



Universidade Federal do Piauí
Centro de Tecnologia
Departamento de Engenharia Elétrica
Programa de Pós-Graduação em Engenharia Elétrica

**UMA ABORDAGEM BASEADA EM
COEFICIENTES DE FREQUÊNCIA MEL
CEPSTRAIS E MODELOS DE APRENDIZADO
DE MÁQUINA PARA LOCALIZAÇÃO DE
FALTAS EM LINHA DE TRANSMISSÃO DE
ALTA TENSÃO**

José de Anchieta Araújo Marques

Teresina-PI, Julho de 2022

José de Anchieta Araújo Marques

**UMA ABORDAGEM BASEADA EM COEFICIENTES DE
FREQUÊNCIA MEL CEPSTRAIS E MODELOS DE
APRENDIZADO DE MÁQUINA PARA LOCALIZAÇÃO
DE FALTAS EM LINHA DE TRANSMISSÃO DE ALTA
TENSÃO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Piauí, como um dos pré-requisitos para obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistema de Energia Elétrica.

Universidade Federal do Piauí – UFPI

Centro de Tecnologia

Programa de Pós-Graduação em Engenharia Elétrica

Orientador: Prof. Dr. Hermes Manoel Galvão C. Branco

Coorientador: Prof. Dr. Ricardo de Andrade Lira Rabelo

Teresina-PI

Julho de 2022

FICHA CATALOGRÁFICA
Universidade Federal do Piauí
Biblioteca Comunitária Jornalista Carlos Castello Branco
Serviço de Processos Técnicos

M357a Marques, José de Anchieta Araújo.
Uma abordagem baseada em Coeficientes de Frequência Mel
Cepstrais e modelo de aprendizado de máquina para localização de faltas
em linha de transmissão de alta tensão / José de Anchieta Araújo
Marques. -- 2022.
125 f.

Dissertação (Mestrado) – Universidade Federal do Piauí, Programa
de Pós-Graduação em Engenharia Elétrica, Teresina, 2022.

“Orientador: Prof. Dr. Hermes Manoel Galvão C. Branco.”

“Coorientador: Prof. Dr. Ricardo de Andrade Lira Rabelo.”

1. Localização de Falta. 2. Linha de Transmissão. 3. Coeficientes de
Frequência Mel Cepstrais. 4. Rede Neural Artificial. 5. Sistemas
Elétricos de Potência. 6. Aprendizado de Máquina. I. Branco, Hermes
Manoel Galvão C. II. Rabelo, Ricardo de Andrade Lira. III. Título.

CDD 621.3

Bibliotecária: Francisca das Chagas Dias Leite - CRB3/1004

José de Anchieta Araújo Marques

**UMA ABORDAGEM BASEADA EM COEFICIENTES DE
FREQUÊNCIA MEL CEPSTRAIS E MODELOS DE
APRENDIZADO DE MÁQUINA PARA LOCALIZAÇÃO
DE FALTAS EM LINHA DE TRANSMISSÃO DE ALTA
TENSÃO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Piauí, como um dos pré-requisitos para obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistema de Energia Elétrica.

Trabalho aprovado em: Teresina-PI, 25 de Julho de 2022:

Prof. Dr. Hermes Manoel Galvão C. Branco
Orientador

Prof. Dr. Ricardo de Andrade Lira Rabelo
Coorientador

Prof. Dr. Aryfrance Rocha Almeida
Convidado 1

Prof. Dr. Vinicius Ponte Machado
Convidado 2

Teresina-PI
Julho de 2022

*Dedico este trabalho a minha família,
por estarem sempre presentes e
pelo apoio incondicional em todos os momentos,
sem o qual eu não teria conseguido chegar
até o fim deste trabalho.*

Agradecimentos

Muitos foram os que me ajudaram nesse processo, aos quais tenho a satisfação e a obrigação de agradecer. Certamente esses parágrafos não irão atender a todas as pessoas que fizeram parte dessa importante fase de minha vida, mas podem estar certas que fazem parte do meu pensamento e de minha gratidão.

Agradeço a Deus por todas as oportunidades recebidas e caminhos abertos.

Agradeço aos meus pais, Demétrio Marques (*in memoriam*) e Maria do Carmo, por ter sempre me ensinado o caminho certo.

A minha esposa Célia Soares, pelo apoio e tempo que se dedicou a me liberar para focar neste trabalho;

Aos meus filhos Yasmin (que me ajudou muito na revisão dos textos), José (*in memoriam*) e Yago por serem a luz na minha vida;

Aos meus irmãos Edilmar, Leide, Leila, Lucilene e Junior que me ajudaram a passar por um momento tão difícil na Pandemia do COVID-19 e a toda minha família que se fizeram sempre presentes quando precisei.

Agradeço ao meu orientador, Prof. Dr. Hermes Manoel Galvão Castelo Branco, e ao meu coorientador, Prof. Dr. Ricardo de Andrade Lira Rabelo, por todos os conselhos, pelo trabalho competente, pelo incentivo contante e ajuda no desenvolvimento deste trabalho.

Aos colegas de profissão Raniere e Anderson pelos ajustes no documento e nas construções de parte das ilustrações apresentadas nesta dissertação.

Aos meus amigos que me apoiaram e deram forças no intuito de eu chegar ao fim desta etapa.

Aos professores que contribuíram para o desenvolvimento e aprimoramento deste trabalho.

Agradecer à Universidade Federal do Piauí pela disponibilização de toda a infraestrutura necessária que possibilitou a realização desta pesquisa.

*“Uma mente que se abre
a uma nova ideia
jamais volta
ao seu tamanho original.”
(Albert Einstein)*

Resumo

Faltas nas Linhas de Transmissão (LTs) podem causar grandes prejuízos aos usuários e aos gestores de Sistemas Elétricos de Potência (SEP). Dessa forma, é de suma importância tornar o processo de localização de tais faltas cada vez mais eficiente, para que estas possam ser reparadas o mais rápido possível. No presente estudo, foram aplicados os Coeficientes de Frequência Mel Cepstrais (MFCC) como ferramenta de pré-processamento dos sinais de tensão coletados nos dois terminais da linha de transmissão durante a falta, além de um modelo de Aprendizado de Máquina (AM), responsável pela localização das faltas na prática. Foram testados diferentes modelos de AM, quais sejam: Rede Neural Artificial (RNA), Regressão de Vetores de Suporte (SVR) e Regressão de Vetores de Suporte com Mínimos Quadrados (LS-SVR), dentre os quais se percebeu que a RNA teve o melhor resultado geral, sendo capaz de processar todas as simulações. Utilizou-se uma linha de transmissão modelada com base em parâmetros de uma linha real. No MATLAB, vários cenários foram simulados com a RNA, que apresentou os melhores resultados iniciais, e o método proposto forneceu resultados com alta precisão na localização de faltas em ambientes não ruidosos, com Erro Médio Relativo (EMR) geral de 0,00004 % e Erro Médio Absoluto (EMA) geral de 0,13 m. Posteriormente, foram verificadas as influências do tipo de falta, das resistências de faltas, dos ângulos de faltas e das distâncias de faltas no método de localização, utilizando-se os resultados da melhor arquitetura da RNA. O método proposto demonstrou ainda ser capaz de realizar a detecção rápida e precisa de faltas, mesmo quando considerados percentuais pequenos da base de dados ou/e a partir da adição de várias relações sinais-ruídos aos sinais de tensão. Esses resultados apontam que o procedimento metodológico proposto é uma boa alternativa para localização de faltas em LT.

Palavras-chaves: Localização de Falta; Linha de Transmissão; Coeficientes de Frequência Mel Cepstrais; Rede Neural Artificial; Regressão de Vetores de Suporte; Sistemas Elétricos de Potência; Aprendizado de Máquina.

Abstract

Faults in transmission lines (TLs) may cause great loss to users and to managers of Electric Power Systems (EPS). Thus, it is important to make the process of locating these faults more efficient, in order to repair them as quickly as possible. In the present study, Mel Frequency Cepstral Coefficients (MFCC) were used as a tool for processing voltage signals collected on both of the transmission line terminals during faults, in addition to an Machine Learning (AM) model, responsible for locating faults in practice. Different AM models were tested, namely: an Artificial Neural Network (ANN), a Support Vector Regression (SVR) and a Least Squares Support Vector Regression (LS-SVR), among which it was noticed that the ANN had the best overall result, being able to process all simulations. A modeled line based on parameters of a real line was used as well. Several scenarios were performed on MATLAB and the proposed method provided results with high precision in locating faults in environments without noise, with a Mean Relative Error (MRE) of 0.00004 % and a Mean Absolute Error (MAE) of 0.13 meters. Subsequently, the influences of fault's types, of fault's resistances, of fault's angles and of fault's distances in the location method were evaluated, through the results of the best ANN architecture. The proposed method was still able to detect the faults quickly and precisely, even with small percentages of the data base and/or different signal to noise ratio. These results indicate that the proposed methodological procedure is a good alternative for fault location in LT.

Keywords: Fault location. Transmission line. Mel Frequency Cepstral Coefficients. Artificial Neural Network. Support Vector Regression. Electric Power Systems. Machine Learning.

Lista de ilustrações

Figura 1 – Número de Perturbações por tipo de componentes do SEP	2
Figura 2 – Estados do Nordeste e quatro do Norte afetados com interrupção total de energia	3
Figura 3 – Modelo de LT baseado em parâmetros concentrados: (a) linhas curtas ($\ell < 80$ km); (b) linhas médias ($80 \leq \ell < 250$ km)	10
Figura 4 – Modelo de LT baseado em parâmetros distribuídos	11
Figura 5 – Ondas regressivas e progressivas	12
Figura 6 – Modelo da LT a parâmetros distribuídos para a i -ésima componente simétrica	13
Figura 7 – Registro oscilográfico real de uma falta na Fase C em uma LT de 230 kV: (a) variações nas formas de onda de tensão; (b) variações nas formas de onda da corrente.	15
Figura 8 – Diagrama fasorial de sequência a) positiva, b) negativa e c) zero	16
Figura 9 – Janelas do sinal de corrente ao longo do tempo	22
Figura 10 – Diagrama de reflexão das ondas viajantes	23
Figura 11 – Sistema característico para o sistema homomórfico usando DTFT	24
Figura 12 – Combinação não linear em domínio cepstrais	25
Figura 13 – Componentes são somadas, solucionando o problema da não linearidade	26
Figura 14 – Representação dos Componentes do sinal no domínio <i>cepstral</i>	26
Figura 15 – Filtros triangulares em escala mel usados na extração dos coeficientes MFCC	27
Figura 16 – Registro oscilográfico real sem distúrbios: (a) tensões; (b) correntes.	28
Figura 17 – Registro oscilográfico sem distúrbios: (a) is sem a componente de frequência fundamental e harmônicas de ordem 2, 3,4, 5 e 7; (b) histograma da frequência relativa dos ruídos de i_A	29
Figura 18 – Registro oscilográfico real de uma falta CT: (a) tensões; (b) correntes.	30
Figura 19 – Figura com frentes não lineares e lineares	32
Figura 20 – Fluxograma do procedimento metodológico proposto na fase de Treinamento do Modelo de AM	46
Figura 21 – Fluxograma do procedimento com inclusão de ruído na fase de Treinamento do Modelo de AM	47
Figura 22 – Fluxograma do procedimento metodológico proposto para localização de faltas de LT.	47
Figura 23 – Parte das linhas de transmissão da rede de operação Norte/Nordeste.	48
Figura 24 – Modelo de linha com torre em V Feixe Expandido Simétrico (VX – Simétrico) de 500 kV.	48
Figura 25 – Sistema de Transmissão modelado no software <i>ATPDraw</i>	49
Figura 26 – Entrada de dados no componente <i>ACSOURCE</i> da fonte <i>GER-1</i> do Terminal 1.	50

Figura 27 – Entrada de dados no componente <i>RLC3</i> da carga trifásica equilibrada do Terminal 1.	51
Figura 28 – Entrada de dados para o modelo <i>LCC</i> do Terminal 1.	51
Figura 29 – Entrada de dados da linha de transmissão no Terminal 1.	52
Figura 30 – Entrada de dados no componente <i>ACSOURCE</i> da fonte <i>GER-2</i> do Terminal 2.	52
Figura 31 – Entrada de dados no componente <i>RLC3</i> da carga trifásica equilibrada do Terminal 2.	53
Figura 32 – Entrada de dados para o modelo <i>LCC</i> do Terminal 2.	53
Figura 33 – Entrada de dados da linha de transmissão no Terminal 1.	54
Figura 34 – Entrada de dados para o componente <i>TSWITCH</i> para ângulo de incidência 0°.	54
Figura 35 – Representação do <i>probe</i> trifásico de tensão.	55
Figura 36 – Estrutura de uma das RNAs treinadas.	58
Figura 37 – Sinal Transitório de Falta Sem e Com Ruído Branco Gaussiano de SNR 25 dB.	60
Figura 38 – Desempenho de treinamento da rede neural.	64
Figura 39 – Regressão linear para o algoritmo de treinamento (RNA).	64
Figura 40 – Desempenho de modelos baseados em RNA com 240 entradas e 80 neurônios na camada oculta, para treinamento com diferentes subconjuntos de diferentes tamanhos e diferentes níveis de ruído.	68

Lista de tabelas

Tabela 1 – Frequências típicas de ocorrências por tipo de faltas	14
Tabela 2 – Revisão Bibliométrica sobre Localização de Faltas em LT	35
Tabela 3 – Características da linha de transmissão	49
Tabela 4 – Quantidades de simulações por tipo de falta	56
Tabela 5 – Parâmetros da arquitetura da RNA	57
Tabela 6 – Percentuais da base de dados original	58
Tabela 7 – Resultado geral do uso de diferentes quantidades de coeficientes MFCC e de diferentes quantidades de neurônios na camada oculta de uma RNA	63
Tabela 8 – Resultado geral da utilização de diferentes quantidades de coeficientes MFCC com entrada de SVRs, para todos os conjuntos de dados.	65
Tabela 9 – Influência do tamanho da base de dados no desempenho da localização de falta considerando diferentes algoritmos	66
Tabela 10 – Influência do desempenho de modelos baseados em RNA com subconjuntos de banco de dados e inserção de ruído gaussiano nos sinais de falta	69
Tabela 11 – Influência do tipo de falta	70
Tabela 12 – Influência da resistência de falta	71
Tabela 13 – Influência do ângulo de falta	72
Tabela 14 – Influência da distância de falta	72
Tabela 15 – Comparação dos resultados de técnicas que usam inteligência computacional	73
Tabela 16 – Resultado com o uso da base de dados reduzida	103
Tabela 17 – Resultado com a adição de ruído branco gaussiano na base de tensões originais	104
Tabela 18 – Resultado com o uso da base de dados reduzida e SNR de 100 dB	104
Tabela 19 – Resultado com o uso da base de dados reduzida e SNR de 75 dB	105
Tabela 20 – Resultado com o uso da base de dados reduzida e SNR de 50 dB	105
Tabela 21 – Resultado com o uso da base de dados reduzida e SNR de 25 dB	106
Tabela 22 – Resultado com o uso da base de dados reduzida e SNR de 25 dB a 100 dB	106

Lista de abreviaturas e siglas

AG	Algoritmos genéticos
AM	Aprendizado de Máquina
ANACE	Associação Nacional dos Consumidores de Energia
ANEEL	Agência Nacional de Energia Elétrica
ANFIS	<i>Adaptive Neuro-fuzzy Inference Systems</i>
ANN	Artificial Neural Network
ATP	<i>Alternative Transient Program</i>
C	Coefficientes <i>melcpstais</i>
CHESF	Companhia Hidroelétrica do São Francisco
CNN	Rede Neural Convolutacional (<i>Convolutional Neural Network</i>)
DCT	Transformada Discreta de Cosseno
DFF	Característica de Função Determinante
DFT	Transformada Discreta de Fourier
DWT	Transformada <i>Wavelet</i> Discreta
DRL	Aprendizagem por Reforço Profundo (<i>Deep Reinforcement Learning</i>)
DTFT	Transformada de Fourier de Tempo Discreto
E_i	Erro de localização da falta
EMA	Erro Médio Absoluto
EMR	Erro Médio Relativo
EMTP	<i>Eletromagnetic Transient Program</i>
EQM	Erro Quadrático Médio
F	Faixas de frequência
FT	Fase-Terra
FFT	Fase-Fase-Terra

