grandezas elétricas para identificar as possíveis faltas e isto é feito analisando a queima de fusíveis indicando o lugar aproximado da falta.

Para faltas trifásicas o local da falta é definido por:

$$x = \frac{Im\{I_s''^{(1)*}(V_s^{(1)} - V_s^{(2)})\}}{Im\{I_s''^{(1)*}(Z^{(1)}I_s^{(1)} - Z^{(2)}I_s^{(2)})\}} \quad (31)$$

Para faltas bifásicas para terra:

$$x = \frac{Im\{I_s''^{(0)*}(V_s^{(1)} - V_s^{(0)})\}}{Im\{I_s''^{(0)*}(Z^{(1)}I_s^{(1)} - Z^{(0)}I_s^{(0)})\}} \quad (32)$$

Para faltas fase-terra:

$$x = \frac{Im(V_s I_s''^*)}{Im(Z * I_s''^* I_s)} \quad (27)$$

As equações 31 e 32 foram desenvolvidas a partir de estudos feitos pelo autor em cima das bibliografias de Tagaki e Girgis já mencionadas. Lee parte da equação 27 mostrada no tópico de Tagaki e encontra as duas outras equações utilizando a mesma manipulação algébrica de encontrar a tensão no terminal se levar em conta os valores pré-falta, só que para essas novas equações foi utilizado as tensões de sequência positiva quando ocorre uma falta bifásica e trifásica.

Uma limitação desse método é que ele precisa de duas condições para ser executado a primeira condição é que se deve considerar toda a carga do sistema e em seguida é preciso que seja levado em conta a informação das grandezas elétricas instantes antes da carga ser interrompida após o primeiro religamento efetuado pelo disjuntor da subestação.

### 3.4 Método de aprendizagem de máquinas

O método se baseia em princípios de aprendizagem de máquina para encontrar o local da falta. Usualmente os dados de entrada da máquina são os parâmetros gerais da rede como tensão, corrente, impedância. A aprendizagem de máquina é um campo da inteligência artificial que visa solucionar problemas baseando-se em modelos computacionais e na análise de padrões de comportamento de dados,

fazendo projeções a partir da comparação das informações e assim reconhecendo qual a melhor opção dentre os dados que corresponde a solução do problema almejada pelo usuário.

A aprendizagem se divide em três grandes ramos: a supervisionada em que há entradas e se espera uma saída determinada, a não supervisionada em que não há padrões de entradas e saídas e o algoritmo faz a separação dos dados de acordo com suas similaridades com relação a algum critério definido, e o por reforço em que a máquina tenta encontrar um padrão repetindo um processo repetidas vezes até atingir a referência (MONARD; BARANAUSKAS, 2013).

Existem várias formas da máquina adquirir conhecimento e realizar suas operações para identificar e resolver os problemas, podendo ocorrer de forma simbólica que é denominada desta maneira pois a máquina recebe vários dados simbólicos e constroem sua aprendizagem com exemplos e contraexemplos para que no momento que realmente precise ser utilizada com dados reais opere da melhor maneira possível. Outro meio de aprendizagem é a aprendizagem estatística que é similar à simbólica, porém utiliza informações que foram previamente descritas em estudos probabilísticos e estatísticos levando em consideração que haja conhecimento prévio do problema e que se entenda a adequação dos estudos com a problemática em questão.

Construções com conexões também são usadas quando se fala em aprendizado de máquinas, esse método é baseado em um sistema biológico nervoso do cérebro realizando várias operações matemáticas conectadas umas com as outras. Estudiosos do ramo afirmam que esta metodologia se mostra uma das mais eficazes porque tenta aproximar ao máximo a análise computacionais para o reconhecimento de padrões com a complexidade de um sistema neural.

E por último há o método genético, que recebe esse nome porque se utiliza da seleção dos dados tal qual o processo de seleção natural evolutivo das espécies, em que os genes mais dominantes se sobressaem diante dos genes menos dominantes, basicamente o que ocorre é que na base de dados as entradas que estiverem mais correlacionadas com as informações que se deseja na saída são escolhidas e as que menos estão correlacionadas são descartadas (MONARD; BARANAUSKAS, 2013).

Os localizadores de faltas podem ser constituídos por máquinas de aprendizagem utilizando a metodologia das Redes Neurais Artificiais (RNA). Lovisolo *et al.* (2012) aborda em seu trabalho o uso desse tipo de máquina de aprendizado em que inicialmente é feita a coleta dos dados de tensão e correntes fazendo simulações para os tipos de falta com medidores posicionados na subestação que alimenta o sistema de distribuição.

Após a obtenção das informações das grandezas é feito um tratamento com valores obtidos, antes de ocorrer a falta e no momento da falta, que são decompostos em senoides amortecidas, ou seja, que têm amplitudes crescentes, cada senoide com a frequência natural do sistema, que pode ser múltipla da frequência fundamental, esses sinais de tensão e corrente trifásicas são relacionados como a soma das senoides amortecidas que têm harmônicas da frequência fundamental.

Com o tratamento de dados concluído se fez necessário categorizar quais seriam as entradas do sistema para a modelagem da máquina, que a princípio havia 180 valores iniciais e depois da seleção de variáveis obteve-se 30 valores de entrada. Em seguida os dados simulados foram inseridos na RNA levando em conta que 70% das amostras foram usadas para treinamento e 30% para testes.



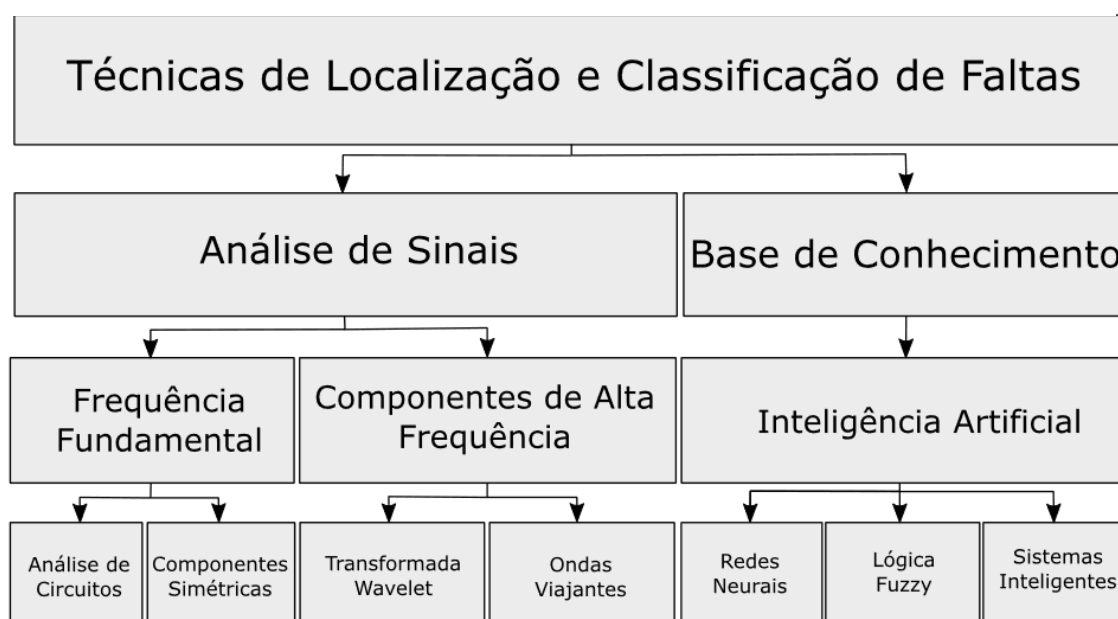
## 4 METODOLOGIA

Nesta seção são descritos todos os procedimentos realizados para obtenção dos resultados do trabalho.

### 4.1 Etapa 1: Seleção da técnica de localização de faltas mais adequada para o cenário

Inicialmente, foi realizada uma análise comparativa para determinação do método mais adequado para localização das faltas em sistemas de distribuição. Portanto as técnicas analisadas foram subdivididas e categorizadas conforme a Figura 12.

**Figura 12 - Técnicas de Localização e Classificação de Faltas**



Fonte: Adaptado de Bíscaro (2013).

