

**CESAR SOLÉ**

**Proteção de Distância de Linhas de Transmissão com  
Compensação Série**

São Paulo  
2023

**CESAR SOLÉ**

**Proteção de Distância de Linhas de Transmissão com  
Compensação Série**

**Versão Corrigida**

Dissertação apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do Título de Mestre em Ciências.

São Paulo  
2023

**CESAR SOLÉ**

**Proteção de Distância de Linhas de Transmissão com  
Compensação Série**

**Versão Corrigida**

Dissertação apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do Título de Mestre em Ciências.

Área de Concentração:

Engenharia Elétrica

Orientador:

Giovanni Manassero Junior

São Paulo  
2023

**Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.**

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, 12 de Julho de 2023

Assinatura do autor: \_\_\_\_\_

Assinatura do orientador: \_\_\_\_\_

#### **Catálogo-na-publicação**

**Solé, Cesar**

**Proteção de distância de linhas de transmissão com compensação série / C. Solé -- versão corr. -- São Paulo, 2023.**

**100 p.**

**Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Energia e Automação Elétricas.**

**1.Linhas de transmissão de energia elétrica 2.Proteção de sistemas elétricos 3.Relés 4.Inteligência artificial 5.Simulação de sistemas I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Energia e Automação Elétricas II.t.**

# AGRADECIMENTOS

Ao meu pai Sergio Solé, ao meu irmão Danilo Solé, à minha madrastra Regina Incau Marchetti e minha irmã Katia Regina Marchetti pelo apoio e carinho nesta minha empreitada.

Ao meu orientador Prof. Giovanni Manassero Junior pelo apoio e suporte para o desenvolvimento deste trabalho.

Ao Prof. Eduardo Lorenzetti Pellini pelo apoio e paciência para resolver as minhas dúvidas para implementação do meu trabalho no IED de plataforma aberta disponível no LPROT.

À Profa. Milana Lima dos Santos pelo apoio e suporte ao uso da ferramenta Wolfram Mathematica para a execução deste trabalho.

Ao Engenheiro Leonardo Pereira Ramos pelo suporte durante a execução das atividades no LPROT.

Ao Doutor em Engenharia Elétrica Daniel Texidor Dantas pelo apoio no desenvolvimento do algoritmo e ensaios no RTDS.

Ao Engenheiro Marcei Fernandes da Rosa Pereira Setti pela contribuição com o seu trabalho sobre redes neurais em sistemas elétricos utilizado neste algoritmo com muito sucesso.

Ao Graduando Giacomo Jaremciuk Paschoal de Lima pelo seu trabalho de iniciação científica também utilizado neste algoritmo com muito sucesso.

*“O único homem que está isento de erros é aquele que não arrisca acertar.”*

-- Albert Einstein

# RESUMO

Este trabalho apresenta o desenvolvimento e teste de dois algoritmos de proteção de distância de linhas de transmissão com compensação série, que utilizam varistores de óxido metálico para limitar a tensão imposta aos capacitores que integram essa compensação.

O primeiro algoritmo utiliza redes neurais artificiais e o segundo é baseado em técnicas matemáticas de linearização do comportamento da compensação série com a utilização do *software* Wolfram Mathematica. O algoritmo de inteligência artificial aproveita diretamente os sinais de tensões e correntes, que são amostrados e digitalizados pelo dispositivo eletrônico inteligente responsável pela proteção da linha de transmissão. Por outro lado, o algoritmo baseado em linearização matemática utiliza os fasores desses sinais obtidos por meio da transformada discreta de Fourier, tanto durante o regime de operação normal quanto na ocorrência de distúrbios elétricos.

Para implementar a rede neural artificial, foi utilizada a biblioteca TensorFlow na plataforma de computação em nuvem Google Colab. Foram realizadas prototipagens dos algoritmos no Matlab e sua avaliação foi conduzida utilizando o modelo computacional de um sistema de transmissão de energia elétrica. Esse sistema é composto por equivalentes de curto-circuito e uma linha de transmissão com compensação série. O modelo foi submetido a cenários de simulação de curtos-circuitos, variando a sua localização da falta, sua resistência e instante de inserção.

Uma parcela dos resultados das simulações foi utilizada para o treinamento do algoritmo baseado em redes neurais artificiais, enquanto a parte restante foi reservada para avaliar a resposta dos dois algoritmos.

Foi demonstrada a metodologia para o desenvolvimento dos algoritmos e implementação em um dispositivo eletrônico inteligente de plataforma aberta desenvolvido no Laboratório de Pesquisa em Automação e Proteção de Sistemas Elétricos da Escola Politécnica da Universidade de São Paulo e testado com técnicas *Hardware-in-the-loop* com o uso do simulador digital de tempo real RTDS.

**Palavras-Chave** – Proteção de distância, Linha de transmissão, Compensação série, MOV, IED, Redes Neurais Artificiais, IEC 61850, RTDS.

# ABSTRACT

This work presents the development and test of two distance protection algorithms for series compensation transmission lines that use metallic oxide varistors to limit the tension imposed on capacitors that integrate this compensation.

The first algorithm uses artificial neural networks, and the second is based on mathematical linearization techniques of series compensation behavior using the software Wolfram Mathematica. The artificial intelligence algorithm works directly with the sampling and digitized tension and current signals by the intelligent electronic device responsible for transmission line protection. On the other hand, the algorithm based on mathematical linearization uses these signals phasors, calculated using the discrete Fourier transform, both during normal operation and under disturbances.

The TensorFlow library is used in the Google Colab cloud computing platform to implement the artificial neural network. The two algorithm prototypes were developed in Matlab and evaluated using a computational model of an electrical transmission system. This system is compounded by Thevenin equivalents at both terminals and series-compensated transmission lines. The model was submitted to short-circuit simulation scenarios, varying the fault location, resistance, and inception angle.

One part of the simulation results were used to train the algorithm based on the artificial neural network, while the remaining ones were reserved to evaluate the two algorithm response.

The proposed methodology was implemented on an open platform for developing protection solutions and was evaluated using hardware-in-the-loop techniques with a real-time digital simulator (RTDS). The platform was developed by the Laboratory of Research in Automation and Protection of Electrical Systems of the Polytechnic School of the University of São Paulo.

**Keywords** – Distance protection, Transmission line, Series compensated, MOV, IED, Artificial neural network, IEC 61850, RTDS.



## LISTA DE FIGURAS

1	Representação de um circuito elétrico . . . . .	23
2	Diagrama de impedâncias R-X . . . . .	23
3	Diagrama R-X com impedâncias de carga e curto-circuito . . . . .	24
4	Curva característica reatância . . . . .	25
5	Curva característica MHO . . . . .	25
6	Curva característica Quadrilateral . . . . .	26
7	Neurônio biológico . . . . .	28
8	Ocorrência de sinapse entre neurônios biológicos . . . . .	28
9	Modelo de McCulloch-Pitts . . . . .	29
10	Nó Sigma . . . . .	30
11	Tipo de função de ativação linear . . . . .	31
12	Tipo de função de ativação limiar ou Heaviside . . . . .	31
13	Tipo de função de ativação rampa . . . . .	32
14	Tipo de função de ativação sigmóide . . . . .	32
15	Tipo de função de ativação tangente hiperbólica . . . . .	33
16	Modelo matemático de um neurônio . . . . .	33
17	Diagrama de blocos da regra delta . . . . .	36
18	Método de gradiente decrescente . . . . .	37
19	<i>Perceptron</i> de múltiplas camadas e propagação dos sinais . . . . .	39
20	Interligação entre uma fonte e um sistema elétrico . . . . .	41
21	Limite de estabilidade aplicando a equação 2.29 . . . . .	43
22	Margem de estabilidade transitória de uma linha de transmissão convencional	43
23	Margem de estabilidade transitória com compensação série . . . . .	44

24	Diagrama elétrico de um banco capacitor série . . . . .	46
25	Diagrama elétrico de um banco capacitor série com centelhador duplo . . .	48
26	Diagrama elétrico de um banco capacitor série com MOV . . . . .	48
27	Diagrama elétrico de um TCSC . . . . .	49
28	Comportamento da reatância de um TCSC em função do ângulo de disparo $\alpha$	50
29	Compensação série instalada no meio da linha de transmissão . . . . .	51
30	Compensação série instalada em um dos terminais da linha de transmissão	52
31	Compensação série instalada em cada terminal da linha de transmissão . .	52
32	Efeito da inversão de tensão durante curto-circuito . . . . .	53
33	Impedância aparente de uma linha de transmissão . . . . .	54
34	Representação da rede neural no TensorFlow . . . . .	62
35	Gráfico de uma função assintótica . . . . .	64
36	Diagrama de blocos dos algoritmos de proteção de distância propostos . . .	67
37	Fluxograma dos algoritmos de proteção de distância propostos . . . . .	72
38	IED de plataforma aberta utilizado . . . . .	73
39	Topologia da rede neural implementada no TensorFlow . . . . .	76
40	Programação da rede neural . . . . .	78
41	Topologia da rede neural extraída da programação . . . . .	78
42	Comparação dos valores de resistência do conjunto CP/MOV . . . . .	80
43	Comparação dos valores de reatância do conjunto CP/MOV . . . . .	81
44	Sistema elétrico proposto para testes . . . . .	81
45	Modelo da torre para o sistema elétrico proposto . . . . .	82
46	Esquema de teste <i>hardware-in-the-loop</i> com RTDS . . . . .	83
47	Plano R-X e Oscilografia das correntes para curto-circuito AN - redes neurais	86
48	Plano R-X e Oscilografia das correntes para curto-circuito BC - redes neurais	87
49	Plano R-X e Oscilografia das correntes para curto-circuito ABC - redes neurais . . . . .	87

50	Plano R-X e Oscilografia das correntes para curto-circuito BCN - redes neurais . . . . .	88
51	Plano R-X e Oscilografia das correntes para curto-circuito AN - linearização matemática . . . . .	89
52	Plano R-X e Oscilografia das correntes para curto-circuito BC - linearização matemática . . . . .	89
53	Plano R-X e Oscilografia das correntes para curto-circuito ABC - linearização matemática . . . . .	90
54	Plano R-X e Oscilografia das correntes para curto-circuito BCN - linearização matemática . . . . .	90

## LISTA DE TABELAS

1	Coeficientes da equação 4.7 para fase A . . . . .	79
2	Coeficientes da equação 4.7 para fase B . . . . .	79
3	Coeficientes da equação 4.7 para fase C . . . . .	80
4	Coeficientes da equação 4.8 para fase A . . . . .	80
5	Coeficientes da equação 4.8 para fase B . . . . .	80
6	Coeficientes da equação 4.8 para fase C . . . . .	80
7	Dados do sistema elétrico proposto . . . . .	81
8	Dados da torre utilizada no sistema elétrico proposto . . . . .	82
9	Cenários da simulação no RTDS . . . . .	83
10	Total de cenários simulados pelo RTDS algoritmo com uso de RNA . . . . .	84
11	Total de cenários simulados pelo RTDS algoritmo com linearização matemática . . . . .	84
12	Tempo de atuação da proteção de distância RNA . . . . .	85
13	Tempo de atuação da proteção de distância linearização matemática . . . . .	85
14	Tempo de atuação e impedância calculada da proteção de distância para curto-circuito AN - redes neurais . . . . .	88
15	Tempo de atuação e impedância calculada da proteção de distância para curtos-circuitos BC, BCN e ABC - redes neurais . . . . .	88
16	Tempo de atuação e impedância calculada da proteção de distância para curto-circuito AN - linearização matemática . . . . .	91
17	Tempo de atuação e impedância calculada da proteção de distância para curtos-circuitos BC, BCN e ABC - linearização matemática . . . . .	91

## LISTA DE ABREVIATURAS E SIGLAS

ACU	<i>Acquisition and Control Unit</i>
ADALINE	<i>Adaptative Linear Element</i>
ANN	<i>Artificial Neural Network</i>
ATP	<i>Alternative Transients Program</i>
CA	Circuito de amortecimento
COMTRADE	<i>Common Format for Transient Data Exchange</i>
CP	Capacitor série
CPU	Unidade de Processamento Central
CS	Compensação série
EMTP	<i>Eletromagnetic Transients Program</i>
FACTS	<i>Flexible Alternating Current Transmission Systems</i>
G	Centelhador
GPU	Unidade de Processamento Gráfico
IEEE	<i>The Institute of Electrical an Electronics Engineers</i>
IED	<i>Intelligent Electronic Device</i>
LMS	<i>Least Mean Square Error</i>
LTCS	Linhas de transmissão com compensação série
MLP	<i>Multilayer Perceptron</i>
MOV	Varistor a Óxido Metálico
MSE	<i>Mean Square Error</i>
ONS	Operador Nacional do Sistema Elétrico
PMU	<i>Phase Measurement Unit</i>
RAM	<i>Random Access Memory</i>
RNA	Redes Neurais Artificias
SEP	Sistemas Elétricos de Potência
SH	<i>Sample and Hold</i>
SoC	<i>System-on-a-Chip</i>
SSD	<i>Solid State Disk</i>
STATCOM	<i>Static Synchronous Compensator</i>
SVC	<i>Static VAR Compensator</i>
TC	Transformador de Corrente

TCSC	<i>Thyristor-Controlled Series Capacitor</i>
TDF	Transformada Discreta de Fourier
TP	Transformador de Potencial
WAMPAC	<i>Wide Area Monitoring, Protection, Automation and Control</i>

# LISTA DE SÍMBOLOS

$\bar{Z}$	Impedância complexa
$\dot{V}$	Tensão elétrica fasorial
$\dot{I}$	Corrente elétrica fasorial
C	Capacitância elétrica
L	Indutância elétrica
R	Resistência elétrica
X	Reatância elétrica
Z	Impedância elétrica
I	Corrente elétrica
i	Corrente elétrica instantânea
$\alpha$	Ângulo de disparo do tiristor
$\alpha_m$	Termo <i>momentum</i> da regra delta generalizada
$\omega$	Velocidade angular
$\vartheta_k$	Potencial de ativação de um neurônio
$\eta$	Taxa de aprendizado
$x_i$	Sinal de entrada de um neurônio
$w_i$	Peso sináptico
$y_i$	Saída do neurônio
$y_i^d$	Saída desejada do neurônio
$E$	Sinal de erro
$P_n(x)$	Polinômio de grau $n$
$Q_m(x)$	Polinômio de grau $m$
$\Omega$	Unidade de resistência / reatância elétricas (ohm/s)
V	Unidade de tensão elétrica (volt/s)
A	Unidade de corrente elétrica (ampere/s)
km	Unidade de comprimento (quilômetro/s)
m	Unidade de comprimento (metro/s)

# SUMÁRIO

<b>1</b>	<b>Introdução</b>	<b>19</b>
1.1	Considerações iniciais . . . . .	19
1.2	Objetivo . . . . .	20
1.3	Estrutura do texto . . . . .	20
<b>2</b>	<b>Revisão bibliográfica</b>	<b>22</b>
2.1	Proteção de distância . . . . .	22
2.1.1	Característica de impedância . . . . .	23
2.1.2	Característica de reatância . . . . .	24
2.1.3	Característica de admitância (MHO) . . . . .	25
2.1.4	Característica Quadrilateral . . . . .	26
2.2	Redes Neurais Artificiais . . . . .	26
2.2.1	Modelo biológico de um neurônio . . . . .	27
2.2.2	Modelo de McCulloch-Pitts . . . . .	29
2.2.3	Modelo matemático de um neurônio . . . . .	33
2.2.4	Modelo estocástico de um neurônio . . . . .	34
2.2.5	Métodos de aprendizagem de máquina . . . . .	35
2.2.6	Arquiteturas de Redes Neurais Artificiais (RNA) . . . . .	39
2.3	Linhas de transmissão com compensação série . . . . .	40
2.3.1	Aspectos principais . . . . .	40
2.3.2	Tipos de compensação . . . . .	46
2.3.2.1	Compensação fixa . . . . .	46
2.3.2.2	Compensação variável (TCSC) . . . . .	49
2.3.3	Posição e quantidade da compensação . . . . .	51



2.3.4	Impacto na proteção de distância . . . . .	52
2.4	Proteção de distância em linhas de transmissão com compensação série . . .	55
2.5	Estratégias de linearização do conjunto capacitor série/MOV . . . . .	60
2.5.1	Estratégia por Redes Neurais Artificiais (RNA) . . . . .	61
2.5.2	Estratégia por Linearização Matemática . . . . .	63
<b>3</b>	<b>Metodologia proposta</b>	<b>67</b>
3.1	Diagrama de blocos dos algoritmos de proteção propostos . . . . .	67
3.2	Algoritmos de proteção propostos . . . . .	69
3.3	Fluxograma dos algoritmos de proteção propostos . . . . .	71
<b>4</b>	<b>Desenvolvimento e Testes</b>	<b>73</b>
4.1	Implementação do algoritmo no IED . . . . .	73
4.2	Linearização do conjunto capacitor série/MOV . . . . .	74
4.2.1	Redes Neurais Artificiais . . . . .	74
4.2.1.1	Programação do TensorFlow em linguagem <i>Python</i> . . . . .	77
4.2.2	Linearização matemática . . . . .	78
4.3	Cenário de simulação . . . . .	81
<b>5</b>	<b>Resultados e discussões</b>	<b>84</b>
5.1	Análise quantitativa . . . . .	84
5.2	Análise qualitativa . . . . .	86
5.2.1	Algoritmo de linearização por Redes Neurais Artificiais . . . . .	86
5.2.2	Algoritmo com uso de linearização matemática . . . . .	88
5.3	Conclusão das análises . . . . .	91
<b>6</b>	<b>Conclusões e trabalhos futuros</b>	<b>93</b>
	<b>Referências</b>	<b>95</b>



# 1 INTRODUÇÃO

## 1.1 Considerações iniciais

O uso da energia elétrica é cada vez mais presente para atender as necessidades de consumo das indústrias, residências e comércios, em várias partes do nosso planeta. O aumento do uso dessa energia pode ser relacionado ao desenvolvimento da sociedade após a primeira revolução industrial, onde se aplicava o uso da energia do vapor para movimentar as máquinas industriais, sendo a mesma substituída pela eletricidade. Com a evolução e expansão dos Sistemas Elétricos de Potência (SEP), é possível transportar grandes blocos de energia a longas distâncias através de linhas de transmissão, interligando pontos ou regiões de geração aos centros de consumo (REIS, 2003), otimizando a produção e racionalizando os recursos energéticos utilizados para a conversão em energia elétrica, como as fontes hídrica, eólica, solar, combustíveis fósseis, biomassa e nuclear.

Para melhorar a capacidade de transporte das linhas de transmissão, utiliza-se linhas de transmissão com compensação série (LTCS). A compensação série permite aumentar o bloco de energia transportado pela linha de transmissão existente, sem a necessidade de criar um novo circuito elétrico na mesma torre, em torres distintas ou percorrendo outra faixa de servidão, que geram custos às concessionárias de energia elétrica para construção e indenização aos donos de terrenos a serem ocupados. Entretanto, a compensação série altera o cálculo realizado pelos algoritmos implementados nos dispositivos eletrônicos inteligentes (*Intelligent Electronic Device* - IED) de proteção de distância das linhas de transmissão, o que pode causar erros de operação durante a presença de distúrbios no sistema elétrico.

As funções de proteção típicas utilizadas em IEDs de linhas de transmissão em sistemas interligados e seus números correspondentes de acordo com a norma IEEE C37.2 de 2008 são as funções de sobrecorrente direcional (67), distância (21) e diferencial de corrente (87), sendo que a função de distância (21) é utilizada, na grande maioria das linhas, como função de proteção principal e a função sobrecorrente direcional de neutro (67N) é muito

utilizada como função de proteção *backup* de linhas de transmissão (FILHO; MAMEDE, 2011; ONS, 2021; IEEE, 2008).

Criar um algoritmo de proteção de distância para linhas de transmissão com compensação série, com a devida mitigação de seus efeitos durante um curto-circuito, não é uma tarefa trivial e exige desenvolvimento, prototipagem e testes de certificação com cenários de distúrbios em sistemas elétricos implementados em simuladores de tempo real e técnicas *hardware-in-the-loop*. O Laboratório de Pesquisa em Automação e Proteção de Sistemas Elétricos (LPROT) da Escola Politécnica da Universidade de São Paulo possui esses recursos e também dispõe de um IED de plataforma aberta, que permite a implementação de algoritmos para controle e proteção de sistemas elétricos, despertando o interesse em realizar essa pesquisa na criação de dois algoritmos de proteção.

## 1.2 Objetivo

O objetivo desse trabalho é apresentar dois algoritmos de proteção de distância para linhas de transmissão com compensação série que utilizam varistores a óxido metálico (MOV) para limitar a tensão imposta aos capacitores que integram essa compensação. O primeiro algoritmo utiliza redes neurais artificiais e o segundo é baseado em técnicas matemáticas de linearização do comportamento da compensação série (CS) durante ocorrências de curtos-circuitos na linha.

Os dois algoritmos são implementados em um IED de plataforma aberta, avaliados utilizando-se o modelo computacional de um sistema de transmissão de energia elétrica composto por equivalentes de curto-circuito e uma linha de transmissão com compensação série e testado com técnicas *hardware-in-the-loop* com o uso do simulador digital de tempo real RTDS.

## 1.3 Estrutura do texto

Esta dissertação está estruturada da seguinte forma:

- O capítulo um mostra uma breve introdução sobre o tema de dissertação;
- O capítulo dois apresenta a revisão bibliográfica do trabalho, mostrando o estado da arte das linhas de transmissão com compensação série;
- O capítulo três descreve a metodologia proposta para o trabalho de dissertação;

- O capítulo quatro detalha o desenvolvimento dos algoritmos de proteção e os testes realizados;
- O capítulo cinco mostra os resultados do trabalho de dissertação; e
- O capítulo seis apresenta as conclusões e futuros trabalhos a partir deste trabalho de dissertação.

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo é apresentada a revisão bibliográfica de trabalhos referentes ao tema desenvolvido nesta pesquisa e ele é dividido em cinco itens: proteção de distância, redes neurais artificiais, linhas de transmissão com compensação série, proteção de distância em linhas de transmissão com compensação série e estratégias de linearização do conjunto capacitor série/MOV.

### 2.1 Proteção de distância

A função de proteção de distância identifica o aumento ou diminuição da impedância, reatância ou admitância de uma linha de transmissão comparando tais grandezas com valores pré-determinados (IEEE, 2008), cujo ajuste depende da impedância da linha de transmissão. A proteção de distância é identificada pelo número 21 conforme norma IEEE C37.2.

Esses valores de impedância são determinados a partir da medição das tensões e correntes fasoriais do circuito elétrico, através de transformadores de instrumentação (Transformador de Potencial (TP) e Transformador de Corrente (TC)) (ZIEGLER, 2011), conforme demonstrado na figura 1 com os transformadores de instrumentação no terminal local (L), como em:

$$\bar{Z} = \frac{\dot{V}}{\dot{I}} \quad (2.1)$$

onde  $\dot{V}$  é a tensão elétrica fasorial obtida a partir das medições fornecidas pelo transformador de potencial em [V],  $\dot{I}$  é a corrente elétrica fasorial obtida a partir das medições fornecidas pelo transformador de corrente em [A] e  $\bar{Z}$  a impedância calculada em [ $\Omega$ ].

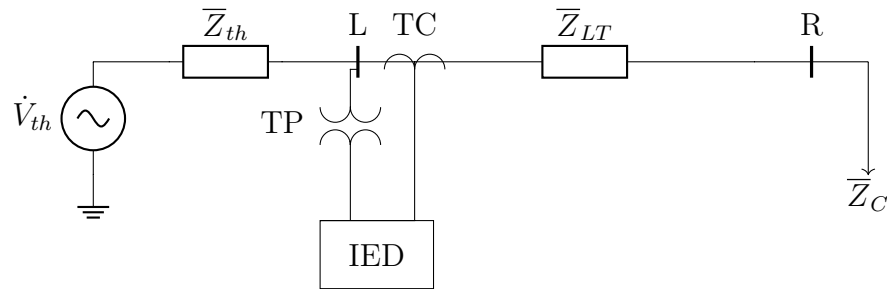


Figura 1: Representação de um circuito elétrico

### 2.1.1 Característica de impedância

A forma mais usual de mostrar as características de uma proteção de distância é o uso do diagrama de impedâncias R-X. Neste diagrama, o eixo da abcissa representa a resistência elétrica R enquanto o eixo da ordenada representa a reatância X, conforme mostra a figura 2. Essencial para análise do comportamento da impedância medida da linha de transmissão, principalmente durante a ocorrência de curto-circuito, o diagrama mostra de forma objetiva o desempenho da função de proteção de distância no sistema elétrico (BLACKBURN; DOMIN, 2007; ZIEGLER, 2011).




Figura 2: Diagrama de impedâncias R-X

Durante condições normais de operação da linha de transmissão, a impedância calculada refere-se a impedância de carga  $\bar{Z}_C$ . O ângulo formado pela tensão fasorial e pela corrente fasorial refere-se ao ângulo de  $\bar{Z}_C$ ,  $\varphi$  (ZIEGLER, 2011) e a magnitude pode ser calculada a partir da equação 2.1. Nesta condição, a impedância de carga sempre deve ficar fora da zona de proteção definida no diagrama R-X, conforme demonstrado na figura 2, para evitar desligamento do disjuntor da linha em condições normais de operação.

Durante eventos de curto-circuito, a impedância calculada corresponde à impedância de curto-circuito. Essa impedância é normalmente menor que a impedância de carga,

cuja magnitude refere-se a distância entre o local de aplicação do curto-circuito e o terminal da linha onde os transformadores de instrumentação estão ligados, e o ângulo de curto-circuito geralmente é igual ao ângulo de impedância da linha de transmissão,  $\beta$  quando a impedância de curto-circuito é próxima de zero (ZIEGLER, 2011; HOROWITZ; PHADKE, 1992).

A impedância de curto-circuito  $\bar{Z}_{cc}$  caminha para dentro da zona de proteção do diagrama R-X, onde a função de proteção de distância realiza a sua detecção e envia o comando de abertura do disjuntor da linha para isolamento e extinção do curto-circuito. A figura 3 mostra os conceitos de impedâncias de carga e de curto-circuito.