FFFT	Fase-Fase-Fase-Terra
IA	Inteligência Artificial
IC	Inteligência Computacional
IDFT	<i>Inverse Discrete Fourier Transform</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
k-NN	Método dos Vizinhos mais Próximos
L	Comprimento da Linha
LDA	Análise Discriminante Linear
LS-SVR	Regressão por Vetor de Suporte com Mínimos Quadrados
LT	Linhas de Transmissão (<i>transmission lines</i>)
MFCC	Coefficiente de Frequência Mel <i>Cepstral (Mel Frequency Cepstral Coefficients)</i>
MLP	<i>Multilayer Perceptron</i>
MRA	Análise <i>Wavelet</i> Multi-Resolução
MU	constante de momento ou Parâmetro de momento
N	Quantidade de faltas
NN	Números de neurônios
ONS	Operador Nacional do Sistema
OV	Ondas Viajantes
P_s	Potência média do sinal
P_n	Potência média do ruído
PSD	Densidade Espectral de Potência
R	Coefficiente de Correlação
RNA	Rede Neural Artificial
RTDS	Simulador Digital em Tempo Real
SEP	Sistema Elétrico de Potência

SIN	Sistema Interligado Nacional
SNR	Relação Sinal-Ruído
SNR_{dB}	Relação Sinal-Suído em Decibel
SVR	Regressão de Vetores de Suporte
SVM	Máquina de Vetores de Suporte
SWT	Transformada Estacionária de Wavelet
VMD	Decomposição de Modo Variacional
T	Período
TC	Transformadores de Corrente
TF	Transformada de Fourier
TRF	Transformada Rápida de Fourier
TP	Transformadores de Potencial
TW	Transformada <i>Wavelet</i>
TWD	Transformada <i>Wavelet</i> Discreta

Lista de símbolos

R	Resistência
L	Indutância
C	Capacitância
R_L	Resistência série da linha.
V_S	Tensão no terminal emissor da linha.
V_R	Tensão no terminal receptor da linha.
X_L	Reatância indutiva série da linha.
Z_c	Impedância característica
Z_L	Impedância série da linha
c	Capacitância em derivação da linha por unidade de comprimento
g	Condutância em derivação da linha por unidade de comprimento
l	Indutância série da linha por unidade de comprimento
r	Resistência série da linha por unidade de comprimento
$\%$	Porcentagem
®	Marca Registrada
Δx	Unidade de comprimento ‘
ℓ	Comprimento da linha
γ	Constante de propagação
ω	Frequência angular fundamental (dada em rad/s)
Ω	Ohm

Sumário

1	INTRODUÇÃO	1
A	Motivação e Relevância	1
B	Objetivos	5
B.1	Objetivo geral	6
B.2	Objetivos específicos	6
C	Contribuições	6
D	Organização do Texto	7
2	REFERENCIAL TEÓRICO	9
A	Modelos de Linha de Transmissão	9
A.1	Baseados em Parâmetros Concentrados	9
A.2	Baseados em Parâmetros Distribuídos	10
B	Variações de Tensões e Correntes Envolvidas nas Faltas em LT	14
B.1	Representação Fasorial	15
B.2	Componentes Simétricos	16
C	Ferramentas de Processamento de Sinais normalmente utilizadas para Localização de Faltas em LT	17
C.1	Transformada de Fourier	17
C.2	Transformada Rápida de Fourier	18
C.3	Transformada Discreta dos Cossenos	18
D	Teoria das Ondas Viajantes	19
E	Análises dos Métodos de Localização de Faltas em Linhas de Transmissão	19
E.1	Fundamentos para Localização de Faltas Utilizando Um Terminal	20
E.2	Fundamentos para Localização de Faltas Utilizando Dois Terminais	21
E.3	Componentes de Frequência Fundamental	21
E.4	Componentes de Alta Frequência	22
F	Coefficientes de Frequência Mel Cepstrais (MFCC)	24
F.1	<i>Cepstrum</i> Real	24
F.2	Filtros Triangulares em escala Mel	26
F.3	Processamento dos coeficientes MFCC	27
G	Ruídos em Linhas de Transmissão	28
H	Redes Neurais Artificiais (RNA)	30
H.1	Algoritmo Levenberg-Marquardt	31
I	Regressão de Vetores de Suporte (SVR)	31
J	Regressão de Vetores de Suporte com Mínimos Quadrados (LS-SVR)	33

K	Considerações Finais do Capítulo	33
3	ESTUDOS DOS MÉTODOS DE LOCALIZAÇÃO DE FALTAS EM LT	34
A	Revisão Bibliográfica	34
B	Relacionados a Componentes de Frequência Fundamental	36
C	Relacionados a Componentes de Alta Frequência	37
D	Relacionados a Aprendizado de Máquina	39
E	Considerações Finais do Capítulo	45
4	PROCEDIMENTO METODOLÓGICO	46
A	Abordagem Proposta Para Localização de Falhas	46
B	Sistema Elétrico de Potência Modelado no Software ATP	48
C	Aquisição dos Dados	55
D	Experimentação	56
D.1	Experimentos com o banco de dados total e sem inserir ruído nos sinais de falta	57
D.2	Experimentos com subconjuntos de banco de dados sem inserir ruído nos sinais de falta	58
D.3	Experimentos utilizando a melhor topologia de RNA com subconjuntos de banco de dados com inserção de ruído gaussiano nos sinais de falta	59
D.4	Análise do desempenho do melhor modelo frente à variação dos parâmetros de falta	60
D.5	Avaliação de desempenho	60
E	Considerações Finais do Capítulo	61
5	RESULTADOS E DISCUSSÕES	62
A	Resultados de experimentos com o banco de dados total e sem inserir ruído nos sinais de falta	62
B	Resultados de experimentos com subconjuntos do banco de dados original sem inserir ruído nos sinais de falta	65
C	Resultados de experimentos utilizando a melhor topologia de RNA com subconjuntos de banco de dados e inserção de ruído gaussiano nos sinais de falta	67
D	Resultados da análise do desempenho do melhor modelo frente à variação dos parâmetros de falta	70
D.1	Influência dos Tipos de Falhas	70
D.2	Influência das Resistências de Falhas	71
D.3	Influência dos Ângulos de Falhas	71
D.4	Influência das Distâncias de Falhas	72
E	Considerações Finais do Capítulo	73
6	CONCLUSÕES E TRABALHOS FUTUROS	75

A	Conclusões	75
B	Trabalhos Futuros	76
	REFERÊNCIAS	78
	APÊNDICE A – ARQUIVOS DE ENTRADA PARA O PROGRAMA	
	ATP/EMTP	88
A	Tipo de Falta AB, a 25 km, com 0 grau (taxa de amostragem de 400khz)	88
B	Tipo de Falta ABT, a 35 km, com 10 ohms e 45 graus (taxa de amostragem de 400khz)	89
C	Tipo de Falta ABC, a 55 km, com 90 graus (taxa de amostragem de 400khz)	90
D	Tipo de Falta ABCT, a 75 km, com 40 ohms e 0 grau (taxa de amostragem de 400khz)	92
E	Tipo de Falta AT, a 105km, com 440 ohms e 90 graus (taxa de amostragem de 400khz)	93
	APÊNDICE B – PROGRAMAS NO MATLAB PARA GERAR A BASE DE DADOS E A EXTRAÇÃO DOS COEFICIENTES MFCC	95
	APÊNDICE C – ANÁLISES MAIS DETALHADAS SOBRE USO DE SUBCONJUNTOS DA BASE PRINCIPAL E ADIÇÃO DE VÁRIAS RELAÇÕES SINAIS RUÍDOS NA PRECISÃO DOS MÉTODOS LOCALIZADORES DE FALTAS	103
A	Avaliação do Método Proposto com Subconjuntos da Base de Dados Original de 50 %, 25 %, 12,5 % e 6,25 %	103
B	Avaliação do Método Proposto Considerando Dados na Presença de Ruído Branco Gaussiano	104
B.1	Variando o tamanho da base de dados com SNR de 100 dB	104
B.2	Variando o tamanho da base de dados com SNR de 75 dB	105
B.3	Variando o tamanho da base de dados com SNR de 50 dB	105
B.4	Variando o tamanho da base de dados com SNR de 25 dB	106
B.5	Variando o tamanho da base de dados com SNR de 25 a 100 dB	106

1 INTRODUÇÃO

A Motivação e Relevância

Os Sistemas Elétricos de Potência (SEP) ¹ têm como principal papel o fornecimento de energia elétrica para diversas regiões distantes umas das outras, as quais estão sujeitas a interrupções no fornecimento de energia. Uma possibilidade de mitigar esse problema seria a implementação de um sistema imune a falhas, o que exigiria um grande esforço na redundância de equipamentos e de circuitos, além de altos investimentos, que culminariam em um custo muito elevado para os consumidores e para os fornecedores (ONS, 2021).

Devido à constante demanda por energia elétrica de toda a sociedade, disponibilizar energia com qualidade e de forma contínua é de extrema importância (COSTA, 2006). Entretanto, variados são os cenários nos quais os SEP têm o fornecimento de energia interrompido de forma programada ou de forma não programada (RODRIGUES Jr et al., 2020). As interrupções não programadas de energia podem ter as mais variadas causas, quais sejam: defeitos de equipamentos, descargas atmosféricas, vendavais, chuvas, queimadas, falhas nos sistemas de proteção e controle, erro humano na execução de serviços de manutenção, erro de operação, dentre outras (ONS, 2021). Ademais, dentre as interrupções não programadas, destacam-se as faltas permanentes, que, na maioria dos casos, necessitam de deslocamento de equipe até o local da falha para o reestabelecimento do sistema (AHMED et al., 2017).

Conforme a Agência Nacional de Energia Elétrica (ANEEL) e o Operador Nacional do Sistema Elétrico (ONS), os serviços de transmissão e de distribuição de energia elétrica no Sistema Interligado Nacional (SIN) ² devem satisfazer limites mínimos de qualidade de energia, relacionados tanto à disponibilidade quanto à continuidade de serviço. Assim, em casos nos quais a duração de desligamentos, programados ou não programados, ultrapassem os limites padrões de indisponibilidade estabelecidos pelos órgãos regulamentadores, penalidades em forma de multas ou de compensações financeiras aos consumidores afetados são aplicadas, onerando as concessionárias de energia elétrica (LOPES et al., 2014). Dessa maneira, busca-se formas cada vez mais eficientes de localização dos pontos de falta em um sistema, o que permite restabelecer o fornecimento de energia de forma rápida e mitigar os impactos negativos para o consumidor e para as concessionárias (CARNEIRO; RABELO; BRANCO, 2018).


O ONS concluiu, a partir dos indicadores de desempenho do SIN, ilustrados na Figura

¹ Sistemas elétricos de potência (SEP) consiste em subsistemas de Geração, de Transmissão e de Distribuição de energia elétrica e são suportados por equipamentos, processos e pessoas.

² O Sistema Interligado Nacional (SIN) é constituído por quatro subsistemas: Sul, Sudeste/Centro-Oeste, Nordeste e a maior parte da região Norte.

1, que as Linhas de Transmissão (LT)³ são responsáveis por originar, em média, 70 % das perturbações envolvendo a Rede Básica. As principais causas dessas perturbações são: condições climáticas adversas, queimadas, curto-circuitos e desligamentos não programados, ocasionando apagões. Esse panorama é justificado pela maior exposição das linhas em relação aos demais componentes do sistema elétrico (ONS, 2022).

Figura 1 – Número de Perturbações por tipo de componentes do SEP




Fonte: ONS (2022)

Para exemplificar as perturbações registradas na Figura 1, é possível citar a perturbação que aconteceu às 15h48min do dia 21 de março de 2018, em que um "apagão", ilustrado na Figura 2, atingiu todos os nove estados do Nordeste, além do Amazonas, do Pará, do Amapá e do Tocantins. Nas regiões Sul e Sudeste/Centro-Oeste, também ocorreram pequenos cortes de carga (ONS, 2018). Segundo a estimativa da ANACE (2018)⁴, tal "apagão" causou prejuízo de R\$ 600 milhões para a economia brasileira, além de ter deixado cerca de 70 milhões de consumidores sem energia elétrica.

³ Uma linha de transmissão (LT) é um sistema usado para transmitir energia eletromagnética do ponto de geração até o ponto de distribuição.

⁴ A Associação Nacional dos Consumidores de Energia (ANACE) representa os interesses dos consumidores brasileiros que têm a energia como um componente estratégico de suas atividades-fim.

Figura 2 – Estados do Nordeste e quatro do Norte afetados com interrupção total de energia



Fonte: ANACE (2018)

Dentre os vários componentes do SEP, as linhas de transmissão merecem uma atenção especial, visto que suas grandes extensões as tornam mais vulneráveis a possíveis ocorrências (HASSANI et al., 2019), conforme demonstrado na Figura 1. Além disso, essa característica revela a importância de se localizar com precisão as faltas em LT, na medida em que isso possibilita o direcionamento adequado das equipes de manutenção⁵ aos locais de ocorrência de falta, agilizando o restabelecimento do SEP (CHEN; HUANG; HE, 2016).

Dessa forma, a busca por meios de minimizar a duração de desligamentos decorrentes de faltas nos SEP tem motivado o desenvolvimento de diversos métodos de localização de faltas em linhas de transmissão, os quais têm sido cada vez mais utilizados por empresas atuantes na transmissão e na distribuição de energia elétrica (LOPES et al., 2014). Esses métodos são costumeiramente baseados em componentes de frequência fundamental ou em componentes de

⁵ Equipes de manutenção de LT são grupos profissionais que utilizam vias terrestres e/ou helicópteros para identificar o ponto exato da falta, procedimento este que pode ser lento em alguns casos, a depender do comprimento da LT, do relevo da região na qual a LT se encontra instalada, das condições climáticas no momento da inspeção e da precisão dos dispositivos localizadores (LOPES et al., 2014).

alta frequência. Recentemente, foram usadas ferramentas de Aprendizado de Máquina (AM), unindo-se características tanto de frequência fundamental quanto de alta frequência (MISHRA; RAY, 2017).

Dentre as propostas baseadas em componentes de frequência fundamental, têm-se algoritmos que utilizam como ferramenta de extração de características a Transformada de Fourier (PHADKEDR; THORP, 2009; SWETAPADMA; YADAV, 2018), a Teoria dos Mínimos Quadrados (AJAEI; SANAYE-PASAND, 2008) e a Transformada de *Wavelet* (LIANG; JEYASURYA, 2004; SILVA et al., 2008; LIVANI; EVRENOSOGLU, 2014; YADAV; SWETAPADMA, 2015; ASHOK et al., 2019), nas quais os parâmetros são muito sensíveis a ruído (SAMANTARAY, 2013), além de abordagens com filtros (SIDHU et al., 2003; GUO; KEZUNOVIC; CHEN, 2003; LEE; KANG; NAM, 2008). Apesar de suas particularidades, todos esses algoritmos atuam estimando a impedância da linha entre o ponto de medição e o ponto de falta (LOPES et al., 2018). A estimativa da impedância, por sua vez, dá-se através do cálculo dos fasores, com a inspeção das variações de fase e de módulo das tensões durante a falta (ALMEIDA et al., 2017). Entretanto, elementos como resistência de falta, carregamento de linha, parâmetros da fonte e contribuição de corrente do terminal remoto podem prejudicar a acurácia de tais métodos (YUMURTACI et al., 2016).

Já as propostas baseadas em componentes de alta frequência têm como núcleo a Teoria das Ondas Viajantes (HASHEMINEJAD et al., 2016; LOPES et al., 2018). Inicialmente, procura-se determinar dois tipos de informações, a saber: 1) a velocidade de propagação da onda de tensão na LT; 2) o intervalo de tempo que essa tensão ou corrente levou para percorrer a distância entre o ponto de falta e o terminal da linha onde está instalado o localizador (FEI; QI; LI, 2018). Dessa maneira, o sistema é capaz de definir com maior precisão a distância da falta na LT (ZHANG; SHU; LIAO, 2016).

Salienta-se a necessidade de identificar rigorosamente o instante de incidência das ondas viajantes nos terminais da linha. Da mesma forma, deve-se garantir que as informações obtidas do transitório do distúrbio sejam pertinentes, posto que, com base nestas, serão desenvolvidas expressões matemáticas associadas à distância da falta (CHEN; HUANG; HE, 2016). Como consequência de tais especificidades, numerosas pesquisas propuseram maneiras de acelerar o reconhecimento dos transitórios (SILVA et al., 2008; LIN et al., 2008; LOPES et al., 2011; LOPES; FERNANDES; NEVES, 2013; COSTA, 2014). A obtenção de informações pertinentes se dá mediante análise espectral dos transitórios no período de falta ou até mesmo no período logo após seu isolamento (FAYBISOVICH; FEIGINOV; KHOROSHEV, 2010; SHI; TROELTZSCH; KANOUN, 2010; NGU; RAMAR, 2011; IURINIC, 2013; MAMIS; ARKAN; KELEŞ, 2013; DOBAKHSHARI, 2018). Por fim, vale destacar que um dos maiores obstáculos desse método é a necessidade de se utilizar altas taxas de amostragem, o que, apesar do custo, vem se tornando um problema cada vez menor em face da produção de processadores cada vez mais rápidos (ALMEIDA et al., 2017).