Como pode ser visto na Figura 12 12, existem dois grandes grupos de técnicas para localização de faltas, o grupo da análise de sinais se baseia na obtenção de sinais relacionado as grandezas elétricas podendo ser corrente ou tensão. A partir da captura de dados são feitos tratamentos dessas informações aplicando aos métodos análise de circuito, componentes simétricas ou transformada Wavelet que são modelagens matemáticas capazes de determinar o local da falta.

No grupo relacionado a base de conhecimento nota-se que uma abordagem mais robusta, pois este utiliza as grandezas elétricas e faz uso de modelagens matemáticas também. Porém, a inteligência artificial que, em comparação com análise de sinais, leva vantagem na maioria dos casos porque faz associações e comparações com os dados para obter o resultado, podendo se adaptar, melhorar e até aprender com os diferentes dados de entrada.

A técnica escolhida foi a de Redes Neurais Artificiais, pois apresentam as seguintes vantagens:

- Capacidade de aprender ou se adaptar a informações paralelamente, conseguindo lidar com mais de uma tarefa ao mesmo tempo sendo então mais eficaz em determinadas situações que exigem velocidade de resposta.
- Resolução de sistema complexos pela sua capacidade de identificar padrões e entregar soluções com alto grau de confiabilidade.
- Ter bom desempenho em áreas da engenharia elétrica tanto para localização de faltas como em problemas envolvendo proteção de sistemas elétricos, determinação de fluxo de potência e até geração de energia.
- Os resultados obtidos nas referências bibliográficas indicam que é uma boa técnica para determinar o local da falta em redes de distribuições com ramificações.

#### **4.2 Etapa 2: Seleção dos dados de entradas utilizados nos localizadores de faltas**

Foi criada uma tabela para analisar quais seriam os possíveis dados de entradas que poderiam ser utilizados em localizadores de faltas. Após a análise foram selecionados os dados sob duas condições. A primeira é que seriam dados de fácil obtenção em redes de distribuição e a segunda é que seriam dados que a maioria das concessionárias conseguissem fornecer. Pode ser visto na Tabela 2 os potenciais dados de entradas utilizados em localizadores.

Tabela 2 - Análise dos dados de entrada de localizadores de falta.

Bibliografia	V e I na SE	V  na rede	Z vista	\Delta V  na rede	P na SE
1. (TAKAGI, 1982)	X		X		
2. (GIRGIS; FALLON, 1992).	X		X		
3. (ZHU; LUBKEMAN; GIRGIS, 1997)	X		X		
4. (SENGER <i>et al.</i> , 2005)	X		X		
5. (MANASSERO; SANTO; SOUTO, 2017)	X	X	X		
6. (GALIJASEVIC; ABUR, 2002)		X		X	
7. (TREMBLAY, 2007)		X		X	X
8. (ZVIETCOVICH, 2011)		X		X	X
9. (ZAVODA, 2010)		X		X	X
10. (PARKER; MCCOLLOUGH 2011)		X			
11. (JÚNIOR; TAKADA; FREITAS, 2014)	X				
12. (TRINDADE, 2014)		X		X	X
13. (CORDOVA; FARUQUE, 2015)	X	X			
14. (CAPELINI, 2016)		X			
15. (CRESPO, 2021)	X		X		
16. (JÚNIOR, 2015)	X	X	X		

Fonte: Adaptado de Pereira (2019).

No presente trabalho, os dados de entradas que podem ser obtidos mais facilmente são aqueles referentes aos 5 trabalhos iniciais, os fasores de corrente e tensão obtidos na unidade de medição da subestação fornecedora. Estes dados podem ser obtidos facilmente porque não é necessário que a rede tenha componentes do tipo *SmartGrids*, é necessário apenas uma única medição do valor eficaz da corrente e tensão elétrica no início do alimentador e essa medição é padronizada no sistema de distribuição. Portanto, qualquer alimentador possuirá estas informações.

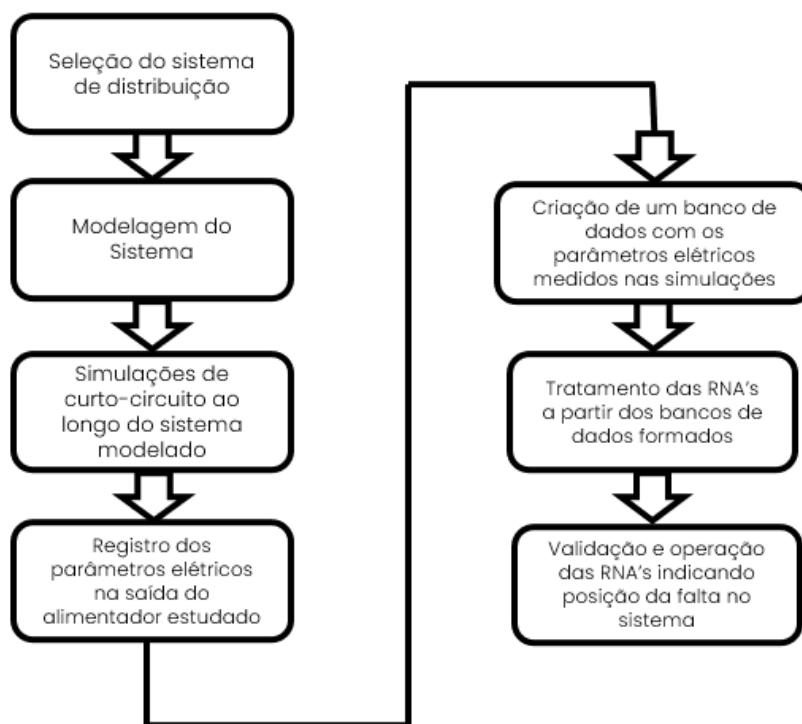
Os fasores de tensão e corrente no início do alimentador foram escolhidos como dados de entrada para o localizador de falta no presente trabalho. Dentre as razões para a escolha, destaca-se o fato de que são facilmente obtidos em qualquer

alimentador, já que, por padrão, todos os alimentadores devem possuir um medidor na saída da subestação PRODIST (Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional) - Módulo 7.

### 4.3 Etapa 3: Criação de um fluxograma para desenvolvimento de localizadores de faltas

Para utilização da RNA em um localizador de faltas, foram realizadas as etapas descritas na Figura 13.

**Figura 13 - Fluxograma para utilização de RNA's em Localizadores de Faltas**



Fonte: Autor

Como pode ser observado na Figura 13, foi utilizado um processo de obtenção de uma base de dados, a partir de simulações, para o posterior treinamento e testes da RNA. Nas subseções seguintes são fornecidas maiores informações sobre estas etapas.

#### 4.4 Etapa 4: Seleção da Rede de Distribuição

Para a escolha da rede foram impostos alguns critérios:

- I. Ser uma Rede de Distribuição Aérea;
- II. Possuir dados suficientes para modelagem em softwares;
- III. Conter uma quantidade expressiva de equipamentos elétricos, para que houvesse um bom quantitativo de dados para a RNA;
- IV. Ser uma Rede de Distribuição real.

Com esses critérios foi escolhido um alimentador urbano de média tensão com, as seguintes características:

**Tabela 3 - Configurações da Rede**

	<b>Média Tensão</b>	<b>Baixa Tensão</b>
<b>Barras</b>	5657	491
<b>Quilômetro de rede</b>	15,14	84,67
<b>Cargas</b>	45	11047
<b>Transformadores 13,8kV/220V</b>	78	

Fonte: Autor

#### 4.5 Etapa 5: Seleção das ferramentas matemáticas utilizadas para aplicação de curto-circuitos e suas utilizações ao longo do processo

Para o cálculo de faltas em sistemas de distribuição de grande porte, se fez necessário a aplicação de ferramentas computacionais, que se baseiam em métodos numéricos para solução de matrizes de grande dimensão. Neste contexto foi selecionado o *software* OpenDSS, do inglês *Open Distribution System Simulator*, que é um programa para simulação de fluxo de carga em sistemas de distribuição. Ele foi escolhido pela sua estruturação, pois funciona a partir da implementação de código aberto do *Data Distribution System* (DSS) que serve para manipulação de dados.