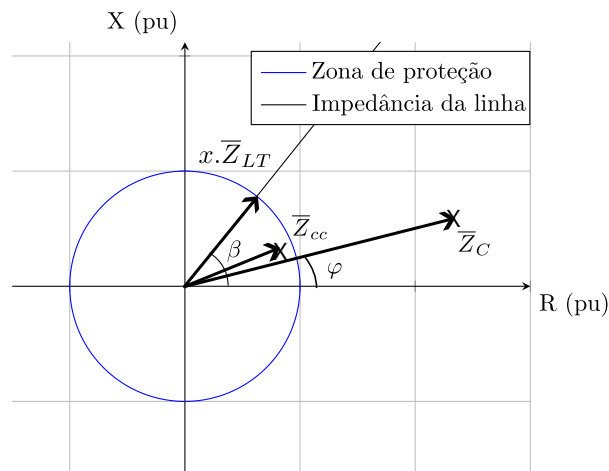


Figura 3: Diagrama R-X com impedâncias de carga e curto-circuito

### 2.1.2 Característica de reatância

A função de distância com curva característica de reatância trabalha com uma área no diagrama R-X delimitada por uma linha paralela ao eixo da abscissa R como mostra a figura 4. A curva de reatância se estende ao infinito ao longo do eixo R e se estende ao infinito abaixo do eixo da ordenada X formando uma área abaixo da linha delimitada demarcada pelo quadrado hachurado da figura 4.

Essa característica pode ser utilizada em linhas de transmissão de curtas distâncias pois em linhas de transmissão longas pode ocorrer atuação indevida para uma situação de carga normal ou em caso de curto-circuito na direção reversa (ANDERSON, 1999; HOROWITZ; PHADKE, 1992; FILHO; MAMEDE, 2011).



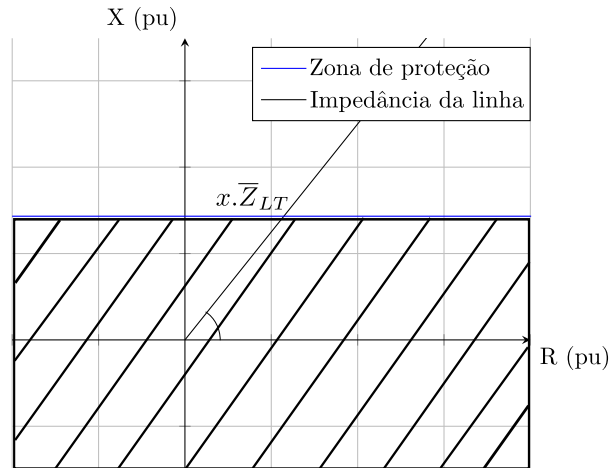


Figura 4: Curva característica reatância

### 2.1.3 Característica de admitância (MHO)

Uma curva característica bastante utilizada para definir as zonas de proteção é a curva de admitância ou curva MHO, conforme apresentada na figura 5. A circunferência da curva cruza a origem do diagrama R-X, permitindo que a função de proteção tenha direcionalidade e sensibilidade nas condições típicas de curto-circuito (BLACKBURN; DOMIN, 2007; ZIEGLER, 2011).

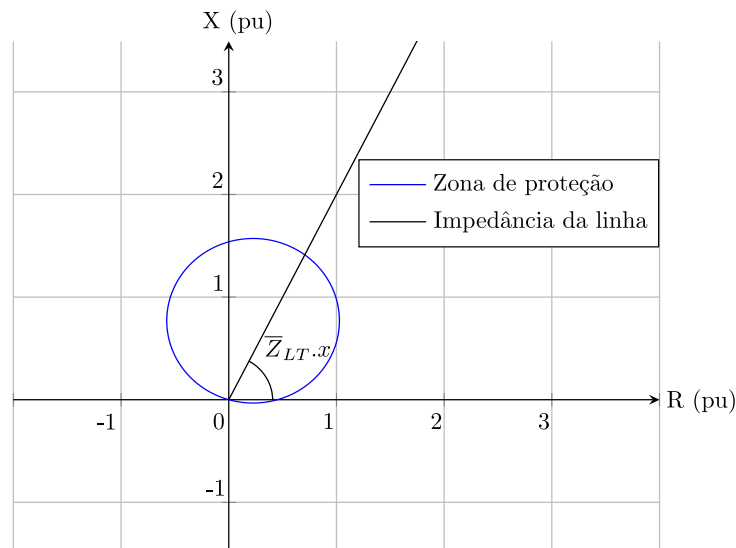


Figura 5: Curva característica MHO

Essa curva foi muito utilizada em relés eletromecânicos e estáticos, mas ainda continua sendo utilizada em algoritmos de proteção de relés de tecnologia digital. Para definição da curva, são utilizados dois parâmetros: a impedância do relé  $\bar{Z}_r$  que define o diâmetro da zona de proteção em função da impedância da linha de transmissão e o ângulo característico do relé  $\bar{Z}_{LT} \cdot x$  que define a inclinação da curva MHO, onde  $x$  pode variar entre 0

e 1 (ZIEGLER, 2011).

### 2.1.4 Característica Quadrilateral

Uma outra curva característica utilizada para definir as zonas de proteção da função de distância é a quadrilateral, conforme ilustrada na figura 6. A curva quadrilateral permite maior flexibilidade de definição da zona de proteção do que a curva MHO, que se baseia em torno de um círculo. Essa característica possibilita uma grande vantagem em caso de utilização para detecção de curto-circuito fase-terra, permitindo um aumento na cobertura com resistências de curto-circuito de alta impedância (ZIEGLER, 2011).

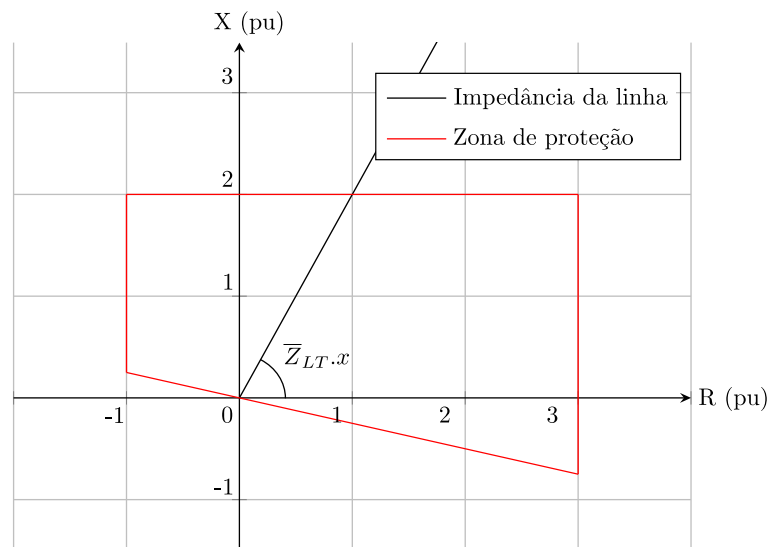


Figura 6: Curva característica Quadrilateral

## 2.2 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA), ou redes neurais, consistem em máquinas que conseguem trabalhar do mesmo modo que neurônios biológicos para resolução de problemas. O estudo de redes neurais começou a partir de pesquisas sobre o funcionamento do cérebro humano, com o desenvolvimento de modelos matemáticos que reproduzem o funcionamento de um neurônio biológico (HAYKIN, 2001; MENEZES, 2008). Os primeiros modelos matemáticos originaram na década de 1940 do século XX com uso de operações binárias para representar a ativação de um neurônio feito por McCulloch e Pitts. Entre as décadas de 1940 e 1960 apareceram trabalhos como o postulado de aprendizado de Hebb, a rede de *perceptron* de Rosenblatt, que possui uma ou múltiplas camadas de neurônios, o elemento linear adaptativo (ADALINE) de Widrow e Hoff, que introduziu um

processo de aprendizagem utilizado em redes neurais mais elaboradas, e a comprovação matemática feita por Minsky e Papert de que os *perceptron* de camada única possuem limitações para realização de cálculos (HAYKIN, 2001; KOVÁCS, 2006; KARAYIANNIS; VENETSANOPOULOS, 1993).

### 2.2.1 Modelo biológico de um neurônio

Um neurônio apresenta as mesmas características de outras células do corpo humano ou de outras espécies vivas, porém ele tem a função de realizar processamento de sinais com o uso de processos químicos e eletrofísicos. A estrutura do neurônio biológico, conforme mostrado na figura 7, começou a ser estudada a partir dos trabalhos de Ramón y Cajál entre o final do século XIX e início do século XX para explicar o funcionamento do cérebro humano. Um neurônio possui os mesmos elementos de outras células do corpo humano e sua estrutura é constituída por (HAYKIN, 2001; KOVÁCS, 2006; MENEZES, 2008; TRAPPENBERG, 2002):

- Soma: corpo celular do neurônio, contém o núcleo da célula com o Ácido Deoxirribonucleico (DNA), ribossomos para fabricação das proteínas com o código genético e mitocôndrias para geração de energia consumida pelo mesmo;
- Dendritos: extensão do soma do neurônio com uma superfície irregular, são responsáveis por receber os sinais elétricos emitidos por outros neurônios. Os dendritos formam várias ramificações e extensões parecidas com raízes de árvores com o objetivo de receber sinal elétrico de mais de um neurônio;
- Axônio: possuindo uma superfície mais lisa, com menos ramificações e maior comprimento que os dendritos, o axônio de um neurônio é responsável pela transmissão do sinal elétrico do soma até os dendritos de outros neurônios ligados em sua superfície através de terminais axonais.

A troca de informações entre os neurônios é feita a partir dos terminais axonais de um neurônio e os dendritos do neurônio adjacente por meio de sinais elétricos. Essa interação elétrica entre os neurônios é chamada de sinapse e a forma mais comum de ocorrência de conexões sinápticas no cérebro é a sinapse química através da fenda sináptica formada entre o terminal axonal e o dendrito, conforme mostrado nas figuras 7 e 8 (TRAPPENBERG, 2002; HAYKIN, 2001; KOVÁCS, 2006).




Figura 7: Neurônio biológico

Fonte: Wikimedia (2019)

A figura 8 mostra a transmissão de informações entre os terminais axonais e os dendritos, aplicando uma lente de aumento na fenda sináptica durante a ocorrência desse processo. Na fenda sináptica, o estímulo elétrico enviado pelo terminal axonal é sintetizado por substâncias químicas denominadas neurotransmissores. Os neurotransmissores ficam agrupados em uma espécie de pacote chamado de vesícula sináptica, que trafega pela fenda até o dendrito do neurônio adjacente. O processo de envio das vesículas sinápticas pelo terminal é denominado de processo pré-sináptico. Ao entrar no dendrito, as vesículas são convertidas novamente em estímulos elétricos para envio ao soma do neurônio, denominado de processo pós-sináptico (TRAPPENBERG, 2002; HAYKIN, 2001; MENEZES, 2008).

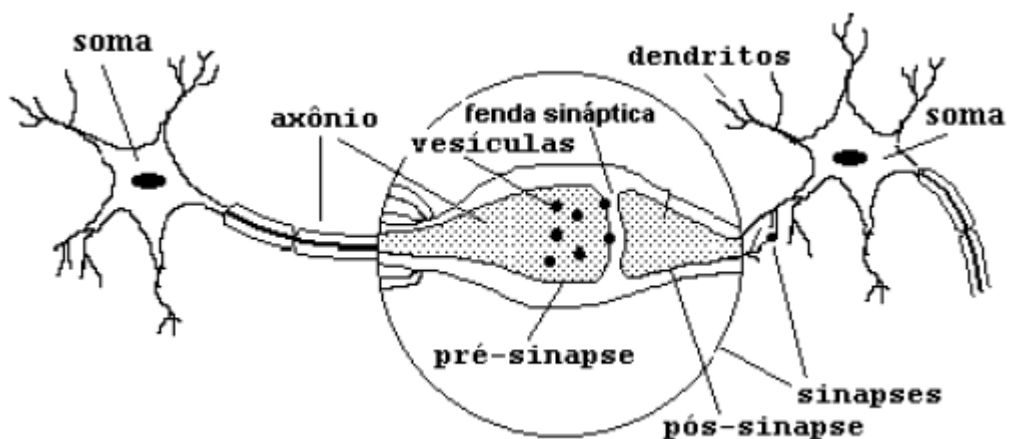


Figura 8: Ocorrência de sinapse entre neurônios biológicos

Fonte: Menezes (2008)

A execução dos processos pré e pós-sináptico pelos neurônios é realizada na ordem de milissegundos, mais lento que a execução de um evento em circuitos eletrônicos de silício.

Para compensar esse tempo de execução, existe uma grande quantidade de neurônios no cérebro, cuja quantidade é estimada em torno de 10 bilhões. Essa imensa quantidade de neurônios está interligada entre si formando aproximadamente 60 trilhões de conexões sinápticas (TRAPPENBERG, 2002; HAYKIN, 2001; MENEZES, 2008).

### 2.2.2 Modelo de McCulloch-Pitts

Como descrito no início desta seção, o modelo de McCulloch-Pitts foi o primeiro modelo matemático de um neurônio artificial desenvolvido em 1943 para representar o funcionamento de um neurônio biológico, conforme mostra a figura 9. Comparando com um neurônio biológico, as entradas representam os dendritos, a saída seria o axônio, a função somatória representa o soma e a função limiar  $g$  representa os processos sinápticos (HAYKIN, 2001; MENEZES, 2008; KOVÁCS, 2006).




Figura 9: Modelo de McCulloch-Pitts

O neurônio de McCulloch-Pitts funciona como uma função binária onde a sua saída é resultado da soma de suas entradas quando atingem um valor limiar, resultando em uma saída de valor unitário. As entradas do neurônio, representadas por  $x_1$ ,  $x_2$ ,  $x_3$  e  $x_n$ , podem assumir valores  $+1$  para valores excitatórios ou  $-1$  para valores inibitórios, simulando o comportamento dos impulsos elétricos de um neurônio biológico, e com a somatória ponderada delas a saída  $v_k$  também pode resultar em um valor  $+1$  ou  $-1$ , transmitindo o resultado para outros neurônios. A ativação da saída acontece quando a somatória é maior que o limiar  $g$ , resultando em  $v_k$  igual a  $+1$  (excitatório) ou quando a somatória for menor ou igual ao limiar  $g$ , resultando em  $v_k$  igual a  $-1$  (inibitório) (TRAPPENBERG, 2002; KOVÁCS, 2006; MENEZES, 2008).

Uma forma simplificada de tratar um neurônio de McCulloch-Pitts, como uma unidade que recebe sinais binários, realiza um cálculo e distribui o seu resultado é denominada de nó. Um dos nós mais utilizados em modelagem de RNA é o nó sigma, que possui uma estrutura parecida com o neurônio de McCulloch-Pitts. A figura 10 mostra a estrutura de um nó (TRAPPENBERG, 2002).




Figura 10: Nó Sigma

Fonte: adaptado de Trappenberg (2002)

Em um nó sigma, cada entrada  $x_i$  é multiplicada pelo peso  $w_i$  definido em seu respectivo canal conforme a seguinte equação (TRAPPENBERG, 2002):

$$h_i = w_i x_i \quad (2.2)$$

onde  $h_i$  é a entrada da rede de nós. Ao receber o valor de cada entrada da rede, o nó realiza a somatória de todos os valores resultando no valor de ativação do nó  $h$  conforme:

$$h = \sum_{i=1}^n h_i \quad (2.3)$$

Substituindo 2.2 em 2.3 resulta em:

$$h = \sum_{i=1}^n w_i x_i \quad (2.4)$$

A saída  $\vartheta_k$  é resultado do limiar  $g$  que é função de  $h$ , como em:

$$\vartheta_k = g(h) \quad (2.5)$$

Substituindo 2.4 em 2.5 é possível escrever a saída  $\vartheta_k$  conforme:

$$\vartheta_k = g \left( \sum_{i=1}^n w_i x_i \right) \quad (2.6)$$

O limiar  $g(h)$  é também denominado função de ativação ou função transferência onde a sua saída resulta da transformação dos sinais das entradas do neurônio em uma saída específica. Existem vários tipos de funções de ativação usadas em RNA identificadas nas

seguintes formas (TRAPPENBERG, 2002; HAYKIN, 2001; MENEZES, 2008; KOVÁCS, 2006):

- Linear: tipo de função onde a soma das entradas da rede de nós corresponde diretamente no valor de saída do neurônio, provendo um conhecimento melhor do comportamento da rede neural. A figura 11 e a equação 2.7 mostram a função de ativação linear.




Figura 11: Tipo de função de ativação linear

Fonte: adaptado de Trappenberg (2002) e Menezes (2008)

$$g(h) = h \quad (2.7)$$

- Limiar: também denominada *função de Heaviside*, a saída da função produz uma resposta binária que pode ser 0 ou 1. Essa função de ativação foi utilizada no neurônio de McCulloch-Pitts. A figura 12 e a equação 2.8 mostram a função de ativação.




Figura 12: Tipo de função de ativação limiar ou Heaviside

Fonte: adaptado de Trappenberg (2002) e Menezes (2008)

$$g(h) = H(h) = \begin{cases} 1 & \text{se } h \geq 0 \\ 0 & \text{se } h < 0 \end{cases} \quad (2.8)$$

- Rampa: combinação das funções de ativação linear e Heaviside, essa função não apresenta atividade para valores de ativação de nós  $h$  negativos e para valores de ativação de nós positivos a saída de  $g(h)$  é diretamente proporcional ao valor de  $h$ .




Figura 13: Tipo de função de ativação rampa

Fonte: adaptado de Trappenberg (2002) e Menezes (2008)

$$g(h) = \begin{cases} g(h) = hH(h) & \text{se } h \geq 0 \\ 0 & \text{se } h < 0 \end{cases} \quad (2.9)$$

- Sigmóide: é uma função crescente que mostra uma resposta balanceada na transição dos valores  $h$  mínimo e máximo. A figura 14 e a equação 2.10 mostram a função de ativação, onde  $a$  é o parâmetro de inclinação da função.




Figura 14: Tipo de função de ativação sigmóide

Fonte: adaptado de Trappenberg (2002) e Menezes (2008)

$$g(h) = \frac{1}{1 + e^{-ah}} \quad (2.10)$$



- Tangente hiperbólica: assim como a função sigmóide, a função tangente hiperbólica é uma função crescente que mostra uma resposta balanceada na transição dos valores  $h$  mínimo e máximo, porém essa função permite que essa função varie entre -1 e 1. A figura 15 e a equação 2.11 mostram a função de ativação.




Figura 15: Tipo de função de ativação tangente hiperbólica  
Fonte: adaptado de Menezes (2008)

$$g(h) = \tanh(h) \quad (2.11)$$

### 2.2.3 Modelo matemático de um neurônio

O modelo matemático de um neurônio é ilustrado na figura 16 e nas equações 2.12 e 2.13, sendo  $x_1$ ,  $x_2$  e  $x_n$  os sinais de entradas,  $w_{k1}$ ,  $w_{k2}$  e  $w_{kn}$  os pesos sinápticos atribuídos a cada entrada,  $b_k$  o *bias*,  $u_k$  a saída do combinador linear,  $\vartheta_k$  o potencial de ativação ou campo local induzido do neurônio,  $\varphi(\vartheta_k)$  a função de ativação do neurônio e  $y_k$  o sinal de saída do neurônio (HAYKIN, 2001).




Figura 16: Modelo matemático de um neurônio

$$u_k = \sum_{j=1}^n w_{kj}x_j \quad (2.12)$$

$$y_k = \varphi(\vartheta_k), \text{ onde } \vartheta_k = u_k + b_k \quad (2.13)$$

O modelo matemático segue a mesma estrutura do nó sigma, com as entradas e seus respectivos pesos, as funções somatória, de ativação e o sinal de saída do nó. As funções de ativação que podem ser utilizadas pelo nó são as mesmas descritas na subseção 2.2.2, onde a função sigmóide é uma das mais utilizadas por delimitar um intervalo contínuo de valores  $\varphi(\vartheta_k)$  entre os limites mínimo 0 e máximo 1, conforme mostrado na figura 14. No modelo matemático existe uma entrada denominada *bias*,  $b_k$ , que tem a função de alterar o valor de  $\vartheta_k$ , aumentando em caso de valor de  $b_k$  positivo ou diminuindo em caso de valor de  $b_k$  negativo (HAYKIN, 2001).

#### 2.2.4 Modelo estocástico de um neurônio

O modelo matemático definido na subseção 2.2.3 funciona de forma determinística, onde o resultado da saída é determinado por todas as entradas do neurônio. Porém, o uso de um modelo estocástico de um neurônio artificial é feito para algumas aplicações de redes neurais. Esse modelo estocástico é determinado a partir de uma interpretação da função de ativação do neurônio de McCulloch-Pitts, onde a decisão de um neurônio mudar o seu estado é probabilística. Para isso, a saída do neurônio assume somente dois valores como por exemplo:  $-1$  e  $+1$  (HAYKIN, 2001).

Para a definição do estado da saída do neurônio em um modelo estocástico, o estado da saída de  $y_k$  é determinado a partir da função probabilidade  $P(\vartheta_k)$ , que pode ser calculada a partir uma função sigmóide igual a figura 14 e expressa conforme:

$$y_k = \begin{cases} +1 & \text{com probabilidade } P(\vartheta_k) \\ -1 & \text{com probabilidade } 1 - P(\vartheta_k) \end{cases} \quad (2.14)$$

$$P(\vartheta_k) = \frac{1}{1 + e^{-\vartheta_k/T}} \quad (2.15)$$

sendo  $\vartheta_k$  o potencial de ativação ou campo local induzido do neurônio e  $T$  a variável que determina as flutuações pseudotérmicas dos efeitos dos ruídos sinápticos. Em um neurônio biológico o ruído sináptico se caracteriza pela perda de neurotransmissores durante a transmissão de sinal na fenda sináptica, que ocorre devido a quantidade de neurotransmissores que podem ser liberados. Essa perda pela liberação, recaptação dos neurotransmissores e troca de íons entre os neurônios interligados resulta em uma variação estocástica da

intensidade da sinapse em relação ao tempo (HAYKIN, 2001; SCHAPPO, 2016).

### 2.2.5 Métodos de aprendizagem de máquina

Como dito no início desta seção, redes neurais são feitas para resolver problemas da mesma forma que um cérebro biológico. Para isso, redes neurais possuem a habilidade de aprender a partir de estímulos do ambiente, melhorar o seu desempenho com ajustes em seus pesos sinápticos e *bias*, por meio de um processo iterativo e responder de uma nova maneira com as modificações do processo. O mais antigo e famoso é o postulado de aprendizado de Hebb (HAYKIN, 2001).

Em 1949 o psicólogo canadense Donald O. Hebb definiu em seu postulado que o aprendizado de um sistema nervoso biológico é um processo local, onde dois neurônios podem ter a eficiência entre si aumentada quando eles estão pertos para que o axônio de um troque sinapses com o outro de forma repetida e persistente, criando uma modificação metabólica em um dos neurônios ou em ambos. Essa intensidade sináptica acontece pela detecção de erros localmente e pode ser expressa matematicamente da seguinte forma (KOVÁCS, 2006; HAYKIN, 2001):

$$w_i^{novo} = w_i^{velho} + \Delta w_i \quad (2.16)$$

Onde  $w_i^{novo}$  e  $w_i^{velho}$  são os pesos sinápticos da iteração atual e anterior e  $\Delta w_i$  a diferença de ajuste dos pesos sinápticos, que pode ser definida pela equação 2.17:

$$\Delta w_i = \eta(y_l^d - y_l)x_{i,l}^d \quad (2.17)$$

Onde  $x_{i,l}^d$  é a entrada de estímulo desejada,  $y_l^d$  a saída do neurônio desejada,  $y_l$  a saída com parâmetros de entradas e pesos da iteração anterior, ou velhos, e  $\eta$  a taxa de aprendizado. A saída  $y_l$  deve utilizar uma das funções de ativação mostradas na seção 2.2.2, sendo a sigmóide a mais utilizada e a taxa de aprendizado representa a taxa de alteração dos pesos sinápticos em função dos erros calculados.

Um segundo método de aprendizagem utiliza correção de erro da saída do neurônio comparando com uma resposta desejada. A comparação da saída do neurônio com a saída desejada produz um sinal de erro para ajustar os pesos sinápticos das entradas do neurônio e, conseqüentemente, aproximar a saída do neurônio com a resposta desejada com erro mínimo. Esse método é chamado de Mínimo Quadrado Médio (LMS ou MSE) ou

também conhecido como regra delta, método desenvolvido a partir de um modelo neural linear denominado *Adaptive Linear Element* (ADALINE) criado por Widrow e Hoff em 1960 (HAYKIN, 2001; KOVÁCS, 2006; MENEZES, 2008).

O erro estimado na regra delta pode ser expresso pela equação 2.18 e a figura 17 mostra um diagrama de blocos de como a regra delta funciona (TRAPPENBERG, 2002; HAYKIN, 2001):

$$E = \frac{1}{2} \sum_l (y_l^d - y_l)^2, \text{ onde } y_l = x_i w_i \quad (2.18)$$

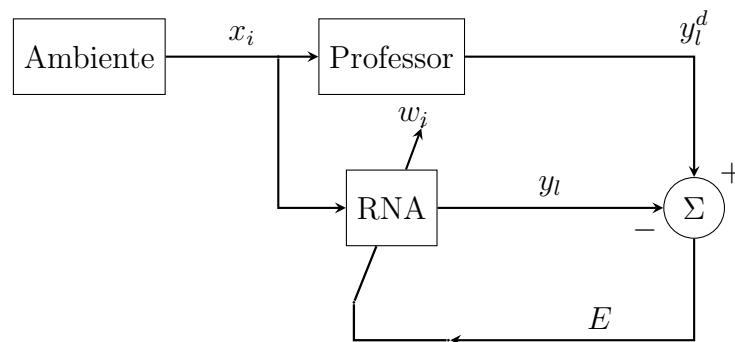


Figura 17: Diagrama de blocos da regra delta

O funcionamento da regra delta, em um sistema de realimentação em malha fechada como o da figura 17, é denominado de aprendizagem supervisionada ou aprendizagem com um professor. Em uma aprendizagem supervisionada as entradas  $x_i$  oriundas do ambiente seguem tanto para a rede neural, que não conhece o comportamento do ambiente, quanto para o módulo denominado professor, que possui conhecimento sobre o comportamento do ambiente. Com a resposta desejada  $y_l^d$  disponibilizada pelo professor, a rede neural vai ajustando os pesos sinápticos  $w_i$  de forma iterativa, diminuindo o quadrado do erro até que a resposta da rede neural seja próxima da resposta desejada do professor, condição em que a rede neural tem o mesmo conhecimento do ambiente que o professor (HAYKIN, 2001; MENEZES, 2008).