Métodos relacionados à AM têm se destacado recentemente na literatura correlata. Diversas pesquisas foram conduzidas nas últimas décadas, por meios como a Lógica *Fuzzy* (REDDY; MOHANTA, 2008; SAMANTARAY, 2013; HASSANI et al., 2019) e os Algoritmos Genéticos (DAVOUDI; SADEH; KAMYAB, 2012; AHMED et al., 2017), assim como as Redes Neurais Artificiais (RNAs) (SADINEZHAD; AGELIDIS, 2009; YADAV; SWETAPADMA, 2015) e outras propostas baseadas em Regressão de Vetores de Suporte (SVR) (YUSUFF et al., 2011; YUSUFF; JIMOH; MUNDA, 2014; ALMEIDA et al., 2017; FEI; QI; LI, 2018), no Método dos Vizinhos Mais Próximos (k-NN) (SWETAPADMA; YADAV, 2018) e também propostas baseadas em Regressão de Vetores de Suporte com Mínimos Quadrados (LS-SVR) (UYAR, 2012).

Outro aspecto da análise de faltas em linhas de transmissão é a existência de correlação entre ruído e defeitos nas linhas de transmissão, que, eventualmente, culminam em falhas. A partir da literatura, sabe-se que a presença de ruídos de natureza elétrica nos sinais avaliados pode ocasionar a detecção errônea de transitórios (ALMEIDA et al., 2017). Assim, estudos apontam a importância de se investigar a influência de ruído em condições de faltas em LT (BIRLASEKARAN; LI, 2000; BELLO; CORRÊA, 2008; ALMEIDA et al., 2017).

Vários trabalhos da literatura correlata têm empregado um extrator de características em conjunto com ferramentas de AM, a fim de: reduzir o tempo computacional dos algoritmos propostos, mitigar erros de estimativa decorrentes de ruídos, identificar a localização da falha de toda a linha sem área escura e, por fim, reduzir a influência de diversos parâmetros, como impedância de falta, tipo de falta, ângulo de falta, dentre outros, nos algoritmos de localização.

Dessa forma, esta pesquisa sistematizou os principais estudos sobre o tema e observou a ausência de abordagens sobre a técnica de extração de características dos sinais transitórios de faltas em LT por meio dos Coeficientes de Frequência Mel Cepstrais (MFCC)⁶. Diante disso, combinou-se os coeficientes MFCC com algoritmos de AM, sendo desenvolvidos modelos de RNA, SVR e LS-SVR⁷, para a detecção e a localização de faltas em uma LT real, com e sem ruído. Foi utilizada como objeto de estudo e de teste das técnicas propostas a linha de transmissão de 500 kV que interliga a subestação de Teresina (PI) à subestação de Sobral (PI) da Companhia Hidrelétrica do São Francisco (CHESF).

B Objetivos

Os objetivos almejados neste trabalho estão divididos em geral e em específicos, como apresentados a seguir:

⁶ Os MFCC consistem no *cepstrum* real de um sinal definido por uma janela.

⁷ RNA, SVR e LS-SVR são algoritmos de aprendizado de máquina que se baseiam no comportamento do cérebro humano.

B.1 Objetivo geral

Este trabalho tem como objetivo geral propor um procedimento metodológico capaz de localizar, com baixa taxa de erro, pontos de falta em LT, mediante uso de sinais de tensão com extração de características por meio dos coeficientes MFCC e algoritmos de aprendizado de máquina, usando modelos distintos com RNA, SVR e LS-SVR, a fim de realizar uma comparação entre os resultados objetivos por cada um. Esses modelos usam como entrada os coeficientes MFCC obtidos dos sinais de tensão dos dois terminais da linha. Utilizou-se uma LT modelada com base em parâmetros de uma linha real.

B.2 Objetivos específicos

Os objetivos específicos são apresentados a seguir:

- Verificar se os coeficientes MFCC são capazes de fornecer boas características para uma estimativa precisa de distância de falta;
- Avaliar a influência de diferentes níveis de ruídos, ângulos de incidência, resistências e tipos de falta na estimativa da distância de falta;
- Avaliar o desempenho de diferentes modelos de aprendizagem de máquinas na localização de falta em sinais com e sem ruído, frente a variação do tamanho dos conjuntos de treinamento utilizados;
- Identificar a localização de falta de toda a linha sem área escura; e
- Comparar o desempenho da solução proposta com outras estudadas até o momento.

C Contribuições

As principais contribuições deste trabalho foram:

- Emprego inédito dos MFCC obtidos dos sinais de tensão como características para localização de faltas em linhas de transmissão;
- Comparação do desempenho de modelos de AM com diferentes conjuntos de entrada, a fim de identificar o melhor conjunto de MFCC para a taxa de amostragem utilizada; e
- Análise da influência do tamanho da base de dados de treinamento e da quantidade de ruído presente no sinal para a performance da metodologia proposta.

O seguinte artigo foi publicado:

MARQUES, J. A. A.; BRANCO, H. C. Localização de Faltas em Linha de Transmissão Utilizando Coeficientes de Frequência Mel Cepstrais (MFCC) e Redes Neurais Artificiais (RNA).

SBA Sociedade Brasileira de Automática: CBA2020, v. 2, 2020. ISSN 2525-8311. Disponível em: https://www.sba.org.br/open_journal_systems/index.php/sba/article/view/1037

D Organização do Texto

O presente trabalho é constituído por sete capítulos, que estão distribuídos, resumidamente, da seguinte maneira:

- No Capítulo 2, apresentou-se o referencial teórico do tema a ser desenvolvido, na medida em que se abordou alguns dos principais conceitos sobre modelos de linhas de transmissão e sobre variações de tensão e de corrente envolvidas nas faltas em LT, além de processamento de sinais para localização de faltas em LT. Foram abordados, ainda, os fundamentos para localização de faltas com a utilização de dois terminais e, também, as análises requeridas pelos métodos de localização de faltas abordados nesta tese. Além disso, foi feita uma breve explanação sobre os coeficientes MFCC, sobre ruídos em linhas de transmissão e sobre os principais modelos de aprendizado de máquina (RNA, SVR e LS-SRV);
- No Capítulo 3, são analisados estudos dos métodos de localização de faltas em LT, realizando-se uma revisão bibliográfica das publicações relevantes no âmbito de localização de faltas, principalmente aquelas relacionadas a componentes de frequência fundamental, de alta frequência ou de AM;
- No Capítulo 4, foi abordada a proposta, com descrição do procedimento metodológico elaborado para localização de faltas, destacando-se o novo algoritmo para detecção de transitórios de falta;
- No Capítulo 5, foi mostrada a experimentação, contemplando-se a apresentação dos dispositivos usados para a modelagem do sistema elétrico de potência no software ATP, além dos parâmetros da experimentação;
- No Capítulo 6, realizou-se a avaliação dos resultados e a discussão do método proposto, considerando tanto dados sem ruído, como também dados na presença de ruído branco gaussiano. Além disso, avaliou-se o desempenho da técnica proposta com a utilização de percentuais de 50 %, 25 %, 12,5 % e 6,25 % da base de dados original. Ademais, também se variou o tamanho da base em conjunto à adição de Relação Sinal-Ruído (SNR) em diferentes simulações. Ao final, como forma de comparar o desempenho do método proposto, foram realizados testes alterando os modelos de aprendizado: RNA, SVR e LS-SVR na tentativa de investigação de melhora da localização encontrada;
- No Capítulo 7, foram relatadas as conclusões proporcionadas pela dissertação, apresentadas sugestões para melhorias e propostas alternativas para trabalhos futuros;

- No Apêndice A, foram apresentados exemplos de arquivos com formatos utilizados pelo programa ATP/EMTP para o cálculo dos parâmetros de uma linha de transmissão de 330 Km;
- No Apêndice B, foram apresentados programas em MATLAB utilizados para gerar a base de dados e a extração dos coeficientes MFCC, que são tratados nesta tese; e
- No Apêndice C, foram apresentadas análises mais detalhadas sobre uso de subconjuntos da base principal e adição de várias relações sinais ruídos na precisão dos Métodos Localizadores de Faltas.

2 REFERENCIAL TEÓRICO

O intuito dessa seção é abordar todos os conceitos que se relacionam às variações de tensão e de corrente envolvidas nos distúrbios em LT, os modelos de linhas de transmissão discutidos na literatura, os parâmetros concentrados e distribuídos, os tipos de falta e os métodos de processamento de sinais para extrair características importantes da tensão e da corrente no momento de ocorrência da falta. Por fim, o objetivo é abordar também os problemas de localização de faltas e como eles são expostos na literatura, bem como os princípios básicos de funcionamento dos algoritmos relacionados ao cálculo dos coeficientes MFCC e dos modelos de AM.

A Modelos de Linha de Transmissão

Desde a década de 1960, encontram-se trabalhos que relacionam ou que definem modelos de LT no meio científico (COLQUI et al., 2020). A escolha do modelo de linha de transmissão tem impacto direto na precisão do localizador de falta. Uma das formas de se relacionar os modelos de LT encontrada na literatura conta com a diferenciação de parâmetros concentrados e distribuídos.

Um dos parâmetros para se trabalhar a diferença entre esses modelos é a extensão das linhas de transmissão. Nesse caso, linhas de transmissão seriam consideradas curtas quando sua extensão fosse menor ou igual a 80 km, enquanto as médias teriam extensão entre 80 km e 250 km. Nessas duas situações, o modelo de transmissão se enquadraria no modelo baseado em parâmetros concentrados. Já nos casos em que a extensão superaria os 250 km, seriam classificadas de acordo com os modelos baseados em parâmetros distribuídos, os quais devem considerar o tempo de propagação. Em situações em que a linha é curta, o tempo de propagação é desconsiderado (SAHA; IZYKOWSKI; ROSOLOWSKI, 2010).

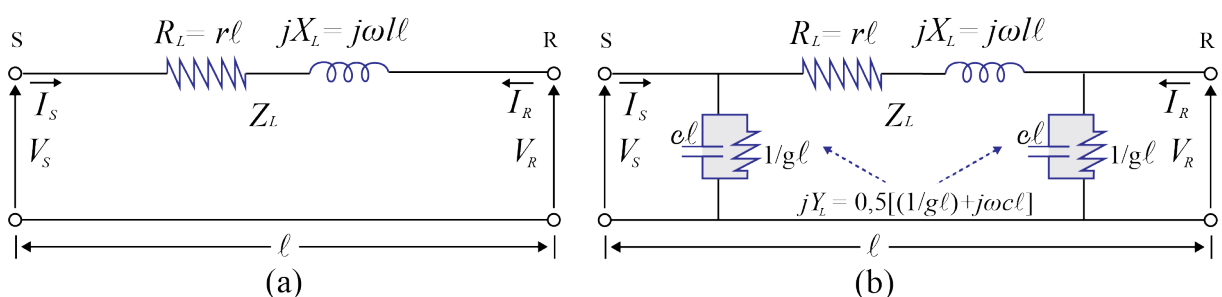
A.1 Baseados em Parâmetros Concentrados

Representado de maneira simples, com apenas uma impedância, o modelo de parâmetros concentrados é dado por sua impedância série Z_L entre os terminais S e R, ou seja, emissor e receptor da linha. No cálculo dessa impedância, normalmente se leva em consideração a frequência fundamental do sistema elétrico de potência. Considera-se, neste modelo, uma linha de transmissão de até 80 km, desprezando-se o efeito capacitivo (GLOVER; SARMA; OVERBYE, 2011). Logo, o modelo de parâmetro concentrado simples é formado por uma resistência R_L e uma reatância indutiva X_L em série, conforme apresentado na Figura 3(a). Nessa figura, as tensões nos terminais S e R são representadas como V_S e V_R , respectivamente; as correntes nos

terminais S e R como I_S e I_R ; a resistência e a indutância por unidade de comprimento como r e l , respectivamente; a frequência angular fundamental do SEP como ω ; a impedância da LT como Z_L e o comprimento da Linha de Transmissão como ℓ (LOPES, 2014).

No caso de linhas de comprimento médio, entre 80 Km e 250 km, é comum a inclusão de admitâncias em derivação no modelo a parâmetros concentrados da LT, desprezando-se suas condutâncias. Nesses casos, restam apenas as reatâncias capacitivas em derivação para a representação do efeito capacitivo dos condutores. Uma ação muito utilizada é dividir a admitância em duas parcelas iguais, inseridas nas extremidades da linha de transmissão, conforme mostrado na Figura 3(b). Nessa figura, Y_L representa a admitância; g e c , a condutância e a capacitância em derivação, respectivamente, por unidade de comprimento (SAHA; IZYKOWSKI; ROSOŁOWSKI, 2010).

Figura 3 – Modelo de LT baseado em parâmetros concentrados: (a) linhas curtas ($\ell < 80$ km); (b) linhas médias ($80 \leq \ell < 250$ km)



Adaptado de Zanetta Jr. (2020)

É desconsiderado o tempo de propagação nos modelos, devido a baixa extensão dos mesmos. Diante disso, será apresentado na próxima seção o modelo de LT baseado em parâmetros distribuídos, que leva em consideração a propagação da onda e a condutância em derivação. Observa-se, ainda, que esse modelo também é dependente da frequência (LOPES, 2014).

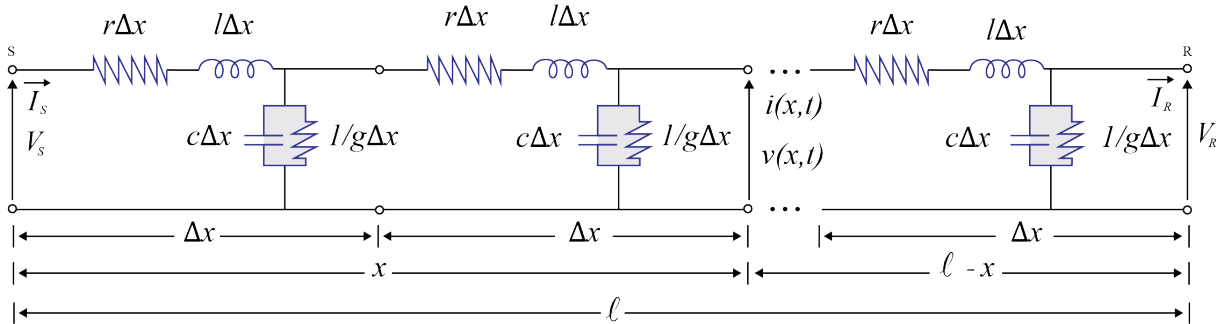
A.2 Baseados em Parâmetros Distribuídos

A partir da análise dos modelos baseados em parâmetros distribuídos, o comprimento do condutor é um critério muito importante a ser considerado, incluindo-se os efeitos do tempo de propagação da onda. A distância do ponto em que os cálculos serão realizados, as tensões e as correntes ao longo da LT são valores utilizados para os cálculos das grandezas elétricas (SAHA; IZYKOWSKI; ROSOŁOWSKI, 2010).

O modelo baseado em parâmetros distribuídos, ilustrado na Figura 4, mostra o circuito equivalente de uma linha de transmissão longa de comprimento ℓ . Esse circuito é composto por elementos resistivos, representados em série por r , indutivos, representados em série por l , e capacitivos, representados por c , de uma linha de transmissão monofásica de comprimento Δx . A

uma distância x do terminal S , há o ponto X , local a ser medido e analisado, no qual é verificada uma tensão $v(x,t)$ e uma corrente $i(x,t)$ (LOPES, 2014).

Figura 4 – Modelo de LT baseado em parâmetros distribuídos



Fonte: Adaptado de Zanetta Jr. (2020)

Tomando por base o valor da tensão $v(x,t)$ e o valor da corrente $i(x,t)$, foi elaborada uma relação entre esses dois valores, usando as equações 2.1 e 2.2 (NAIDU, 1985).

$$-\frac{\partial v(x,t)}{\partial x} = r \cdot i(x,t) + l \cdot \frac{\partial i(x,t)}{\partial t} \quad (2.1)$$

$$-\frac{\partial i(x,t)}{\partial x} = g \cdot v(x,t) + c \cdot \frac{\partial v(x,t)}{\partial t} \quad (2.2)$$

Para expor as variações da tensão $v(x,t)$ e da corrente $i(x,t)$, foram usadas as equações 2.1 e 2.2, contrapondo-as com x , temos (NAIDU, 1985):

$$-\frac{\partial^2 v(x,t)}{\partial x^2} = r \cdot \frac{\partial i(x,t)}{\partial x} + l \cdot \frac{\partial^2 i(x,t)}{\partial x \cdot \partial t} \quad (2.3)$$

$$-\frac{\partial^2 i(x,t)}{\partial x^2} = g \cdot \frac{\partial v(x,t)}{\partial x} + c \cdot \frac{\partial^2 v(x,t)}{\partial x \cdot \partial t} \quad (2.4)$$

Ao alterar $\partial i(x,t)/\partial x$, presente em 2.2, na 2.3, e também $\partial v(x,t)/\partial x$, apresentada em 2.1, da 2.4, gerou-se novas equações equivalentes a 2.1 e 2.2, respectivamente (NAIDU, 1985):

$$\frac{\partial^2 v(x,t)}{\partial x^2} = r \cdot g \cdot v(x,t) + (r \cdot c + l \cdot g) \cdot \frac{\partial v(x,t)}{\partial t} + l \cdot c \cdot \frac{\partial^2 v(x,t)}{\partial t^2} \quad (2.5)$$

$$\frac{\partial^2 i(x,t)}{\partial x^2} = r \cdot g \cdot i(x,t) + (r \cdot c + l \cdot g) \cdot \frac{\partial i(x,t)}{\partial t} + l \cdot c \cdot \frac{\partial^2 i(x,t)}{\partial t^2} \quad (2.6)$$

Naidu (1985) apresenta essas duas novas equações, 2.5 e 2.6, denominadas equações telegráficas.