Outra vantagem é que o OpenDss pôde ser integrado com Python, mas para além do Python ele pode ser integrado com VBA, Matlab e Linguagem em C. O DSS

sendo implementado como um *software stand-alone* e uma *Data Definition Language Componente Object Model* (DLL COM) que é um banco de dados e um servidor foi possível fazer alterações em estruturas de dados em linguagem SQL. A versão executável adiciona uma interface de usuário básica que facilitou o seu uso no desenvolvimento de scripts e visualização de soluções.

O programa pôde ser utilizado para análise de curto-circuito AC e planejamento e análises em sistemas de distribuição. Todavia, o OpenDSS pode ser utilizado em vários outros tipos de análises, como por exemplo:

- Estudos de geração distribuída;
- Simulação do carregamento de cargas e gerações anualmente;
- Simulação de geração eólica;
- Análises de configurações não tradicionais para transformadores;
- Estudos de harmônicas;
- Desenvolvimento de alimentadores testes para casos do IEEE.
- Planejamento e análises em sistemas de distribuição;
- Análises de curto-circuito AC com múltiplas fases;

No OpenDSS o fluxo de potência foi calculado tanto para circuitos em malha de média tensão (MT) como para a redes em malha de baixa (BT). Embora a precisão de alguns algoritmos pode depender do modelo do circuito ser radial ou não, a solução de fluxo de potência precisou ser averiguada para qual poderia entregar melhores resultados. Um fato observado é que as duas soluções funcionam melhor em sistemas que têm pelo menos uma fonte não variável. Os dois tipos básicos de solução de fluxo de energia são:

- Fluxo de potência iterativo;
- Solução direta.

Na solução direta, é adicionado ao programa as matrizes de admitância do sistema e então é resolvido o fluxo de potência sem nenhuma iteração. O fluxo de potência iterativo se divide em dois outros métodos, o método de injeção de corrente e método de Newton, que se diferem pelo fato de que o método de injeção de corrente precisa de menos esforço computacional, logo é o preferido em determinados casos, como quando se almeja obter um grande conjunto de dados. O método de Newton

que foi o selecionado é mais robusto, por isso, pode ser usado para modelos de cargas não-lineares e sistemas mais robustos (DUGAN, 2016).

Para análises de curtos foi utilizando também um modo de simulação específico, chamado *Fault Studies*, no qual foi possível simular faltas em barras da linha de distribuição podendo elas serem trifásicas, bifásicas, bifásicas para terra e monofásicas. Nesse modo de simulação foi preciso que os transformadores fossem representados como bobinas reais. Foi simulado faltas em diferentes pontos da rede, e em mais de um ponto ao mesmo tempo. E por fim com o modo de simulação *Snapshot Fault* se capturou os valores das grandezas elétricas no sistema, como corrente, tensão e potência em determinados pontos do circuito.

#### **4.6 Etapa 6: Construção da rotina computacional para simulações de curto-circuito**

Após a seleção de quais ferramentas computacionais disponíveis que mais se adequavam com os objetivos do trabalho para realizar a simulação dos eventos de curtos-circuitos foi possível iniciar as simulações de curto-circuito. O OpenDSS foi determinado como a melhor opção de ferramenta, pois, nele é possível aplicar todos os tipos de faltas. Além disso O OpenDSS se sobressai a outros softwares por haver uma integração mais fluida com a linguagem Python, o que é de grande relevância para execução da atividade desejada no trabalho, além de ser feito diretamente para redes de distribuição, o que pode resultar em valores mais satisfatórios e precisos na realização e faltas no sistema.

Para iniciar as simulações foi inserida a rede de 13,8 kV/380 V e ajustados os parâmetros para que se adequasse a linguagem do programa. Os dados necessários para que o software realizasse os cálculos foram os dados dos transformadores como potência aparente, tensão e admitância, dos cabos como diâmetro, resistência, ampacidade e distância entre os condutores e de carga como potência ativa e reativa, tensão e tipo de conexão. O método utilizado foi o fluxo de potência iterativo que se divide em dois outros métodos, o método de injeção de corrente e método de Newton, esse método foi escolhido porque consegue entregar melhores resultados com banco de dados maiores.

O objetivo da simulação no OpenDSS foi obter os fasores de tensão e corrente elétrica na barra inicial do alimentador, no momento em que ocorre um curto-circuito em diferentes pontos da rede. Foi considerado a possibilidade de curtos-circuitos monofásicos, bifásicos e trifásicos em cada uma das 6.148 barras da rede, o que resulta em 18.444 cenários para cada tipo de falta. Evidentemente não é viável realizar a simulação de todos os cenários de forma manual, por isso, a utilização da linguagem Python se apresentou como uma boa alternativa para automatizar o processo.

A linguagem Python é uma linguagem de programação em que foi possível fazer a análise das faltas e obter os valores que futuramente seriam utilizados na RNA. Ao invés de utilizar a interface direta com o usuário no OpenDSS, foi utilizada a interface COM (*Component Object Model*), que fez sua integração com o Python por meio do servidor COM e a partir de uma linguagem de definição de dados o DDL.

Para a construção da rotina de simulação em Python foi necessário a utilização do pacote computacional Py-Dss-Interface, o qual foi instalado em um ambiente virtual denominado PyCharm que oferece ferramentas para facilitar a programação do usuário em Python como correções rápidas, realocação de erros e recursos de navegação avançado. Com a utilização deste pacote não foi necessário que o OpenDSS estivesse instalado na máquina de simulação, pois, o pacote computacional já fornecia o software.

Do pacote computacional foram usadas funções específicas que puderam ser utilizadas para obter e manipular os dados resultantes da simulação. Além destas funções, do Py-Dss-Interface foram utilizados métodos e ferramentas que auxiliaram para uma programação de forma mais fluída e a fazer um tratamento de dados mais eficiente quando comparado ao uso do OpenDSS separadamente do ambiente virtual do Python. Além do pacote Py-Dss-Interface, também foi utilizada a biblioteca Numerical Python, cujo objetivo foi permitir manipulações matemáticas na rotina de simulação. Em seguida foram adicionados ao programa a interface COM do programador de faltas e a rede de distribuição de 6.148 barras sob estudo.

Para obter as grandezas elétricas na barra inicial do alimentador, foi adicionado à função EnergyMeter alocado na barra inicial do sistema, o qual consiste em um medidor de energia capaz de fornecer informações do fluxo de carga no ponto em que está instalado, ele é uma função que já vem com a instalação do da interface COM.



Com a utilização do EnergyMeter foi possível obter as distâncias de cada barramento até o ponto de referência com a função responsável por isto, que já estava contida no pacote de instalação. Depois, foram utilizadas as funções de captura dos nomes das barras, dos nós de cada barra e também o tamanho dessas *strings* para que futuramente fossem usadas em laços de repetições. Para simular uma falta monofásica no sistema de distribuição, primeiro deve-se analisar quantas fases tem a linha e em qual nó elas estão posicionadas. Então foi criada uma função que não havia no Py-Dss-Interface para que retornasse o índice do nó inicial de cada barra para que fosse aplicada uma fase monofásica na linha desse nó. Todas as faltas foram aplicadas com uma resistência entre a linha e a terra de 5 ohms.

Em faltas bifásicas-terra na rede de distribuição foi preciso fazer algumas adaptações no código, pois era preciso primeiro encontrar qual seria as fases que iriam ocorrer o curto. Então foi feito um código para identificar qual a era a primeira fase que existia na linha, podendo ser a fase A, B ou C e então, depois de descoberta qual seria, essa fase, realizar uma nova busca para encontrar a fase seguinte, isso é preciso ser feito porque na rede havia linhas com apenas uma fase, com duas fases ou com três fases.

Foi criado um novo código apenas para faltas trifásicas em que era primeiramente preciso identificar se a rede havia três fases para aplicar a falta nelas. É importante frisar que o OpenDSS permite aplicar faltas trifásicas em linhas com apenas duas fases, por isso se faz necessária essa adaptação no código. No Py-Dss-Interface, antes de qualquer obtenção de dados, era preciso ativar qual seria o elemento da rede que forneceria esses dados elétricos, por exemplo, para obter os dados de corrente era preciso ativar a linha. Então, dentro do código, foram ativadas as barras para obtenção de tensão e todas as linhas.