Uma forma de diminuir rapidamente o sinal de erro para ajustar os pesos sinápticos com o uso da regra delta, para uma rede de camada única, é o método do gradiente descendente. Neste método, a rede neural inicia o processo de aprendizagem com valores de pesos sinápticos aleatórios que geram um sinal de erro  $E$  alto e, a cada iteração do processo, os valores dos pesos  $w_i$  são alterados na direção do gradiente negativo, formando um vetor como demonstrado na figura 18 (TRAPPENBERG, 2002; MENEZES, 2008).

Os valores dos pesos alterando na direção do vetor permitem que a rede neural tenha




Figura 18: Método de gradiente decrescente  
 Fonte: adaptado de Trappenberg (2002)

o menor erro na resposta da saída do neurônio, sendo que a velocidade de alteração dos pesos diminui à medida que o gradiente chega a um valor mínimo (TRAPPENBERG, 2002; MENEZES, 2008). O funcionamento do método pode ser descrito pela seguinte equação:

$$\delta w_i = -\eta \frac{dE}{dw_i} \quad (2.19)$$

Uma variação da regra delta para uso em redes neurais de múltiplas camadas é chamada de regra delta generalizada ou algoritmo de retropropagação de erro (*error-back-propagation algorithm*), permitindo que a resposta da saída da rede neural seja minimizada pela soma do quadrado dos erros de saída mesmo não conhecendo os valores resultantes dos nós intermediários de uma rede múltipla. A regra delta generalizada também é uma aprendizagem supervisionada com um professor mostrando a resposta desejada da saída do neurônio como mostrado na figura 17, porém em uma rede múltipla não é possível que cada neurônio da rede seja supervisionado, sendo utilizado para isso, o neurônio da camada de saída da rede (MENEZES, 2008; TRAPPENBERG, 2002; KOVÁCS, 2006). A rede neural múltipla é abordada na seção 2.2.6.

Um terceiro método de aprendizagem é baseado no uso de memória, processo onde o aprendizado é armazenado e pode ser acessado quando solicitado. Em uma rede neural é utilizada memória associativa que tem como características ser distribuída, os estímulos e as respostas são formados por vetores de dados, o armazenamento é feito em um padrão espacial com quantidade alta de neurônios, o estímulo possui informação que permite localizar e determinar o endereço dos dados para recuperação, possui resistência alta a

ruídos e falhas e pode interagir com outros dados que estejam armazenados (HAYKIN, 2001).

Um outro método de aprendizagem é o chamado aprendizagem competitiva, processo onde os neurônios disputam qual será ativado e qual permanecerá desativado. Diferente do postulado de aprendizado de Hebb, onde os neurônios são ativados simultaneamente, a aprendizagem competitiva permite a classificação de padrões de entrada nos neurônios fazendo com que os neurônios de uma rede neural se especializem em determinados conjuntos de padrões. Essa característica é possível porque na aprendizagem competitiva os neurônios da rede são iguais, porém os valores dos pesos sinápticos têm distribuição aleatória que causa respostas distintas a determinados padrões de entrada. Então é imposto um limite para a ativação de cada neurônio que possui um mecanismo onde, para responder a um conjunto de entradas, todos os neurônios têm direito de responder, mas somente um é ativado (HAYKIN, 2001; MENEZES, 2008).

O limite imposto para que um neurônio seja vencedor é que o campo local induzido  $\vartheta_k$  seja maior que os campos locais induzidos  $\vartheta_j$  dos outros neurônios da rede para um dado padrão de entrada. Essa condição pode ser expressa da seguinte forma (HAYKIN, 2001):

$$y_k = \begin{cases} 1 & \text{se } \vartheta_k > \vartheta_j, \forall j, j \neq k \\ 0 & \text{se } \vartheta_k \leq \vartheta_j \end{cases} \quad (2.20)$$

Considerando que o somatório dos pesos sinápticos  $w_{kj}$  das entradas  $j$  de um neurônio  $k$  tenha valor unitário como mostrado na equação 2.21 e cada peso tenha um valor positivo, fixo e distribuído entre si, o neurônio pode deslocar os pesos dos nós de entrada desativados para os nós ativados. Caso o neurônio responda a um conjunto de entradas nos nós, cada nó ativado distribui uma parte do valor de seu peso sináptico entre si mantendo uma distribuição uniforme dos pesos. Caso o neurônio não responda ao padrão de entradas, o neurônio permanece desativado. A equação 2.21 demonstra a regra de aprendizagem competitiva (HAYKIN, 2001):

$$\sum_j w_{kj} = 1, \forall k \quad (2.21)$$

$$\Delta w_{kj} = \begin{cases} \eta(x_j - w_{kj}) & \text{se } k \text{ vencedor} \\ 0 & \text{se } k \text{ perdedor} \end{cases} \quad (2.22)$$

## 2.2.6 Arquiteturas de Redes Neurais Artificiais (RNA)

Para falar sobre arquiteturas de redes neurais é preciso primeiro falar sobre o *perceptron*, proposto por Rosenblatt em 1958. O *perceptron* de Rosenblatt consiste de um neurônio com pesos sinápticos que podem ter seus valores modificados e ajustados por meio de aprendizagem supervisionada e *bias*. A estrutura de um *perceptron* é igual a do modelo mostrado na figura 16 e classifica os vetores de entradas em padrões linearmente separáveis, que corresponde a um hiperplano com duas classes distintas e podem ser definidas pela seguinte equação (HAYKIN, 2001):

$$\sum_{i=1}^m w_i x_i + b_k = 0 \quad (2.23)$$

Um *perceptron* de camada única é um *perceptron* que consegue separar os vetores de entrada em duas classes distintas com um neurônio que segue o modelo de McCulloch-Pitts, porém caso seja necessário classificar mais de duas classes distintas é necessário incluir mais neurônios. Isso é possível com a generalização do *perceptron* de camada única, onde os neurônios são interligados em várias camadas mostradas na figura 19, formando uma rede neural denominada *perceptron* de múltiplas camadas (*Multilayer Perceptron - MLP*) (HAYKIN, 2001).

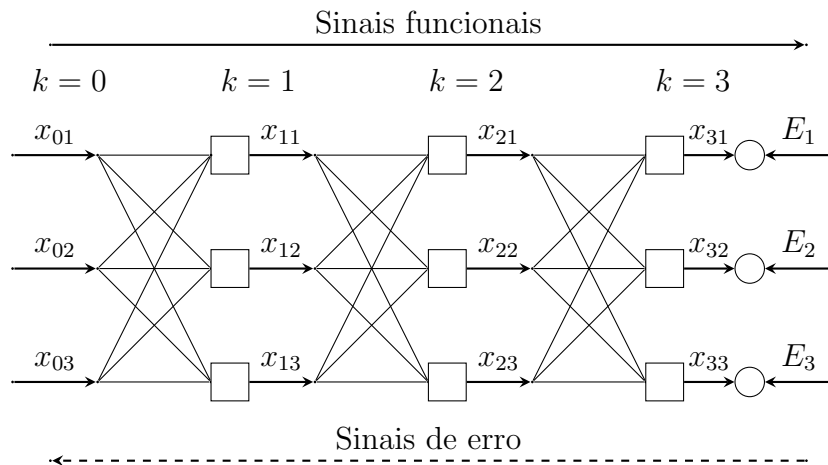


Figura 19: *Perceptron* de múltiplas camadas e propagação dos sinais

Fonte: adaptado de Kovács (2006)

Na figura 19 as entradas e saídas dos neurônios e os próprios neurônios estão verticalmente alinhados. Esse alinhamento é denominado de camada e cada uma delas possui um índice  $k$  para identificação. A camada  $k=0$  é chamada de camada de entrada, pois recebe os sinais de entrada da rede neural. A camada  $k=3$ , que recebe o resultado do proces-

samento de sinais das camadas anteriores, é denominada camada de saída e as camadas  $k = 1$  e  $k = 2$ , que recebem os sinais da camada de entrada, processam e transmitem o resultado para a camada de saída, recebem o nome de camadas ocultas. Os neurônios das camadas ocultas realizam o cálculo do sinal enviado por cada saída de neurônio, que é em função do sinal de entrada e seus pesos sinápticos, e repassam o resultado à camada seguinte (KOVÁCS, 2006; HAYKIN, 2001).

O *perceptron* de múltiplas camadas é a topologia de rede neural mais utilizada por permitir classificação de padrões de entradas e realizar aproximação universal de funções. Para isso, ela utiliza aprendizagem supervisionada com o algoritmo de retropropagação de erro. Para poder determinar o erro da saída, os neurônios das camadas ocultas realizam a estimativa do vetor gradiente para a retropropagação do erro da saída da rede neural. A figura 19 também mostra como a topologia realiza a propagação dos sinais, sendo que a função destes são (HAYKIN, 2001; MENEZES, 2008):

- Sinais funcionais: sinal de entrada da rede neural que se propaga da camada de entrada até a camada de saída e calculado quando passa por cada camada, cujo resultado é distribuído pela saída do neurônio da respectiva camada;
- Sinais de erro: sinal que se propaga da camada de saída até a camada de entrada, realizando o cálculo do vetor gradiente de erro no neurônio da respectiva camada, cujo resultado permite a atualização dos pesos sinápticos dos neurônios de cada camada.

A atualização dos pesos sinápticos dos neurônios do *perceptron* pode ser expressa da seguinte forma (MENEZES, 2008; HAYKIN, 2001):

$$\Delta w_{ik} = \eta E_i y_l + \alpha_m \Delta w_{ik}^{anterior}, \quad 0 < \eta < 1 \text{ e } 0 < \alpha < 1 \quad (2.24)$$

Onde  $\alpha_m$  é o termo *momentum*, que é utilizado para acelerar a taxa de aprendizagem da rede neural evitando região de mínimo local na estimativa do vetor gradiente.

## 2.3 Linhas de transmissão com compensação série

### 2.3.1 Aspectos principais

Usadas em Sistemas Elétricos de Potência há várias décadas por fabricantes de equipamentos para linhas de transmissão de longas distâncias, a compensação série reduz a



contribuição da reatância na impedância da linha, fazendo com que diminua o ângulo de transmissão e, conseqüentemente, a distância elétrica entre os terminais da mesma. A vantagem do uso da compensação série pode ser demonstrada a partir da análise do sistema mostrado na figura 20, que consiste em uma fonte de geração  $\dot{V}_{th}$  ligada ao sistema elétrico através de uma linha de transmissão sem perdas, sendo  $V_L$  o módulo da tensão no terminal local,  $V_R$  o módulo da tensão no terminal remoto,  $\Theta_L$  o ângulo de fase da tensão  $V_L$ ,  $\Theta_R$  o ângulo de fase da tensão  $V_R$  e  $X_l$  a reatância indutiva da linha.

Para essa redução, utiliza-se um capacitor em série com a linha, diminuindo a reatância indutiva da linha (HASHEMI; HAGH; SEYEDI, 2014; FRONTIN, 2013). A capacitância é dimensionada em função da reatância indutiva da linha  $X_L$ , sendo expressa da seguinte forma (SONG; JOHNS, 1999):

$$k_C = \frac{X_C}{X_L} \quad (2.25)$$

Sendo  $k_C$  o grau de compensação em [pu],  $X_L$  a reatância indutiva da linha de transmissão em  $[\Omega]$  e  $X_C$  a reatância capacitiva do Capacitor série em  $[\Omega]$ . Linhas de transmissão com compensação série com grau de compensação de até 70% da reatância indutiva da linha são valores normais de dimensionamento (ZIEGLER, 2011).

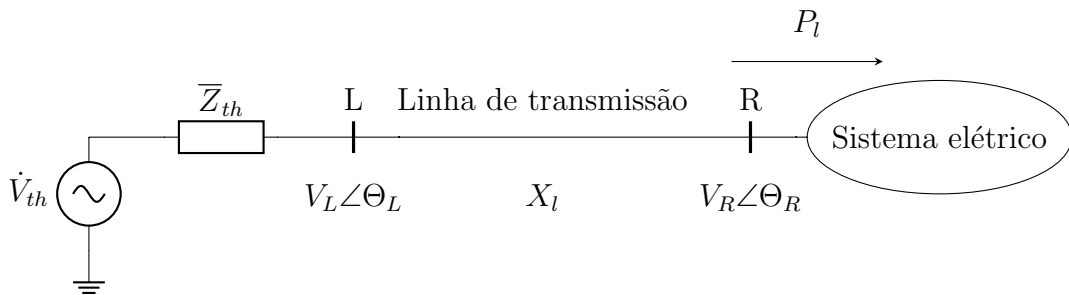


Figura 20: Interligação entre uma fonte e um sistema elétrico

A potência transmitida pela linha entre  $\dot{V}_{th}$  e o sistema elétrico pode ser descrita a partir da seguinte equação (FRONTIN, 2013; SONG; JOHNS, 1999):

$$P_l = \frac{V_L \cdot V_R}{X_l} \cdot \sin \alpha, \text{ sendo } \alpha = \Theta_L - \Theta_R \quad (2.26)$$

Com a inserção do capacitor série é possível reescrever a equação 2.25 da seguinte forma (ABB, 2016):

$$P_l = \frac{V_L \cdot V_R}{X_l - X_C} \cdot \sin \alpha \quad (2.27)$$

A partir da equação 2.25, é possível aumentar a potência  $P_l$  transmitida na linha nas seguintes condições:

- A potência  $P_l$  pode ter aumento diretamente proporcional ao aumento das tensões  $V_L$  e  $V_R$ , porém esse aumento de tensão é limitado a até 10% do valor nominal para evitar danos aos equipamentos, como por exemplo os transformadores de potência. Esse limite que pode ser atribuído pelo Operador Nacional do Sistema Elétrico (ONS) ou pelo projeto elétrico da linha de transmissão ou equipamentos da subestação (FRONTIN, 2013; ONS, 2018);
- A potência  $P_l$  também pode ter aumento diretamente proporcional ao aumento do ângulo  $\alpha$  até o limite de estabilidade, idealmente  $90^\circ$ . Essa condição resultaria em um aumento de potência maior que a do aumento das tensões, porém diminui a margem de estabilidade transiente durante a ocorrência de um curto-circuito (FRONTIN, 2013); e
- A potência  $P_l$  pode ter aumento inversamente proporcional a diminuição da reatância indutiva da linha  $X_l$ .

Isolando a reatância  $X_C$  na equação 2.25 e substituindo na equação 2.27, temos:

$$P_l = \frac{V_L \cdot V_R}{X_l - (k_C \cdot X_l)} \cdot \sin \alpha \quad (2.28)$$

Portanto a equação de potência transmitida pela Linhas de transmissão com compensação série fica da seguinte forma (SONG; JOHNS, 1999):

$$P_l = \frac{V_L \cdot V_R}{X_l(1 - k_C)} \cdot \sin \alpha, \text{ sendo } \alpha = \Theta_L - \Theta_R \quad (2.29)$$

Dependendo do grau de compensação a ser aplicado à linha, é possível ter aumentos consideráveis de potência transmitida. A potência reativa gerada no capacitor série aumenta em função do aumento do carregamento da linha de transmissão, fazendo com que aumente o valor da tensão no terminal remoto e, conseqüentemente, aumente a estabilidade da tensão do sistema elétrico (SONG; JOHNS, 1999). Na figura 21 é possível observar a estabilidade de um sistema elétrico sem compensação série, com 50% e 75% de compensação, no gráfico da tensão elétrica  $V_r$  em função da potência elétrica transmitida  $P_l$ , ambos em [pu]. O ponto de máximo valor do vértice de cada gráfico representa a tensão mínima do sistema antes da perda de estabilidade, portanto é possível observar que

quanto maior o grau de compensação da linha de transmissão, maior o valor de potência transmitida antes da perda de estabilidade do sistema elétrico (HINGORANI; GYUGYI, 2000).




Figura 21: Limite de estabilidade aplicando a equação 2.29

Fonte: adaptado de Hingorani e Gyuyi (2000)

O uso de linhas de transmissão com compensação série permite o aumento da margem de estabilidade transitória do sistema elétrico, conforme demonstra as figuras 22 e 23, mostrando cada uma o gráfico de potência entregue ao sistema elétrico pelo gerador  $P$  no eixo da ordenada e o ângulo da potência entregue pelo gerado  $\delta$  no eixo da abscissa durante a ocorrência de um curto-circuito.

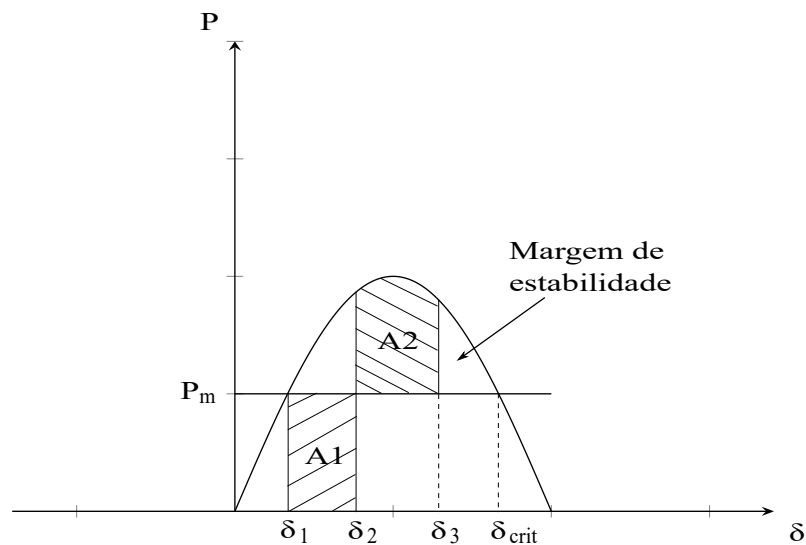


Figura 22: Margem de estabilidade transitória de uma linha de transmissão convencional

Fonte: adaptado de Hingorani e Gyuyi (2000)

Sendo  $P_m$  que representa a potência mecânica do gerador,  $\delta_1$  representa o ângulo da

potência  $P_m$ ,  $\delta_2$  representa o ângulo de aceleração do gerador durante a falta,  $\delta_3$  representa o ângulo máximo de troca entre potência mecânica e elétrica do gerador e  $\delta_{crit}$  representa o ângulo que determina a margem de estabilidade transiente do sistema elétrico.

A figura 22 mostra a margem de estabilidade de uma linha de transmissão convencional durante a aplicação de um curto-circuito. Antes da ocorrência do curto-circuito, a potência elétrica entregue ao sistema é a potência  $P_m$  com ângulo  $\delta_1$ . Durante a ocorrência, a potência  $P_m$  continua estável, porém o gerador acelera até atingir a potência entregue com ângulo  $\delta_2$ , quando ocorre a atuação da proteção e o encerramento do distúrbio elétrico. A energia de aceleração é representada como a área A1. Após o encerramento, a potência elétrica transmitida ultrapassa a potência mecânica  $P_m$ , e conseqüentemente a máquina começa a desacelerar. Porém, a energia cinética acumulada durante a aceleração aumenta até ocorrer uma estabilização, representada na área A2 e atingindo o ângulo  $\delta_3$ . A margem de estabilidade transiente é representada pela área entre os ângulos  $\delta_3$  e  $\delta_{crit}$ , que corresponde ao ângulo máximo que permite o gerador entregar potência  $P_m$  ao sistema elétrico (HINGORANI; GYUGYI, 2000).

A figura 23 mostra a margem de estabilidade transitória com compensação série com grau de compensação de 50%, com o gráfico de potência elétrica versus ângulo  $\delta$  de uma linha de transmissão convencional representado em tracejado. É possível observar que a margem de estabilidade aumenta proporcionalmente ao aumento do grau de compensação da linha de transmissão, fazendo com que os ângulos  $\delta_1$ ,  $\delta_2$  e  $\delta_3$  fiquem mais distantes de  $\delta_{crit}$ , diminuindo a probabilidade de colapso do sistema elétrico durante a ocorrência de um curto-circuito.

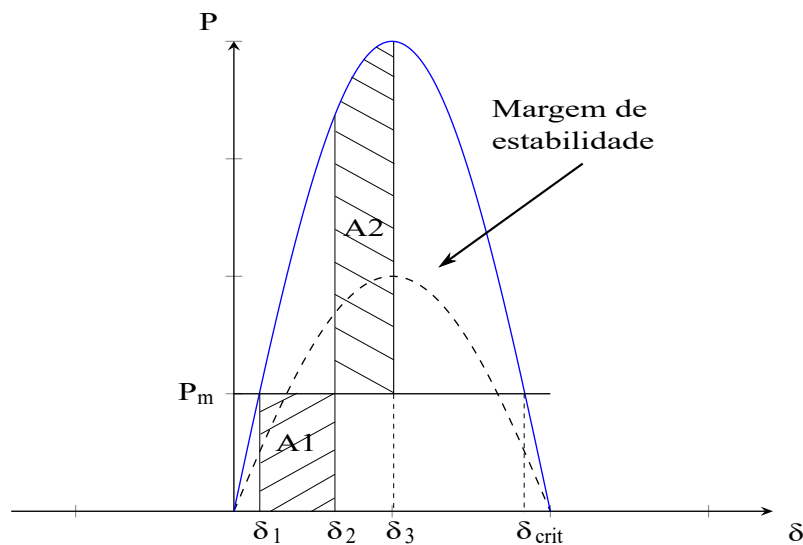


Figura 23: Margem de estabilidade transitória com compensação série  
 Fonte: adaptado de Hingorani e Gyuyi (2000)

Uma outra vantagem do uso de linhas de transmissão com compensação série é a diminuição da oscilação de potência quando aplicada compensação com controle, variando o grau de compensação para contrabalancear a aceleração e a desaceleração do gerador durante a ocorrência de curto-circuito, contribuindo para não submeter os geradores do sistema elétrico à oscilação que possa ocasionar perda de sincronismo (HINGORANI; GYUGYI, 2000; ABB, 2016).

Uma desvantagem do uso da compensação série é o fenômeno de ressonância subsíncrona, que pode aumentar a intensidade das oscilações mecânicas e elétricas dos geradores e suas respectivas turbinas, podendo gerar danos ao conjunto de geração elétrica. A frequência de ressonância elétrica de um circuito série, em [rad/s], pode ser expressa conforme equação 2.30 (HINGORANI; GYUGYI, 2000; ORSINI; CONSONNI, 2002):

$$\omega_e = \frac{1}{\sqrt{LC}} \quad (2.30)$$

A frequência de ressonância, em [Hz], pode ser expressa da seguinte forma:

$$f_e = \frac{1}{2\pi\sqrt{LC}} \quad (2.31)$$

Escrevendo L e C em função, respectivamente, da reatância indutiva da linha de transmissão  $X_L$  e da reatância do capacitor série  $X_C$ , a equação 2.31 pode ser escrita da seguinte forma (HINGORANI; GYUGYI, 2000):

$$f_e = f \sqrt{\frac{X_C}{X_L}} \quad (2.32)$$

Sendo f a frequência fundamental do sistema elétrico. Substituindo a equação 2.25 na equação 2.32, a equação da frequência de ressonância de uma linhas de transmissão com compensação série pode ser escrita da seguinte forma:

$$f_e = f \sqrt{k_C} \quad (2.33)$$

Observando a equação 2.33, a frequência de ressonância será sempre menor que a frequência fundamental do sistema, devido ao fato de que o grau de compensação série utilizado é de até 70% da indutância da linha de transmissão, resultando em uma frequência sub-harmônica. Quando ocorre uma oscilação no sistema devido a um curto-circuito, a componente sub-harmônica da corrente de linha contribui para um campo sub-harmônico

correspondente ao campo principal do gerador, resultando em um torque complementar no rotor. Caso esse torque sincronize com a ressonância torcional da turbina, pode contribuir para uma oscilação torcional e, conseqüentemente, gera uma contribuição para a ressonância elétrica (HINGORANI; GYUGYI, 2000).

### 2.3.2 Tipos de compensação

Existem dois tipos de compensação série de uma linha de transmissão: compensação fixa e compensação variável com o uso de *Flexible Alternating Current Transmission Systems* (FACTS).

#### 2.3.2.1 Compensação fixa

A compensação fixa é feita com capacitor série (CP), utilizando um valor de grau de compensação  $k_C$  definido em projeto, que pode ser de até 70% da indutância da linha de transmissão. A compensação com uso de capacitor série é aplicada e aprimorada desde os primeiros anos do século XX, com a primeira aplicação em linha de transmissão com tensão de 33 [kV] nos Estados Unidos, em 1928, e no Brasil, em 1989, para transmissão da energia elétrica gerada na usina hidrelétrica de Itaipu até o Estado de São Paulo, em 765 [kV] (FRONTIN, 2013; KOROT; MARKEN; BOCK, 2014).

O arranjo do conjunto de CP é composto de vários capacitores em série e paralelo para atender o valor de  $k_C$  definido no projeto, sendo que cada fase possui seu próprio conjunto. O capacitor pode sofrer sobretensão durante eventos de curto-circuito no sistema elétrico, por isso os fabricantes instalam vários dispositivos para proteção do capacitor série (ABB, 2015; GE, 2015b). A figura 24 mostra o diagrama de um banco capacitor série e seus dispositivos de proteção.




Figura 24: Diagrama elétrico de um banco capacitor série

Na figura 24 é possível observar os seguintes dispositivos de proteção do capacitor série:

- Circuito de amortecimento (CA): composto de um reator e em alguns casos de um resistor, o CA tem a função de limitar e amortecer a corrente de descarga durante operação do centelhador (ABB, 2015; GE, 2015b);
- Centelhador (G): tem a função de desviar a corrente do CP durante a ocorrência de um curto-circuito. O centelhador entra em operação quando a tensão entre os dois terminais atinge um valor definido, criando um arco elétrico entre os terminais. Isso permite absorver a energia gerada pelo curto-circuito e diminuir a tensão do capacitor, evitando danificar os seus elementos (FRONTIN, 2013; GE, 2015b); e
- Disjuntor de *By-pass* (DBP): é um disjuntor que tem objetivo de remover o CP do sistema quando o centelhador atinge o seu limite de absorção de energia, permitindo o seu resfriamento. Esse disjuntor também pode ser utilizado para isolar o capacitor série, retirando o mesmo de serviço para eventual manutenção (FRONTIN, 2013; GE, 2015b).