Levando-se em consideração uma LT sem perdas, em que g e r estão zerados, há a possibilidade de simplificar as equações 2.7 e 2.8, também denominadas equações de ondas (NAIDU, 1985).

$$\frac{\partial^2 v(x,t)}{\partial x^2} = l \cdot c \cdot \frac{\partial^2 v(x,t)}{\partial t^2} \quad (2.7)$$

$$\frac{\partial^2 i(x,t)}{\partial x^2} = l \cdot c \cdot \frac{\partial^2 i(x,t)}{\partial t^2} \quad (2.8)$$


As equações acima têm suas soluções gerais simplificadas conforme as equações 2.9 e 2.10, sendo $Z_c = \sqrt{l/c}$ a impedância característica e $v_p = \sqrt{1/lc}$, a velocidade de propagação das ondas para uma linha de transmissão sem perdas.

$$v(x,t) = f_1 \left(t - \frac{x}{v_p} \right) + f_2 \left(t + \frac{x}{v_p} \right) \quad (2.9)$$

$$i(x,t) = \frac{1}{Z_c} \left[f_1 \left(t - \frac{x}{v_p} \right) + f_2 \left(t + \frac{x}{v_p} \right) \right] \quad (2.10)$$

Dessa forma, as equações 2.9 e 2.10 representam a superposição de duas ondas eletromagnéticas que viajam em sentidos opostos ao longo da linha de transmissão, representadas pelas funções f_1 e f_2 . A primeira função, chamada de "ondas progressivas", propaga-se no sentido do terminal S para o R. Já a segunda, chamada de "ondas regressivas", propaga-se do terminal R para o S. Suas polaridades e sentidos de propagação são mostrados na Figura 5 (LOPES, 2014).

Figura 5 – Ondas regressivas e progressivas

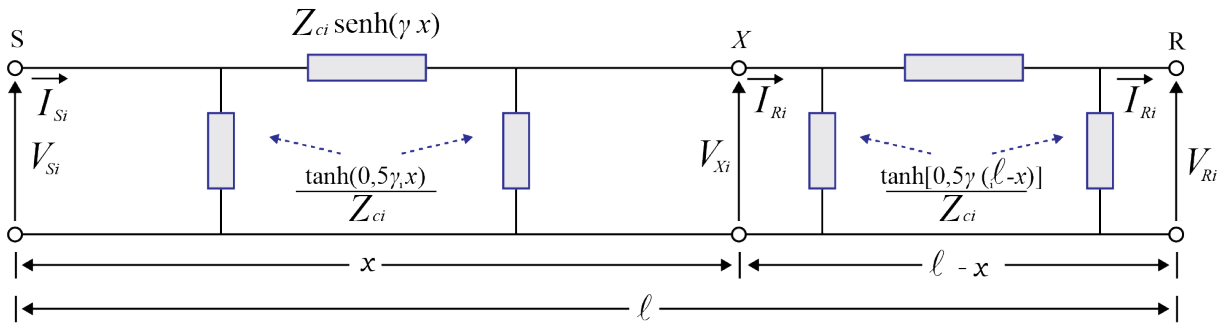


Fonte: Adaptado de Zanetta Jr. (2020)

A Figura 5 apresenta as variações nas tensões e nas correntes que percorrem, na forma de ondas eletromagnéticas, o eixo x da linha de transmissão. Dessa forma, estas não são percebidas instantaneamente nos terminais da linha de transmissão monitorada. Portanto, em linhas de transmissão longas, faz-se necessário o uso do modelo de linha baseado em parâmetros distribuídos. Nesse modelo, é possível analisar os níveis de tensão e de corrente sem desprezar as ondas que viajam ao longo da linha (LOPES, 2014).

A estimativa da distância de falta em linhas de transmissão longas, baseada em componentes de frequência fundamental, pode ser realizada através da avaliação das grandezas desacopladas do sistema elétrico (GLOVER; SARMA; OVERBYE, 2011), conforme apresentado no circuito equivalente da Figura 6.

Figura 6 – Modelo da LT a parâmetros distribuídos para a i -ésima componente simétrica



Fonte: Adaptado de Zanetta Jr. (2020)

A i -ésima componente simétrica é considerada na análise do circuito da Figura 6, sendo $i = 1$ a sequência positiva, $i = 2$, a sequência negativa, $i = 0$, a sequência zero e γ_i , a constante de propagação da linha de transmissão para i -ésima componente de sequência (SAHA; IZYKOWSKI; ROSOLOWSKI, 2010).

$$\gamma_i = \sqrt{(r_i + j\omega l_i)(g_i + j\omega c_i)} \quad (2.11)$$

A impedância característica Z_{ci} da LT para a i -ésima componente de sequência é dada por:

$$Z_{ci} = \sqrt{\frac{r_i + j\omega l_i}{g_i + j\omega c_i}} \quad (2.12)$$

Considera-se r_i , l_i , g_i e c_i a resistência série, a indutância série, a condutância em derivação e a capacitância em derivação, respectivamente, por unidade de comprimento, para a i -ésima componente de sequência.

Finalmente, como as tensões e as correntes no ponto X dependem da distância x do terminal S, é possível avaliar as tensões e as correntes do sistema monitorado sem desprezar os efeitos dos parâmetros distribuídos da linha. Os fundamentos apresentados nesta subseção são muito utilizados como base para a elaboração de diversos métodos de localização de faltas em LT longas. Ou seja, os modelos de linhas apresentados são essenciais para as técnicas de detecção de transitórios da linha de transmissão estudadas nesta pesquisa.

B Variações de Tensões e Correntes Envolvidas nas Faltas em LT

Entre os possíveis distúrbios que podem ocorrer em um SEP, as faltas em linha de transmissão são as mais preocupantes, visto que ocasionam desligamentos não-programados dos sistemas. Além disso, há um alto grau de dificuldade na interpretação e/ou diagnóstico da origem exata dessas faltas (ESCOTO, 2020). As faltas, ainda, são causadas por modificações nos parâmetros normais do sistema elétrico de potência (SEP), através de curtos-circuitos de diversos tipos, quais sejam: monofásicos envolvendo a terra (FT), bifásicos (FF), bifásicos envolvendo a terra (FFT), trifásicos (FFF) e trifásicos envolvendo a terra (FFFT). Além disso, as faltas podem ser do tipo balanceada ou desbalanceada. A balanceada acontece nas três fases da mesma maneira, podendo ser chamada também de falta trifásica ou falta trifásica envolvendo terra. A desbalanceada, por sua vez, pode ser monofásica, bifásica ou bifásica envolvendo terra.

Além disso, as faltas podem ser classificadas também em permanentes¹ ou em transitórias² (PARMAR, 2015; TLEIS, 2019).

Na Tabela 1, apresenta-se mais detalhes de cada tipo de falta e de suas frequências de ocorrência na rede elétrica. Essa tabela evidencia que os tipos mais frequentes são as monofásicas, consistindo em 70 % das faltas, e as bifásicas sem terra, que representam 15 % das faltas (SATO; FREITAS, 2015).

Tabela 1 – Frequências típicas de ocorrências por tipo de faltas

Tipos de faltas	Frequência (%)
Monofásicas envolvendo terra	70
Bifásicas	15
Bifásicas envolvendo terra	10
Trifásicas	5

Fonte: Adaptado de Sato e Freitas (2015)

Os parâmetros de configuração das LTs são modificados pelas condições climáticas e pela vegetação da região em volta da linha de transmissão, as quais podem gerar curtos-circuitos. Assim, quaisquer modificações que provoquem alterações nos parâmetros de configuração das LTs podem gerar grandes variações de magnitude na tensão e na corrente e, ainda, no seu ângulo de fase. Essa situação gera transitórios com sobretensões, cujas amplitudes dependem das características do tipo de falta e do aterramento do SEP em questão (ZANETTA Jr., 2020).

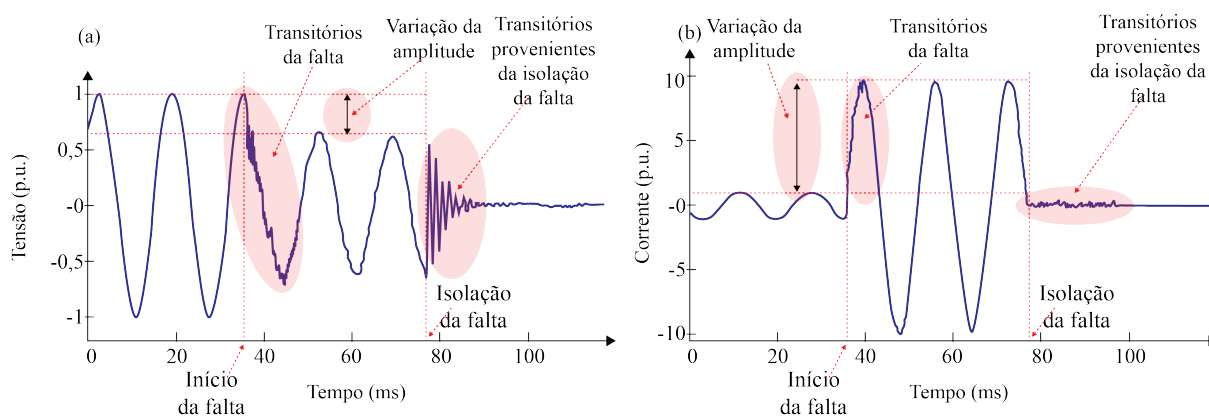
¹ Falta permanente é quando, mesmo após a sequência de tentativas de religamento estabelecidas pela concessionária ou pelo proprietário da linha, não se consegue reenergizar, mantendo assim um circuito aberto para que não ocorram mais danos ao sistema (PARMAR, 2015).

² Falta transitória é quando, após uma sequência de tentativas de religamentos, a linha pode ser reestabelecida com sucesso, porém ocorre, com isso, a propagação de ondas que podem desestabilizar as fases, sendo assim prejudiciais para o sistema elétrico (PARMAR, 2015).

Lopes (2014) afirma que, além dos transitórios gerados no SEP devido à ocorrência e ao isolamento de faltas durante o distúrbio, as amplitudes e os ângulos de fase das tensões e das correntes do sistema estabilizam em condições diferentes das nominais, atingindo valores que dependem das características do curto-circuito. Então, para localizar a falta ou o seu tipo em uma LT, analisa-se os transitórios provenientes da falta ou as mudanças oscilográficas dos sinais de tensão e de corrente no momento da sua ocorrência (FAYBISOVICH; FEIGINOV; KHOROSHEV, 2010).

A Figura 7 mostra as mudanças oscilográficas reais de uma falta na Fase C para uma linha de 230 kV, na qual ficam aparentes as variações nas formas de onda da tensão e da corrente na ocorrência e no isolamento da falta.

Figura 7 – Registro oscilográfico real de uma falta na Fase C em uma LT de 230 kV: (a) variações nas formas de onda de tensão; (b) variações nas formas de onda da corrente.



Fonte: Adaptado de Lopes (2014)

Conclui-se que a base dos métodos de localização de faltas se fundamenta na análise das variações nas tensões e nas correntes de um SEP durante e/ou após curtos-circuitos. Os estudos dos transitórios provenientes de tais variações é de grande importância para o desenvolvimento desta proposta.

B.1 Representação Fasorial

O monitoramento é realizado nas medições oscilográficas de tensão e de corrente durante todas as segmentações do circuito trifásico, que, em situações normais, possui um regime contínuo. Mas, no momento de ocorrência da falta, há uma alteração no sinal, descrita como $s(t)$, em função do tempo. Dessa forma, armazena-se os valores obtidos da onda senoidal a cada momento. Tal alteração no sinal é apresentada de forma mais simples na equação 2.13 (JUNIOR, 2013).

$$s(t) = s_m \cos(\omega t + a) \quad (2.13)$$

Sendo:

- s_m A amplitude do sinal
- $\omega = 2\pi f \text{ rad/s}$ A frequência angular fundamental em rad./s
- α é a fase


A representação fasorial consiste na substituição das informações de intensidade instantânea do sinal pelas informações de amplitude e de fase. Tais parâmetros indicam o formato da onda senoidal presente no componente de frequência fundamental do sinal descrito na equação 2.13. Entretanto, apresenta-se uma nova formulação, utilizada para descrever o domínio fasorial na equação 2.14

$$s(t) = \Re\{s_m e^{j(\omega t + \alpha)}\} \quad (2.14)$$

B.2 Componentes Simétricos

Devido a complexidade dos sistemas desequilibrados, ambiente este comum em LT, têm-se a necessidade de buscar formas alternativas para viabilizar as análises destas linhas, sendo uma rotina aplicável a transformação do sistema desequilibrado possuindo 3 fases em 3 sistemas equilibrados: o positivo, negativo e o de sequência zero. Com o estudo dos componentes equilibrados nota-se que, conforme ilustrado na Figura 8, a sequência positiva (abc), mostrado na Figura (8a), é composta por 3 fasores com seus valores de módulo semelhantes e defasados 120° entre si com sequência de fase semelhante aos fasores originais. A sequência negativa (cba), mostrado na Figura 8b, é semelhante a positiva, diferindo apenas na sequência de fase que se apresenta oposta aos fasores, e a sequência zerada, mostrado na Figura 8c, possui defasagem nula (STEVENSON Jr., 1986).

Figura 8 – Diagrama fasorial de sequência a) positiva, b) negativa e c) zero



Fonte: Adaptado de Stevenson Jr. (1986)

No qual Stevenson Jr. (1986) expressa de forma conclusiva a transformação para os componentes simétricos pelas equações 2.15, 2.16 e 2.17.

$$V_{a0} = \frac{1}{3} (V_a + V_b + V_c) \quad (2.15)$$

$$V_{a1} = \frac{1}{3} (V_a + aV_b + a^2V_c) \quad (2.16)$$

$$V_{a2} = \frac{1}{3} (V_a + a^2V_b + aV_c) \quad (2.17)$$

Sendo:

- V_{a1} a componente de sequencia positiva;
- V_{a2} a componente de sequencia negativa;
- V_{a3} a componente de sequencia zero;

C Ferramentas de Processamento de Sinais normalmente utilizadas para Localização de Faltas em LT

Entre as técnicas de processamento de sinais encontradas na literatura, ganham destaque as que operam nos domínios da frequência, do tempo e do tempo-frequência. Dentre elas, a Transformada de Fourier faz a extração das características do sinal apenas no domínio da frequência, apresentando a desvantagem de não informar o tempo, o que torna inviável a extração de informações de sinais não estacionários, como as ondas viajantes. Entretanto, no domínio tempo-frequência, é aplicada a Transformada Rápida de Fourier e a Transformada *Wavelet* para extrair características do sinal (PHADKEDR; THORP, 2009).

C.1 Transformada de Fourier

Uma das formas mais utilizadas para o cálculo dos componentes de frequência é a Transformada de Fourier (TF), que faz uso das funções seno e cosseno. Vale destacar uma deficiência da equação, qual seja, a falta de dados sobre o tempo de frequência do sinal. A TF é realizada através da equação 2.18 (PHADKEDR; THORP, 2009).

$$TF(w) = \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt \quad (2.18)$$

As variáveis específicas são:

- (w) Variável da frequência
- (t) variável tempo

C.2 Transformada Rápida de Fourier

A Transformada de Fourier (TF) fornece somente informações sobre a frequência do sinal. Tal problema é resolvido através da Transformada Rápida de Fourier (TRF), aplicando-se uma técnica de janelamento (PHADKEDR; THORP, 2009).

$$TF(w) = \int_{-\infty}^{\infty} f(t) W(t-T) e^{-j\omega t} dt \quad (2.19)$$

As variáveis específicas são:

- $W(t-T)$, é uma função que realiza o janelamento;
- (w) variável de frequência;
- (T) é uma função que faz a translação do sinal.

A TRF é uma adaptação da TF convencional e utiliza a técnica de janelamento para manter a referência de tempo associada ao tamanho do deslocamento de cada janela. No entanto, a janela da TRF e seu deslocamento são ajustados manualmente para cada situação, a fim de manter uma relação equivalente entre o tempo e a frequência do sinal analisado (PHADKEDR; THORP, 2009).