A cada iteração era simulada uma falta em uma barra do sistema e eram obtidos quatro tipos de dados elétricos na barra: módulo da tensão, ângulo da tensão, módulo da corrente e ângulo da corrente. As funções que forneciam esses valores analisavam o perfil de tensão e corrente em toda a rede e então no *looping* era feita a seleção de qual barramento seria aplicada a falta. Após a simulação de todos os tipos de faltas em todos os barramentos, os dados elétricos obtidos foram utilizados para compor um banco de dados, o qual foi utilizado para treinamento e testes da rede neural artificial.

#### 4.7 Etapa 7: Subdivisão e seleção dos dados elétricos para início do treinamento da rede

O treinamento da Rede Neural Artificial foi feito por meio da plataforma KNIME que é um software que contém técnicas de aprendizado de máquinas baseados em Javascript. A programação foi feita através de blocos visuais que facilitaram implementação dos códigos, fazendo então com que houvesse uma integração mais fluída entre diferentes módulos de carregamento, processamento de sinais, análise de dados. Foi possível mediante a plataforma a adição de plugins para análises mais sofisticadas. Caso necessário o usuário poderia integrar outros tipos de aprendizagem de máquina e desenvolver técnicas para análises mais específicas desse ramo capaz de fornecer ferramentas gráficas e informações para estudos da ciência de dados, porque o KNIME tem um código aberto.

A partir das simulações de faltas realizadas, foi possível obter dados suficientes para formação de um *dataset* de treinamento e teste da RNA. Os dados foram divididos em três grupos: um referente aos dados de faltas monofásicas, outro referente aos dados de faltas bifásicas e outro referente aos dados faltas trifásicas. A divisão foi realizada para o melhor gerenciamento de dados, devido as características distintas dos diferentes tipos de falta.

Além das grandezas capturadas diretamente da simulação, também foram calculadas outras variáveis para utilização no modelo de RNA. Assim, como dados de entradas utilizadas foram as seguintes variáveis: magnitude de tensão e corrente, ângulo de tensão e corrente, fator de potência, potências ativa, reativa e aparente. De forma correspondente, a variável de interesse nos modelos de RNA (*target*) foi definida como a distância do barramento de ocorrência da falta em relação ao barramento inicial do alimentador.

A cada tipo de falta foram selecionados quais parâmetros seriam treinados pela rede, e isso foi feito mediante a análise da correlação de Spearman, que foi responsável por quantificar o nível e direção da associação entre duas variáveis classificadas, o coeficiente gera um número que varia de -1 a +1, quanto mais próximo dos extremos, -1 ou 1, maior era a força da correlação.

Após esta etapa foi realizada uma etapa de pré-processamento no banco de dados, o qual consistiu na normalização dos dados com a função de ativação sigmoide

logística, que foi usada por se aproximar ao formato “s” porque consegue alcançar muitos pontos de dados em comparação a retas quando são feitas suas aproximações. A normalização realizada para este sistema ficou no range entre 0 e 1, pois a função tem um intervalo contínuo entre 0 e 1 podendo ser diferenciável nestes valores, se adequando assim aos requisitos para utilização em RNA's. Por seguinte, houve a repartição dos dados, em que 80% deles foram utilizados para treinamento e 20% para validação da rede.

#### **4.8 Etapa 8: Seleção da rede e do algoritmo de treinamento**

Foi utilizada uma rede de múltiplas camadas retroalimentadas (*feedforward*), essa rede se mostrou mais eficiente que as outras porque além poder haver um grande número de camadas ocultas, e conseqüentemente grande número de nós, contém conexões que ligam a entrada a saída podendo sempre realizar comparações que tentam aproximar os erros a zero (CRISTÓVÃO, 2018). A quantidade de nós foi definida levando em consideração as entradas e saídas, os valores dos erros e a complexidade da rede.

Dentro da categoria de redes *feedforwards*, foi utilizada a Multilayer Perceptron (MLP) em que foi possível determinar que era uma rede que poderia ser aplicada a este cenário porque consiste em três ou mais camadas, uma de entrada, uma ou mais ocultas e uma de saída e essa camada de saída pode possuir vários neurônios podendo assim relacionar conhecimento entre eles. Mesmo que a rede MLP não solucionasse problemas com linearidade separável ela foi a escolhida, pois é constituída do mínimo números de elementos que uma rede precisa para conseguir realizar um processamento rápido em seu treinamento de validação, entregando então saídas com alta velocidade. Outra limitação é que só há apenas uma retroalimentação que está localizada na camada oculta mais próxima da saída. Quando a rede é treinada só é possível saber qual o valor exato do erro nesta camada, as camadas que antecedem estas só têm estimativas. Logo, só se pode calcular erros com precisão no final da rede.

O algoritmo de treinamento utilizado foi o Levenberg-Marquardt, pois, este algoritmo usou o artifício de separar classes iterativamente, em que os pesos sinápticos permaneceram em uma classe até que a rede fosse treinada

completamente. Então, após uma iteração finalizada, os pesos foram atualizados indo para outra classe e esse procedimento aconteceu até encontrar um bom estado da rede

#### **4.9 Etapa 9: Otimização dos hiperparâmetros da rede e validação cruzada**

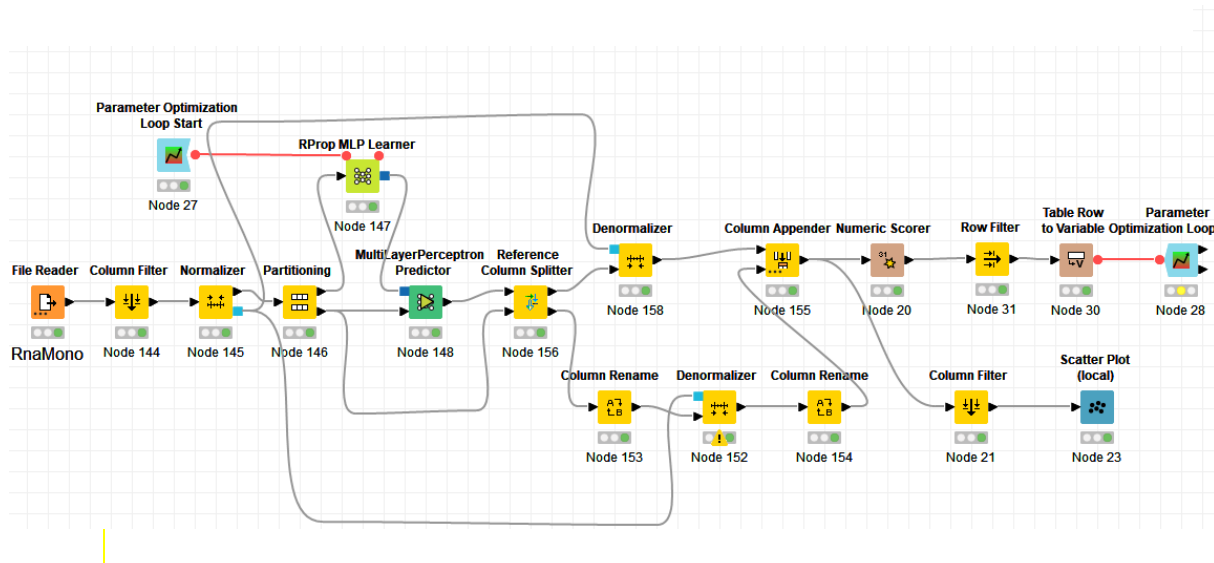
. Além disso, foram feitas otimizações de hiperparâmetros com 100 iterações, em que em cada iteração um nó realizava o cálculo matemático correspondente a informação contida nele. As otimizações foram feitas mediante o método de força bruta, em que todas as combinações de parâmetros possíveis (dados os intervalos e os tamanhos dos passos) são verificadas e o melhor é retornado com a definição prévia de atingir um erro de zero entre as previsões e os valores reais.

O número de camadas ocultas foi definido por meio de otimização dos parâmetros da rede, esse valor foi selecionado para obter os melhores resultados relacionados aos erros. Com a configuração da rede completa e a repartição de quais dados seriam utilizados como verificação e treinamento escolhida, foi possível executar o programa que se iniciou treinando a rede e executado os cálculos de correlação dos neurônios.