O centelhador é o dispositivo mais antigo utilizado para proteção de um capacitor série. Neste tipo de uso, quando ocorre um curto-circuito na linha de transmissão o centelhador G começa a disparar um arco elétrico entre os terminais, absorvendo a energia e mantendo a tensão em cima do CP, que tende a subir devido ao curto-circuito na rede. Durante distúrbios elétricos longos, o disjuntor DBP fecha, absorvendo a corrente conduzida pelo centelhador, permitindo o seu resfriamento e isolando o CP do sistema elétrico. Após a extinção do curto-circuito na linha de transmissão, pelo seu sistema de proteção, o DBP abre e o capacitor série volta a operar (FRONTIN, 2013).

Algumas soluções de compensação série utilizam um esquema de dois centelhadores para proteção do banco capacitor série, conforme mostra a figura 25.

O esquema de proteção com centelhador duplo funciona da mesma forma que o de centelhador simples, porém a tensão de disparo do centelhador G1 é ajustada em um valor 20% menor que o centelhador G2. Durante um curto-circuito, G1 dispara um arco elétrico entre os terminais absorvendo a energia e mantendo a tensão em cima do CP. Após a isolação do curto-circuito, o disjuntor D abre e a linha de transmissão fica assistida pelo G2, enquanto ocorre o resfriamento e recuperação de G1. Passado o tempo de resfriamento dos terminais de G1, o disjuntor D fecha e a linha fica assistida por G1 novamente (FRONTIN, 2013).




Figura 25: Diagrama elétrico de um banco capacitor série com centelhador duplo

Uma terceira forma de proteger o banco capacitor série é o uso do Varistor a Óxido Metálico (MOV), conforme mostra a figura 26. O MOV consiste em um resistor não linear, que funciona como um circuito aberto em caso de operação normal do sistema elétrico e, quando a tensão de condução projetada é atingida durante a ocorrência de um curto-circuito, o MOV começa a conduzir, absorvendo a energia gerada pelo distúrbio elétrico e mantendo constante a tensão em cima do CP (FRONTIN, 2013; ABB, 2015).




Figura 26: Diagrama elétrico de um banco capacitor série com MOV

Mesmo com a utilização do MOV, alguns fabricantes também utilizam um centelhador e um disjuntor de *By-pass* em paralelo ao MOV e ao CP. Com esse esquema, é possível preservar o MOV. Caso da tensão de condução seja maior do que ele consiga suportar, forma-se um arco elétrico no centelhador e a proteção do CP funciona da mesma forma



que de um centelhador simples (FRONTIN, 2013; GE, 2015b).

### 2.3.2.2 Compensação variável (TCSC)

Uma outra forma de realizar uma compensação série em uma linha de transmissão é o uso de compensação variável em FACTS. O conceito de *Flexible Alternating Current Transmission Systems* consiste no uso de eletrônica de potência em Sistemas Elétricos de Potência, aprimorando o seu controle com dispositivos eletrônicos que respondem mais rápido à demanda do sistema, do que os dispositivos mecânicos (FRONTIN, 2013; HINGORANI; GYUGYI, 2000). Existem diversas tecnologias aplicadas em FACTS, como por exemplo o *Thyristor-Controlled Series Capacitor* (TCSC), conforme mostra a figura 27.




Figura 27: Diagrama elétrico de um TCSC

O TCSC consiste de um Capacitor série, um MOV para proteção de sobretensão do CP durante a ocorrência de curto-circuito e um conjunto em série de um reator L e dois tiristores, ambos em paralelo ao CP e o MOV. A vantagem desse esquema é que ele permite uma variação dinâmica do grau de compensação da linha de transmissão. Essa variação dinâmica é possível através da relação em paralelo do CP e do reator L, demonstrada pela equação 2.34 (FRONTIN, 2011; HINGORANI; GYUGYI, 2000):

$$X_{TSCS} = \frac{X_C X_{L(\alpha)}}{X_{L(\alpha)} - X_C} \quad (2.34)$$

sendo  $X_C$  a reatância capacitiva do CP,  $X_{L(\alpha)}$  a reatância indutiva de L e  $\alpha$  o ângulo de disparo dos tiristores. A função dos tiristores é regular a reatância  $X_{L(\alpha)}$ , fazendo com que o conjunto reator-tiristores e CP se comportem como um circuito série de reatância controlável. Dependendo do valor de  $\alpha$  ajustado pelo algoritmo de controle do TCSC,

$X_{L(\alpha)}$  pode variar. A figura 28 ilustra o comportamento da reatância  $X_{TCSC}$  em função do ângulo  $\alpha$ .

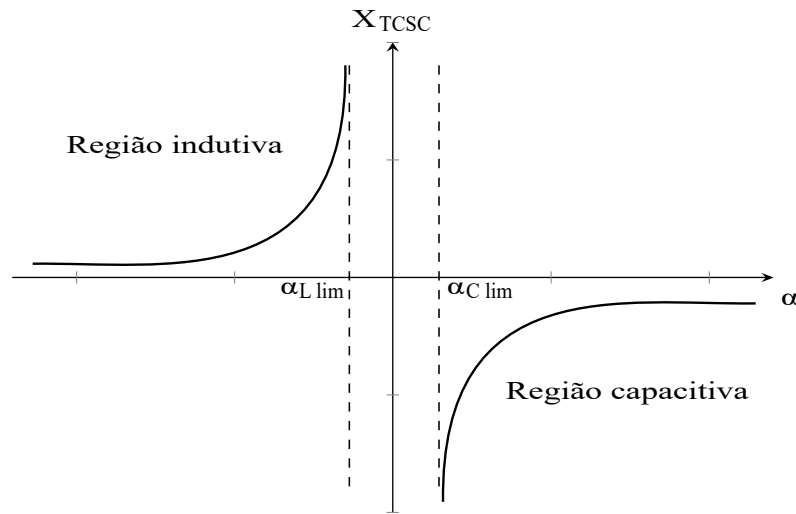


Figura 28: Comportamento da reatância de um TCSC em função do ângulo de disparo  $\alpha$   
 Fonte: adaptado de Frontin (2011) e Frontin (2013)

Sendo  $\alpha_{L \text{ lim}}$  o ângulo de disparo limite para região indutiva e  $\alpha_{C \text{ lim}}$  o ângulo de disparo limite para região capacitiva. O valor da reatância  $X_{TCSC}$  tende ao infinito quando o ângulo de disparo é  $\alpha_{L \text{ lim}}$  ou  $\alpha_{C \text{ lim}}$ . Conforme o valor de  $\alpha$  é diminuído ou aumentado, o valor de  $X_{TCSC}$  pode assumir, respectivamente, o comportamento de uma reatância indutiva ou uma reatância capacitiva.

O modo mais comum do TCSC trabalhar é na região capacitiva, através da condução parcial dos tiristores, variando o grau de compensação desejado na linha de transmissão para atender às demandas do sistema elétrico. Para trabalhar na região indutiva, é necessário que a condução dos tiristores ocorra de forma contínua, inserindo o valor total de reatância de L, esse modo denominado de *by-pass*, que pode ser utilizado para limitar a corrente de curto-circuito na linha de transmissão. Um terceiro modo de condução, denominado de modo de bloqueio, é quando não ocorre condução dos tiristores e a reatância do conjunto corresponde à reatância capacitiva do CP (FRONTIN, 2011; SONG; JOHNS, 1999).

A grande vantagem do uso do TCSC é a eliminação do fenômeno de ressonância subsíncrona, que acontece quando o valor de  $\alpha$  se encontra na região entre  $\alpha_{L \text{ lim}}$  e  $\alpha_{C \text{ lim}}$ , e os valores das reatâncias  $X_{L(\alpha)}$  e  $X_C$  se igualam. Para isso, a estratégia de controle do TCSC faz com que o conjunto trabalhe na região indutiva quando o sistema elétrico está na faixa de frequência subsíncrona e, quando a frequência do sistema está na faixa de operação normal, estratégia de controle do TCSC trabalha na região capacitiva (ABB,

2016, 2010).

Porém, é necessário ter cuidado no dimensionamento da reatância indutiva de L. Um reator com valor de reatância indutiva  $X_{L(\alpha)}$  baixo pode permitir proteção para correntes de surto de alta intensidade realizando o *by-pass*, além de prover carregamento reverso e controle do tempo da tensão compensada no CP. Entretanto, um  $X_{L(\alpha)}$  baixo também aumenta a magnitude das correntes harmônicas geradas por L que circulam através do capacitor série, aumentando assim as tensões harmônicas enviadas para a linha de transmissão e diminuindo a faixa para controle do ângulo de disparo  $\alpha$ , tornando o seu controle mais complexo. Além disso, o uso do TCSC insere mais equipamentos e componentes para o seu controle, o que torna mais cara a sua implementação em uma linha de transmissão do que o uso de compensação série fixa (HINGORANI; GYUGYI, 2000).

### 2.3.3 Posição e quantidade da compensação

Existem três formas de instalar a compensação série (CS) em uma linha de transmissão. Uma delas é instalando o conjunto no meio da linha, com distância de 50% de cada terminal e utilizando o valor total do grau de compensação  $k_C$  definido em projeto, conforme a figura 29 (ZIEGLER, 2011; ANDERSON, 1999). Uma desvantagem deste tipo de instalação é a necessidade de um terceiro terreno para construção do conjunto de compensação série, encarecendo a construção e aumentando a complexidade de manutenção da instalação, pois é necessário que a equipe visite três locais distintos para a manutenção de uma linha de transmissão. Além disso, um curto-circuito que aconteça após a CS gera impactos na localização da falta da linha de transmissão, que são descritos na subseção 2.3.4.




Figura 29: Compensação série instalada no meio da linha de transmissão

A segunda forma é instalar um conjunto de CS em um dos terminais da linha de transmissão e utilizando o valor total de  $k_C$  definido em projeto, conforme a figura 30 (ZIEGLER, 2011; ANDERSON, 1999). Esse tipo de instalação apresenta uma vantagem com relação à anterior devido ao fato dela ser instalada em um dos terminais da linha,

dentro do terreno da subestação ligada a esse terminal, facilitando o trabalho da equipe de manutenção e diminuindo os custos de construção por não precisar comprar um terreno adicional para instalação da compensação série.




Figura 30: Compensação série instalada em um dos terminais da linha de transmissão

A última forma de instalação é dois conjuntos de CS em cada terminal da linha de transmissão, onde o valor total de  $k_C$  definido em projeto é dividido para cada conjunto, conforme a figura 31 (ZIEGLER, 2011; ANDERSON, 1999). As vantagens dessa forma de instalação são manter a instalação do conjunto capacitor série no terreno da subestação onde está o terminal da linha de transmissão e a necessidade de menos unidades capacitivas em cada conjunto, diminuindo o seu custo de instalação para cada fase.




Figura 31: Compensação série instalada em cada terminal da linha de transmissão

### 2.3.4 Impacto na proteção de distância

O uso de compensação série em uma linha de transmissão gera impactos na proteção de distância que podem dificultar a identificação de um curto-circuito e comprometer a sua precisão. Os impactos podem ser descritos em quatro efeitos: inversão da tensão elétrica medida pelo TP, inversão da corrente elétrica medida pelo TC, reatância de curto-circuito reduzida e resistência não-linear durante a ocorrência de um curto-circuito (ZIEGLER, 2011).

A inversão de tensão em uma linha de transmissão com compensação série ocorre quando a reatância do capacitor série é maior que a reatância da linha, fazendo com que a tensão medida pelo IED de proteção seja negativa, conforme demonstra a figura 32. Em uma linha com a compensação série instalada nos terminais, como mostram as figuras 30

e 31, isso ocorre quando o curto-circuito está sendo aplicado próximo do capacitor série, cuja reatância proporcional da linha é menor que a reatância do capacitor (ZIEGLER, 2011; ANDERSON, 1999).




Figura 32: Efeito da inversão de tensão durante curto-circuito

A equação da inversão de tensão pode ser deduzida da seguinte forma:

$$\dot{V}_l = \frac{\dot{V}_{th}(-jX_{CS} + x_f \cdot \bar{Z}_{LT})}{\bar{Z}_{th} - jX_{CS} + x_f \cdot \bar{Z}_{LT}} \quad (2.35)$$

onde  $\dot{V}_l$  é a tensão fasorial medida pelo TP no terminal local,  $jX_{CS}$  a reatância capacitiva do capacitor série,  $x_f$  a localização do curto-circuito em porcentagem da linha de transmissão e  $\bar{Z}_{LT}$  a impedância da linha de transmissão.

A inversão de corrente medida pelo TC ocorre em caso de um curto-circuito aplicado próximo do capacitor série, quando a reatância entre o ponto de aplicação do curto-circuito e a fonte de energia é negativa e pode ocorrer em compensação série instalada nos terminais da linha de transmissão conforme arranjo das figuras 30 e 31. À medida que o curto-circuito ocorre afastado do terminal da linha, a inversão deixa de acontecer (ZIEGLER, 2011; ANDERSON, 1999).

A equação da inversão de corrente pode ser deduzida da seguinte forma:

$$\dot{I}_l = \frac{\dot{V}_{th}}{\bar{Z}_{th} - jX_{CS} + x_f \cdot \bar{Z}_{LT}} \quad (2.36)$$

onde  $\dot{I}_l$  é a corrente fasorial da linha de transmissão medida pelo TC. Os efeitos de inversão da corrente elétrica e da tensão elétrica durante a ocorrência de um curto-circuito fazem com que a impedância calculada pelo IED de proteção através dos valores medidos pelos transformadores de instrumentação seja menor que em uma linha de transmissão sem

compensação série (ZIEGLER, 2011; ANDERSON, 1999), como mostra a figura 33.




Figura 33: Impedância aparente de uma linha de transmissão

Esse valor reduzido é devido a reatância negativa do capacitor série, que diminui a reatância da linha de transmissão. É possível observar na figura 33 que existe uma parte da linha próxima do banco capacitor que fica fora da zona de proteção determinada pela curva característica MHO, fazendo com que a ocorrência de um curto-circuito próximo do terminal da linha fique desprotegido pela função de proteção de distância do IED, de modo que a função de proteção não atue. Além disso, curto-circuitos em trechos da linha fora da zona de proteção determinada pela curva MHO acabam sendo identificados pelo algoritmo da função de proteção de distância como dentro da zona, fazendo com que o IED envie a ordem de abertura do disjuntor. Isso cria um problema de seletividade da função de proteção, onde a mesma acaba atuando por sobrealcance.

O último efeito que impacta na proteção de distância de uma linha de transmissão com compensação série é a introdução de resistência não-linear durante um curto-circuito. Essa resistência é introduzida pela condução do MOV durante a ocorrência do curto-circuito na linha, funcionando como uma impedância variável para manter a tensão sobre o banco capacitor série. Com esse comportamento variável e não-linear, a impedância equivalente da associação capacitor série-MOV torna-se não linear também, fazendo com que o algoritmo de proteção do IED não realize a atuação da forma correta e tenha problemas de seletividade (ZIEGLER, 2011).

## 2.4 Proteção de distância em linhas de transmissão com compensação série

Existem diferentes formas de realizar a proteção de distância em linhas com compensação série. O trabalho de (MANASSERO; SANTO; ROJAS, 2016) apresenta um método para localização de curto-circuitos em linhas de transmissão com compensação série em circuitos simples ou duplos através das componentes de fase das correntes e tensões, e com o uso de método heurístico. O método heurístico utilizado foi o *pattern search*, que busca o mínimo de uma função através de combinações dos valores de entrada em torno de uma combinação central. Foi utilizado um sistema de 440 [kV] e 220 [km] simulado no programa ATP e os resultados apresentados mostram que o método possui um erro menor que 1,5% de acordo com o tipo de curto-circuito aplicado (fase-fase ou fase-terra), com erro em parametrização da linha e erro nos fasores.

No trabalho de (HASHEMI; HAGH; SEYEDI, 2014) é utilizada a impedância mútua entre as fases da linha de transmissão para o algoritmo de proteção. Proposto para ser uma função de proteção de retaguarda, o algoritmo calcula o valor de impedância mútua entre as fases através da leitura dos valores de tensão e corrente em cada terminal e compara o valor obtido com uma zona de atuação pré-definida. Foram realizados testes com os três tipos de arranjo de compensação série e os resultados apresentados demonstram que o algoritmo conseguiu detectar os curtos-circuitos aplicados, distinguiu as faltas internas e externas à linha de transmissão. Além disso, os autores realizaram comparações com uma proteção de distância com curva característica quadrilateral. Porém, os próprios autores ressaltam que esse algoritmo de proteção só consegue proteger a linha em casos de curtos-circuitos do tipo fase-terra e dupla fase terra, pois em casos de curtos-circuitos trifásicos e dupla fase não é possível o cálculo da impedância de sequência zero. Além disso, no trabalho não está claro em que programa foram feitas as simulações e se os autores utilizaram IEDs comerciais.

O artigo de (ÇAPAR; ARSOY, 2015) apresenta um algoritmo de localização de curto-circuito em linhas com compensação série com arranjo do banco capacitor série localizado no meio da linha, sendo que a linha de transmissão testada no trabalho possui 300 [km]. Os parâmetros do algoritmo proposto, além da leitura dos sinais de tensões e correntes, são as distâncias em porcentagem entre os terminais local e remoto até o capacitor série e a impedância da linha. O algoritmo trabalha com dois cenários distintos: um onde o curto-circuito acontece entre terminal local e o banco capacitor série e outro onde o curto-circuito acontece entre o terminal remoto e o banco capacitor série.

Em cada cenário são calculadas: a tensão e corrente no ponto de aplicação do curto-circuito, a taxa de erro de ângulo entre a tensão e a corrente, escolhida a menor taxa de erro que corresponde à localização em potencial do distúrbio, e a impedância entre o capacitor e o ponto de aplicação do curto-circuito. A partir disso, é extraída a parte real dessa impedância e estimada a localização. O algoritmo foi simulado no programa DigSILENT aplicando os curtos entre 15% e 85% do terminal local e comparado os erros de localização com outros dois algoritmos: Takagi (ZIMMERMAN; COSTELLO, 2005) com os valores medidos de tensões e correntes de um dos terminais, e outro dos próprios autores, com a utilização das medições de tensões e correntes nos dois terminais da linha. Exceto em dois casos de curto-circuito fase-terra e trifásico aplicados antes do capacitor série, em que o algoritmo Takagi apresentou menor erro, o algoritmo proposto pelos autores teve desempenho melhor que os outros dois.

Em (GHANY; ELSADD; AHMED, 2019) é apresentado um algoritmo de proteção de distância que possui um esquema de votação baseado em teorias de análise de curtos-circuitos, identificando se o curto-circuito é aplicado antes ou depois da compensação série, instalada no meio da linha. O algoritmo realiza a leitura das tensão e corrente no terminal local, aplica a transformada discreta de Fourier (TDF) e determina o tipo de curto-circuito aplicado na linha. Após a determinação, são calculados dois tipos de impedância, com seus respectivos valores de magnitude e fase: uma chamada de convencional que seria igual a equação 2.1 e outra chamada de modificada que seria a impedância convencional descontando-se a divisão da tensão sobre o capacitor série e a corrente medida no terminal local.

A tensão sobre o capacitor série é obtida a partir da relação entre a impedância equivalente do conjunto de compensação e a corrente de curto medida na linha. Após a determinação das impedâncias, os ângulos de fase obtidos nas impedâncias convencional e modificada são utilizados no que os autores chamam de sistema de votação, comparando os ângulos de fase obtidos com valores pré-definidos para determinar se o curto-circuito ocorreu antes ou depois do banco capacitor série. Após determinada a localização do curto-circuito, é selecionada qual impedância será utilizada no plano de impedâncias R-X com suas respectivas zonas de proteção: a impedância convencional para antes da compensação série ou a impedância modificada para depois da compensação.

O algoritmo foi simulado na ferramenta Simulink do MATLAB e foram testados diversos cenários com variação de valores do grau de compensação de 10 até 100% em uma linha de transmissão de 300 [km], variação da localização da compensação série na linha de transmissão de 5% até 100%, variação do ponto de aplicação do curto-circuito de 5%



até 100%, variação da resistência de curto até 100 [ $\Omega$ ] e com valores de frequência de amostragem de 2 [kHz] e 4 [kHz]. Os resultados obtidos mostram que, com a frequência de amostragem maior, o erro de localização é menor e, para casos de curtos-circuitos entre fases, o erro de localização do curto-circuito é menor próximo do capacitor série. Porém, quando comparado com um IED comercial, o algoritmo apresenta erros de localização maiores e o erro também aumenta à medida que a resistência de curto-circuito também aumenta.

Os autores (SWETAPADMA; YADAV, 2018) apresentam um método de estimação de distúrbio em linhas de transmissão com compensação série fixa em circuito duplo com uso de transformada *wavelet* discreta e árvore de decisões regressiva. Árvore de decisão é um processo de mineração de dados que consiste em nós interligados entre si formando uma árvore invertida, onde cada nó realiza teste de comparação de valores cujo resultado remete ao nó adjacente. A árvore de decisões regressivas utiliza instrução *if-then* devido à sua simplicidade e precisão. Os autores decidiram utilizar a transformada *wavelet* discreta devido ao fato de aparecimento de efeito de decaimento da componente exponencial amortecida em curtos-circuitos com ângulos de incidência zero.

A simulação foi feita na ferramenta Simulink do MATLAB com um sistema de circuito duplo de 400 [kV] com os três arranjos de compensação e uso do MOV para proteção do capacitor série. Durante os testes foram aplicados curtos-circuitos trifásicos, dupla-fase, dupla-fase-terra e fase-terra em diversos tipos de cenários com variação de resistência, ângulo de incidência e ponto de aplicação do curto-circuito, mudanças nos parâmetros de impedância da linha de transmissão, variação do grau de compensação (em uma faixa entre 10 e 60%) e variação da impedância equivalente de Thevenin. O erro calculado em todos os testes permaneceu entre -1% e 1%, um erro muito baixo. Porém, a árvore de decisões precisa ser treinada primeiro com todos os tipos de curtos-circuitos possíveis de serem aplicados no sistema para aprendizagem e o tempo dessa aprendizagem ficou em torno de 4 [s].

O trabalho de (SAHA et al., 2016) apresenta teste de três algoritmos de impedância para linhas de transmissão com compensação série, um com método baseado na TDF, outro baseado em técnicas de equações diferenciais e um terceiro com uma combinação dos dois métodos. Foi simulado um sistema de 400 [kV] e linha de 300 [km] e o capacitor série foi protegido por MOV com o uso de modelos disponíveis no programa ATP-EMTP. Os autores usaram as TDFs de meio ciclo e um ciclo e os resultados obtidos foram tempo maior que 30 [ms] em um dos terminais da linha para as duas transformadas, o que segundo os autores é inaceitável para um dispositivo eletrônico inteligente (IED) e pode

comprometer o desempenho da função de proteção de distância.

Durante os testes com método de equações diferenciais, foram avaliados quatro tipos de técnicas: aplicação de diferenciação retangular com e sem pré-filtragem, introdução de defasagem de  $90^\circ$  no sinal de entrada em frequência fundamental e diferenciação retangular com componentes ortogonais. Os resultados mostram que o uso dos quatro métodos de equações diferenciais, propiciam tempos de resposta menores do que os do método de Fourier, principalmente o que não possui pré-filtragem, e não apresentam efeito de sobrealcance. Porém, o primeiro método mostrou tempo de resposta elevado quando o curto-circuito acontece próximo do MOV devido à transição da sua operação entre a região não-linear e linear.

No teste com a combinação dos dois métodos foram utilizadas memorização e polarização cruzada de tensão para evitar que o afundamento da tensão durante a aplicação do curto-circuito prejudicasse a direcionalidade da função de proteção. Os resultados obtidos com essa combinação foram que quando aplicado um curto-circuito próximo aos transformadores de instrumentação, o algoritmo definia esse distúrbio no terceiro quadrante do diagrama R-X, que corresponde a um curto-circuito em zona reversa. A conclusão dos autores foi de que os resultados foram satisfatórios, porém em curtos-circuitos próximos a IEDs de proteção, o algoritmo indica como se estivesse acontecendo atrás dos mesmos e não realiza a contento a seletividade esperada.

Os autores (JENA; SAMANTARAY; PANIGRAHI, 2015) apresentam trabalho baseado em medição fasorial sincronizada para proteção de linhas de transmissão com compensação série, porém como função de proteção de retaguarda, atendendo a norma C37.118.1-2011 da IEEE. A medição é feita a partir de *Phase Measurement Units* (PMU), que realizam a leitura dos valores instantâneos de tensão e corrente nos dois terminais de uma linha de transmissão. O esquema proposto pelos autores usa o ângulo de fase da impedância integrada de sequência positiva a partir dos fasores medidos nos dois terminais da linha, que consiste na impedância total integrada de cada fase sendo usada em uma zona de operação circular onde o ângulo de fase define a área de restrição e operação da função de proteção.

Os autores avaliaram o método proposto por meio de simulações de um sistema de 400 [kV] com 9 barras interligadas, sendo a interligação entre duas com arranjo de compensação série em um dos terminais da linha. Esse sistema foi implementado no simulador *Real Time Digital Simulator* (RTDS). Foram realizados testes com os três arranjos de compensação série, considerando inversões de tensão e corrente durante curtos-circuitos não

balanceados, inserindo zona de carregamento da linha e durante oscilação de potência e diferentes graus de compensação. Foram aplicados curtos-circuitos trifásico, dupla-fase, dupla-fase-terra e fase-terra e os resultados apresentados demonstram que o algoritmo detectou todos os casos de curtos aplicados na linha com os três tipos de arranjos de compensação série e com graus de compensação de 30% e 50%.