C.3 Transformada Discreta dos Cossenos

A Transformada Discreta dos Cossenos (DCT, do inglês *Discrete Cosine Transform*) é amplamente utilizada para reduzir a quantidade de sinais ou dados de imagens. Justifica-se seu uso nos casos em que se precisa de transformações de sinais de amplitude que variem pelo tempo, em sinais de frequência espaciais. Outra característica da DCT é que esta concentra energia nos primeiros coeficientes do sinal. O DCT em si não introduz perda no sinal. Tal efeito acontece somente após o descarte de componentes de menor energia e o preenchimento por zeros para compressão, os quais introduzem uma perda irreversível de informação (BIRVINSKAS et al., 2015).

A abordagem desse cálculo é realizar uma mudança entre o domínio do sinal, a fim de viabilizar uma operação inversível, refazendo o conjunto de dados de entrada inicial. Nesse cálculo, um sinal com N dados é processado, gerando-se uma matriz $N \times N$, que é multiplicada por T , cuja inversa é dada por T^{-1} . Observa-se que x representa um dado da entrada, δ_k , a Delta de Kronecker e, além disso, os coeficientes DCT são apresentados por Shu, Wu e Liu (2017), na seguinte fórmula:

$$y(k) = \sqrt{\left(\frac{2}{N}\right)} \sum_{n=1}^N x(n) \frac{1}{\sqrt{1 + \delta_{k1}}} \cos\left(\frac{\pi}{2N}(2n-1)(k-1)\right). \quad (2.20)$$

D Teoria das Ondas Viajantes

As Ondas Viajantes (OV) podem ser desencadeadas por qualquer interferência causada por raio ou por interrupção em condições de estado estacionário, o que faria com que as ondas eletromagnéticas se propagassem a partir do local de ocorrência do raio ou do curto circuito (NAIDU, 1985). Bewley (1931) propôs um método para localização e diagnóstico de transitórios que foi a base para muitas pesquisas, Dommel (1986) fundamentou teorias baseadas na teoria de ondas viajantes para sistemas de proteção, mas devido à alta taxa de amostragem, não existia tecnologia viável na época, e isso só foi possível após o advento da tecnologia digital dos reles de proteção.

Contudo, visto o enorme desenvolvimento dos conversores analógicos/digitais (A/D) de alta velocidade e da tecnologia dos transdutores de corrente e tensão capazes de registrar os transitórios oriundos de uma falta com altas taxas de amostragem, a sua aplicação tem-se tornado viável (SILVA; OLESKOVICZ; COURY, 2005).

Do exposto acima, temos que qualquer distúrbio em uma linha de transmissão (tal como os provocados por descargas atmosféricas, curtos-circuitos, ou uma alteração da condição de regime permanente) dá origem a ondas viajantes, as quais representam uma composição de frequência, que pode variar de poucos kilohertz a diversos megahertz. Essas por sua vez, deslocam-se no sentido das extremidades da linha de acordo com a velocidade de propagação característica da mesma. Quando estas ondas viajantes encontram certas discontinuidades físicas do sistema, estas discontinuidades provocam a sua reflexão ou refração. Este sucessivo processo continua até que as ondas sejam atenuadas e ou extintas devido às perdas na linha, alcançando o regime permanente do distúrbio (SILVA; OLESKOVICZ; COURY, 2005).

Quando uma onda viajante atinge uma discontinuidade, ou seja, um ponto de transição no qual há uma súbita mudança nos parâmetros do circuito, tais como num terminal aberto, uma junção com uma outra linha, um enrolamento de uma máquina ou transformador etc., uma parte da onda é refletida para trás, e outra parte, transmitida para a sessão seguinte do circuito. A onda que chega na discontinuidade é chamada de onda incidente e as duas ondas oriundas da discontinuidade são chamadas de ondas refletidas e refratadas, respectivamente (ALVES et al., 2015). Tais ondas formadas no ponto de transição seguem as leis de *Kirchhoff*. Elas satisfazem a equações diferenciais das linhas de transmissão, e obedecem os princípios de conservação de energia (SILVA; OLESKOVICZ; COURY, 2005).

E Análises dos Métodos de Localização de Faltas em Linhas de Transmissão

Os métodos de localização de falta podem utilizar os sinais medidos em apenas 1 terminal da linha, ou mais de um terminal quanto a frequência dos sinais e podem ser divididos em dois:

métodos baseados em frequência fundamental e métodos baseados em componentes de alta frequência. Tais métodos serão apresentados nas próximas seções.

E.1 Fundamentos para Localização de Faltas Utilizando Um Terminal

Essa técnica utiliza os sinais registrados apenas no terminal local da linha de transmissão em análise. Para o caso de falha não aterrada, a onda refletida a partir um terminal remoto não é observada no terminal de medição. Assim, para faltas não aterradas a distância d entre o ponto de falta e um terminal local s pode ser determinada pela equação abaixo (NAIDU, 1985):

$$d = \frac{v(t_{s2} - t_{s1})}{2} \quad (2.21)$$

sendo:

- v é a velocidade de propagação da onda (km/s);
- s é o terminal local;
- t_{s1} é o tempo de propagação da primeira frente de onda originada no ponto de falta até o terminal local s ;
- t_{s2} é o tempo de propagação considerando-se o tempo de retorno dessa primeira onda até o ponto de falta e desse ponto novamente ao terminal local s .

Considerando a falta fase e terra, a onda refletida a partir do terminal remoto pode ser observada no terminal local. Portanto, a Equação 2.21 é usado para as faltas na primeira metade da linha. Considerando que, para falta à terra na segunda metade da linha, a distância do ponto de falta ao terminal local pode ser determinada por:

$$d = l_t - \frac{v(t_{s2} - t_{s1})}{2} \quad (2.22)$$

sendo:

- v é a velocidade de propagação da onda (km/s);
- s é o terminal local;
- t_{s1} é o tempo de propagação da primeira frente de onda originada no ponto de falta até o terminal local s ;
- t_{s2} é o tempo de propagação considerando-se o tempo de retorno dessa primeira onda até o ponto de falta e desse ponto novamente ao terminal local s ;
- l_t é o comprimento total da linha de transmissão (km).

E.2 Fundamentos para Localização de Falhas Utilizando Dois Terminais

No caso de dois terminais, o cálculo da localização da falta é baseado na identificação da primeira ocorrência de reflexão da onda em ambos os barramentos. Tomando t_{s1} como o tempo de propagação da primeira frente de onda e t_{r1} como o tempo de propagação da primeira frente de onda, temos (ABREU, 2015):

$$t_d = t_{r1} - t_{s1} \quad (2.23)$$

Uma vez determinado t_d , a distância entre o ponto da falta e o terminal local é calculada pela seguinte equação:

$$d = \frac{l_t - v_{ml} \times t_d}{2} \quad (2.24)$$

sendo l_t o comprimento da LT (km), v_{ml} a velocidade de propagação da onda (km/s) e d a distância da falta em relação ao terminal local (km).

Observa-se que essa técnica é de fácil aplicação e não envolve muitos cálculos. Entretanto, possui como desvantagens a necessidade de sincronização e a transmissão dos dados entre os terminais da linha. Silveira (2007), por sua vez, ressalta que algoritmos que se utilizem de dois terminais apresentam um maior grau de precisão, possibilitando redução das simplificações e maior precisão na determinação do ponto da falta.

E.3 Componentes de Frequência Fundamental

O método de componentes em frequência fundamental é a base para muitas técnicas de localização de faltas disponíveis na literatura. Dentre estas, podem ser citadas as fundamentadas em Transformada *Wavelet* (LIVANI; EVRENOSOGLU, 2014) ou em algoritmos baseados na Transformada de Fourier (YADAV; SWETAPADMA, 2015). Tais algoritmos se baseiam no cálculo dos fasores fundamentais. Por meio desse método, é possível avaliar a variação do módulo e da fase de tensão e de corrente durante a ocorrência da falta. A partir disso, o algoritmo de estimativa de fasores é usado em amostra do sinal que está sendo avaliado. Após a realização dos cálculos dos fasores fundamentais, os resultados são utilizados como entrada do algoritmo de localização de faltas.

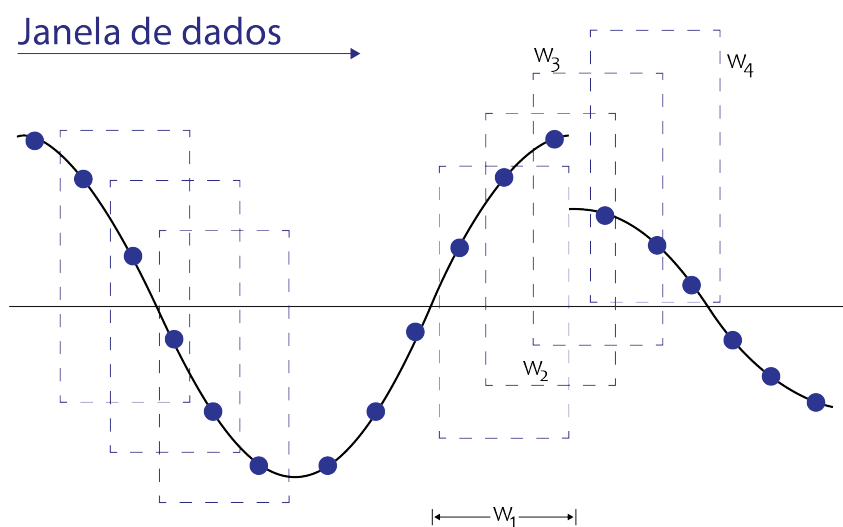
Os algoritmos para estimação fasorial são obtidos inicialmente pela conversão do sinal analógico-digital. Em seguida, é realizada a estimativa através das janelas de tempo. O processo de digitalização do sinal analógico é iniciado, limitando-se a banda de frequência do sinal a ser analisado, com o intuito de evitar erro de sobreposição do espectro do sinal durante a etapa de amostragem. Por fim, utiliza-se um filtro passa-baixa com uma frequência de corte igual a metade da frequência de amostragem (PHADKEDR; THORP, 2009).

Os métodos baseados em componentes de frequência fundamental determinam a localização da falta estimando a impedância da linha entre o ponto de medição e o local de ocorrência da falta. Nessa estimativa, o módulo e a fase das tensões e das correntes durante a falta são observados, porém, esse método tem a precisão afetada pelos parâmetros da fonte, pela resistência de falta e pela carga da linha (REIS, 2020).

Na análise dos possíveis casos de falta, é aplicado um método de janelamento em que W_1 representa a leitura de dados antes da falta, W_2 e W_3 sinalizam os dados pré e pós falta e W_4 indica a região de dados após a ocorrência da falta. Nota-se que a janela de dados sofre atualização, indicando o módulo e a fase do fasor do sinal que está sendo avaliado. Logo conclui-se que as janelas não possuem sinais com faltas no decorrer do regime permanente.

Uma fase de transição é iniciada após a falta, na qual as janelas apresentam sinais faltosos. Observa-se, ainda, que a janela utilizada gera uma diferença na duração dessa transição. Os cálculos para determinar os fasores não são usados como dados para leitura nos métodos de localização de falta com frequência fundamental e, além disso, resultam em novos métodos a serem apresentados para calcular os fasores de janelas mais curtas, como representado na Figura 9 (REIS, 2020).

Figura 9 – Janelas do sinal de corrente ao longo do tempo



Fonte: Adaptado de Reis (2020)

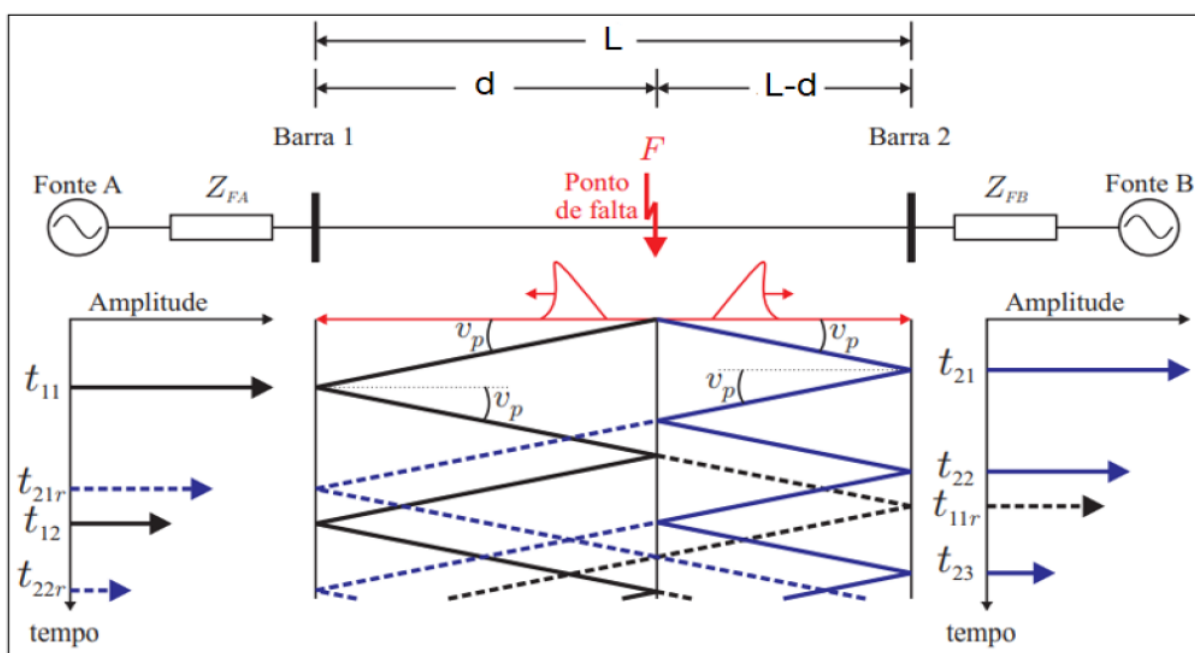
E.4 Componentes de Alta Frequência

Quando se utiliza métodos fundamentados em componentes de alta frequência para estimativa da distância de falta o tempo computacional aumenta muito, devido às altas taxas de amostragem. Na prática, essa característica limita o seu uso em aplicações reais. Entretanto, o avanço tecnológico dos conversores A/D tem rompido essa barreira (RAJENDRA; MCLAREN, 1985) e feito surgir a necessidade de novas técnicas que utilizassem dois terminais da linha de

transmissão para sincronização dos dados.

Isso solucionaria as limitações da metodologia de um terminal apenas, beneficiando o desenvolvimento tecnológico dos relés digitais, aplicados na proteção do sistema elétrico de potência (SAHA; IZYKOWSKI; ROSOŁOWSKI, 2010). No diagrama de propagação das ondas viajantes, conhecido na literatura por diagrama de *lattice* ou diagrama de reflexão, é possível visualizar o processo de propagação das ondas viajantes na linha de transmissão. Esse diagrama foi desenvolvido por Bewley (1931), conforme ilustrado na Figura 10.

Figura 10 – Diagrama de reflexão das ondas viajantes



Fonte: Lopes (2014)

Os componentes em alta frequência são baseados na teoria das ondas viajantes. Seu cálculo pode ser realizado por meio do tempo de viagem entre o ponto de ocorrência da falta até o terminal de medição, desde que o indivíduo tenha conhecimento da velocidade de propagação da onda viajante. Com isso, é possível identificar o local da falta. Vale lembrar que os sinais de alta frequência gerados no momento da falta se combinam com os sinais de frequência fundamental ao longo da LT, apresentando erro de localização (ZIMATH; RAMOS et al., 2010; LOPES, 2014).

A figura anterior apresenta uma linha de transmissão a uma distância (d) da barra 1. Tal linha possui uma extensão de comprimento L . O processo de reflexão se inicia através da incidência de uma falta no ponto F . Através desta, são geradas as ondas incidentes (t_{11} e t_{21}) e, por meio destas, as ondas refletidas (t_{12} , t_{22} e t_{23}) e, como consequência, as ondas refratadas (t_{21r} , t_{22r} e t_{11r}). Ressalta-se que a velocidade de propagação da onda viajante se aproxima da velocidade da luz, sendo representada por v_p , que equivale a 300.000 km/s, pode-se calcular esta

a partir da soma entre o tempo de viagem e a velocidade de propagação. É possível determinar o local da falta, os modos que o transitório propagam separados usando a Transformada de Clarke (CLARKE, 1993). (BEWLEY, 1931; NAIDU, 1985; LOPES, 2014).