Após a etapa de otimizar os hiperparâmetros, foi realizado o processo de validação cruzada (*cross validation*) para que pudesse confirmar se a rede realmente poderia entregar bons valores com os hiperparâmetros obtidos. Sendo assim, foi selecionado uma parte dos dados para aprendizagem de máquina e a outra para simulação da máquina, a cada iteração um conjunto de dados que foi usado para aprendizagem era usado para simulação do evento, até que todos os dados fossem utilizados para as duas funções.

#### **4.10 Esquema de como foi feita a construção da Rede Neural Artificial**

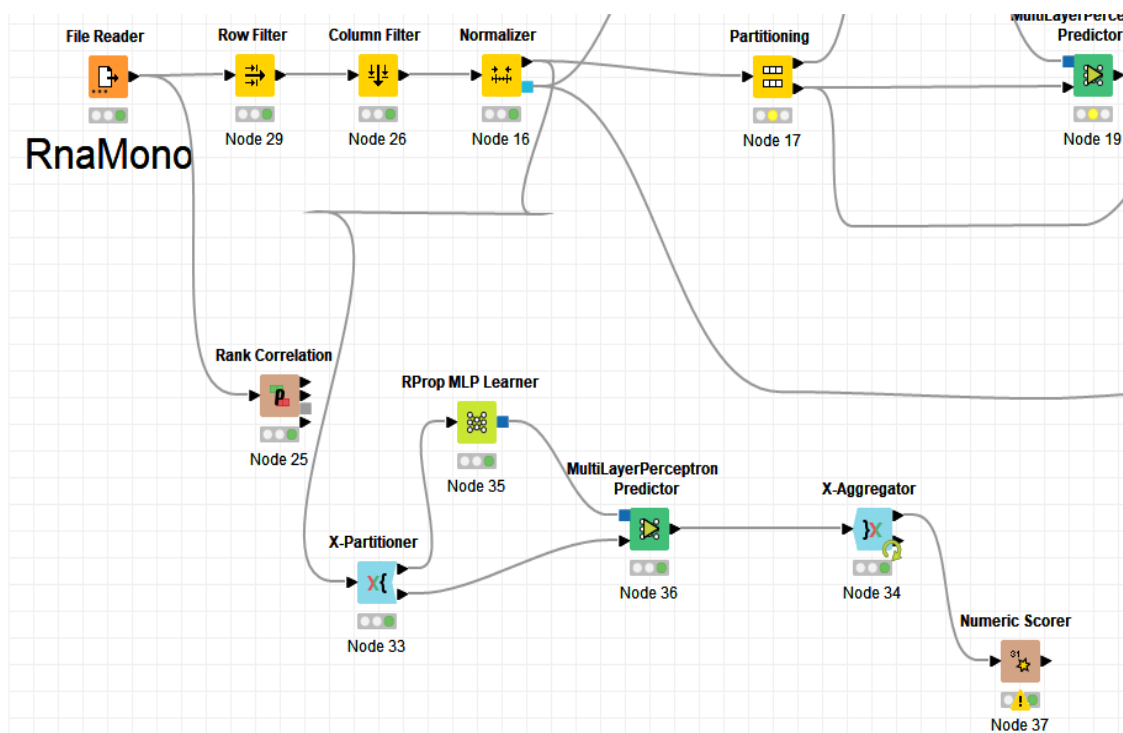
**Figura 14 - Rede Neural Artificial Feita no KNIME.**



Fonte: Autor

Na Figura 14 é mostrado como foi feita a construção da RNA no KNIME em que o bloco File Reader continha os dados elétricos das faltas nas redes neurais e a distância dos barramentos, Column Filter era um filtro de coluna para seleção de colunas, Normalizer era o normalizador e Denormalizer o desnormalizador. O RProp MPL Learner faz adequação dos pesos, MultiLayerPerceptron é a rede Multi Camadas, Reference Column separa a coluna das previsões das colunas dos dados de entradas, Column Rename para renomear uma coluna, Column Appender une colunas, Numeric Scorer informa erros e dados do sistema, Row Filter filtra as linhas das tabelas, Table Row to Variable converte os valores das linhas de uma tabela em variável para que seja utilizada para otimização dos hiperparâmetros com os blocos Parameter Optimization Loop.

Figura 15 - Cross Validation da RNA.



Fonte: Autor

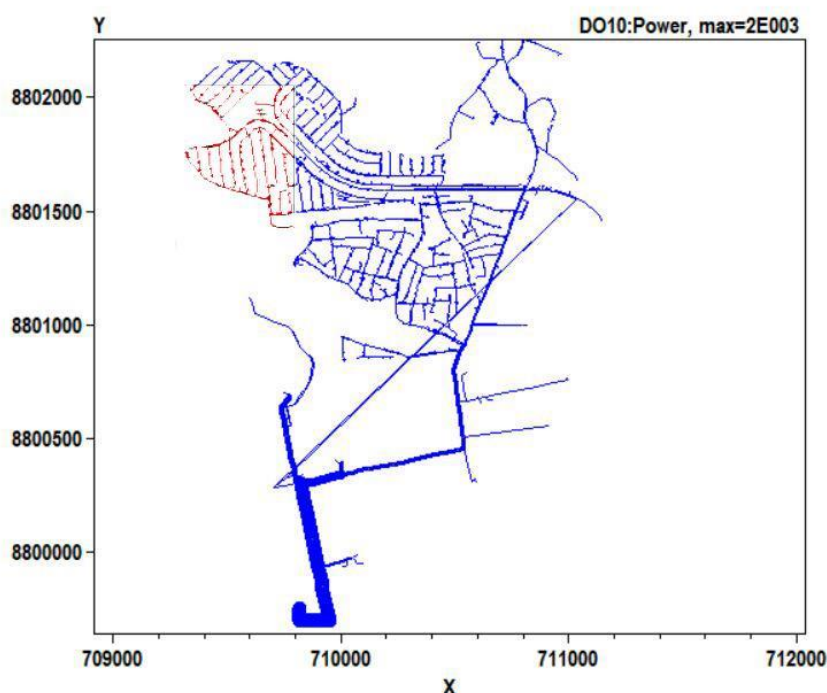
Pode ser visto na Figura 15 o bloco Rank Correlation, e ele informa a correlação entre as variáveis sendo calculada mediante a correlação de Spearman. Também pode ser visto os nós X-Partitioner e X-Aggregator que são responsáveis por realizar a validação cruzada dos dados por meio do método de *cross validation*.

## 5 RESULTADOS E ANÁLISES

A partir da rotina computacional desenvolvida, foram obtidos os dados de distância das 6.148 barras para o início do alimentador principal e, a partir das simulações no OpenDSS, foi possível obter os dados elétricos resultantes da ocorrência de cada falta e por seguinte aplicado as redes neurais artificiais como banco de dados.

Inicialmente, o primeiro resultado a ser obtido foi a distância entre alimentador e as demais barras do sistema que foram adquiridas em quilômetros com valores variando de 0,05 a 4,5 quilômetros. Essas distâncias foram obtidas levando em consideração as 5657 barras de MT e as 491 barras de BT. As distâncias foram encontradas primeiramente porque para realização das aplicações de faltas se fez necessário adquirir esses dados. Na Figura 16, pode ser visto o esquema da rede em que as linhas azuis indicam as linhas de baixa tensão e as linhas vermelhas indicam as linhas de média tensão. A figura representa um gráfico que contém as coordenadas de cada barra do sistema.

**Figura 16 – Gráfico da Rede de Distribuição em coordenadas de latitude e longitude**



Fonte: Autor

Foram aplicadas em média 18444 faltas nos barramentos do sistema para que fosse possível obter, mediante ao Py-Dss-Interface, dados de tensão, corrente e seus ângulos, potência ativa, reativa, aparente e fator de potência, tanto para quando aplicadas faltas monofásicas, quanto para faltas bifásicas, quanto para faltas trifásicas. A partir das simulações de curto-circuito realizadas e da obtenção do banco de dados, foi possível realizar uma análise de correção entre as variáveis obtidas e a variável *target* no problema, ou seja, a distância de ocorrência das faltas. Nas tabelas 4, 5 e 6 são apresentados os valores calculados pela correlação de Spearman, os quais indicam as variáveis que possuem maior associação com o *target* e, por isso, tendem a gerar melhores previsões para o sistema após o treinamento e validação da rede.