Também foram aplicados curtos-circuitos nas outras barras do sistema com graus de compensação de 30%, 50% e 70% e o algoritmo detectou somente os curtos-circuitos aplicados na linha protegida como dentro da sua zona de operação, os restantes foram classificados como fora da zona de operação. Além disso, foram medidos os tempos de execução da proteção entre a aplicação do distúrbio na linha até abertura do disjuntor, comparando-os com outros dois esquemas de proteção (NAYAK; PRADHAN; BAJPAI, 2014; EISSA; MASOUD; ELANWAR, 2009), os resultados ficaram entre 20 e 25 [ms], abaixo dos valores obtidos com os outros dois esquemas.

O artigo de (NAYAK; PRADHAN; BAJPAI, 2014) apresenta um algoritmo de proteção de retaguarda também baseado em PMU que utiliza dois critérios: busca da barra mais próxima ao curto-circuito através da comparação da magnitude das tensões sequenciais de todas as barras e identificação com uso do cosseno do ângulo entre tensão e corrente elétricas de cada terminal da linha ligada à barra mais próxima ao curto. No caso do ângulo, foi definida uma zona de operação entre  $-90^\circ$  e  $0^\circ$  e  $90^\circ$  e  $180^\circ$  para curtos balanceados e desbalanceados.

Para os testes foi implementado um sistema de 400 [kV] no EMTDC/PSCAD, com nove barras interligadas entre si, sendo uma delas com compensação série, onde foram testados vários cenários com curtos-circuitos simétricos e assimétricos, oscilação de potência e diferentes carregamentos. No algoritmo proposto, os fasores da componente fundamental são estimados por técnicas de TDF. Nos testes de curto-circuito assimétrico são monitorados os valores de tensão de sequências negativa e zero, que normalmente apresentam valores máximos de magnitude nestas condições.

O resultado obtido foi que o algoritmo conseguiu localizar a barra onde estava sendo aplicado o curto, mesmo tendo acontecido inversão de corrente em sequência negativa. Também foi aplicado um curto-circuito trifásico e monitorados a tensão e ângulo de fase de sequência positiva, cujo resultado foi a localização do curto-circuito na linha compensada pelo afundamento da tensão da barra ligada ao terminal e ângulo de fase dentro da zona de operação, mesmo ocorrendo a inversão da tensão. Com os testes de inserção de carregamento na linha não houve atuação da proteção mesmo com o aumento gradativo da

corrente na linha que classificaria o curto-circuito na região da terceira zona de operação. Com testes de oscilação de potência também não houve atuação da proteção mesmo em uma condição que classificaria o curto-circuito na região da terceira zona de operação.

O trabalho de (S; SAMANTARAY; PANIGRAHI, 2016) apresenta um estudo de esquema de proteção de distância em uma planta eólica que contém tanto o *Static VAR Compensator* (SVC) quanto o *Static Synchronous Compensator* (STATCOM), equipamentos que fazem parte do conceito de FACTS para controle de reativos e da tensão, simulando em um sistema elétrico de 500 [kV] na ferramenta Simulink do MATLAB integrado ao simulador em tempo real OPAL-RT eMEGASIM, com os modelos disponíveis do SVC, STATCOM e geradores eólicos. Nesses trabalhos os autores avaliaram o comportamento da proteção com a aplicação do SVC e STATCOM, analisando o seu desempenho para curtos-circuitos fase-terra e compararam os resultados.

Foram analisados o comportamento do esquema de proteção com relação às medições de impedância aparente e seu desempenho. Durante as análises do cálculo da impedância aparente com SVC e STATCOM, os autores perceberam que no caso do SVC aparece uma corrente de sequência zero quando aplicado um curto-circuito fase-terra, devido a contribuição do transformador de acoplamento cuja ligação é estrela solidamente aterrada no lado de 500 [kV].

Os autores propõem duas zonas de operação quadrilateral para as condições de instalação do SVC e STATCOM no terminal local e no meio da linha de transmissão. Essas zonas foram comparadas com zonas de operação de IEDs convencionais e os resultados obtidos indicam que as zonas de operação propostas para o esquema de proteção atuaram nos casos de curtos-circuitos a 25% e 75% da linha e com resistência de curto-circuito entre 15 [ $\Omega$ ] e 85 [ $\Omega$ ], enquanto que as outras zonas atuaram somente para curtos-circuitos a 25% da linha.

## 2.5 Estratégias de linearização do conjunto capacitor série/MOV

Existem algoritmos que utilizam modelos linearizados para determinar o comportamento do conjunto capacitor série e MOV durante sua operação em um sistema elétrico. Pretende-se, neste trabalho de pesquisa, contribuir nessa área com duas estratégias que podem ser utilizadas para linearizar o comportamento desse conjunto: com o uso de redes neurais artificiais (*Artificial Neural Network*) e por meio de linearização matemática.

### 2.5.1 Estratégia por Redes Neurais Artificiais (RNA)

Existem diversas estratégias para a implementação de redes neurais artificiais. Algumas são baseadas em prototipagem de alto nível, por meio de ferramentas como o MATLAB e outras pela implementação de soluções em linguagens de programação mais eficientes. Uma alternativa que implementa ambas as estratégias é a utilização de prototipagem combinada com linguagem de programação eficiente. Nessa linha pode-se utilizar o TensorFlow aliado à linguagem de programação *Python*.

TensorFlow é um *software* desenvolvido pela equipe da Google chamada *Google Brain Team* com o objetivo de realizar pesquisas com aprendizagem de máquina e redes neurais artificiais. Aprendizagem de máquinas, tradução do termo em inglês *Machine Learning*, é uma área da inteligência artificial e da ciência da computação onde são estudados sistemas e algoritmos que aprendem e criam novos conhecimentos a partir da análise de dados. Uma habilidade básica de técnicas de aprendizagem de máquinas é que o sistema consiga melhorar o seu desempenho por meio de reconhecimento de padrões do conjunto de dados analisados, que pode ser feito por aprendizagem supervisionada ou não-supervisionada (ZACCONE, 2016).

TensorFlow utiliza técnicas de otimização de álgebra computacional, facilitando o cálculo de expressões matemáticas quando é necessário processamento rápido pelo computador. O TensorFlow consegue otimizar e realizar cálculos matemáticos que envolvem vetores de múltiplas dimensões de forma eficiente, suporta programações de redes neurais e técnicas de aprendizagem de máquinas, uso da Unidade de Processamento Gráfico (*Graphic Process Unit* - GPU) com gerenciamento e otimização automática do uso da memória e dos dados e alta escalabilidade de processamento entre máquinas (ZACCONE, 2016).

As linguagens utilizadas para programação do TensorFlow são *Python* e C++, porém a linguagem *Python* tem um suporte melhor e é mais simples de se aprender. Além disso, *Python* é uma linguagem dinâmica onde não é necessário declarar as variáveis usadas, sensível a letras maiúsculas e minúsculas e orientada a objetos. O TensorFlow pode ser instalado em computadores com sistemas operacionais Windows da Microsoft, Linux e Mac Os da Apple ou pode ser executado por meio do Google Colab, abreviação de Google Colaboratory, plataforma de computação em nuvem acessada por navegador Web que utiliza linguagem de programação *Python* (ZACCONE, 2016; GOOGLE, 2020).

No TensorFlow os nós são as instâncias que realizam os cálculos e as arestas que interligam os nós constituem o conjunto de dados multidimensional desenvolvido e transmitido

pelos nós, também chamado de tensores. Essas arestas podem também representar uma dependência entre os nós, como por exemplo um nó executa o cálculo somente quando o nó anterior termina. A figura 34 mostra a representação da relação entre os nós e tensores no TensorFlow (ZACCONE, 2016).

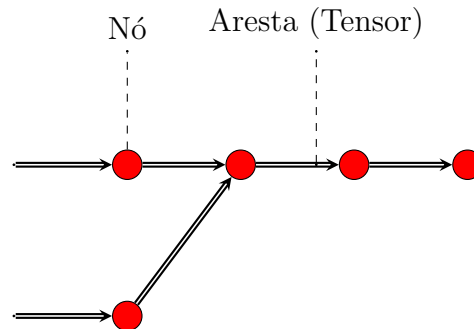


Figura 34: Representação da rede neural no TensorFlow

O TensorFlow possui algoritmos de aprendizagem de máquinas para realização de linearização matemática, como o algoritmo de regressão linear onde a relação entre uma variável dependente  $y$  e uma independente  $x$  possui comportamento linear. Esse algoritmo é bastante utilizado para diversas pesquisas em ciências aplicadas e é expressa pela seguinte equação (ZACCONE, 2016):

$$y = Ax + B \quad (2.37)$$

Outra forma de linearização matemática no TensorFlow é o uso de redes neurais artificiais. O TensorFlow pode trabalhar com o MLP, formado por várias camadas de perceptrons, com uma camada de entrada, uma de saída e uma ou mais camadas ocultas na rede neural conforme explicado na subseção 2.2.6. O MLP utiliza aprendizagem supervisionada para realizar o treinamento a partir do conjunto de dados disponibilizados pelos tensores, sendo o algoritmo de retropropagação de erros o mais utilizado para essa tarefa.

No algoritmo de retropropagação o valor de saída é comparado com o valor desejado para a resposta do tensor, modificando o peso da rede neural até a convergências da saída com o valor de resposta desejado. Para realizar a aproximação de uma determinada função  $f(x)$ , o TensorFlow trabalha em duas etapas: uma chamada de etapa de treinamento onde a rede neural aprende o comportamento da função por meio de um determinado conjunto de dados e a outra é a etapa de teste onde a função  $f(x)$  encontrada na etapa anterior é testada a partir dos valores de  $x$  extraídos dos tensores (ZACCONE, 2016).

## 2.5.2 Estratégia por Linearização Matemática

Diversas áreas da engenharia e de outras ciências descrevem o comportamento de sistemas físicos a partir de conjuntos discretos de valores, sem conhecimento prévio da função matemática que estabelece a resposta contínua desses sistemas. Isso é possível aplicando-se funções de aproximação  $z = g(x)$  com uso dos conjuntos de dados que descrevem o comportamento desses sistemas, desde que sejam respeitadas algumas premissas: a função deve ser simples, contínua em um intervalo onde  $x \in [a, b]$  e ser de fácil computação, além de derivável e integrável (VARGAS; ARAKI, 2017; PETERS; SZEREMETA, 2018).

Os tipos de funções de aproximação utilizados são (PETERS; SZEREMETA, 2018):

- Polinomial: função que possui operações elementares, cujo resultado das transformações algébricas sempre forma outro polinômio. Esta função pode ser derivada e integrada, e está expressa em

$$P_n(x) = g(x) = \sum_{p=1}^{n+1} a_p x^{p-1} \quad (2.38)$$

- Racional: função estabelecida pela razão entre os polinômios  $P_n(x)$  e  $Q_m(x)$ , cujos graus são  $n$  e  $m$ , respectivamente, e que permitem aproximações de funções assintóticas, como mostra a figura 35. Esta função está descrita em

$$g(x) = \frac{P_n(x)}{Q_m(x)} \quad (2.39)$$

- Trigonométrica: função que permite aproximação de sistemas com comportamento oscilatório, como demonstra a equação 2.40.

$$g(x) = \sum_{p=1}^m \{a_p \sin(px) + b_p \cos(px)\} \quad (2.40)$$

Nesse trabalho optou-se por utilizar a aproximação racional visto que testes preliminares e empíricos apresentaram melhores resultados e porque o comportamento do MOV é bastante assintótico. Por sua utilização simples e prática, a função polinomial é a mais aplicada para aproximação de funções e uma forma do uso de polinômios para essa aproximação é a técnica de aproximação por interpolação polinomial. Em uma interpolação polinomial, busca-se a aproximação com uso de um polinômio de grau  $n$  que passe por todos os pontos do conjunto de dados que descreve a resposta do sistema.




Figura 35: Gráfico de uma função assintótica  
Fonte: adaptado de Peters e Szeremeta (2018)

Para aplicar a aproximação por interpolação polinomial primeiro é utilizada a tabela com o conjunto de dados extraídos com  $n + 1$  pontos  $\{x_p, y_p = f(x_p)\}$  com  $p = 1, 2, 3, \dots, n + 1$  e  $x_p \in [x_1, x_{n+1}]$ . O segundo passo é utilizar um polinômio genérico de grau  $n$  como mostrado na equação 2.41 (PETERS; SZEREMETA, 2018).

$$P_n(x) = \sum_{p=1}^{n+1} a_p x^{p-1} \quad (2.41)$$

O terceiro passo é definir a condição de interpolação onde  $P_n(x_p) = y_p$  com  $p = 1, 2, 3, \dots, n + 1$ , garantindo que a interpolação polinomial passe por todos os pontos disponíveis na tabela, permitindo que o erro da aproximação seja nulo ou próximo de nulo. Aplicando a condição de interpolação na equação 2.41 resulta na seguinte equação (PETERS; SZEREMETA, 2018):

$$\begin{cases} P_n(x_1) = a_1 + a_2x_1 + a_3x_1^2 + \dots + a_{n+1}x_1^n = y_1 \\ P_n(x_2) = a_1 + a_2x_2 + a_3x_2^2 + \dots + a_{n+1}x_2^n = y_2 \\ \vdots \\ P_n(x_{n+1}) = a_1 + a_2x_{n+1} + a_3x_{n+1}^2 + \dots + a_{n+1}x_{n+1}^n = y_{n+1} \end{cases} \quad (2.42)$$

A equação 2.42 forma um sistema de  $n + 1$  equações lineares e  $n + 1$  incógnitas, que pode ser escrita na seguinte matriz:



$$\begin{bmatrix} 1 & x_1 & x_1^2 & \dots & x_1^n \\ 1 & x_2 & x_2^2 & \dots & x_2^n \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & x_{n+1} & x_{n+1}^2 & \dots & x_{n+1}^n \end{bmatrix} \times \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_{n+1} \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{n+1} \end{bmatrix} \quad (2.43)$$

O método de interpolação descrito acima é chamado de método de Vandermonde. Outro método utilizado é o método de Newton que pode ser descrito pelas seguintes equações (VARGAS; ARAKI, 2017):

$$P_n(x) = f(x_p) = \sum_{p=0}^n c_p s_p(x_p) \quad (2.44)$$

$$s_p(x) = \prod_{q=0}^{p-1} (x - x_q) \quad (2.45)$$

O método de Newton permite que os coeficientes do polinômio  $c_p$  sejam dependentes dos pontos do conjunto de dados  $(x_p, f(x_p))$ , que é demonstrada pela seguinte equação (VARGAS; ARAKI, 2017):

$$c_p = f[x_0, x_1, \dots, x_p] = \frac{f[x_1, x_2, \dots, x_p] - f[x_0, x_1, \dots, x_{p-1}]}{x_p - x_0}, \quad (0 \leq p \leq n) \quad (2.46)$$

Um terceiro método de interpolação é o método de Lagrange que utiliza os valores da ordenada do conjunto de dados  $y_p$  para determinar os coeficientes do polinômio, como mostrado na equação 2.47 (VARGAS; ARAKI, 2017):

$$P_n(x) = \sum_{p=0}^n y_p l_p(x) \quad (2.47)$$

$$l_p(x) = \prod_{\substack{q=0 \\ q \neq p}}^{p-1} \frac{x - x_q}{x_p - x_q}, \quad (0 \leq p \leq n) \quad (2.48)$$

Sendo  $l_p(x)$  polinômios que dependem dos valores de abscissa  $x_0, x_1, \dots, x_n$  do mesmo grau do polinômio  $P_n(x)$ . Quando é aproximada uma função por interpolação polinomial ocorre erro de truncamento para cada  $x \neq x_p$  que pode ser determinada pela seguinte equação (VARGAS; ARAKI, 2017; PETERS; SZEREMETA, 2018):

$$EP_n(x) = |P_n(x) - f(x)|, \forall x \in [x_1, x_{n+1}] \quad (2.49)$$

### 3 METODOLOGIA PROPOSTA

Este capítulo descreve o desenvolvimento dos algoritmos de proteção de distância para linhas de transmissão com compensação série propostos nesta dissertação para linearização do comportamento da compensação série durante ocorrências de curtos-circuitos na linha e a sua implementação em um IED de plataforma aberta.

#### 3.1 Diagrama de blocos dos algoritmos de proteção propostos

A figura 36 mostra o diagrama de blocos dos algoritmos de proteção propostos neste trabalho que contempla os algoritmos propostos e a estrutura de amostragem e digitalização dos sinais de tensões e correntes, bem como a estrutura de cálculo das impedâncias dos elementos de distância e a lógica de trip (disparo).

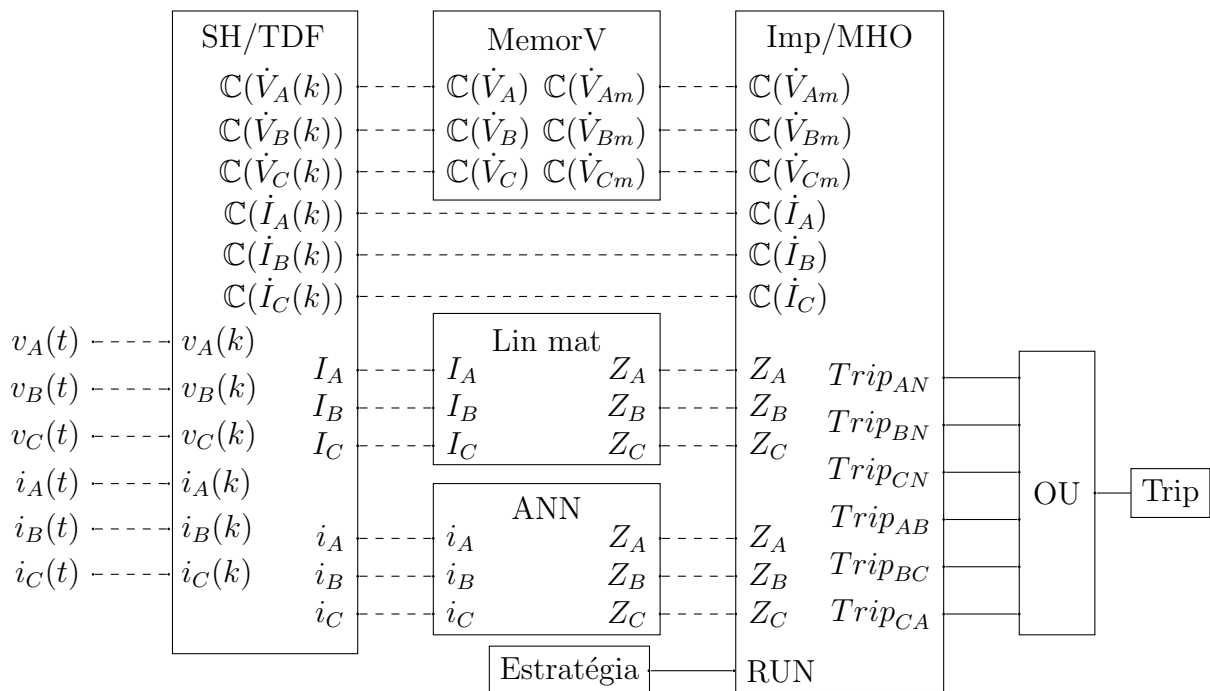


Figura 36: Diagrama de blocos dos algoritmos de proteção de distância propostos

As linhas tracejadas representam o envio de valores analógicos entre os blocos e as linhas contínuas representam envio de valores binários (0 e 1) entre os blocos. O primeiro bloco do diagrama é o bloco SH/TDF, que recebe os valores das tensões  $v_A(t)$ ,  $v_B(t)$  e  $v_C(t)$  e correntes  $i_A(t)$ ,  $i_B(t)$  e  $i_C(t)$  provenientes, respectivamente, dos TPs e TCs da linha, realiza a amostragem dos valores e aplica a transformada discreta de Fourier (TDF) para estimação dos fasores das tensões e correntes. A amostragem dos valores de tensão e corrente permite, com mecanismo de frequência de leitura dos valores trabalhando de forma rápida e precisa, a estimação dos fasores com uma boa filtragem (GE, 2015a). A utilização da TDF permite o uso dos valores das tensões e correntes amostrados uniformemente, transformado em fasores para o cálculo da impedância da linha (DINIZ; SILVA; NETTO, 2004; ZIEGLER, 2011). Os algoritmos utilizados pela amostragem e aplicação da TDF nos valores de tensões e correntes, além do cálculo da magnitude da corrente de cada fase, estão implementados no IED de plataforma aberta e foram utilizados em outras pesquisas do LPROT. O IED é descrito na seção 4.1.

O segundo bloco de memorização de fasores de tensões em uma fila circular de tamanho definido é o bloco MemorV, que realiza a memorização dos valores das tensões complexas  $\Re(\dot{V}_A)$ ,  $\Im(\dot{V}_A)$ ,  $\Re(\dot{V}_B)$ ,  $\Im(\dot{V}_B)$ ,  $\Re(\dot{V}_C)$  e  $\Im(\dot{V}_C)$  lidas de ciclos elétricos anteriores para utilização no cálculo dos elementos de impedância. Durante a ocorrência de um curto-circuito a tensão tende a diminuir, fazendo com que o algoritmo de proteção tenha problemas de seletividade e direcionalidade. Para solucionar estes problemas, é utilizada uma técnica onde é memorizada ciclicamente a tensão medida e quando a sua magnitude fica abaixo de um determinado valor, é disponibilizado o valor de tensão memorizado no ciclo anterior ao distúrbio, permitindo que o algoritmo consiga determinar se o curto-circuito ocorre a montante ou a jusante dos transformadores de instrumentação. Essa técnica é muito utilizada para linhas com compensação série devido a inversão de tensão (ZIEGLER, 2011; GE, 2015a). O algoritmo de memorização implementado permite armazenamento dos valores de tensões complexas de um ciclo elétrico anterior para cada fase e disponibiliza esses valores quando a magnitude da tensão de cada fase fica abaixo de 80%.

O terceiro bloco é o bloco Lin mat, que determina o comportamento da impedância do conjunto capacitor série/MOV durante a ocorrência do curto-circuito por meio da estratégia de linearização matemática. O algoritmo desse bloco utiliza a magnitude das correntes  $\dot{I}_A$ ,  $\dot{I}_B$  e  $\dot{I}_C$  para determinação das impedâncias  $\bar{Z}_A$ ,  $\bar{Z}_B$  e  $\bar{Z}_C$ , cada uma composta por uma componente resistiva e outra reativa conforme mostra a equação 3.1:

$$\bar{Z} = R + jX \quad (3.1)$$

sendo  $\bar{Z}$  a impedância elétrica,  $R$  a resistência elétrica e  $jX$  a reatância elétrica resultantes da linearização. Detalhes da linearização matemática serão mostrados na subseção 4.2.2. O quarto bloco é o ANN, que determina o comportamento da impedância do conjunto capacitor série/MOV durante a ocorrência do curto-circuito por meio da estratégia de redes neurais artificiais. O algoritmo utiliza os valores das correntes instantâneas  $i_A(k)$ ,  $i_B(k)$  e  $i_C(k)$  para determinação das impedâncias  $\bar{Z}_A$ ,  $\bar{Z}_B$  e  $\bar{Z}_C$ , cada uma composta por uma componente resistiva e outra reativa de acordo com a equação 3.1. Detalhes da rede neural estão mostrados na subseção 4.2.1.

O quinto bloco é o bloco Imp/MHO, que realiza o cálculo dos elementos de impedância fase terra AN, BN e CN e entre fases AB, BC e CA a partir dos valores das tensões memorizadas e correntes complexas disponibilizadas, respectivamente, pelos blocos MemorV e SH/TDF e dos valores das impedâncias  $\bar{Z}_A$ ,  $\bar{Z}_B$  e  $\bar{Z}_C$  disponibilizadas pelos blocos Lin mat e ANN, comparando seus valores com a curva característica MHO para cada elemento. Neste bloco também existe uma entrada binária chamada de “Estratégia” que serve para escolher a estratégia de linearização do conjunto capacitor série/MOV a ser usada para o cálculo dos elementos de impedância. Valor binário 1 é utilizada a estratégia de redes neurais artificiais e valor binário 0 é utilizada a estratégia de linearização matemática.

O bloco possui seis saídas binárias  $Trip_{AN}$ ,  $Trip_{BN}$ ,  $Trip_{CN}$ ,  $Trip_{AB}$ ,  $Trip_{BC}$  e  $Trip_{CA}$  e o valor binário varia conforme o valor calculado de cada elemento. Para valor binário 1 o elemento de impedância se encontra dentro da curva MHO e para valor binário 0 o elemento se encontra fora da curva MHO. Cada saída binária entra em uma porta lógica OU, resultando em uma única saída binária chamada Trip, usada para o comando de abertura do disjuntor do terminal da linha quando qualquer um dos elementos de impedância estiver dentro da curva característica MHO durante a ocorrência de um curto-circuito.

## 3.2 Algoritmos de proteção propostos

Os algoritmos de proteção de distância propostos, cujo número é o 21 conforme norma C37.2 da IEEE (2008), calculam a impedância utilizando valores de medição fasorial de tensão e corrente elétricas vindas dos transformadores potencial e de corrente da linha de transmissão. Os algoritmos descontam a impedância do conjunto capacitor série/MOV

da impedância calculada pelos valores medidos de acordo com a seguinte equação:

$$\bar{Z}_{linha} = \frac{\dot{V}_{TP}}{\dot{I}_{TC}} - \dot{Z}_{CP/MOV} \quad (3.2)$$

sendo  $\bar{Z}_{linha}$  a impedância complexa calculada da linha de transmissão,  $\dot{V}_{TP}$  a tensão elétrica fasorial medida pelo transformador potencial,  $\dot{I}_{TC}$  a corrente elétrica fasorial medida pelo transformador de corrente e  $\dot{Z}_{CP/MOV}$  a impedância fasorial do conjunto capacitor série/MOV. A impedância do conjunto CP/MOV é determinada por duas estratégias distintas: linearização matemática e uso de redes neurais artificiais (ANN).