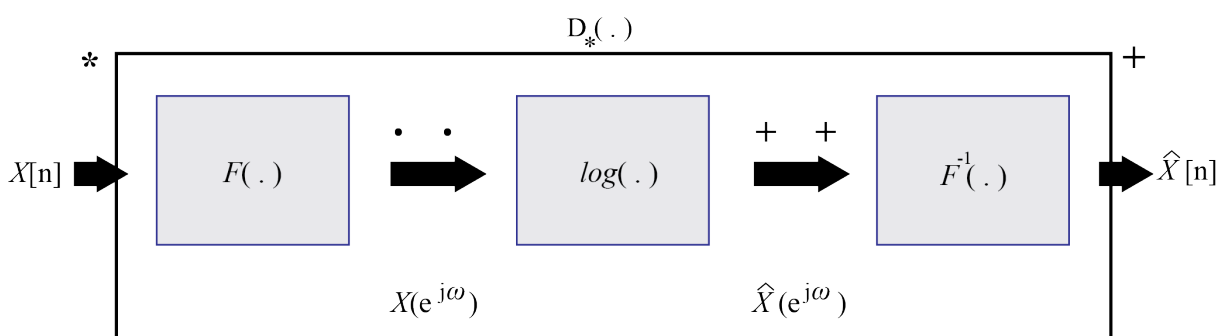
F Coeficientes de Frequência Mel Cepstrais (MFCC)

Os coeficientes MFCC – que consistem no *cepstrum* real de um sinal definido por uma janela – são utilizados com frequência nas áreas de reconhecimento de voz ou fala, posto que conseguem obter as propriedades lineares e não lineares do sinal mesmo com as características dinâmicas destes (NELWAMONDO; MARWALA, 2006). Isso porque o *cepstrum* real utiliza uma escada de frequência não linear, similar ao comportamento do aparelho auditivo humano (NELWAMONDO; MARWALA, 2006). Dessa forma, os coeficientes MFCC obtêm o espectro médio de cada frequência central com larguras de banda cada vez maiores.

F.1 Cepstrum Real

Em um sistema homomórfico, o princípio generalizado de superposição é obedecido. Neste, a representação real depende da operação de interesse. Nesse caso, trata-se da convolução. Em um sistema característico de realização da convolução homomórfica se utiliza a Transformada de Fourier de Tempo Discreto (DTFT) apresentada na Figura 11. Essa transformação converte uma convolução em uma soma (PEIXOTO, 2019).

Figura 11 – Sistema característico para o sistema homomórfico usando DTFT



Fonte: Adaptado de Peixoto (2019)

O *cepstrum* de um sinal $x(n)$ é definido como o *Inverse Discrete Fourier Transform* (IDFT), do logaritmo da amplitude espectral de um sinal (FURUI, 2000), conforme apresentado na Equação 2.25

$$c[n] = \frac{1}{2\pi} \cdot \int_{-\pi}^{\pi} \log [X (e^{j\omega})] e^{j\omega} d\omega \tag{2.25}$$

Os coeficientes cepstrais são amplamente utilizados para modelar a voz, que resulta da excitação das cordas vocais com a resposta do trato vocal, como as vibrações lentas e as variações rápidas (pulso/picos). Essa modelação é representada por:

$$s(n) = u(n) * h(n) \quad (2.26)$$


Sendo:

- $s(n)$ Sinal de entrada da voz;
- $u(n)$ Excitação;
- $h(n)$ Resposta impulsiva da cavidade vocal.

A separação dessas duas fontes é desafiadora, pois a representação no domínio da frequência ainda não seria suficiente para separar os dois componentes (DELLER; HANSEN; PROAKIS, 2000). Dessa forma, surgiram os coeficientes cepstrais para resolver tal problema, uma vez que no domínio da frequência as duas fontes são multiplicadas. A equação 2.27 e a Figura 12 retratam o domínio *cepstral* de uma combinação não linear.

$$S(\omega) = U(\omega) * H(\omega) \quad (2.27)$$

Figura 12 – Combinação não linear em domínio cepstrais




Fonte: Adaptado de Deller, Hansen e Proakis (2000)

Usando-se as propriedades da transformação homomórfica da Transformada Discreta Rápida de Fourier (DFFT) e as propriedades dos logaritmos, o sistema homomórfico tem a capacidade de converter uma convolução em uma soma. A Equação 2.27 pode ser reescrita e obtemos a equação 2.28 solucionando o problema da não linearidade, essa representação na Figura 13 (PEIXOTO, 2019; FURUI, 2000).

$$\text{Log}[s(\omega)] = \text{Log}[u(\omega)] + \text{Log}[H(\omega)] \quad (2.28)$$

Figura 13 – Componentes são somadas, solucionando o problema da não linearidade




Fonte: Adaptado de Deller, Hansen e Proakis (2000)

Então, soma-se os componentes no domínio *cepstral*, faz-se a transformada discreta inversa de fourier para obter a variável independente (k), essa variável é chamada de quefrêncy. De acordo com a equação 2.28 (PEIXOTO, 2019). A quefrêncy representado por (k) é uma medida de tempo implementada através da multiplicação da janela no domínio da quefrêncy, em seguida convertendo para domínio da frequência, assim produzira um sinal mais suave. Então o *cepstrum* do sinal é expresso na equação 2.29, também representado na Figura 14.

$$C_s(k) = C_u(k) * C_h(k) \tag{2.29}$$

Figura 14 – Representação dos Componentes do sinal no domínio *cepstral*.



Fonte: Adaptado de Deller, Hansen e Proakis (2000)

Sendo:


- $C_u(k)$ Componentes situados em baixas quefrências;
- $C_h(k)$ Componente situados em altas quefrências;
- $C_s(k)$ *Cepstrum* do sinal.

F.2 Filtros Triangulares em escala Mel

Os Coeficientes de Frequência Mel *Cepstral* deverão fornecer informações no domínio da frequência baseada em um banco de filtros triangulares, também chamados de filtros triangulares

em escala mel, como ilustrado na Figura 15. Também pode-se obter informações no plano tempo-frequência dispondo do janelamento do sinal.

Figura 15 – Filtros triangulares em escala mel usados na extração dos coeficientes MFCC



O espaçamento não linear obedece a escala mel descrita em (2.30).

$$mel = 2595 \cdot \log_{10} \left(1 + \frac{f(Hz)}{700} \right) \quad (2.30)$$

Os filtros têm a função de calcular o espectro médio em torno de cada frequência central com o aumento da largura de banda.

F.3 Processamento dos coeficientes MFCC

O processamento para extrair os coeficientes MFCC (FURUI, 2000; PEIXOTO, 2019) segue os seguintes passos:

1. Divide-se o sinal em janelas pequenas ou toma-se o sinal inteiro como única janela;
2. Para cada janela, aplica-se a Transformada Discreta de Fourier (DFT) para calcular o periodograma do espectro de potência;
3. Aplica-se um banco de filtros em escala mel e soma-se a energia em cada filtro;
4. Aplica-se o logaritmo de todas as energias do banco de filtros.
5. Aplica-se a Transformada Discreta de Cosseno (DCT) sobre o sinal de energia final.

Neste trabalho, foram usados 10, 20, 30 e 40 filtros mel (faixas de frequência) para os sinais de tensão das 3 fases nos dois terminais do SEP. Foram utilizados como entrada todos os coeficientes MFCC obtidos com cada conjunto de filtros para cada um dos sinais. Os sinais foram amostrados a uma taxa de 400 KHz. Destaca-se que os coeficientes mais altos, relativos às maiores frequências, significam mudanças aceleradas nas energias do banco de filtros. Têm como função apresentar informações relacionadas a métodos baseados em componentes de

alta frequência para localização de faltas. Por outro lado, os coeficientes mais baixos trazem informações associadas aos métodos de frequência fundamental (BRENT, 2010).

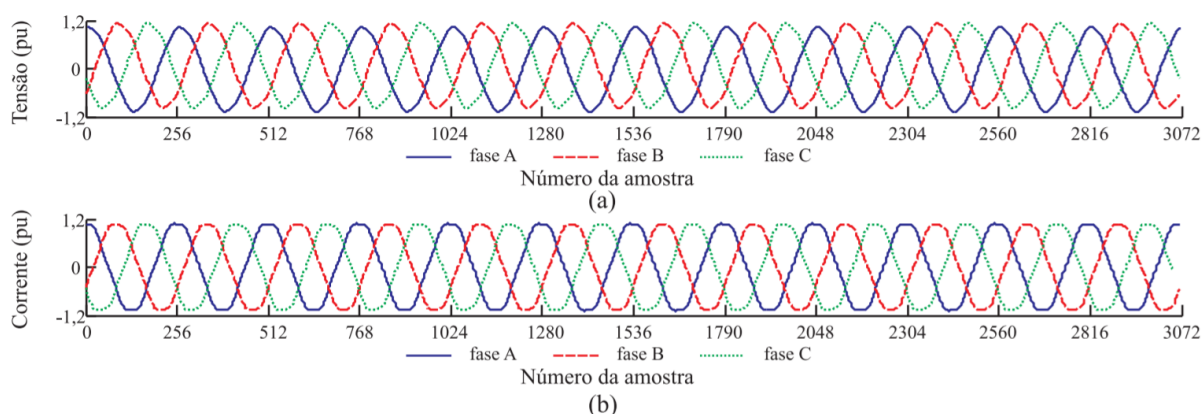
Outra informação relevante acerca das vantagens apresentadas pelos coeficientes MFCC é que as energias de filtro são mais resistentes a erros de estimativa decorrentes de espectro e ruído (BRENT, 2010), além de reduzir a dimensionalidade dos dados, obtendo-se, por consequência, a redução da complexidade do esquema de regressão. Tal característica é benéfica aos objetivos da aplicação pretendida neste trabalho.

G Ruídos em Linhas de Transmissão

Abreu (2015) relata que as tensões e correntes dos registros oscilográficos reais não se apresentam como ondas exclusivamente senoidais, possuem uma componente fundamental, acrescida a componentes harmônicas e ruídos que apresentam distribuição de probabilidade normal.


Na Figura 17 são apresentados os ruídos da corrente i_A , após a eliminação da componente fundamental e das componentes harmônicas de ordem 2, 3, 4, 5, 6 e 7, assim como o histograma da frequência relativa dos ruídos de i_A , destacando-se o valor médio (μ) e o desvio padrão (σ) dos ruídos. Observou-se que a curva da função densidade de probabilidade para uma variável aleatória com distribuição de probabilidade normal, com parâmetros μ e σ , apresenta forma similar ao histograma (ABREU, 2015).

Figura 16 – Registro oscilográfico real sem distúrbios: (a) tensões; (b) correntes.



Fonte: Costa (2010)

Figura 17 – Registro oscilográfico sem distúrbios: (a) is sem a componente de frequência fundamental e harmônicas de ordem 2, 3, 4, 5 e 7; (b) histograma da frequência relativa dos ruídos de i_A .



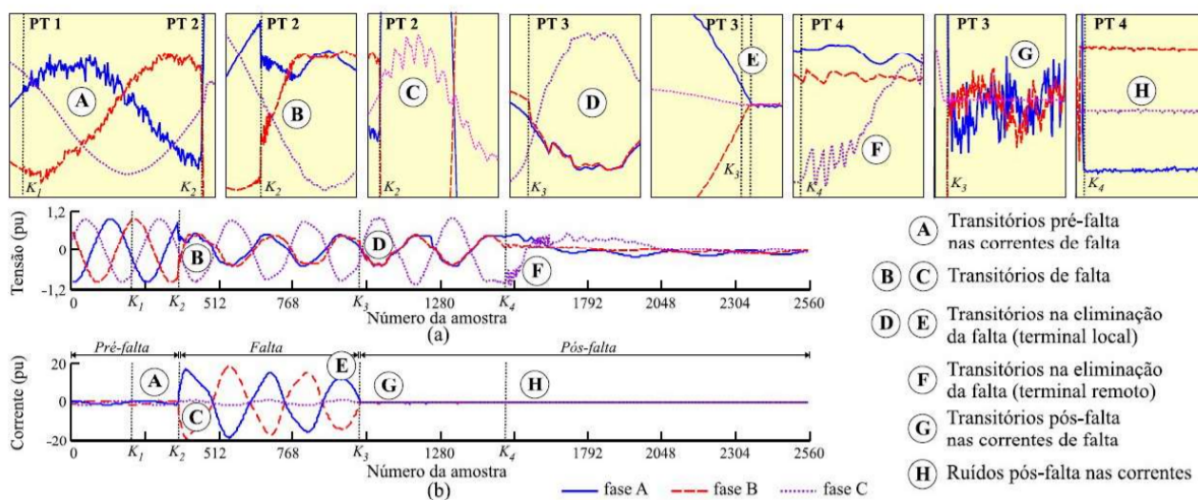
Fonte: Costa (2010)

Como pode ser observado acima, o ruído está presente em sistemas de medição reais mesmo sem a existência de distúrbios, nesses casos Araujo (2011) afirma que os sinais medidos nos extremos de LT's reais possuem relação sinal-ruído (SNR) maiores que 60 dB.

Já na ocorrência de uma falta observa-se a presença de transitórios de altas frequências, ondas viajantes, bem como ruídos como pode ser observado na Figura 18. Na Figura 18 são ilustradas as tensões e correntes de fase, em pu, de um registro oscilográfico real com uma falta do tipo AB. De modo geral na situação de falha identificamos três momentos distintos:

1. Período de pré-falta: compreende as amostras dos sinais referentes à situação de regime permanente do sistema elétrico, antes da ocorrência da falta.
2. Período de falta: corresponde ao período no qual o sistema encontra-se em uma situação de falta. Dependendo da natureza da falta e das condições elétricas do sistema, é comum o surgimento de um aumento nas correntes e um afundamento nas tensões das fases envolvidas na falta (BO et al., 2000).
3. Período de pós-falta: contém as amostras dos sinais após a atuação da proteção. A transição entre os diversos períodos em uma falta se caracteriza pela incidência de transitórios nas tensões e/ou correntes. Estudo minucioso realizado nos registros oscilográficos reais revelou aspectos dos fenômenos transitórios dos distúrbios, dificilmente encontrados em simulações digitais, o que pode comprometer a aplicação prática de métodos de diagnóstico de faltas avaliados apenas com dados simulados. (COSTA, 2014):

Figura 18 – Registro oscilográfico real de uma falta CT: (a) tensões; (b) correntes.



Fonte: Costa (2010)

H Redes Neurais Artificiais (RNA)

Na tentativa de apresentar um conjunto de dados de saída a partir de um conjunto de entrada, seguindo uma determinada necessidade, tem-se o processo de treinamento de uma rede. Tratando as entradas como um vetor, toma-se uma função de ajuste do estado interno da rede para que possa chegar no vetor saída desejado, seguindo um algoritmo pré-determinado. Assim desta forma há duas possibilidades de classificação dos métodos de aprendizagem: aprendizagem supervisionada e aprendizagem não supervisionada (BREGA et al., 2018).

Seguindo a primeira classificação tem-se que a aprendizagem supervisionada apresenta o papel de um instrutor externo ou uma informação global, na qual dentro do ambiente de treinamento há a apresentação das saídas desejadas para determinadas entrada e partir da comparação do resultado obtido com a saída desejada é calculado o erro, sendo este propagado através da rede e os pesos ajustados visando minimizar o mesmo. De forma geral as etapas dessa forma de aprendizagem envolvem: avaliar o momento de parada da aprendizagem; avaliar o tempo de treinamento com base nos dados de saída apresentados e tratar/minimizar o erro (BREGA et al., 2018).

O modo de aprendizado não supervisionado não possui a figura do instrutor externo, neste modo há uma organização dos dados, utilizando apenas os dados de entrada e a partir desta entrada o algoritmo de treinamento vai ajustando a rede para gerar os vetores de saída. O algoritmo de treinamento vai trabalhando as entradas e avaliando estatisticamente os grupos visando classificá-los por sua similaridade (BREGA et al., 2018).

É dito como rotina o uso de Algoritmos Genéticos (AG) para cálculos de seleção de variáveis em trabalhos de avaliações de um grande volume de dados. Um dos fatores para este uso

é o custo computacional envolvido nos métodos de pesquisa exaustivos, nos quais os algoritmos evolutivos apresentam soluções de forma mais otimizada e com o uso de favorável recurso computacional (TINOCO; CORREIA; CORTEZ, 2021).

Um método de aprendizado que retém e alcançam novos conhecimento é o método de Redes Neurais Artificiais (HAYKIN, 2001). Trabalhos relatam a notável capacidade das RNAs no tratamento de padrões. Isso significa que as RNAs têm notório potencial no que concerne à identificação de padrões e à realização de decisões autônomas. Com a possibilidade de paralelismo, as RNAs podem ser utilizadas para análise e cálculo de um grande volume de dados, portanto, são amplamente utilizadas para análise de falhas de sistemas elétricos de potência (HASSANI et al., 2019).

Um dos modelos de rede neural existentes é o *Multilayer Perceptron* (MLP) (HAYKIN, 2001). Assim como outras redes neurais, a MLP deve ser treinada antes de ser colocada em operação. Essa tarefa será realizada por algoritmos de regressão apropriados, que tem como objetivo gerar uma saída que tenta prever resultados para valores contínuos e, para a averiguação em pauta, optou-se neste trabalho pelo *backpropagation* de *Levenberg-Marquardt* (LM) (LEVENBERG, 1944; MARQUARDT, 1963), porque é um método de convergência mais rápida e emprega os métodos do Gradiente Descendente e de *Gauss-Newton*.