**Tabela 4 - Matriz de correlação de variáveis com a distância na fase A**

Variável	Correlação 1	Correlação 2	Correlação 3
Mag. Corrente	-0,974	-0,973	-0,9745
Ang. Corrente	0,933	0,828	0,842
Mag. Tensão	0,981	0,626	0,969
Ang. Tensão	-0,243	-0,635	0,993
FP	0,832	-0,829	0,829
Potência Ativa	0,830	-0,956	-0,983
Potência Reativa	0,424	-0,982	-0,956
Potência Aparente	0,827	-0,973	-0,974

Fonte: Autor

**Tabela 5 - Matriz de correlação de variáveis com a distância na fase B**

Variável	Correlação 1	Correlação 2	Correlação 3
Mag. Corrente	-0,982	-0,973	-0,974
Ang. Corrente	0,881	0,911	0,148
Mag. Tensão	-0,989	0,966	0,967
Ang. Tensão	0,980	0,828	0,992
FP	0,402	-0,975	0,805
Potência Ativa	0,941	-0,896	-0,982
Potência Reativa	-0,975	-0,973	-0,954
Potência Aparente	-0,974	-0,943	-0,974

Fonte: Autor



**Tabela 6 - Matriz de correlação de variáveis com a distância na fase C**

<b>Variável</b>	<b>Correlação 1</b>	<b>Correlação 2</b>	<b>Correlação 3</b>
<b>Mag. Corrente</b>	-0,705	-0,973	-0,974
<b>Ang. Corrente</b>	-0,724	0,950	0,817
<b>Mag. Tensão</b>	-0,961	-0,173	0,968
<b>Ang. Tensão</b>	-0,988	0,815	0,996
<b>FP</b>	0,988	-0,135	0,804
<b>Potência Ativa</b>	-0,890	-0,968	-0,982
<b>Potência Reativa</b>	-0,985	-0,973	-0,954
<b>Potência Aparente</b>	-0,963	-0,973	-0,974


Fonte: Autor

Nas tabelas 4, 5 e 6 a coluna referente a correlação 1 indica a medida de associação entre a distância e variáveis em faltas monofásicas, a coluna correlação 2 indica para faltas bifásicas e a correlação 3 indica para faltas trifásicas. A partir dos resultados apresentados nas tabelas, pode-se constatar que existem variáveis fracamente associadas com a distância do local da falta tanto para faltas monofásicas como bifásicas e trifásicas, visto que, o coeficiente de Spearman gera um número que varia de -1 a 1, quanto mais próximo dos extremos, -1 ou 1, maior é a força da correlação.

As variáveis com associações fracas foram eliminadas do processo de treinamento da RNA, em faltas monofásicas foram eliminadas as variáveis analisadas no alimentador principal da rede foi o ângulo de tensão da fase A, fator de potência da fase B e potência reativa da fase A por estarem pouco correlacionadas. Para bifásicas não se utilizou as variáveis de ângulo de tensão da fase B e potência ativa da fase B. E por fim, para faltas trifásicas, apenas a variável de ângulo de tensão da fase B não foi utilizado no treinamento da rede. As demais variáveis foram utilizadas no treinamento e podem ser vistas nas figuras 17, 18 e 19.



**Figura 19 - Correlação das variáveis com o *target* em faltas trifásicas**



Fonte: Autor

Em faltas monofásicas, houve pequenas variações nos valores dos ângulos da tensão da fase A em cada falta realizada, como pode ser visto na Figura 17 induzindo ao sistema encarar esse dado como uma constante, logo, não variando de acordo com o *target*. A potência reativa da fase A acabou ocorrendo o mesmo por estar relacionada com o ângulo de tensão da fase A.

Nas faltas bifásicas a variáveis que estavam relacionadas ao ângulo da tensão da fase B se não pode obter bons resultados de correlação como pode ser visto na Figura 18. Isso aconteceu pois os valores do ângulo obtidos haviam grande parte com valores negativos e com pequenas variações em seu valor, o que não aconteceu com as outras variáveis.

E por fim, em faltas trifásicas, ocorreu o mesmo com as outras fases. Houve uma pequena variação entre os valores de ângulo da fase B quando a falta ocorria em cada barramento, logo no cálculo da correlação isso foi entendido como um coeficiente constante que não tinha relação nenhuma com *target*.


Após a definição do *dataset* de treinamento da RNA, foi realizado o processo de otimização dos hiperparâmetros da rede que foi feito pelo método da força bruta. Na tabela 7 é possível ver quais foram os números de camadas ocultas e neurônios por camada ocultas nos três tipos de faltas.

**Tabela 7 - Camadas ocultas e neurônios por camada ocultas**

	<b>Camada Ocultas</b>	<b>Neurônios Ocultos</b>
<b>Monofásicas</b>	7	41
<b>Bifásicas</b>	2	49
<b>Trifásicas</b>	6	49


Fonte: Autor

No gráfico da Figura 20 o eixo X está a distância que foi obtida em simulações de faltas monofásicas na rede e no eixo Y a previsão da distância que foi obtido por meio da RNA. A previsão indica quais são os possíveis locais da falta com os dados de entrada atual, levando em conta todo o aprendizado da rede. No cenário ideal a previsão deveria haver o mesmo valor que a distância já que os dados de entradas são os mesmos, porém, por causa a aprendizagem e adequação a generalização da rede, isso não acontece. É mostrado no gráfico apenas um indicativo visual da relação dos dois valores, para ter a certeza é preciso analisar os erros.


**Figura 20 - Distância vs Previsão em faltas monofásicas**

Fonte: Autor

Nas Figura 21 e 22, pode-se observar que existem dados de previsão que estão diferentes da distância pelo fato que a aprendizagem da rede não é perfeita devido a correlação das variáveis de entrada que nem todas que têm grau máximo de 1 ou -1 de correlação. Porém, visualmente é possível deduzir que para a maioria dos pontos em X de distância tem um ponto em Y de previsão com valores próximos ou exatos, o indicativo que esta afirmação é verdadeira é visto no gráfico uma aproximação linear, ou seja, para cada ponto em X há um Y com valores semelhantes.

**Figura 21 - Distância vs Previsão em faltas bifásicas**

Fonte: Autor

**Figura 22 - Distância vs Previsão em faltas trifásicas**

Fonte: Autor

Na tabela 8 são apresentados as métricas de erro do valor real da distância em comparação da previsão dos dados criada pela rede levando em consideração apenas 1 camada oculta e 10 neurônios ocultos, ou seja, sem otimização dos hiperparâmetros

e levando em consideração a rede otimizada com método da força bruta com os valores de camadas ocultas e neurônios ocultos mostrados na tabela 7. Esses erros são as métricas que realmente indicam se os valores criados de previsão das distâncias são realmente bons resultados.

**Tabela 8 - Métricas de erros**


<b>Tipos de faltas</b>	<b>Métrica de erros</b>	<b>Sem otimização</b>	<b>Com otimização</b>
<b>Monofásicas</b>	Erro absoluto	0,155	0,006
	Erro médio quadrático	0,031	0
	Raiz do erro médio quadrático	0,327	0,009
<b>Bifásicas</b>	Erro absoluto	0,138	0,004
	Erro médio quadrático	0,022	0
	Raiz do erro médio quadrático	0,153	0,006
<b>Trifásicas</b>	Erro absoluto	0,976	0,022
	Erro médio quadrático	0,192	0,001
	Raiz do erro médio quadrático	0,438	0,034

Fonte: Autor.