O algoritmo calcula a impedância de sequência positiva para cada estratégia, porém é selecionado previamente qual estratégia será utilizada no cálculo. Definida a estratégia, são calculados seis elementos de impedância para determinar se o curto-circuito aplicado à linha de transmissão é entre fases ou entre fase e terra, utilizando a equação 3.1 como base. Dos seis elementos calculados, três são elementos de fase conforme demonstram as equações 3.3, 3.4 e 3.5 (ZIEGLER, 2011; HOROWITZ; PHADKE, 1992):

$$\bar{Z}_{AB} = \frac{\dot{V}_A - \dot{V}_B}{\dot{I}_A - \dot{I}_B} - (\dot{Z}_{CP/MOV-A} + \dot{Z}_{CP/MOV-B}) \quad (3.3)$$

$$\bar{Z}_{BC} = \frac{\dot{V}_B - \dot{V}_C}{\dot{I}_B - \dot{I}_C} - (\dot{Z}_{CP/MOV-B} + \dot{Z}_{CP/MOV-C}) \quad (3.4)$$

$$\bar{Z}_{CA} = \frac{\dot{V}_C - \dot{V}_A}{\dot{I}_C - \dot{I}_A} - (\dot{Z}_{CP/MOV-C} + \dot{Z}_{CP/MOV-A}) \quad (3.5)$$

sendo  $\bar{Z}_{AB}$  a impedância calculada entre as fases A e B,  $\bar{Z}_{BC}$  a impedância calculada entre as fases B e C,  $\bar{Z}_{CA}$  a impedância calculada entre as fases C e A,  $\dot{V}_A$  a tensão fasorial da fase A,  $\dot{V}_B$  a tensão fasorial da fase B,  $\dot{V}_C$  a tensão fasorial da fase C,  $\dot{I}_A$  a corrente fasorial da fase A,  $\dot{I}_B$  a corrente fasorial da fase B,  $\dot{I}_C$  a corrente fasorial da fase C,  $\dot{Z}_{CP/MOV-A}$  a impedância do conjunto capacitor série/MOV da fase A,  $\dot{Z}_{CP/MOV-B}$  a impedância do conjunto capacitor série/MOV da fase B e  $\dot{Z}_{CP/MOV-C}$  a impedância do conjunto capacitor série/MOV da fase C. Os outros três elementos calculados são entre fase e terra, porém é considerada a corrente de sequência zero gerada neste tipo de curto-circuito junto com fator de compensação de sequência zero conforme demonstra as equações 3.6, 3.7 e 3.8 (ZIEGLER, 2011; HOROWITZ; PHADKE, 1992):

$$\bar{Z}_{AN} = \frac{\dot{V}_A}{\dot{I}_A - K_0 \cdot \dot{I}_0} - \dot{Z}_{CP/MOV-A} \quad (3.6)$$

$$\bar{Z}_{BN} = \frac{\dot{V}_B}{\dot{I}_B - K_0 \cdot \dot{I}_0} - \dot{Z}_{CP/MOV-B} \quad (3.7)$$

$$\bar{Z}_{CN} = \frac{\dot{V}_C}{\dot{I}_C - K_0 \cdot \dot{I}_0} - \dot{Z}_{CP/MOV-C} \quad (3.8)$$

sendo  $\bar{Z}_{AN}$  a impedância entre fase A e terra,  $\bar{Z}_{BN}$  a impedância entre fase B e terra,  $\bar{Z}_{CN}$  a impedância entre fase C e terra,  $\dot{V}_A$  a tensão fasorial da fase A,  $\dot{I}_0$  a corrente fasorial de sequência zero e  $K_0$  o fator de compensação de sequência zero.

O fator de compensação de sequência zero  $K_0$  é calculado conforme a seguinte equação:

$$K_0 = \frac{\bar{z}_0 - \bar{z}_1}{\bar{z}_1} \quad (3.9)$$

sendo  $\bar{z}_0$  a impedância de sequência zero da linha de transmissão e  $\bar{z}_1$  a impedância de sequência positiva da linha de transmissão. Definidos os valores dos seis elementos de impedância, o resultado é analisado e comparado no diagrama de impedâncias R-X com zonas de operação pré-definidas em função da porcentagem da impedância da linha de transmissão. O algoritmo define quatro zonas de operação utilizando a curva característica MHO: zona 1, zona 2, zona 3 e zona reversa.

As zonas são definidas em função da porcentagem da impedância da linha de transmissão, sendo que as zonas 1, 2 e 3 observam a jusante dos transformadores de instrumentação e a zona reversa observa a montante dos transformadores de instrumentação. A comparação dos valores calculados de cada elemento de impedância na curva MHO para determinar se o elemento se encontra dentro ou fora da zona de proteção pré-definida procura seguir o que é utilizado pelos fabricantes de dispositivos de proteção, cuja eficácia é demonstrada no capítulo 5 (ZIEGLER, 2011; GE, 2015a).

### 3.3 Fluxograma dos algoritmos de proteção propostos

A figura abaixo mostra o fluxograma dos algoritmos propostos neste trabalho para proteção de distância em linhas de transmissão com compensação série.

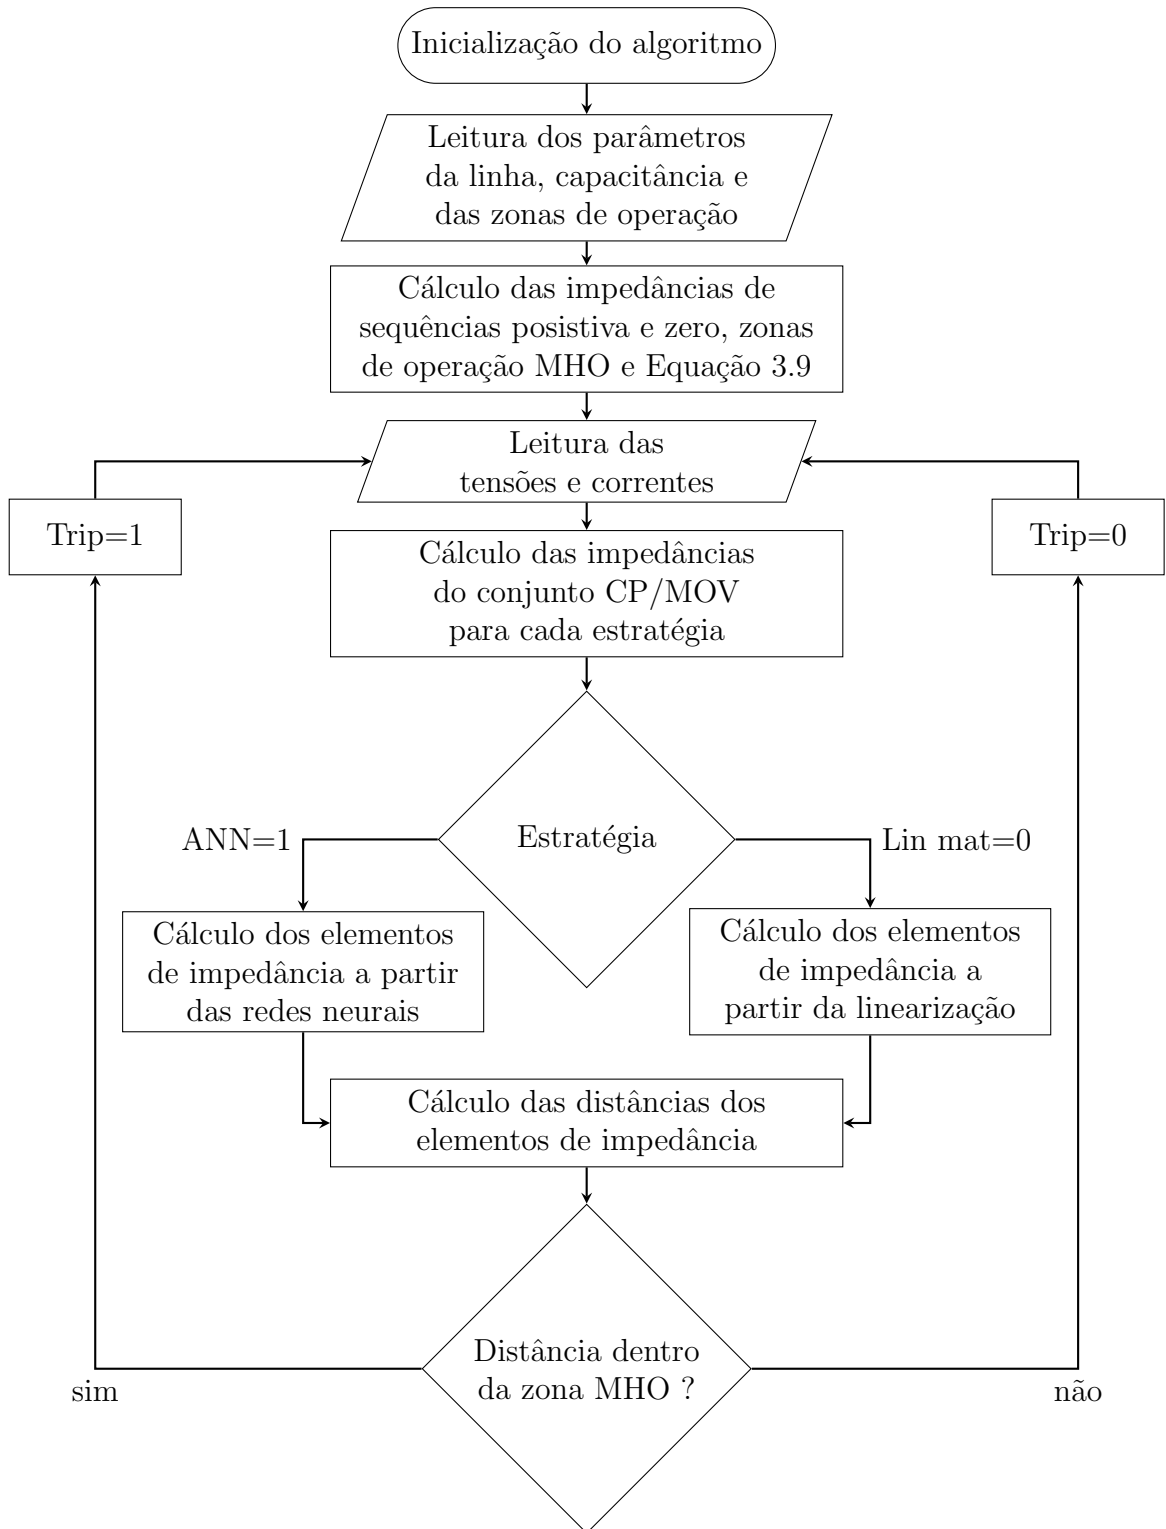


Figura 37: Fluxograma dos algoritmos de proteção de distância propostos



## 4 DESENVOLVIMENTO E TESTES

### 4.1 Implementação do algoritmo no IED

O algoritmo foi implementado em IED de plataforma aberta para proteção de sistemas elétricos desenvolvido no LPROT, como mostra a figura 38. O IED é composto por um *hardware* com Unidade de Processamento Central (CPU) em arquitetura de computador x86, memória RAM e FLASH baseado em disco de estado sólido (SSD), interface de entradas e saídas digitais e analógicas denominada *Acquisition and Control Unit (ACU)* e interface de comunicação. O *software* é composto por um sistema operacional de tempo real com base em Linux e Xenomai na CPU e na ACU é embarcado no *System-on-a-Chip (SoC)* de arquitetura de 32 bits ARM9 integrado ao processador de sinais digitais (DSP) ADSP-21262 (PELLINI et al., 2013; PELLINI, 2010).



Figura 38: IED de plataforma aberta utilizado

O IED também possui um arcabouço de *software*, ou *framework* em inglês, denominado LPROTFRAME. Este arcabouço permite desenvolver as funcionalidades de controle e proteção requisitadas em Sistemas Elétricos de Potência com uma interface de alto nível com comprometimento de execução das tarefas em tempo real. O LPROTFRAME

também executa as funções de comunicação com o uso do protocolo de comunicação IEC 61850, provê pacotes *GOOSE* e *Sampled Values* customizados em 64 amostras em um ciclo de 60 [Hz]. O arcabouço contém uma biblioteca de blocos funcionais à disposição do usuário, um pré-processador para ler e estruturar o código-fonte quando é adicionado ou extraído algum elemento da programação, compilador que permite que a metalinguagem de alto nível do usuário seja convertida em uma linguagem de baixo nível para interpretação da plataforma computacional do IED e o interpretador que inclui as rotinas de inicialização, execução e finalização de cada bloco da biblioteca (PELLINI et al., 2013; PELLINI, 2010).

Antes da implementação do algoritmo no IED, foi realizada a prototipagem do mesmo no programa Matlab e testado a partir dos arquivos COMTRADE (*Common Format for Transient Data Exchange*) gerados no RTDS com todos os casos de curtos-circuitos do sistema elétrico selecionado para os ensaios do algoritmo (IEEE, 1999, 1991). Após a prototipagem do algoritmo e a constatação de seu funcionamento, o algoritmo foi implementado no IED através de linguagem de programação C, linguagem de alto nível amplamente utilizada em diversas aplicações de automação e programação.

## 4.2 Linearização do conjunto capacitor série/MOV

Nesta seção é apresentada a implementação das estratégias de linearização do conjunto capacitor série/MOV para os dois algoritmos de proteção de distância desenvolvidos nesta dissertação, um com uso de redes neurais artificiais e o outro com técnicas matemáticas de linearização.

### 4.2.1 Redes Neurais Artificiais

Na estratégia de redes neurais, é utilizado o simulador digital de tempo real RTDS com o modelo disponível do conjunto capacitor série/MOV. Mesmo não sendo um equipamento real, esse modelo tem comportamento próximo ao real quando submetido em regime de operação normal ou quando submetido a um distúrbio elétrico. A equação do comportamento do MOV é regido pela seguinte equação:

$$I_{pk} = \left( \frac{V_{pk}}{k} \right)^\alpha \quad (4.1)$$

sendo  $I_{pk}$  a corrente de pico que atravessa o MOV,  $V_{pk}$  a tensão de pico aplicada ao

conjunto capacitor série/MOV,  $k$  é uma constante definida pela relação entre a tensão de corte aplicada ao conjunto e a corrente de pico máximo de curto-circuito e  $\alpha$  é um coeficiente que pode variar entre 30 e 50 (MANASSERO; SANTO; ROJAS, 2016).

O conjunto é submetido a valores de tensão igualmente espaçados dentro de um intervalo e a cada aumento de tensão é lido e registrado o seu valor de corrente de linha do conjunto. Desse conjunto foram extraídas 4000 amostras de tensão e corrente, onde 2000 amostras foram utilizadas para o treinamento da rede neural e 2000 amostras para a validação. Foi utilizada a plataforma Google Colab para executar e montar a rede neural no TensorFlow devido a facilidade de não precisar instalar em um computador local e utilizar recursos computacionais em nuvem para executar a RNA. A linguagem de programação utilizada foi *Python*.

A arquitetura da rede neural utilizada é a de *perceptron* de múltiplas camadas e possui cinco camadas: uma de entrada, três camadas ocultas e uma de saída. As camadas ocultas possuem cinco neurônios cada, a entrada possui cinco variáveis e a saída possui duas variáveis resultantes. A função de ativação utilizada nos neurônios é a função tangente hiperbólica ( $\tanh$ ). Esses três parâmetros da rede são denominados de parâmetros de inicialização ou *set-up* da RNA.

Para o treinamento da rede neural foram definidos mais três parâmetros, sendo um deles o número de épocas em 10.000. Também conhecido como *epochs*, é o número de iterações que os dados da amostra passam pela rede neural até a sua convergência. O segundo parâmetro é o método de otimização usado na aprendizagem da rede, sendo utilizado o método Adam que é um método de gradiente descendente estocástico que utiliza estimativas adaptativas de primeira e segunda ordens. O terceiro parâmetro é a taxa de aprendizagem em 0,1, que é a velocidade que a rede neural realiza a convergência a partir dos dados da amostra (TENSORFLOW, 2022; SETTI, 2018).

A figura 39 ilustra a topologia da rede neural implementada no TensorFlow para o método de redes neurais artificiais visualizada com o uso do comando *tf.keras.utils.plot\_model*. A camada k0 é a camada de entrada, a camada k4 é a camada de saída e as camadas k1, k2 e k3 são as camadas ocultas. Os neurônios são representados pelo círculo em vermelho totalizando 15 neurônios para a rede neural implementada.

O cálculo do erro médio quadrático é feito pelos valores obtidos pela rede neural e pela Transformada Discreta de Fourier das partes reais e imaginárias dos valores das amostras obtidas. O resultado obtido a partir desse cálculo resulta em uma rede neural com 5 camadas que requer 5/64 de ciclo para estimar a impedância equivalente do conjunto e




Figura 39: Topologia da rede neural implementada no TensorFlow

equações com as seguintes matrizes:

$$\bar{Z}_A = w1. \begin{bmatrix} i_A(k) \\ i_A(k+1) \\ i_A(k+2) \\ i_A(k+3) \\ i_A(k+4) \end{bmatrix} + b1 \quad (4.2)$$

$$\bar{Z}_B = w1. \begin{bmatrix} i_B(k) \\ i_B(k+1) \\ i_B(k+2) \\ i_B(k+3) \\ i_B(k+4) \end{bmatrix} + b1 \quad (4.3)$$

$$\bar{Z}_C = w1. \begin{bmatrix} i_C(k) \\ i_C(k+1) \\ i_C(k+2) \\ i_C(k+3) \\ i_C(k+4) \end{bmatrix} + b1 \quad (4.4)$$

sendo  $\bar{Z}_A$  a matriz da impedância equivalente da fase A,  $\bar{Z}_B$  a matriz da impedância equivalente da fase B,  $\bar{Z}_C$  a matriz da impedância equivalente da fase C,  $i_A$  a corrente instantânea da fase A,  $i_B$  a corrente instantânea da fase B,  $i_C$  a corrente instantânea da fase C,  $w1$  a matriz de pesos da função de ativação e  $b1$  a matriz de *bias* da função de

ativação. As matrizes  $\bar{Z}_A$ ,  $\bar{Z}_B$  e  $\bar{Z}_C$  possuem tamanho 5x2 e as matrizes  $w1$  e  $b1$  possuem os seguintes valores:

$$w1 = \begin{bmatrix} -0.24512377 & -0.3002073 \\ 1.0033128 & -0.07756497 \\ -0.58760655 & 0.24774301 \\ -0.8456208 & 0.91254634 \\ 0.6836971 & -0.79953593 \end{bmatrix} \quad (4.5)$$

$$b1 = \begin{bmatrix} 1.8638087e - 03 & -1.0794264e + 01 \end{bmatrix} \quad (4.6)$$

#### 4.2.1.1 Programação do TensorFlow em linguagem *Python*

A figura 40 mostra a programação feita no TensorFlow a partir do Google Colab em linguagem *Python*. O número entre colchetes representa uma subseção, ou célula, do programa permitindo a execução de cada célula de forma separada. Na célula [1] é feita a instalação do TensorFlow, na célula [2] é feita a importação do TensorFlow e das bibliotecas utilizadas para a montagem e execução da rede, dando destaque ao Keras, utilizado para construir e treinar a rede a partir dos dados, *numpy* que permite trabalhar com matrizes multidimensionais e *pandas* que permite a leitura e o carregamento de dados a partir de um arquivo externo (TENSORFLOW, 2022).

Na célula [3] é feita a entrada dos dados de corrente e impedância extraídos do RTDS em dois conjuntos de arquivos com extensão CSV: um para o treinamento da rede (*train*) e outro para a validação (*test*) a partir da linha de comando *pd.read*. As correntes e impedâncias são separadas em variáveis distintas. Na célula [4] é feita a montagem da RNA a partir das linhas de comando *keras.Sequential()* e *keras.layers.Dense*, a compilação da rede pela linha de comando *model.compile* e a execução da aproximação e validação a partir do comando *model.fit*. Nesta célula são também apresentados os valores de peso e *bias* usados na camada de saída através das linhas de comando *model.layers.weights* e *model.layers.bias*. O código implementado no TensorFlow está disponível no Anexo A.

A figura 41 mostra a topologia da rede neural implementada no TensorFlow extraída por meio do comando *tf.keras.utils.plot\_model*.

```

# Instalação do pacote TensorFlow no notebook do Colab
!pip install -q tfds-nightly tensorflow matplotlib

[ ] # Cabeçalho e instalação de bibliotecas
from __future__ import absolute_import, division, print_function, unicode_literals
import numpy as np
import tensorflow as tf
from tensorflow import keras
import tensorflow_datasets as tfds
import pandas as pd

[ ] # Tratamento dos dados de treinamento e validação da rede neural
train_file_path = pd.read_csv(r'/content/drive/MyDrive/Colab Notebooks/Dados_train.csv')
test_file_path = pd.read_csv(r'/content/drive/MyDrive/Colab Notebooks/Dados_test.csv')
i_train = np.array([train_file_path.i, train_file_path.i1, train_file_path.i2, train_file_path.i3, train_file_path.i4])
i_train = np.transpose(i_train)
Z_train = np.array([train_file_path.Z])
Z_train = np.transpose(Z_train)
i_test = np.array([test_file_path.i, test_file_path.i1, test_file_path.i2, test_file_path.i3, test_file_path.i4])
i_test = np.transpose(i_test)
Z_test = np.array([test_file_path.Z])
Z_test = np.transpose(Z_test)

[ ] # Montagem e execução da rede neural
epochs = 10000
activation_function = 'tanh'

model = keras.Sequential()
model.add(keras.layers.Dense(5, activation=activation_function, input_shape=(5,)))
model.add(keras.layers.Dense(5, activation=activation_function))
model.add(keras.layers.Dense(2, activation=activation_function))
model.compile(optimizer=tf.keras.optimizers.Adam(learning_rate=0.1), loss='mse', metrics=['mse'])
result = model.fit(i_train, Z_train, epochs=epochs, validation_data = (i_test, Z_test))
model.summary()
print(model.layers[2].weights)
print(model.layers[2].bias)
result.epoch
result.history['mse'][-1]
#Visualização da topologia da rede neural
tf.keras.utils.plot_model(model, to_file='model.png', show_shapes=True, show_layer_names=True)

```

Figura 40: Programação da rede neural

Fonte: própria

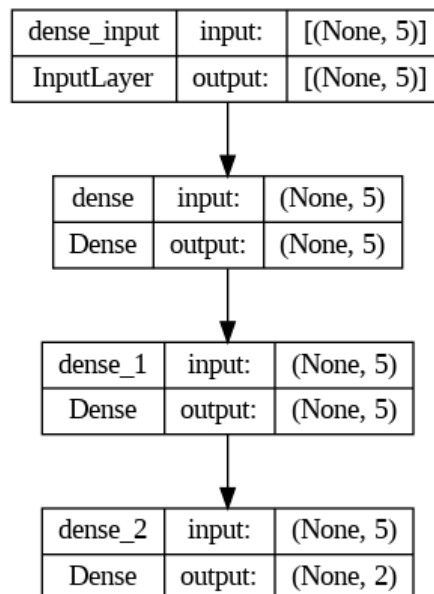


Figura 41: Topologia da rede neural extraída da programação

Fonte: própria

## 4.2.2 Linearização matemática

Assim como na estratégia de redes, o RTDS também é utilizado para simular o modelo do conjunto aumentando o valor de tensão fasorial, lendo e registrando o valor correspon-

dente de corrente de linha fasorial. Com os valores de tensão e corrente fasoriais registrados, é possível calcular os valores de impedância equivalente a cada iteração e com isso determinar a resistência e reatância do conjunto. Nesse conjunto, os valores são organizados em função da corrente de linha  $I$  em [pu], cuja corrente de base utilizada é a corrente máxima de curto-circuito do sistema. Esses dados são inseridos no programa Wolfram Mathematica que possui a capacidade de realizar regressão linear até obter uma equação polinomial e/ou exponencial que corresponda com o menor erro possível de acordo com os dados inseridos.

As equações polinomiais obtidas para, respectivamente, resistência e reatância a partir da regressão linear são as seguintes:

$$R = \frac{aI^9 + bI^8 + cI^7 + dI^6 + eI^5 + fI^4 + gI^3 + hI^2 + iI + j}{kI^{10} + lI^9 + mI^8 + nI^7 + oI^6 + pI^5 + qI^4 + rI^3 + sI^2 + tI + u} \quad (4.7)$$

$$X = \frac{aI^8 + bI^7 + cI^6 + dI^5 + eI^4 + fI^3 + gI^2 + hI + i}{jI^9 + kI^8 + lI^7 + mI^6 + nI^5 + oI^4 + pI^3 + qI^2 + rI + s} \quad (4.8)$$

As tabelas 1, 2, 3, 4 apresentam os coeficientes para as equações polinomiais obtidas pela regressão linear do Wolfram Mathematica e as figuras 42 e 43 mostram, respectivamente, um gráfico comparando os valores obtidos de resistência e reatância do conjunto capacitor série/MOV em função da corrente de linha obtidas no Wolfram Mathematica para cada fase.

Tabela 1: Coeficientes da equação 4.7 para fase A

a	-1.24547	b	26.9558	c	-97.7463	d	143.118	e	-59.4445	f	-8.03742
g	12.5063	h	-3.62704	i	0.446971	j	-0.0203784	k	1	l	70.9836
m	-248.284	n	344.845	o	-105.149	p	-66.8743	q	76.4835	r	-39.5008
s	-248.284	t	344.845	u	-105.149						

Tabela 2: Coeficientes da equação 4.7 para fase B

a	-3.02584	b	45.0577	c	-133.566	d	158.115	e	-23.5671	f	-50.0805
g	31.3221	h	-7.83893	i	0.916477	j	-0.0410523	k	1	l	111.658
m	-310.408	n	313.028	o	86.3218	p	-269.418	q	193.938	r	-85.2858
s	24.50227	t	-4.06502	u	0.288382						

Analisando os dois gráficos e comparando com os valores dos coeficientes obtidos nas tabelas 1, 2, 3, 4, 5 e 6 é possível observar que, mesmo o Wolfram Mathematica estabelecendo valores diferentes para cada fase da resistência e reatância do conjunto capacitor série/MOV, o comportamento dos mesmos estão muito próximas para as três

Tabela 3: Coeficientes da equação 4.7 para fase C

a	-1.36454	b	47.3632	c	-189.212	d	307.352	e	-165.947	f	18.6982
g	12.4233	h	-4.83203	i	0.658066	j	-0.0317904	k	1	l	130.798
m	-507.106	n	809.521	o	-429.404	p	57.9874	q	43.7984	r	-34.9492
s	13.1801	t	-2.58542	u	0.204995						

Tabela 4: Coeficientes da equação 4.8 para fase A

a	12.7339	b	-34.189	c	27.3741	d	-6.44141	e	97.4387	f	-111.02
g	48.818	h	-9.79064	i	0.755939	j	300.771	k	-1164.58	l	1566.91
m	-176.897	n	-794.655	o	683.482	p	-301.453	q	81.5607	r	-12.6944
s	0.860445										

Tabela 5: Coeficientes da equação 4.8 para fase B

a	0	b	2.18575	c	-6.92449	d	-0.164535	e	23.6378	f	-24.2866
g	10.1008	h	-1.95489	i	0.146907	j	0	k	57.1803	l	-302.093
m	614.669	n	-571.583	o	305.905	p	-105.188	q	23.6388	r	-3.18612
s	0.194037										

Tabela 6: Coeficientes da equação 4.8 para fase C

a	0	b	0.779923	c	-2.4203	d	0.140584	e	7.42162	f	-7.68373
g	3.19851	h	-0.618963	i	0.0465093	j	0	k	20.1988	l	-103.701
m	207.011	n	-191.234	o	101.938	p	-34.8567	q	7.7700	r	-1.03775
s	0.062684										




Figura 42: Comparação dos valores de resistência do conjunto CP/MOV

fases, resultando em um erro mínimo entre elas, tanto na resistência calculada quanto na reatância calculada do conjunto.