H.1 Algoritmo Levenberg-Marquardt

O algoritmo *backpropagation* discutido na seção anterior possui apenas derivadas de primeira ordem e utiliza o gradiente descendente como método de aproximação do mínimo da função erro, enquanto o algoritmo de *Levenberg-Marquardt* (LM) utiliza informações sobre a derivada de segunda ordem da função custo e uma aproximação do mínimo da função erro utilizando uma abordagem do método de *Gauss-Newton*. Este algoritmo pode ser interpretado com sendo uma combinação do método iterativo de *Gauss-Newton* com o gradiente descendente, incorporando a vantagem da velocidade de convergência do método de *Gauss-Newton* quando a solução está afastada do mínimo desejado da função objetivo (OLIVEIRA, 2016).

O algoritmo de LM envolve a operação de inversão de matrizes e, além disso, é necessário armazenar uma matriz de ordem $n \times m$, cujo n é o número de elementos do treinamento e m é o número de pesos, fato que, dependendo da dimensão da RNA, pode tornar o algoritmo computacionalmente inviável (para RNA muito grandes, demandaria um alto custo computacional). No entanto, este algoritmo mostra-se muito eficiente para RNA com algumas centenas de pesos sinápticos (OLIVEIRA, 2016).


I Regressão de Vetores de Suporte (SVR)

Para problemas de regressão, foi criada uma adaptação do método Máquina de Vetores de Suporte (SVM), desenvolvido por (VAPNIK, 1998) e denominado de Regressão de Vetores

de Suporte (SVR). Tal extensão se dá pela introdução de uma função de perda. A formulação do modelo SVR utiliza os mesmos princípios do algoritmo de classificação (SVM), com exceção de alguns detalhes.

Em determinados trabalhos nota-se a dificuldade em segmentar/classificar dados usando um hiperplano de forma linear, como mostrado na Figura 19(a), no qual recomenda-se uma função classificativa em formato de curva. As Regressões de Vetores de Suporte (SVRs) trabalham casos não lineares, alterando o plano original e expandindo sua dimensão, chamado de espaço de características (*feature space*). Espaço no qual há a possibilidade, estatisticamente falando, de uma separação linear conforme demonstrada na Figura 19(b) (REIS, 2018).

Figura 19 – Figura com frentes não lineares e lineares



Fonte: Reis (2018)

Apos a definição desse novo espaço, é possível a segmentação de forma linear. A Figura 19(b) indica um estado para uso no cálculo como um todo e a 19(a) ilustra o espaço inicial. O método usa uma função K de núcleo para definir o mapeamento das amostras, expandindo a dimensão sem gerar um incremento na complexidade do algoritmo (REIS, 2018).

Reis (2018) expõe que o SVR pode ser selecionado na atividade de previsão de dados baseada em séries históricas, pois a metodologia abordada neste algoritmo auxilia na análise de dados e identifica padrões por meio de uma função de perda, definindo um hiperplano otimizado no qual os dados estejam mais próximos, independentemente de qual lado da superfície os pontos se encontram, e sim que a distância para a superfície seja a mínima possível, e que desvios sejam permitidos desde que estejam dentro de um limite estabelecido.

J Regressão de Vetores de Suporte com Mínimos Quadrados (LS-SVR)

O LS-SVR é um algoritmo de regressão do tipo máquina de vetores-suporte ou SVM e foi desenvolvido por [Suykens e Vandewalle \(1999\)](#). O LS-SVR trata-se de um classificador supervisionado definido pela existência de um hiperplano ótimo de separação.

O problema dos classificadores Regressão de Vetores de Suporte (SVM) consiste em dividir classes distintas. As classes são divididas através da definição de um hiperplano que separa os n padrões em n regiões diferentes. A condição de existência desse hiperplano é a de que os padrões são linearmente separáveis, entretanto na maioria dos casos essa não é atendida ([GADELHA, 2021](#)).

K Considerações Finais do Capítulo

No decorrer do capítulo fora exposto por meio de conceitos encontrados na literatura a base de termos a serem trabalhados no presente trabalho, relacionado os principais pontos e as principais equações utilizadas para os cálculos que auxiliam na localização de faltas em LT. A partir da base conceitual, visando confrontar a proposta trabalhada com outros resultados encontrados na literatura, fora realizada uma pesquisa bibliográfica apresentada a seguir.

Neste trabalho, os coeficientes extraídos do processamento de sinais são submetidos aos distintos modelos de aprendizagem de máquina investigados: RNA, SVR e LS-SVR na tentativa de cada modelo estimar uma localização da falta em LT e por fim analisar qual apresenta melhor estimativa.

3 ESTUDOS DOS MÉTODOS DE LOCALIZAÇÃO DE FALTAS EM LT

A Revisão Bibliográfica

Para investigar os diferentes métodos de LFs já relatados na literatura, Utilizou-se como formato de revisão bibliográfica a técnica bibliométrica¹, a fim de selecionar as pesquisas de maior relevância sobre o tema em questão. Para identificar os estudos recém-publicados, foram realizadas buscas nas bases de dados *Scopus* (<https://www.scopus.com/>), *IEEE Jordan Section* (<http://sites.ieee.org/jordan/>) e *Springer* (<https://www.springer.com/br/>). Apresenta-se posteriormente a ideia central dos trabalhos de maior relevância encontrados na revisão bibliométrica.

A busca foi realizada de março a abril de 2020 e abril a dezembro de 2021, por meio de combinações das palavras-chave e seus sinônimos com o uso de operadores booleanos. As principais palavras-chave empregadas foram: *transmission line, fault location, computational intelligence, fourier, least square, wavelet, traveling waves, fuzzy, genetic algorithm, artificial neural network, support vector regression, least squares-support vector regression, support vector machine e mel frequency cepstral coefficients*.

O estudo em questão foi desenvolvido seguindo as seguintes etapas (BOTELHO et al., 2011):

Etapa 1: Foram usados critérios de busca definidos antes da realização da pesquisa, que se deu em nível nacional e internacional. As bases utilizadas foram *Scopus, IEEE Jordan Section* e *Springer*, que possuem uma extensa coleção de publicações, o que determinou sua escolha.

Etapa 2: Selecionou-se as áreas de estudos, quais sejam: engenharia, energia e ciência da computação, para todo o período determinado. Em seguida, restringiu-se a busca aos últimos 5 anos. Utilizou-se as palavra-chave relacionadas, conforme demonstrado na Tabela 2.

¹ Técnica Bibliométrica é um método de pesquisa empregado para buscar documentos relevantes sobre um tópico específico e que permite a coleta, a seleção e a análise crítica de referências selecionadas.

Tabela 2 – Revisão Bibliométrica sobre Localização de Faltas em LT

Palavra Chave	Quantidade em todo o período	Quantidade últimos 5 anos
"transmission line"e "fault location"	15.903	7.876
"transmission line", "fault location"e "computational intelligence"	2.603	1.559
"transmission line", "fault location"e "fourier"	2.119	1.165
"transmission line", "fault location"e "least square"	3.669	1.807
"transmission line", "fault location"e "wavelet"	1.526	1.074
"transmission line", "fault location"e "traveling waves"	1.639	891
"transmission line", "fault location"e "fuzzy"	2.624	1.669
"transmission line", "fault location"e "genetic algorithm"	1.987	1.627
"transmission line", "fault location"e "artificial neural network"	2.261	1.871
"transmission line", "fault location"e "support vector regression"	971	912
"transmission line", "fault location"e "least squares-support vector regression"	375	333
"transmission line", "fault location"e "support vector machine"	2.983	2.378
"transmission line", "fault location"e "mel frequency cepstral coefficients"	21	18
"transmission line", "fault location", "mel frequency cepstral coefficients"e "artificial neural network"	13	09
"transmission line", "fault location", "mel frequency cepstral coefficients"e "support vector machine"	16	09
"transmission line", "fault location", "mel frequency cepstral coefficients"e "support vector regression"	06	02
"transmission line", "fault location", "mel frequency cepstral coefficients"e "least squares-support vector regression"	05	01
"transmission line", "fault location", "mel frequency cepstral coefficients"e "fuzzy"	08	05
"transmission line", "fault location", "mel frequency cepstral coefficients"e "genetic algorithm"	08	05

Nos estudos analisados, foram encontradas três principais categorias em que podem ser classificados os métodos de localização de faltas, a saber: Componentes de Frequência Fundamental, Componentes de Alta Frequência e Componentes de Inteligência Computacional, que utilizam características relacionadas tanto aos componentes de Frequência Fundamental como aos de Alta Frequência.

Nas próximas seções, serão apresentados os principais métodos de localização de faltas em LTs encontrados e selecionados por meio da revisão bibliométrica, os quais servem como exemplo do que existe de mais atual na literatura e sustentam a consistência de todo este trabalho.

B Relacionados a Componentes de Frequência Fundamental

Livani e Evrenosoglu (2014) investigaram uma linha de transmissão híbrida, que é uma linha aérea combinada a um cabo subterrâneo. Para tanto, utilizaram-se da Transformada *Wavelet* Discreta (DWT) para a extração de informações transitórias das voltagens medidas. Em seguida, o algoritmo Máquina Vetor de Suporte (SVM) foi utilizado para a identificação da área problemática e, através do diagrama de *Lattice*, foram observados os padrões das ondas viajantes e os coeficientes do sinal de tensão para estimativa da distância de falta na LT. As simulações realizadas levaram em consideração diferentes tipos de faltas, por meio do software ATP, para modelos de linhas dependentes da frequência. O MATLAB foi usado para a aplicação do método proposto na simulação. O desempenho da metodologia foi testado para diferentes ângulos de incidência e diferentes resistências de faltas. Os resultados mostraram que faltas não lineares de alta impedância e faltas não ideais obtiveram resultados satisfatórios.

Por sua vez, Lopes et al. (2014) mostraram que os métodos clássicos de localização de faltas baseados em impedância não são capazes de localizar corretamente faltas. Nesse sentido, apresentou em sua pesquisa um algoritmo baseado em impedância para localização de falhas em linhas muito longas, com comprimentos superiores a um quarto de comprimento de onda. Seus resultados indicaram que o algoritmo proposto não era significativamente influenciado pelo fluxo de carga da linha ou fator de potência, pelas características da falta e pelos esquemas de transposição da linha. Assim, pode-se concluir que esse método é robusto e bastante adequado para localizar faltas em linhas de transmissão maiores que $\lambda/4$, como as linhas de transmissão de $\lambda/2^+$.

Posteriormente, Yadav e Swetapadma (2015) sugerem um método para detecção e para classificação de faltas em Linhas de Transmissão (LT) utilizando a Transformada *Wavelet* (TW) e a Análise Discriminante Linear (LDA). Destaca-se que a LDA é uma das abordagens mais populares para a segmentação de dados a partir do uso de hiperplanos (SANTOS, 2020). Tal método foi testado com alterações de parâmetros, como tipo de falta, resistência de faltas, ângulo inicial de falta e ângulo do fluxo de potência.

Além disso, Swetapadma e Yadav (2018) exploraram o método dos vizinhos mais próximos (k-NN) para estimar as localizações das faltas em linhas paralelas, valendo-se de medições em dois terminais. Para pré-processar os sinais, foi utilizada a Transformada Discreta de Fourier (DFT). Os sinais extraídos do desvio padrão de um ciclo de pré-falta e de um ciclo de pós-falta são usados como entradas para o algoritmo Método dos Vizinhos mais Próximos (k-NN). Os resultados obtidos em várias simulações demonstraram a alta precisão da metodologia proposta para estimar a localização da falta. Tal precisão não foi afetada pela alteração no tipo de falta, na distância, no ângulo de incidência, na resistência e no ângulo de carga de pré-falta.

Em seguida, Ashok et al. (2019) realizaram um estudo comparativo com um algoritmo fundamentado na Transformada de Fourier Discreta (DFT), na Transformada Discreta de Cosseno

(DCT) e na Transformada Discreta de *Wavelet* (DWT). Os pesquisadores valeram-se, ainda, de linhas de transmissão de dois terminais e de tensão de 400 kV. As simulações foram feitas no software Simulink do MATLAB. O algoritmo proposto usava o desvio padrão dos coeficientes dos dados discretos, além da distância dos três ciclos dos sinais de corrente e de tensão do ponto de retransmissão, a fim de construir as conotações ocultas das estruturas neurais. Foram realizadas simulações para todos os tipos de faltas, variando-se diferentes parâmetros na presença de um acoplamento mútuo. Os resultados apresentaram um erro médio de cerca de 1 % na estimativa do local de falta.

No mesmo ano, [Khaleghi e Oukati Sadegh \(2019\)](#) propuseram um método de localização de faltas em linhas de transmissão baseado em *Adaptive Neuro-fuzzy Inference Systems* (ANFIS). Em sua proposta, a Análise *Wavelet* Multi-Resolução (MRA) foi usada para extrair e para registrar as características dos sinais de falha, usando dados de amostragem de um lado da LT estipulada. Essa LT foi simulada no software PSCAD² e contou com 200 km de extensão e com quatro circuitos de 500 kV. Os resultados da análise de *wavelet* foram aplicados como entrada da rede ANFIS no software MATLAB e foram apurados com erro inferior a 0,1 % no experimento, o que demonstrou sua eficácia para solução do problema de localização de falhas.

C Relacionados a Componentes de Alta Frequência

[Lopes et al. \(2014\)](#) sugeriram um novo método de localização de faltas, que usa os dois terminais de uma LT de 500 kV. Essas simulações foram baseadas na teoria das ondas viajantes. Tal procedimento metodológico depende da diferença de tempo entre o primeiro momento do sinal extraído da transformada *wavelet* e a reflexão sucessiva da falta até o final da linha. Com isso, o método proposto pelos autores em questão não necessitou sincronizar dados e não precisou de parâmetros de linha. Os parâmetros de linha são fonte de erros que afetam o esquema de localização com base na transformação *wavelet*. Para validar a proposta, foram realizadas diversas simulações e, posteriormente, comparados os desempenhos das técnicas. Os resultados do método foram satisfatórios na localização da falta em linha de transmissão, mesmo em situações de falta de sincronização de dados entre os terminais da linha.

No ano seguinte, [Lopes et al. \(2015\)](#) abordaram em sua proposta um novo algoritmo de localização de faltas baseado em ondas viajantes (*Traveling Waves*), que também utilizou dois terminais da linha. Uma grande vantagem desse modelo, em relação a outros métodos de dois terminais, reside no fato deste também não exigir a sincronização dos dados dos dois terminais de linha. Essa proposta apresenta um algoritmo aplicado em tempo real e utiliza um sistema de comunicação cuja latência de transmissão de dados é levada em consideração na formulação proposta.

Ainda no trabalho de [Lopes et al. \(2015\)](#), as rotinas de localização de falhas foram

² O PSCAD é um software de simulação de sistemas de potência.

implementadas por meio do software Simulador Digital em Tempo Real (RTDS), juntamente com o algoritmo proposto, para gerar uma variada quantidade de casos de falta. O experimento foi realizado em uma LT de 200 Km de extensão, com tensão de 230 kV, e demonstrou resultados de desempenho satisfatórios quando comparados com métodos clássicos frequentemente sugeridos na literatura correlata para dados sincronizados. Dessa forma, os resultados obtidos indicaram que a metodologia proposta do algoritmo de localização é capaz de detectar faltas usando dados de dois terminais sincronizados ou não sincronizados. Para os dados perfeitamente sincronizados, os erros não excederam 3,72 % (7,44 km), apresentando erro médio de 1,51 % (3,02 km) e desvio padrão de 1,03 % (2,06 km).

Mais tarde, [Lopes et al. \(2018\)](#) propuseram um novo método de localização de faltas, também baseado na teoria das ondas viajantes. As simulações foram executadas com dois terminais de uma linha de transmissão de 500 kV e de 200 Km, necessitando de sincronização de dados. Utilizou-se a Transformada *Wavelet* para extrair os sinais de perturbação da linha em diversos cenários, não dependendo dos parâmetros da LT. O resultado obtido nessa proposta também se mostrou significativo, uma vez que não houve referência de tempo comum e parâmetros exatos da linha. O erro médio para essa situação foi de 0,031 m e o desvio padrão, de 0,036 m.

O método de detecção e de correlação de dados de ondas viajantes de [Zhang, Shu e Liao \(2016\)](#), posteriormente, deu-se através de perturbações em linhas de transmissão, obtidas em diferentes terminais, com base em dados sincronizados. Esses dados de ondas viajantes, quando correlacionados a eventos de perturbação, podem ser adquiridos e utilizados para localizar determinado evento de falta. Nessa proposta, foi possível extrair o segmento efetivo de onda viajante que correspondia ao mesmo evento de perturbação do banco de dados em diferentes pontos de observação, o que facilitou a localização automatizada de uma falha de ponta dupla e demonstrou a alta eficácia desse método para a solução do problema.