Todos esses dados são analisados tomando como base os valores em quilômetros das distâncias e seus possíveis valores de previsão caso ocorra alguma falta no sistema. O erro absoluto, que é a diferença entre o valor medido e o valor real, precisa ser o menor possível já que se almeja que as previsões tenham o mesmo valor das distâncias, com a otimização da rede foi possível reduzir seus valores em todas os três tipos de falta. Outra métrica que foi otimizada foi o erro médio quadrático, que fornece a média da diferença do quadrado da previsão e o valor, é uma boa métrica para compreender a qualidade do modelo, quanto menor o erro maior a qualidade do estimador. E por fim, os resultados da raiz do erro médio quadrático foi satisfatório pois também foi reduzido ao máximo. Essa métrica indica a precisão o modelo, quanto mais baixa mais preciso.

Dentre as 491 faltas aplicadas na rede de média tensão simuladas, pode ser visto, mediante o gráfico de Pareto da Figura 23, que os erros entre a distância e a previsão com valores entre 10% e 20% são minoria ocorrendo em apenas 8 barras 68 quando aplicadas faltas monofásicas, bifásicas e trifásicas no sistema. Quando se analisa previsões na ocorrência faltas é possível identificar que a maior parte dos erros não foram maiores que 10%, sendo o maior range entre 1% e 5%, totalizando 57% das barras, ou seja, mais da metade das barras estavam contidas nesse conjunto. Pode ser visto também que em 92% das barras, levando em conta os três tipos de faltas, os erros tiveram valores menores ou iguais a 5%, isso também pode ser considerado um indicativo do desempenho da rede neural artificial.

**Figura 23 - Gráfico da porcentagem dos erros entre a distância e previsão quando aplicadas faltas nas barras.**




Fonte: Autor.

Todos os resultados mostrados foram levando em consideração a rede de média tensão. Aconteceram dois cenários, quando se aplicou faltas na MT ocorreram grandes quedas de tensão na barra inicial da rede que também estava na MT, já no cenário de faltas BT houveram poucas variações de tensão nesta barra inicial, quando foram analisadas as correlações da tensão com o target distância, obteve-se baixas correlações, pois o sistema encarou a tensão no alimentador inicial constante no



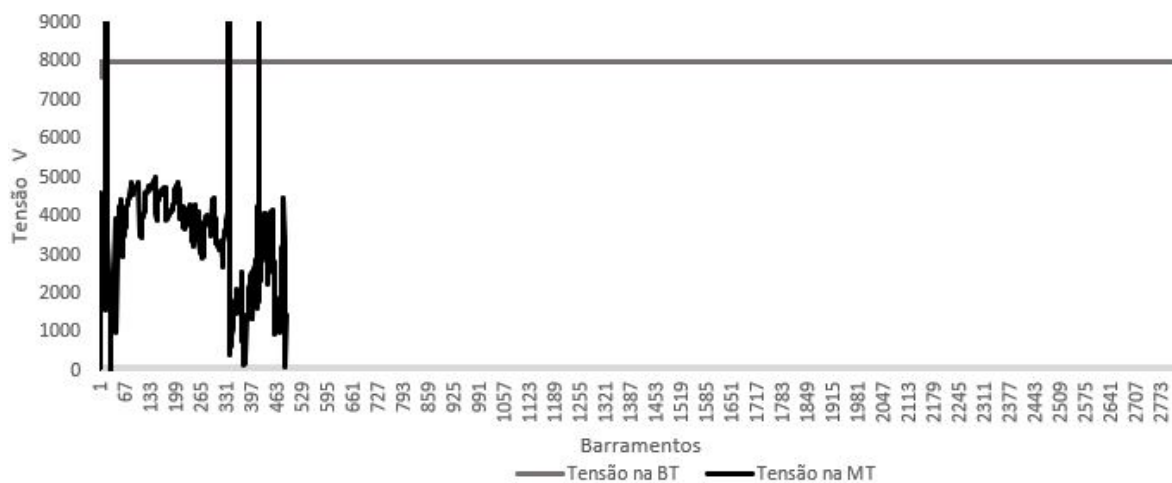
segundo cenário. Na Figura 24 pode-se ver as baixas correlações com os dados das faltas no lado de baixa com o target e na Figura 25 é possível ver a baixa variação de tensão de fase lidas na barra inicial do sistema em faltas BT quando comparada a faltas MT, isso acontece porque as faltas em MT ocorrem próximas do sistema de medição havendo assim altas variações. Para resolver este problema seria preciso que fosse instalado no meio físico da rede medidores no lado de baixa para captar as variações de maneira satisfatória.

**Figura 24 - Correlação das variáveis com a distância em faltas no lado de baixa**



Fonte: Autor.

**Figura 25 - Tensão na barra inicial da rede quando ocorrem faltas na BT e MT**



Fonte: Autor.

Entretanto, todos os valores simulados e calculados na média tensão obtiveram resultados satisfatórios, basta analisar os erros das previsões com a distância que se aproximam de zero, indicando que a previsão contém um bom grau de confiabilidade. Logo, as redes treinadas podem então ser aplicadas a casos gerais para identificar o local da falta, indicando a distância do barramento para o alimentador, trazendo benefícios para as concessionárias, pois, apenas com dados elétricos pode-se reduzir custos energéticos, custos com deslocamentos, o tempo sem energia elétrica, aumentando então os índices de satisfação do cliente.

## 6 CONCLUSÕES

Como conclusão, foi possível verificar a realização do principal objetivo do trabalho, que seria desenvolver um localizador de faltas baseado na aplicação de Redes Neurais Artificiais, capaz de localizar faltas em redes de média tensão no sistema de distribuição. O desenvolvimento desse localizador foi feito visando concluir de forma exitosa os objetivos específicos do trabalho. A criação de um algoritmo capaz de obter valores eficazes de tensão e corrente da rede, a criação de um banco de dados com esses valores, o treinamento e validação de uma Rede Neural Artificial foram os objetivos específicos almejados e concluídos com sucesso ao longo processo.

A partir dos resultados obtidos no trabalho conclui-se que o localizador de faltas desenvolvido está apto para realizar previsões da distância para faltas em redes de média tensão do sistema de distribuição. Esta conclusão pode ser confirmada pela análise dos resultados dos erros após a obtenção dos melhores parâmetros da rede, em que indicaram que a rede tinha uma boa correlação entre os dados de previsão e de entrada, além do modelo ser um bom estimador de valores.

Mesmo não sendo possível analisar faltas em baixa tensão, a rede se mostrou eficiente. Todavia, esse problema poderia ter sido contornado com análises mais profundas de outras variáveis elétricas como: formas de ondas de cada sinal, harmônicas na rede e fazendo análises no domínio da frequência. Outra solução seria adicionar pontos de medições ao longo da rede aumentando assim os níveis elétricos observados nestes novos pontos de medição.

Por fim, é válido considerar que melhorias podem ser feitas no trabalho, como o programa, além de poder realizar localização de faltas, seria agregador que houvesse uma localização de qual especificamente das três fases estaria ocorrendo a falta, fase A, B ou C. Isso poderia ser feito treinando uma nova RNA levando em consideração os dados elétricos fornecidos pelo simulador de faltas em conjunto da separação de colunas indicando qual o local da fase e ao invés de tratar apenas dados numéricos a rede seria criada para tratar dados de classificação.

Outra melhoria que poderia ser aplicada ao localizador seria poder encontrar faltas com alta impedância que são comumente vistas no dia a dia, como fios que caem em áreas com baixa condutividade elétrica e galhos que caem sobre os fios. Para que isso possa ser feito é preciso de um equipamento que consiga ler dados de correntes que não têm incrementos significativos. É preciso também de métodos de localização que consiga captar essa baixa variação e tenha alto processamento de dados para realizar cálculos com valores de diferenças mínimas.

## REFERÊNCIAS

ABB Inc. **Descriptive Bulletin - OVR Three Phase Recloser 15kV - 38kV**. Disponível em: <http://www.abb.com/mediumvoltage>. Acesso em: maio 2022.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL: “**Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional** – PRODIST, Módulo 7 – Acesso ao Sistema de Distribuição”

BÍSCARO, A. P. **Proposta de Algoritmos Inteligentes para Localizar Falhas e Monitorar a Qualidade da Energia em Redes de Distribuição de Energia Elétrica**. 2013. 156 f. Tese (Doutorado) - Universidade Estadual Paulista Júlio de Mesquita Filho, Faculdade de Engenharia de Ilha Solteira, Ilha Solteira, 2013.