Figura 43: Comparação dos valores de reatância do conjunto CP/MOV

### 4.3 Cenário de simulação

Para os testes foi utilizado um sistema elétrico com três linhas de transmissão de 500 [kV], sendo a do meio com arranjo de compensação série fixa nos dois terminais da linha, com dois geradores equivalentes de Thevenin nas extremidades, conforme mostra a figura 44 e dados do sistema elétrico na tabela 7. O comprimento das linhas também é demonstrado na figura 44.




Figura 44: Sistema elétrico proposto para testes

Fonte: Própria

Tabela 7: Dados do sistema elétrico proposto

Dados dos Thevenins Equivalentes	$\dot{V}_{thL}$	$\dot{V}_{thR}$
Potência de curto-circuito trifásica	20,834∠87,57° [GVA]	23,254∠87,57° [GVA]
Potência de curto-circuito monofásica	20,403∠86,43° [GVA]	17,363∠84,07° [GVA]
Tensão	500∠0° [kV]	525∠20° [kV]

A capacitância de cada banco de capacitores série é de 245,46 [ $\mu$ F] e a curva do comportamento do MOV é regida conforme a equação 4.1. O modelo de torre da linha de transmissão utilizado na simulação é o de torre estaiada com quatro cabos condutores por fase e dois cabos guarda conforme ilustra a figura 45, cujas distâncias e alturas dos




Figura 45: Modelo da torre para o sistema elétrico proposto  
 Fonte: Adaptado de Teixeira (2001)

cabos estão definidos na tabela 8 (TEIXEIRA, 2001). Para o cabo condutor é utilizado o tipo *Grosbeak* e para o cabo guarda é utilizado o tipo *Alumoweld*, ambos os cabos são feitos de alumínio com alma de aço (NEXANS, 2020; AFL, 2003).

Tabela 8: Dados da torre utilizada no sistema elétrico proposto

Sigla	Definição	Dimensão [m]
DCG	Distância entre os cabos guarda	15,00
DCC	Distância entre fases	11,90
ACG	Altura do cabo guarda [kV]	33,00
ACCG	Altura da flexa da catenária do cabo guarda	23,44
ACC	Altura do cabos condutores	24,00
ACCC	Altura da flexa da catenária dos cabos condutores	13,38
LFP	Largura da faixa de passagem	50,00

O grau de compensação aplicado ao sistema é de 25% dividido em cada terminal da linha LT2. O sistema é implementado no RTDS e integrado ao IED para os testes utilizando técnicas *hardware-in-the-loop* conforme mostra a figura 46. Os transformadores de instrumentação implementados no RTDS produzem sinais de tensão e corrente que são exportados aos amplificadores OMICRON e transformados em sinais típicos de secundários desses equipamentos. O RTDS envia sinais elétricos de 10 [V] para as malas amplificadoras, que convertem em sinais elétricos de 1 [A] e 115 [V] para ser enviado ao IED. O estado dos disjuntores dos terminais da linha LT2 é enviado via mensagem GOOSE do protocolo de comunicação IEC 61850 e o sinal de abertura dos disjuntores é feito por sinal elétrico de 5 [V].




Figura 46: Esquema de teste *hardware-in-the-loop* com RTDS

Fonte: Própria

O algoritmo é implementado nos IEDs permitindo cobrir 100% da LT2. Para garantir que a abertura dos disjuntores ocorresse somente para curtos-circuitos na LT2, é utilizado um esquema de teleproteção onde a abertura do disjuntor, tanto do terminal local quanto do remoto, ocorre somente com recebimento dos sinais de abertura dos IEDs (IED1 e IED2). A teleproteção é implementada no RTDS, ficando os IEDs responsáveis somente pelo envio do sinal de abertura de seus respectivos disjuntores.

O RTDS aplica quatro tipos de curtos-circuitos para o teste do algoritmo de proteção: fase-terra, dupla-fase, dupla-fase-terra e trifásico. O curto-circuito fase-terra foi realizado com a fase A e terra (AN), o curto-circuito dupla-fase foi realizado com as fases B e C (BC), que também foi utilizada para curto-circuito entre dupla-fase-terra (BCN) e o trifásico com as fases A, B e C. A impedância dos curtos-circuitos e ângulos de incidência são detalhados na tabela 9.

Tabela 9: Cenários da simulação no RTDS

Fases envolvidas	Distância (%)	Resistência de falta ( $R_F$ )	Ângulo de incidência ( $\circ$ )
AN	20 a 90 em	0	0°
BC	passos de 10	1	45°
BCN	4 faltas antes LT2	2	90°
ABC	4 faltas depois LT2	5	

## 5 RESULTADOS E DISCUSSÕES

Neste capítulo são demonstrados os resultados dos algoritmos de proteção implementados no IED para proteção da linha de transmissão com compensação série simulada pelo RTDS.

### 5.1 Análise quantitativa

Durante os testes foram executados 768 cenários de simulação com os tipos de curto-circuitos e impedâncias descritos na seção 4.3 para cada algoritmo de proteção proposto. Destes 768 cenários, 432 foram executados dentro da zona 1 da LT2 conforme mostrado na tabela 9. As tabelas 10 e 11 mostram o total de cenários simulados, o total de cenários simulados dentro da zona 1, o total de cenários onde houve atuação da proteção, o total onde não houve atuação da proteção e o percentual de falhas de atuação da proteção para os dois algoritmos de proteção de distância propostos neste trabalho.

Tabela 10: Total de cenários simulados pelo RTDS algoritmo com uso de RNA

Total de cenários	Total de cenários zona 1	Total de operações zona 1	Total de falhas de operação zona 1	Percentual de falhas de operação (%)
768	432	432	0	0,0

Tabela 11: Total de cenários simulados pelo RTDS algoritmo com linearização matemática

Total de cenários	Total de cenários zona 1	Total de operações zona 1	Total de falhas de operação zona 1	Percentual de falhas de operação (%)
768	432	432	0	0,0

Nos cenários executados também são calculados os tempos médios de resposta da proteção de distância para as duas estratégias de linearização: redes neurais e linearização matemática. O tempo de atuação da proteção é considerado do instante de detecção da primeira amostra da impedância calculada pelo IED na zona 1 até a abertura dos disjuntores dos terminais da LT2, isolando o curto-circuito conforme sistema elétrico e

cenários de simulação mostrados na subseção 4.3. O tempo médio  $\overline{t_m}$  é calculado a partir da seguinte equação (ARA; MUSETTI; SCHNEIDERMAN, 2003):

$$\overline{t_m} = \frac{\sum_{i=1}^n t_i}{n} \quad (5.1)$$

Sendo  $t_i$  o tempo de operação da proteção para cada curto-circuito e  $n$  o número de operações em zona 1 executado pelo IED. Além do tempo médio, é calculado também o desvio padrão dos tempos  $s$  de atuação da proteção a partir da seguinte equação (ARA; MUSETTI; SCHNEIDERMAN, 2003):

$$s = \sqrt{\frac{\sum_{i=1}^n (t_i - \overline{t_m})^2}{n - 1}} \quad (5.2)$$

Nas tabelas 12 e 13 é mostrado o tempo médio, o desvio padrão, o menor tempo e o maior tempo de atuação da proteção, também conhecido como tempo de *trip*, para o de linearização por redes neurais e linearização matemática, respectivamente.

Tabela 12: Tempo de atuação da proteção de distância RNA

Tipo de curto-circuito	Tempo médio (ms)	Desvio padrão (ms)	Tempo mínimo (ms)	Tempo máximo (ms)
AN	15,41	1,63	12,35	19,80
BC	15,77	1,87	11,25	20,15
BCN	13,87	0,90	11,25	16,20
ABC	14,67	1,42	11,60	18,65

Tabela 13: Tempo de atuação da proteção de distância linearização matemática

Tipo de curto-circuito	Tempo médio (ms)	Desvio padrão (ms)	Tempo mínimo (ms)	Tempo máximo (ms)
AN	15,19	1,74	11,25	20,00
BC	15,80	1,92	11,65	19,60
BCN	13,83	0,96	11,40	15,75
ABC	14,61	1,40	11,80	18,65

O método calcula impedâncias e tem valor médio de *trip* inferior a um ciclo elétrico, embora use TDF de um ciclo, mostrando que é um método rápido e o desvio padrão resultante é pequeno, o que resulta em um método robusto. Além disso, não houve *trip* para curto-circuito externo, mostrando que é um método seguro e não houve falha de operação para curto-circuito interno, resultando em um método confiável.

## 5.2 Análise qualitativa

Na análise qualitativa do algoritmo é mostrado o comportamento da proteção de distância com aplicação de curtos-circuitos fase-terra (AN), dupla-fase (BC), dupla-fase-terra (BCN) e trifásico (ABC). A impedância de aplicação dos curtos-circuitos mostrados é de 5  $[\Omega]$  com ângulo de incidência de  $0^\circ$ , aplicados a uma distância de 80% do terminal local da linha LT2.

No final de cada subseção são apresentadas três tabelas para cada curto-circuito com instante de aplicação do curto-circuito, impedância de sequência positiva ( $Z_1$ ) antes do defeito, impedância de sequência positiva ( $Z_1$ ) calculada no instante de abertura dos disjuntores da LT2 dos três elementos fase-terra para curto-circuito AN e fase-fase para os demais curtos-circuitos. Além disso, é apresentado o tempo de *trip* do algoritmo de proteção.

### 5.2.1 Algoritmo de linearização por Redes Neurais Artificiais

A figura 47 mostra o gráfico de impedâncias R-X apresentando o caminho da impedância calculada pelo IED do momento pré-falta até a abertura dos disjuntores local e remoto da LT2 com impedância de 5  $[\Omega]$  e ângulo de incidência de  $0^\circ$  em um curto-circuito AN.

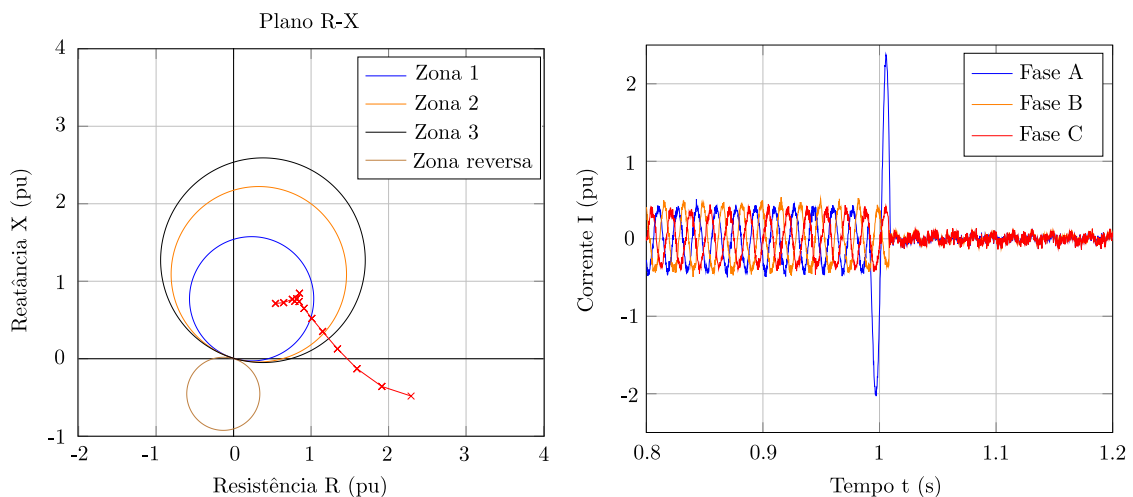


Figura 47: Plano R-X e Oscilografia das correntes para curto-circuito AN - redes neurais

A figura 48 ilustra o gráfico de impedâncias R-X exibindo o caminho da impedância calculada pelo IED do momento pré-falta até a abertura dos disjuntores local e remoto da LT2 com impedância de 5  $[\Omega]$  e ângulo de incidência de  $0^\circ$  em um curto-circuito BC.

A figura 49 mostra o gráfico de impedâncias R-X indicando o caminho da impedância

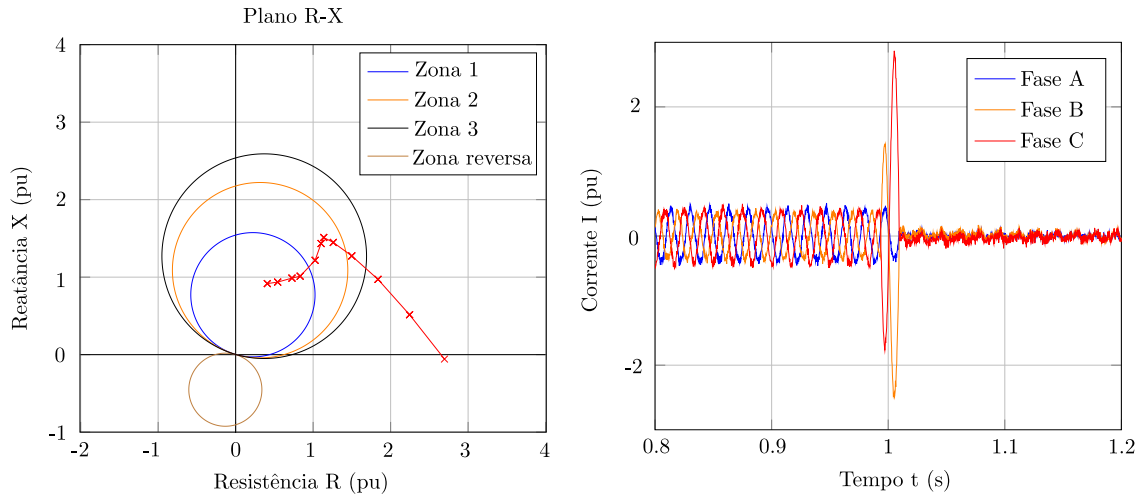


Figura 48: Plano R-X e Oscilografia das correntes para curto-circuito BC - redes neurais

calculada pelo IED do momento pré-falta até a abertura dos disjuntores local e remoto da LT2 com impedância de  $5 [\Omega]$  e ângulo de incidência de  $0^\circ$  em um curto-circuito ABC.

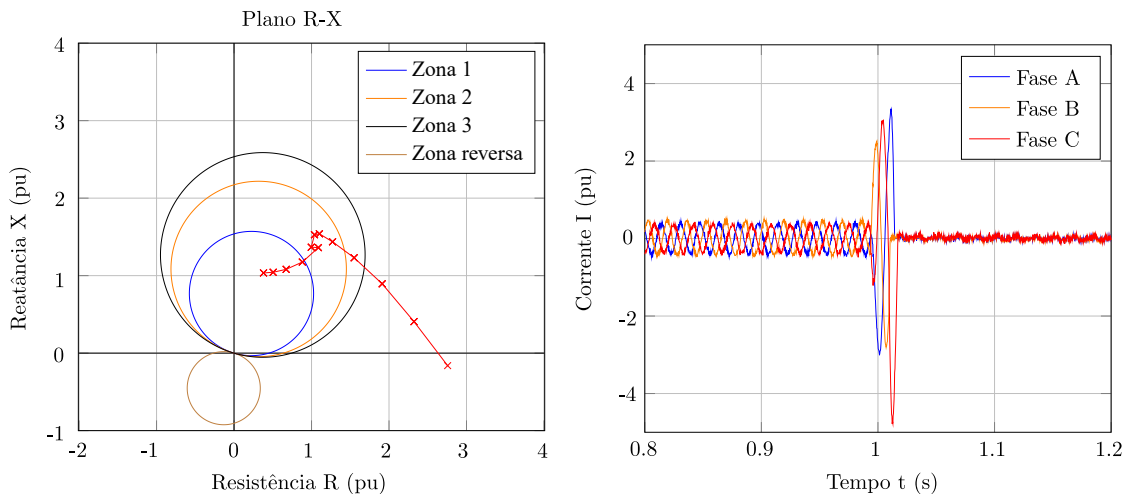


Figura 49: Plano R-X e Oscilografia das correntes para curto-circuito ABC - redes neurais

A figura 50 ilustra o gráfico de impedâncias R-X apresentando o caminho da impedância calculada pelo IED do momento pré-falta até a abertura dos disjuntores local e remoto da LT2 com impedância de  $5 [\Omega]$  e ângulo de incidência de  $0^\circ$  em um curto-circuito BCN.

As tabelas 14 e 15 apresentam o tempo de *trip* e as impedâncias de sequência positiva ( $Z_1$ ) calculadas pelo algoritmo de proteção de distância proposto com uso de redes neurais artificiais para, respectivamente, os curtos-circuitos AN, ABC, BC e BCN. As impedâncias mostradas nas tabelas são as impedâncias calculadas pelo algoritmo antes do defeito na LT2, as impedâncias calculadas no instante de abertura dos disjuntores da LT2 para os três elementos fase-terra, no caso do curto-circuito AN, e para os três elementos fase-fase,

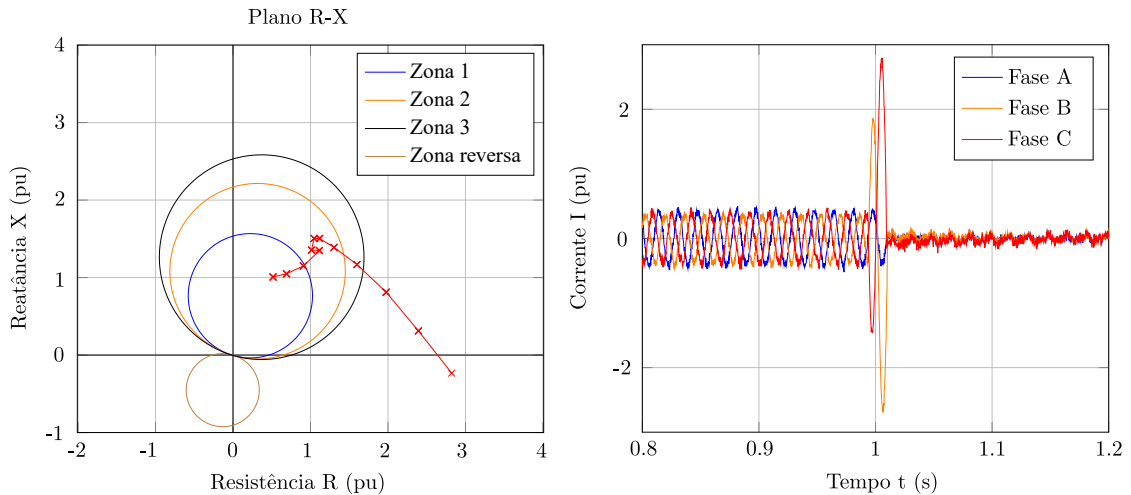


Figura 50: Plano R-X e Oscilografia das correntes para curto-circuito BCN - redes neurais

no caso dos outros curtos-circuitos simulados.

Tabela 14: Tempo de atuação e impedância calculada da proteção de distância para curto-circuito AN - redes neurais

Instante de inserção [s]	0,9958
Z1 pré-falta elemento AN [pu]	1,5854 -j0,1329
Z1 elemento AN [pu]	0,5339 +j0,709
Z1 elemento BN [pu]	0,9993 -j0,9099
Z1 elemento CN [pu]	-5,2051 -j2,1782
Tempo de <i>trip</i> [ms]	10,20

Tabela 15: Tempo de atuação e impedância calculada da proteção de distância para curtos-circuitos BC, BCN e ABC - redes neurais

Elementos de impedância	BC	BCN	ABC
Instante de inserção [s]	0,9958	0,9958	0,9979
Impedância Z1 pré-falta BC [pu]	2,6979 -j0,0606	2,8237 -j0,2293	3,1823 -j0,5572
Impedância Z1 elemento BC [pu]	0,4115 +j0,9134	0,5181 +j1,0116	0,381 +j1,0347
Impedância Z1 elemento AB [pu]	1,1919 +j0,3262	1,2373 +j0,4543	0,5305 +j0,9949
Impedância Z1 elemento CA [pu]	-0,6994 +j2,7154	0,2802 +j2,7898	0,4884 +j1,1766
Tempo de <i>trip</i> [ms]	11,50	9,10	10,20

## 5.2.2 Algoritmo com uso de linearização matemática

A figura 51 exibe o gráfico de impedâncias R-X demonstrando o caminho da impedância calculada pelo IED do momento pré-falta até a abertura dos disjuntores local e remoto da LT2 com impedância de  $5 \text{ } [\Omega]$  e ângulo de incidência de  $0^\circ$  em um curto-circuito AN.



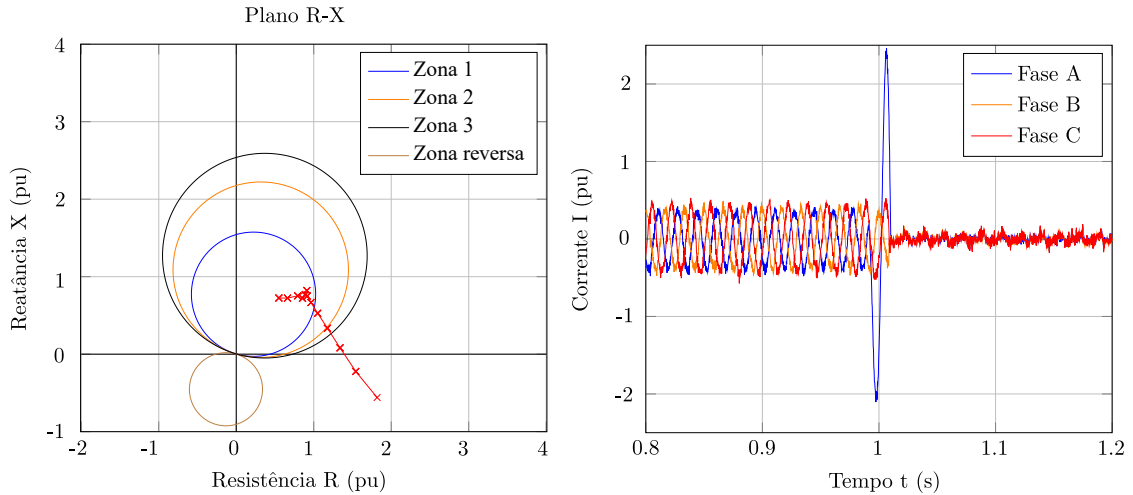


Figura 51: Plano R-X e Oscilografia das correntes para curto-circuito AN - linearização matemática

A figura 52 ilustra o gráfico de impedâncias R-X apresentando o caminho da impedância calculada pelo IED do momento pré-falta até a abertura dos disjuntores local e remoto da LT2 com impedância de  $5 [\Omega]$  e ângulo de incidência de  $0^\circ$  em um curto-circuito BC.

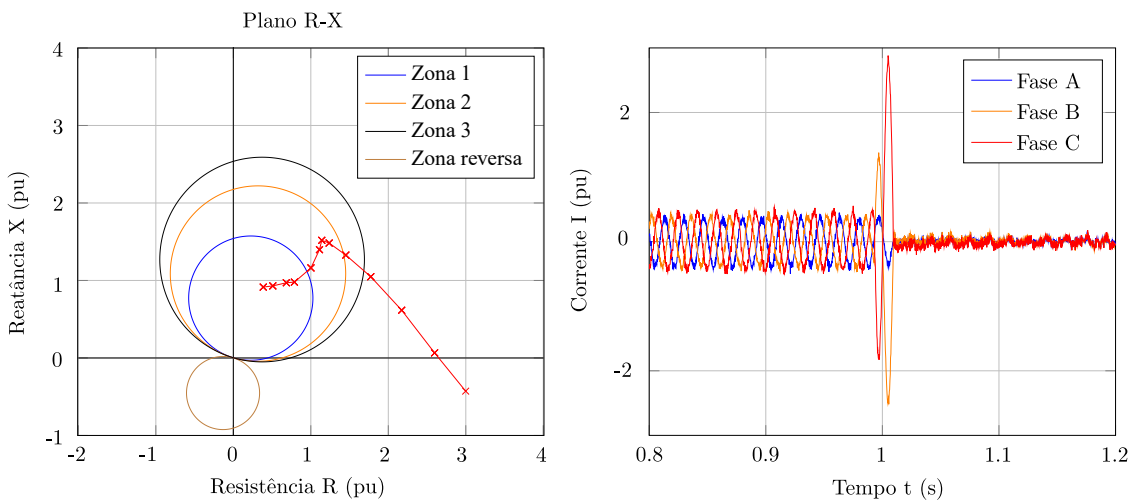


Figura 52: Plano R-X e Oscilografia das correntes para curto-circuito BC - linearização matemática

A figura 53 exibe o gráfico de impedâncias R-X demonstrando o caminho da impedância calculada pelo IED do momento pré-falta até a abertura dos disjuntores local e remoto da LT2 com impedância de  $5 [\Omega]$  e ângulo de incidência de  $0^\circ$  em um curto-circuito ABC.

A figura 54 ilustra o gráfico de impedâncias R-X descrevendo o caminho da impedância calculada pelo IED do momento pré-falta até a abertura dos disjuntores local e remoto da LT2 com impedância de  $5 [\Omega]$  e ângulo de incidência de  $0^\circ$  em um curto-circuito BCN.