BRAGA, A.; CARVALHO, A.; LUDERMIR, T. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000.

BRASIL. Iberdrola. **'Smart grids', ou redes inteligentes, um salto tecnológico para um mundo descarbonizado**. Brasil, janeiro 2019. Disponível em: <https://www.iberdrola.com/quem-somos/energetica-do-futuro/smart-grids>. Acesso em: 12 maio 2022.

CAPELINI, R. M. et al. Methodology for fast fault location in overhead distribution networks by the application of temporary georeferenced fault indicators. In: IEEE INTERNATIONAL CONFERENCE ON HIGH VOLTAGE ENGINEERING AND APPLICATION. **Proceedings...** Chengdu, 2016. p. 1–4.

Companhia Piratininga de Força e Luz. **GED 2912: Proteção de Redes Aéreas de Distribuição Sobrecorrente**. Campinas, p. 8. 2016.

CORDOVA, J.; FARUQUE, M. O. Fault location identification in smart distribution networks with distributed generation. In: NORTH AMERICAN POWER SYMPOSIUM. **Proceedings...** Charlotte, 2015. p. 1–7.

CRESPO D. L. C. **Uma Nova Metodologia para Localização de Falhas em Sistemas de Distribuição Usando Sincrofasores de Tensão**. 2021. Tese (Mestrado) - Escola de Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, 2021.

CRISTÓVÃO J. O. G. **Uso de Redes Neurais Artificiais como Ferramenta de Otimização de Vendas**. 2018. Monografia – Escola de Estatísticas, Universidade Federal Fluminense, Niterói, 2018.

DUGAN R. C. **Reference Guide: The Open Distribution System Simulator**. USA, v.7.6, mar. 2016.

MARTINHO, E. **Distúrbio da Energia Elétrica**. São Paulo: Érica Saraiva, 2013.

GALIJASEVIC, Z.; ABUR, A. Fault location using voltage measurements. **IEEE Transactions on Power Delivery**, p. 441–445, Apr 2002. ISSN 0885-8977.

GIGUER, S. **Proteção de Sistemas de Distribuição**. Porto Alegre: Sagra, 1988. 344p.

JÚNIOR, M. G.; TAKADA, V.; FREITAS, P. R. R. Algoritmo para localização de faltas em redes distribuição de energia elétrica com a presença de unidades de geração distribuída. **Cidel Argentina**, Março, 2014. p 1-4.

GIRGIS, A. A.; FALLON, C. M. Fault location techniques for radial and loop transmission systems using digital fault recorded data. **IEEE Transactions on Power Delivery**, IEEE, p. 1936–1945, out. 1992. ISSN 0885-8977.

JÚNIOR E. R. **Aplicação de Sistema Especialista para Localização de Defeitos em Redes de Distribuição**. 2015. Tese (Doutorado) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2015.

LEÃO, R. **GTD – Geração, Transmissão e Distribuição de Energia Elétrica**. Cerará. 2009.

LEME, D. M. *et al.* **Sistema de Proteção da Rede de Distribuição de Energia Elétrica**. 2013. Monografia – Escola de Engenharia, Universidade São Francisco Itatiba, Itatiba, 2013.

LEE, S. J. *et al.* " An intelligent and efficient fault location and diagnosis scheme for radial distribution systems." **IEEE transactions on power delivery**. USA, v. 19.2, 8012188, p. 524 - 532, abril 2004.

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

HOFFMANN, L. **Aplicação de Metodologia Baseada em Transformada Wavelet Contínua para Localização de Falhas em Redes de Média Tensão**. 2019. TCC – Escola de Engenharia, Universidade Federal de Santa Catarina, Florianópolis, 2019.

MAMEDE FILHO, J.; MAMEDE D. R. **Proteção de Sistemas Elétricos de Potência**. Rio de Janeiro: LTC, 2013.

MANASSERO, G.; SANTO, S. G. D.; SOUTO, L. Heuristic method for fault location in distribution feeders with the presence of distributed generation. **IEEE Transactions on Smart Grid**, IEEE, v. 8, n. 6, p. 2849–2858, nov 2017. ISSN 1949-3053.

Ministério de Minas e Energia/Empresa de Pesquisa Energética: **AVALIAÇÃO DOS CUSTOS RELACIONADOS ÀS INTERRUPÇÕES DE ENERGIA ELÉTRICA E SUAS IMPLICAÇÕES NA REGULAÇÃO**. MME/EPE, 2016. Disponível em: [antigo.mme.gov.br](http://antigo.mme.gov.br). Acesso em: 31 ago. 2022.

MONARD, M. C., BARANAUSKAS, J. A. Conceitos Sobre Aprendizado de Máquina. **Sistemas Inteligentes Fundamentos e Aplicações**. 1 ed. Barueri-SP: Manole Ltda, 2003. p. 89--114. ISBN 85-204-168.

MORETO M. **Localização de Falhas de Alta Impedância em Sistemas de Distribuição de Energia: Uma Metodologia Baseada em Redes Neurais Artificiais**. 2005. Dissertação – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2005.

PARKER, D. M.; MCCOLLOUGH, N. D. Medium-voltage sensors for the smart grid: Lessons learned. In: IEEE POWER AND ENERGY SOCIETY GENERAL MEETING. **Proceedings...** Detroit, 2011. p. 1–7. ISSN 1932-5517.

PEREIRA, D. S. **Localização de Falhas em Redes de Distribuição no Contexto de Redes Elétricas Inteligentes Utilizando Algoritmos Evolutivos**. 2019. Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo, São Paulo, 2019.

ROCHA, H. P. **Treinamento Multiobjetivo de Perceptron de Múltiplas Camadas com Representação Esférica de Pesos**. 2017. Tese (Doutorado) – Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2017.

SANTOS C. A. G.; FREIRE P. K. M. M.; TORRENCE C. A Transformada Wavelet e sua Aplicação na Análise de Séries Hidrológicas. **Revista Brasileira de Recursos Hídricos**. Paraíba, v.18, n.3, p. 271-280, jul/set 2013.

SENGER, E. D. et al. Automated fault location system for primary distribution networks. **IEEE Transactions on Power Delivery**, p. 1332–1340, abril 2005. ISSN 0885-8977.

TAKAGI, T. *et al.* Development of a New Type Fault Locator Using The One-Terminal Voltage and Current Data. **IEEE Transactions on Power Apparatus and Systems**, USA, v.101, n.8, p.2892–2898, agosto 1982. ISSN 0018-9510.

TREMBLAY, M. *et al.* Accurate fault-location technique based on distributed power-quality measurements. In: INTERNATIONAL CONFERENCE ON ELECTRICITY DISTRIBUTION, 19. **Proceedings...** Viena, 2007.

TRINDADE, F. C. L. *et al.* Fault location in distribution systems based on smart feeder meters. **IEEE Transactions on Power Delivery**, IEEE, p. 251–260, Jul 2014. ISSN 1932-5517.

TRIBA, M. N. *et al.* Molecular BioSystems: **PLS/OPLS models in metabolomics: Impact of permutation of dataset rows on the K-fold cross-validation quality parameters**. Paris: Royal Society of Chemistry, 2018.

WITKOVSKI, A. M. **Análise técnica para implementação de reconfiguração automática de alimentadores de distribuição com sistema self healing**. 2019. TCC – Escola de Engenharia, Universidade Federal do Paraná, Pato Branco, 2019.

ZAVODA, F. Advanced distribution automation (ada) applications and power quality in smart grids. In: CHINA INTERNATIONAL CONFERENCE ON ELECTRICITY DISTRIBUTION. **Proceedings...** Nanjing: IEEE, 2010. p. 1–7. ISSN 2161-7481.



ZHU, J.; LUBKEMAN, D. L.; GIRGIS, A. A. Automated fault location and diagnosis on electric power distribution feeders. **IEEE Transactions on Power Delivery**, IEEE, p.801–809, abril 1997. ISSN 0885-8977.

ZVIETCOVICH, W. G. **Estimador de variações de tensão de curta duração em sistemas elétricos de potência utilizando estratégias evolutivas**. Tese (Doutorado) — Escola Politécnica da Universidade de São Paulo, 2011.