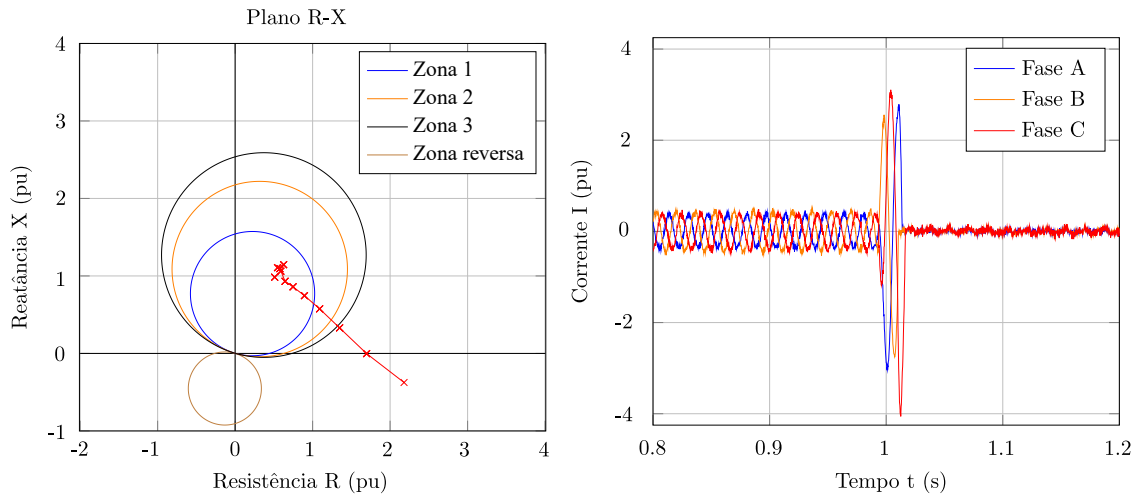


Figura 53: Plano R-X e Oscilografia das correntes para curto-circuito ABC - linearização matemática

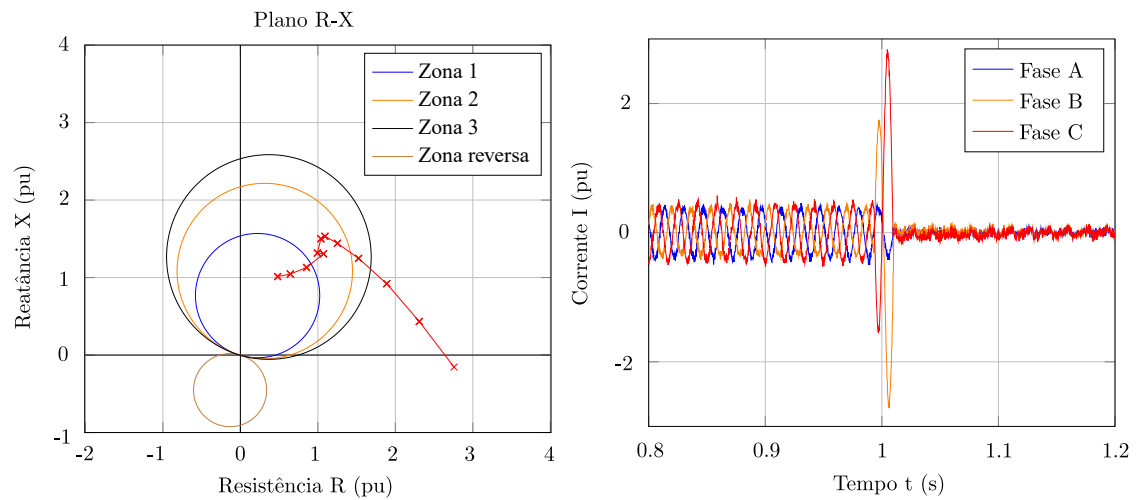


Figura 54: Plano R-X e Oscilografia das correntes para curto-circuito BCN - linearização matemática

As tabelas 16 e 17 apresentam o tempo de *trip* e as impedâncias de sequência positiva ( $Z_1$ ) calculadas pelo algoritmo de proteção de distância proposto com uso de linearização matemática para, respectivamente, os curtos-circuitos AN, ABC, BC e BCN.

As impedâncias mostradas nas tabelas são as impedâncias calculadas pelo algoritmo antes do defeito na LT2, as impedâncias calculadas no instante de abertura dos disjuntores da LT2 para os três elementos fase-terra, no caso do curto-circuito AN, e para os três elementos fase-fase, no caso dos outros curtos-circuitos simulados.

Tabela 16: Tempo de atuação e impedância calculada da proteção de distância para curto-circuito AN - linearização matemática

Instante de inserção [s]	0,9971
Z1 pré-falta elemento AN [pu]	1,545 -j0,2267
Z1 elemento AN [pu]	0,553 +j0,721
Z1 elemento BN [pu]	1,1104 -j1,004
Z1 elemento CN [pu]	-7,7469 -j4,3458
Tempo de <i>trip</i> [ms]	10,20

Tabela 17: Tempo de atuação e impedância calculada da proteção de distância para curtos-circuitos BC, BCN e ABC - linearização matemática

Elementos de impedância	BC	BCN	ABC
Instante de inserção [s]	0,9981	0,9981	0,9981
Impedância Z1 pré-falta BC [pu]	2,9988 -j0,4309	2,7607 -j0,1527	3,1884 -j0,5553
Impedância Z1 elemento BC [pu]	0,3863 +j0,9118	0,4845 +j1,0149	0,3576 +j1,035
Impedância Z1 elemento AB [pu]	1,1774 +j0,3459	1,2147 +j0,463	0,5116 +j0,9813
Impedância Z1 elemento CA [pu]	-0,8163 +j2,5855	0,0942 +j2,8286	0,4855 +j1,1795
Tempo de <i>trip</i> [ms]	9,10	9,10	10,20

### 5.3 Conclusão das análises

Analisando os resultados das tabelas 10 e 11, os algoritmos de proteção de distância implementados neste trabalho não apresentaram nenhum erro de atuação da proteção na zona 1 da linha de transmissão LT2. Isso demonstra que os modelos matemáticos do comportamento do conjunto capacitor série/MOV obtido nas duas estratégias de linearização são assertivos e conseguem representar o comportamento do conjunto durante a ocorrência de um distúrbio elétrico na linha.

Essa constatação também é possível de ser vista na análise qualitativa das duas estratégias, onde os diagramas R-X mostram o caminho percorrido pela impedância medida durante o curto-circuito até a abertura dos disjuntores local e remoto da LT2. Nos diagramas expostos nas subseções 5.2.1 e 5.2.2 é possível observar que nas ocorrências dos quatro tipos de curto-circuitos aplicados na LT2 (AN, BC, ABC e BCN), todos adentram na zona 1 de proteção da curva característica MHO e encerram dentro da mesma zona quando os disjuntores são abertos.

Analisando as tabelas 11 e 12, o tempo médio da execução do curto-circuito BC no algoritmo de redes neurais foi menor que no algoritmo de linearização matemática. Para os outros distúrbios (AN, BCN e ABC) o tempo médio na estratégia de linearização matemática foi menor, mas ambos apresentam tempos médios pequenos de aproximadamente 1,5 [ms] de diferença entre os dois algoritmos. Isso mostra que a dispersão do tempo de

execução para estes distúrbios no algoritmo de rede neural é menor, tornando a função de proteção mais determinística na execução do disparo de abertura do disjuntor.

Os tempos médios para ambos os algoritmos estão bem abaixo do exigido pelo Operador Nacional do Sistema Elétrico (ONS), que exige que o tempo total para eliminação de faltas em uma linha de transmissão não deve ser maior que 100 [ms], incluindo o tempo de abertura dos disjuntores dos terminais da mesma (ONS, 2021). Com os tempos médios obtidos nos dois algoritmos bem abaixo do que estabelecido pelo ONS, com tempo máximo em torno de 20 [ms], sobra 80 [ms] (cinco ciclos elétricos) para a extinção do arco elétrico na câmara do disjuntor. Com esse tempo de sobra é possível atender o tempo total requisitado pelo ONS, mesmo quando inserido o tempo de abertura dos pólos do disjuntor real de uma linha de transmissão que pode ficar entre dois a cinco ciclos elétricos dependendo do tipo de disjuntor utilizado ou de dois a três ciclos nos disjuntores típicos utilizados pelas concessionárias de transmissão de energia elétrica (FRONTIN, 2013).

Esta dissertação mostrou dois algoritmos de proteção de distância com métodos distintos de linearização do comportamento do conjunto capacitor série/MOV, porém vale ressaltar que esses métodos foram aplicados para um caso específico de um modelo computacional do conjunto disponível no RTDS, com uma curva de comportamento do MOV disponível neste modelo. Então não é possível generalizar para outros conjuntos de compensação série fixa disponíveis pelos fabricantes para o setor elétrico. Para isso, seria necessário reaplicar os métodos e encontrar as matrizes, no caso do uso de redes neurais, ou os polinômios, no caso do uso de linearização matemática, para cada conjunto a ser utilizado na linha de transmissão.

No entanto, o procedimento de treinamento das redes neurais artificiais e para obtenção dos polinômios que descrevem a impedância do conjunto capacitor série/MOV estão totalmente descritos no trabalho e podem ser particularizados para qualquer compensação série. Neste ponto o uso de redes neurais para a linearização do comportamento do conjunto capacitor série/MOV durante a ocorrência de distúrbios elétricos mostra ser mais vantajosa pelo fato de resultar em um modelo mais simples e que demanda um uso menor de recursos computacionais do IED do que os polinômios resultantes do método de linearização matemática.

## 6 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho de dissertação apresentou o desenvolvimento de dois algoritmos de proteção de distância em uma linha de transmissão com compensação série em um IED de plataforma aberta, com métodos distintos de linearização do comportamento do conjunto capacitor série/MOV durante a ocorrência de um distúrbio elétrico: rede neural artificial e linearização matemática. A prototipagem do algoritmo foi executada no Matlab e a validação do mesmo foi feita com testes *hardware-in-the-loop* através do simulador digital em tempo real RTDS. Foi utilizado o *software* Wolfram Mathematica para a estratégia de linearização matemática e o TensorFlow para a montagem e execução da rede neural usando a plataforma de computação em nuvem Google Colab.

O algoritmo de proteção obteve resultado satisfatório, sem nenhuma falha de atuação em zona 1 e com tempo médio de resposta bem abaixo do exigido pelos Procedimentos de Rede do ONS para as duas estratégias de linearização do conjunto capacitor série/MOV. Esses tempos médios obtidos nos testes permitem que, mesmo acrescentando o tempo de abertura do disjuntor, atendem ao estabelecido pelo ONS para sistemas de proteção de equipamentos do sistema elétrico nacional da rede básica. A estratégia de linearização matemática obteve tempos médios menores para três dos quatro tipos de distúrbios aplicados na simulação do RTDS (AN, BCN e ABC), porém o desvio padrão na estratégia de redes neurais foi menor em três dos quatro distúrbios aplicados (AN, BC e BCN), mostrando que a estratégia de linearização por redes neurais é mais determinística no tempo de execução da proteção.

A rede neural se mostrou uma ferramenta útil pela facilidade de montagem, execução e análise de um grande volume de dados para determinação do comportamento da linha com compensação série durante a ocorrência de curto-circuito, demonstrado pelos resultados satisfatórios do algoritmo de proteção. A implementação do algoritmo em um IED de plataforma aberta apresenta-se como um grande diferencial quando comparada com outras propostas da literatura, que apresentam desenvolvimentos de algoritmos de proteção utilizando apenas a prototipagem em ferramentas computacionais de alto nível e mode-

lagem de sistemas elétricos em *softwares* de simulação *off-line* (oposto de tempo real). Contudo, o uso de IED's de fabricantes do setor elétrico para esse tipo de implementação possui restrições em virtude de práticas de proteção intelectual e de segredo industrial, além de patentes registradas.

Alguns trabalhos futuros que podem ser feitos a partir desse trabalho podem ser elencados a seguir:

- Pesquisa do uso do algoritmo em linhas de transmissão com compensação variável, utilizado em sistemas FACTS;
- Pesquisa sobre o uso do algoritmo de proteção de distância com compensação série no domínio do tempo; e
- Uso do algoritmo de proteção em sistemas de proteção centralizada ou em conjunto com WAMPACs;

## REFERÊNCIAS

- ABB AB FACTS. *TCSC - Thyristor Controlled Series Compensation - Kepp grids together*. Vasteras, 2010. Disponível em: <https://library.e.abb.com/public/dfd0b019e1fe08a48325771f002dbfc5/A02-0158.pdf>. Acesso em: 16 Set. 2019.
- ABB AB FACTS. *Series Compensation - Boosting transmission capacity*. Vasteras, 2015. Disponível em: [https://library.e.abb.com/public/500e696d077796cf83257e0c0047d487/SC\%20A02-0135E\\\_E\%20KorrI.pdf](https://library.e.abb.com/public/500e696d077796cf83257e0c0047d487/SC\%20A02-0135E\_E\%20KorrI.pdf). Acesso em: 15 Jul. 2019.
- ABB AB FACTS. *A matter of FACTS - Deliver more, high quality power*. Vasteras, 2016. Disponível em: [https://library.e.abb.com/public/1adf0dee2c8f4a65adfb571eea017b9d/A\%20matter\%20of\%20FACTS\\\_Final\%20160209.pdf](https://library.e.abb.com/public/1adf0dee2c8f4a65adfb571eea017b9d/A\%20matter\%20of\%20FACTS\_Final\%20160209.pdf). Acesso em: 16 Jul. 2019.
- AFL. *Wire Products*. [S.l.], 2003.
- ANDERSON, P. M. *Power System Protection*. New York: John Wiley & Sons INC, 1999. ISBN 0-7803-3427-2.
- ARA, A. B.; MUSETTI, A. V.; SCHNEIDERMAN, B. *Introdução a Estatística*. São Paulo: Edgard Blucher, 2003. ISBN 978-85-212-0320-9.
- BLACKBURN, J. L.; DOMIN, T. *Protective relaying - Principals and Applications*. 3th. ed. Boca Raton: CRC Press, 2007. ISBN 978-1-57444-716-3.
- ÇAPAR, A.; ARSOY, A. B. A performance oriented impedance based fault location algorithm for series compensated transmission lines. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 71, p. 209–214, 2015.
- DINIZ, P. S. R.; SILVA, E. A. B. da; NETTO, S. L. *Processamento digital de sinais: projeto e análise de sistemas*. Porto Alegre: Bookman, 2004. ISBN 85-363-0418-9.
- EISSA, M.; MASOUD, M. E.; ELANWAR, M. M. M. A novel back up wide area protection technique for power transmission grids using phasor measurement unit. *IEEE Transactions on Power Delivery*, IEEE, v. 25, n. 1, p. 270–278, 2009.
- FILHO, J. M.; MAMEDE, D. R. *Proteção de sistemas elétricos de potência*. Rio de Janeiro: LTC, 2011. ISBN 978-85-216-1884-3.
- FRONTIN, S. O. *Alternativas não convencionais para a transmissão de energia elétrica - estado da arte*. 1. ed. ed. Brasília: Goya Editora, 2011. ISBN 978-85-88041-03-5.
- FRONTIN, S. O. *Equipamentos de alta tensão - prospecção e hierarquização de inovações tecnológicas*. Brasília: Goya Editora LTDA, 2013. ISBN 978-85-88041-09-7.
- GE DIGITAL ENERGY. *D60 Line Distance Protection System*. Ontario, 2015. Disponível em: <https://www.gegridsolutions.com/app/ViewFiles.aspx?prod=d60&type=3>. Acesso em: 12 Jul. 2019.

- GE GRID SOLUTIONS. *Series Compensation Systems*. [S.l.], 2015. Disponível em: [https://www.gegridsolutions.com/app/Resources.aspx?prod=series\\\_comp&type=1](https://www.gegridsolutions.com/app/Resources.aspx?prod=series\_comp&type=1). Acesso em: 09 Set. 2019.
- GHANY, H. A. A. el; ELSADD, M. A.; AHMED, E. S. A faulted side identification scheme-based integrated distance protection for series-compensated transmission lines. *International Journal of Electrical Power & Energy Systems*, Elsevier, v. 113, p. 664–673, 2019.
- GOOGLE. *Colaboratory - Frequently Asked Questions*. [S.l.], 2020. Disponível em: <https://research.google.com/colaboratory/faq.html>. Acesso em: 12 Jan. 2022.
- HASHEMI, S. M.; HAGH, M. T.; SEYEDI, H. A novel backup distance protection scheme for series-compensated transmission lines. *IEEE Transactions on Power Delivery*, v. 29, n. 2, p. 699–707, April 2014. ISSN 0885-8977.
- HAYKIN, S. *Redes Neurais - Princípios e prática*. 2. ed. ed. Porto Alegre: Bookman, 2001. ISBN 85-7307-718-2.
- HINGORANI, N. G.; GYUGYI, L. *Understanding FACTS: concepts and technology of flexible AC*. New York: IEEE Press, 2000. ISBN 0-7803-3455-8.
- HOROWITZ, S. H.; PHADKE, A. *Power System Relaying*. 1th. ed. Somerset: Research Studies Press, 1992. ISBN 0-86380-135-8.
- JENA, M. K.; SAMANTARAY, S.; PANIGRAHI, B. K. A new wide-area backup protection scheme for series-compensated transmission system. *IEEE Systems Journal*, IEEE, v. 11, n. 3, p. 1877–1887, 2015.
- KARAYIANNIS, N. B.; VENETSANOPOULOS, A. N. *Artificial neural networks: learning algorithms, performance evaluation, and applications*. Norwel: Kluwer Academic Publishers, 1993. ISBN 0-7923-9297-3.
- KOROT, D.; MARKEN, P.; BOCK, L. The next fifty years of series capacitors — and the last eighty-six. In: *IEEE PES T D Conference and Exposition. Proceedings*. [S.l.: s.n.], 2014. p. 1–5. ISSN 2160-8563.
- KOVÁCS, Z. L. *Redes Neurais Artificiais- Fundamentos e Aplicações*. 4. ed. ed. São Paulo: Editora Livraria da Física, 2006. ISBN 85-88325-14-4.
- MANASSERO, G. J.; SANTO, S. G. D.; ROJAS, D. G. Fault location in series-compensated transmission lines based on heuristic method. *Electric Power Systems Research*, Elsevier, v. 140, p. 950–957, 2016.
- MENEZES, M. P. *Classificação e localização de faltas em linhas de transmissão usando diferentes arquiteturas de redes neurais artificiais*: Dissertação mestrado. São Paulo: Universidade de São Paulo, 2008.
- NAYAK, P. K.; PRADHAN, A. K.; BAJPAI, P. Wide-area measurement-based backup protection for power network with series compensation. *IEEE Transactions on Power Delivery*, IEEE, v. 29, n. 4, p. 1970–1977, 2014.



NEXANS. *Cabos de Alumínio Nu com Alma de Aço - CAA (Série KCMIL)*. [S.l.], 2020. Disponível em: [https://www.nexans.com.br/eservice/Brazil-pt\BR/pdf-product\\\_540012771/Grosbeak.pdf](https://www.nexans.com.br/eservice/Brazil-pt\BR/pdf-product\_540012771/Grosbeak.pdf). Acesso em: 9 Jan. 2020.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO. *Módulo 10 - Submódulo 10.18 - Cadastro de Informações Operacionais de Faixas para Controle de Tensão da Área 500 KV da Região Sudeste*. 3. ed. [S.l.], 2018. Disponível em: <http://www.ons.org.br/paginas/sobre-o-ons/procedimentos-de-rede/mpo>. Acesso em: 17 Jul. 2019.

OPERADOR NACIONAL DO SISTEMA ELÉTRICO. *Módulo 2 - Submódulo 2.11 - Requisitos mínimos para os sistemas de proteção, de registro de perturbações e de teleproteção*. 31. ed. [S.l.], 2021. Disponível em: [https://apps08.ons.org.br/ONS.Sintegre.Proxy/ecmprsite/ecmfragmentsdocuments/Subm\%C3%B3dulo\%202.11-RQ\\\_2020.12.pdf](https://apps08.ons.org.br/ONS.Sintegre.Proxy/ecmprsite/ecmfragmentsdocuments/Subm\%C3%B3dulo\%202.11-RQ\_2020.12.pdf). Acesso em: 15 Out. 2022.

ORSINI, L. Q.; CONSONNI, D. *Curso de Circuitos Elétricos*. 2. ed. São Paulo: Editora Edgard Blücher LTDA, 2002. v. 1. ISBN 978-85-212-0308-7.

PELLINI, E. L. *Um arcabouço para aplicações em tempo real em sistemas de potência.*: Tese de doutorado. São Paulo: Universidade de São Paulo, 2010.

PELLINI, E. L. et al. Custom distribution feeder recloser ied with high impedance protection function. IET, 2013.

PETERS, S.; SZEREMETA, J. F. *Cálculo numérico computacional*. Florianópolis: Editora da UFSC, 2018. ISBN 978-85-328-0832-5.

REIS, L. B. d. *Geração de energia elétrica*. 3. ed. Barueri: Manole, 2003. ISBN 85-204-1536-9.

S, R.; SAMANTARAY, S. R.; PANIGRAHI, B. K. Adaptive distance protection scheme for shunt-facts compensated line connecting wind farm. *IET Generation, Transmission & Distribution*, IET, v. 10, n. 1, p. 247–256, 2016.

SAHA, M. M. et al. Evaluation of relaying impedance algorithms for series-compensated line. *Electric Power Systems Research*, Elsevier, v. 138, p. 106–112, 2016.

SCHAPPO, M. G. *Transições de fase em modelos do cérebro : Uma abordagem computacional.*: Tese de doutorado. Florianópolis: Universidade Federal de Santa Catarina, 2016.

SETTI, M. *Machine learning applied to electric transmission grid problems*: Projeto de formatura. São Paulo: Universidade de São Paulo, 2018.

SONG, Y. H.; JOHNS, A. *Flexible ac transmission systems (FACTS)*. Cornwall: TJ International Ltd, 1999. ISBN 0-85296-771-3.

SWETAPADMA, A.; YADAV, A. A hybrid method for fault location estimation in a fixed series compensated lines. *Measurement*, Elsevier, v. 123, p. 8–18, 2018.

TEIXEIRA, P. C. O. Avaliação dos níveis de campos elétricos e magnéticos em linhas de transmissão da CTEEP. *XVI Seminário Nacional de Produção e Transmissão de Energia Elétrica*, Cigre, 2001.

TENSORFLOW. *TensorFlow*. [S.l.], 2022. Disponível em: <https://www.tensorflow.org/>. Acesso em: 12 Out. 2022.

THE INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS. *IEEE Std C37.111-1991 - IEEE Standard Common Format for Transient Data Exchange (COMTRADE) for Power Systems*. New York, 1991. 1-28 p.

THE INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS. *IEEE Std C37.111-1999 - IEEE Standard Common Format for Transient Data Exchange (COMTRADE) for Power Systems*. New York, 1999. 1-55 p.

THE INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS. *IEEE C37.2 - IEEE Standard Electrical Power System Device Function Numbers, Acronyms, and Contact Designations*. New York, 2008.

TRAPPENBERG, T. P. *Fundamentals of Computational Neuroscience*. New York: Oxford University Press, 2002. ISBN 978-0-19-851585-1.

VARGAS, J. V. C.; ARAKI, L. K. *Cálculo numérico aplicado*. Barueri: Editora Manole Ltda, 2017. ISBN 978-85-204-4578-5.

ZACCONE, G. *Getting Started with TensorFlow*. Birmingham: Packt Publishing, 2016. ISBN 978-1-78646-857-4.

ZIEGLER, G. *Numerical Distance Protection-Principals and Applications*. 4th. ed. Erlangen: Publicis Corporate Publishing, 2011. ISBN 978-3-89578-381-4.

ZIMMERMAN, K.; COSTELLO, D. Impedance-based fault location experience. In: *58th Annual Conference for Protective Relay Engineers, 2005*. [S.l.: s.n.], 2005. p. 211–226.

## ANEXO A – CÓDIGO *PYTHON*

```
1  %TensorFlow packet installation on Colab notebook
2  !pip install -q tfds-nightly tensorflow matplotlib
3
4  %TensorFlow libraries installation
5  from __future__ import absolute_import, division, print_function,
6      unicode_literals
7  import numpy as np
8  import tensorflow as tf
9  from tensorflow import keras
10 import tensorflow_datasets as tfds
11 import pandas as pd
12
13 %Data treatment for neural network training and validation
14 train_file_path = pd.read_csv(r'/content/drive/MyDrive/Colab Notebooks
15     /Dados_train.csv')
16 test_file_path = pd.read_csv(r'/content/drive/MyDrive/Colab Notebooks/
17     Dados_test.csv')
18 i_train = np.array([train_file_path.i, train_file_path.i1,
19     train_file_path.i2, train_file_path.i3, train_file_path.i4])
20 i_train = np.transpose(i_train)
21 Z_train = np.array([train_file_path.Z])
22 Z_train = np.transpose(Z_train)
23 i_test = np.array([test_file_path.i, test_file_path.i1, test_file_path
24     .i2, test_file_path.i3, test_file_path.i4])
25 i_test = np.transpose(i_test)
26 Z_test = np.array([test_file_path.Z])
27 Z_test = np.transpose(Z_test)
```

```
24 %Neural network assembling and execution
25 epochs = 10000
26 activation_function = 'tanh'
27
28 model = keras.Sequential()
29 model.add(keras.layers.Dense(5, activation=activation_function,
30     input_shape=(5,)))
31 model.add(keras.layers.Dense(5, activation=activation_function))
32 model.add(keras.layers.Dense(2, activation=activation_function))
33 model.compile(optimizer=tf.keras.optimizers.Adam(learning_rate=0.1),
34     loss='mse', metrics=['mse'])
35 result = model.fit(i_train, Z_train, epochs=epochs, validation_data =
36     (i_test, Z_test))
37 model.summary()
38 print(model.layers[2].weights)
39 print(model.layers[2].bias)
40 result.epoch
41 result.history['mse'][-1]
42
43 %Neural network topology visualization
44 tf.keras.utils.plot_model(model, to_file='model.png', show_shapes=True
45     , show_layer_names=True)
```