Além disso, [Almeida et al. \(2017\)](#) propuseram uma metodologia que utilizou Ondas Viajantes (TOV) para localizar a falta, Análise de Componentes Independentes (ICA) para extrair características dos sinais e, por fim, Máquina Vetor de Suporte para classificar os tipos de faltas. O modelo utilizou, ainda, a linha de transmissão de alta tensão de 500 kV que interliga as subestações de Presidente Dutra-MA e de Boa Esperança-PI. Os métodos propostos obtiveram ótimos resultados na localização e na classificação das faltas. Obtiveram-se erros abaixo de 1 % para localização da falta e acurácia de 100 % para a classificação de faltas com ruído.

Em outro estudo, realizado por [Abu-Siada e Mir \(2019\)](#), apresentou-se uma nova técnica on-line para identificar a localização de faltas em uma LT longa. A técnica se baseou na construção de um diagrama de *locus* da tensão-corrente das extremidades de entrada e de saída de sinais. Tal tensão-corrente foi mensurada em cada ciclo de frequência de energia, para fornecer o estado de condição atualizado da linha, que tem seus dados sincronizados por meio de um *Global Positioning System* (GPS). Os experimentos foram feitos usando o software *DIGSILENT*

*PowerFactory*³, em que vários tipos de falhas foram simuladas para validar a robustez do método proposto. Nesse sentido, as variações nas condições de carga e de resistência de falha da linha foram investigadas. Os resultados revelaram que a proposta possuía alta precisão, além de potencial para detecção de faltas de alta impedância, ao contrário das técnicas existentes até esse momento, que eram empregadas apenas para identificar as localizações após sua ocorrência.

D Relacionados a Aprendizado de Máquina

O método proposto inicialmente por [Salat e Osowski \(2004\)](#), o qual utilizou uma Máquina de Vetores de Suporte (SVM), possuiu duas etapas que, juntas, foram denominadas pelos autores de "algoritmo híbrido". A SVM é utilizada para estimar a distância da falta através de treinamento dos dados característicos, extraídos dos sinais transitórios de tensão e de corrente no momento de ocorrência da falta. Nesse caso, utilizou-se apenas um terminal da linha. A particularidade desse modelo é que, após a análise da SVM, a localização inicialmente prevista foi corrigida por meio das características de alta frequência do sistema. Além disso, a localização é comparada com o pico de frequência medido na faixa de alta frequência. Para extração dos sinais de tensão e de corrente, simulou-se diferentes tipos de faltas na linha de transmissão de 200 km. De acordo com os autores, os resultados obtidos nas experimentações comprovaram que o algoritmo utilizado contou com acurácia muito boa na identificação de distâncias de falta em linhas de transmissão, apresentando uma média de erro de localização de 100 m, nunca ultrapassando 2 km, para linhas de transmissão de 200 km.

[Ekici \(2012\)](#), por sua vez, analisou o desempenho do algoritmo SVM em conjunto com a Transformada Walevet Discreta (DWT). Esse modelo trabalhou com os sinais transitórios de corrente medidos em apenas um terminal, a fim de classificar os tipos de falta e de prever sua localização nas linhas de transmissão. O diferencial do DWT, no experimento em questão, é que o mesmo reduz o tamanho da matriz de características antes dos estágios de classificação e de previsão. Realizaram-se simulações para diferentes tipos de faltas. A média de erros do modelo em uma linha de transmissão de 380 Kv - 380 Km é menor do que 0,26 %. A distância máxima de erro, por seu turno, não excedeu 950 m.

Em uma abordagem encontrada nas bases de pesquisa sobre a temática, [Uyar \(2012\)](#) propôs um método baseado em Transformada-S (ST) e em Regressão por Vetores de Suporte com Mínimos Quadrados (LS-SVR) para prever a localização da falta em uma linha de transmissão (LT) de energia, compensada com um capacitor de série fixo. As características de entropia da matriz ST são extraídas para reduzir a dimensão do sinal de corrente trifásica, que é medido a partir da extremidade da linha de transmissão. Em seguida, as características extraídas são aplicadas como entrada do LS-SVR, que, por sua vez, determina o local da falta na linha compensada em série (SCL). O método apresentado foi testado com um modelo de uma linha de

³ O *PowerFactory* é um software de análise de sistemas de energia usado na análise de sistemas de geração, de transmissão, de distribuição e também industriais.

transmissão de 400 kV e de 320 km. Essa linha foi compensada por um banco de capacitores trifásicos em seu ponto central. Os resultados mostram que o método proposto foi capaz de determinar a localização da falta com erro de 0,1834 %.

Em outra pesquisa, [Yusuff, Jimoh e Munda \(2014\)](#) combinam uma série de algoritmos na análise de uma linha de transmissão de 400 kV e de 361.297 Km. Fez-se uma combinação entre alguns algoritmos de IC, dentre eles: SVM, SVR, Característica de Função Determinante (DFF, do inglês *Determinant Function Feature*) e Transformada Estacionária de *Wavelet* (SWT, do inglês *Stationary Wavelet Transform*). Nessa abordagem, o DFF foi utilizado para extrair características dos sinais das faltas, usando medições de 0.25 de ciclo de sinais pós-falha, após a eliminação de interferências por um filtro baseado na SWT. Em seguida, a SVM foi utilizada para classificação e o SVR, para localização de faltas. Os resultados mostraram que a estimativa da distância de falta foi rápida e precisa, independente de impedância.

Em seguida, [Fathabadi \(2016\)](#) propôs um método de detecção e de determinação da localização de faltas de curto-circuito em LT, sejam elas monofásicas, bifásicas, bifásicas com terra, trifásicas ou trifásicas com terra. Em tal proposta, foi utilizado um filtro FIR de dois estágios e uma RNA para a apresentação da solução da localização da falta, com onze SVRs para auxiliar nesse cálculo. Obteve-se alta precisão na determinação da falta em LT com extensão de 50 Km, utilizando-se uma rede de 230 kV. Ressalta-se que, com apenas 11 amostras, foi possível treinar a RNA e determinar o cálculo da localização da falha.

Já na abordagem apontada por [Yadav e Swetapadma \(2015\)](#), foi proposto um esquema baseado na combinação entre Transformada Discreta de *Wavelet* (DWT, do inglês *Discrete Wavelet Transform*) e Rede Neural Artificial (ANN, do inglês *Artificial Neural Network*) para linhas de transmissão de circuito duplo. O método exigiu que as correntes e as tensões trifásicas fossem medidas em uma extremidade da linha de transmissão, que seria modelada através de parâmetros distribuídos. Considerou, ainda, o efeito da capacidade em derivação. Através da Transformada Discreta de *Wavelet* (DWT), extraiu-se os coeficientes característicos dos vetores de tensão e de corrente trifásicos. Após a extração das características, os dados foram treinados no algoritmo *Levenberg Marquardt* (LM) em uma Rede Neural Artificial (RNA). A metodologia proposta envolveu dois estágios, nos quais o primeiro identificou a zona e a seção da falta e o segundo calculou a localização da falta. Os resultados dessa proposta apresentaram um erro percentual médio dentro de 0,001 %.

Em abordagem parecida, [Shaik e Pulipaka \(2015\)](#) utilizaram Redes Neurais Artificiais (RNAs) para estimar a distância de faltas em uma linha de transmissão. Nesse caso, aplicou-se a Transformada de *Wavelet* (WT, do inglês *Wavelet Transform*) como método de extração de características e, além disso, utilizou-se um GPS para sincronizar a amostragem dos sinais de tensão e de corrente em ambas extremidades da linha. Obteve-se erro médio de 0,1 % como resultado do experimento.

Mais tarde, [Oliveira \(2016\)](#) também propôs um método para localizar e para classificar

faltas em linha de transmissão por meio de Redes Neurais Artificiais (RNA). A base de tal proposta foi o uso de sinais de tensões e de correntes pós-falta obtidos nos terminais da linha. A validação foi realizada através dos modelos disponíveis na biblioteca Simulink MATLAB. Usou-se, na entrada da RNA, os sinais de tensões e de correntes, normalizados no intervalo $[-1,1]$. Na saída da RNA, por sua vez, usou-se a distância da falta, normalizada no intervalo $[0,1]$, para localização e para classificação da falta. Para avaliar os resultados, a linha de 900 km foi dividida em 3 trechos de 300 Km. O trecho 1 apresentou resultado satisfatório, com o menor erro. O trecho 2, para falta monofásica envolvendo terra (FT), apresentou um erro médio relativo de 0,43 %, enquanto o trecho 3 apresentou, para falta trifásica envolvendo terra (FFFT), maior erro, 2,01 %.

Posteriormente, [Mosavi e Tabatabaei \(2016\)](#) propuseram o uso de quatro algoritmos de localização de faltas, baseados na DWT, usando-se, ainda, um Sistema de Posicionamento Global (GPS). Em dois métodos, a localização da falta foi determinada com base na ocorrência da chegada da onda viajante. As Redes Neurais Artificiais foram usadas para simular relações não lineares, a fim de se obter melhores resultados. As simulações foram realizadas no software ATP e os resultados dos quatro métodos indicaram que houve diminuição nos percentuais de erros em duas das abordagens baseadas em transformada *wavelet*. Nesse caso, de 0,35 % para 0,22 % e de 0,21 % para menos de 0,15 %, respectivamente, embora os autores tenham explorado um pequeno banco de dados para treinamento.

[Fathabadi \(2016\)](#), por sua vez, apresentou uma nova abordagem para detecção, classificação e localização, usando uma linha de transmissão trifásica real de 230 kV, 50 Hz e 50 Km. Essa linha foi simulada para validar resultados teóricos e para verificar a precisão da técnica proposta. Utilizou-se uma estrutura híbrida, composta por dois filtros FIR, quatro máquinas de vetores de suporte (SVM) e onze regressões de vetores de suporte (SVR). Os softwares Protheus 6 e MATLAB foram utilizados para realizar as simulações. O filtro FIR foi usado, com o SVM, para detectar e para classificar, enquanto o SVR foi usado para localizar a falta. A estrutura implementada requereu pouquíssimas amostras para treinar SVM e SVR. A exemplo, para uma linha de transmissão de 50 Km de extensão, seriam necessárias apenas 6 amostras para treinar cada SVR. A estrutura híbrida treinada realizaria a detecção e a classificação, além de localizar a falta durante um ciclo. Isso significa que essa metodologia foi capaz de detectar, de classificar e de localizar rapidamente as faltas antes do relé de proteção.

Posteriormente, [Aslan e Yağan \(2017\)](#) propuseram um algoritmo de localização de faltas baseado em RNA, em linhas de distribuição de energia de média tensão. Para a extração de informações, foi utilizada a Transformada Rápida de Fourier. Foi realizada também uma análise espectral de frequência das formas de onda da tensão e da corrente. Um sistema com uma linha de distribuição de 14,8 Km de extensão entre dois pontos foi implementado, em uma simulação feita pela ferramenta MATLAB/Simulink. Esse sistema foi testado com uma voltagem de 34,5 kV, gerando resultados positivos, que demonstraram que o erro estimado da falta foi menor que 1

%, com o uso das RNAs.

Em seguida, um método que combinou a teoria das ondas viajantes, a Análise de Componentes Independentes (ICA) e os SVMs foi proposto por Almeida et al. (2017). Nessa proposta, o ICA foi responsável por extrair as características dos sinais de uma LT de alta tensão, modelada com 500 kV e 200 Km de extensão, entre as subestações de Presidente Dutra-MA e de Boa Esperança-SE. A técnica envolvendo as ondas viajantes teve a função de localizar faltas, enquanto as máquinas de vetores de suporte fizeram a classificação dos tipos de falta. Os resultados dessa abordagem foram excelentes, obtendo-se erros inferiores a 1 % para o esquema produzido. O autor destacou, ainda, que a abordagem introduzida se mostrou superior às tradicionais encontradas, com frequência, na literatura, envolvendo RNAs e *Wavelet*.

Além disso, Lopes et al. (2017) estudou as faltas em linhas de transmissão de longa distância e tentou apresentar, para o problema de identificação do ponto de falha, um modelo de resolução baseado em ondas viajantes. Nesse modelo, não se trabalhou com dados sincronizados nem com parâmetros de linha, fatores que poderiam gerar falhas na avaliação do modelo de ondas viajantes. Para a resolução do problema, foi utilizado um sistema de teste trifásico, de 500 kV/ 60 Hz, em uma linha de transmissão de 200 Km. Considerou-se erros de sincronismo e de imprecisões. Ademais, o método elaborado apresentou uma métrica de erro na localização de falhas na escala de 200 m a 270 m, em diferentes cenários, considerando os erros trabalhados.

Nagam, Koley e Ghosh (2017), ainda, propuseram um método de localização de faltas em LTs baseado em RNAs, para linhas de circuito duplo, trifásicas, utilizando STATCOM⁴ no ponto médio de uma linha esquematizada de 500 kV, de 60 Hz e de 300 Km. Os sinais fundamentais de tensão e de corrente, recolhidos em uma das extremidades da linha tratada, foram extraídos usando Transformada de Fourier Discreta (DFT) e, posteriormente, utilizados como entrada para treinamento da RNA, com auxílio do algoritmo de *Levenberg Marquardt*. Após ser treinada, essa rede neural foi colocada em testes com diferentes condições de falha, para determinar a precisão do erro e para estimar o local da falha. O experimento demonstrou alta eficácia, com erro médio absoluto de 0,9 % para o localizador de faltas.

Ademais, Akmaz et al. (2017) se basearam na teoria das ondas viajantes para determinar a distância de falta em linhas de transmissão longas, com vários níveis de compensação em série. Essas linhas foram modeladas se usando o software *Alternative Transient Program (ATP)* para extrair os sinais transitórios de corrente e de tensão. A transformada rápida de Fourier converteu a frequência e a localização da falta foi estimada a partir das frequências harmônicas geradas pelas faltas do espectro transitório. O algoritmo foi implementado no MATLAB. Os resultados dos diferentes níveis de compensação em série, por sua vez, foram obtidos com a eliminação dos efeitos ruins de indutância da fonte e com a melhoria da precisão da estimativa. O método foi

⁴ Um STATCOM é um dispositivo FACTS baseado em conversão, usado para alimentar instantaneamente a rede com energia reativa, tanto indutiva quanto capacitiva, sem o uso de capacitores e reatores, mas por vários conversores de chaveamento unidos a um controle supervisionado.

bem-sucedido na determinação da localização de faltas em linhas de transmissão compensadas em série.

[Dobakhshari \(2018\)](#), posteriormente, utilizou um sistema de transmissão com formulação não linear para a localização de faltas por medições não sincronizadas. Nesse modelo, foi trabalhada a correção da frequência avaliada, rejeitando-se harmônicos de alta frequência. Além disso, utilizou-se um filtro *anti-aliasing* analógico para gerar a amostragem inicial. Após outras reduções, os valores interpretados foram passados para uma Transformada Discreta de Fourier, o que auxiliou na extração da camada de dados inicial de entrada. Os valores obtidos foram incorporados no algoritmo proposto pelo trabalho em questão, no qual foi utilizado MATLAB para implementação e para coleta dos resultados. Os resultados se mostraram satisfatórios em relação ao tempo e à precisão da localização da falta. Destaca-se a formulação linear como responsável por essas características da solução.

Recentemente, [Fei, Qi e Li \(2018\)](#) pesquisaram a utilização do algoritmo de Regressão de Vetores de Suporte (SVR), empregando a amplitude dos sinais para treiná-lo. Nesse caso, buscou-se a localização de faltas em uma linha de transmissão (LT) de 400 kV e de 300 Km. Essa técnica utilizou as amplitudes das formas de onda de tensão no momento da falta, com apenas um terminal da linha. Simulou-se diferentes tipos de faltas, modificando-se as distâncias, a impedância e o ângulo de incidência da LT. Dessa forma, conseguiu-se obter resultados favoráveis, com a utilização de apenas 1/8 de janela de ciclo dos sinais pós-falta. Houve a utilização, ainda, de um filtro passa-baixa para eliminação de ruído. Desse modo, conseguiu-se um modelo que utilizou menos dados e levou menos tempo, além de ter estimado a distância de faltas em linhas de transmissão com alta precisão. O treinamento da SVR foi realizado através dos sinais de tensão de falta e, após isso, foi encontrado o local da falta. Comparado a outros métodos, verificou-se que a metodologia proposta forneceu estimativas mais precisas, independente do tipo de falta, dos ângulos de incidência e das impedâncias de falta, apresentando um erro médio relativo de 0.0011 %.

Na mesma época, [Swetapadma e Yadav \(2018\)](#) também apresentaram um novo esquema para estimativa da distância de faltas de variados tipos de faltas, em linhas de transmissão paralelas, com base no algoritmo Método dos Vizinhos mais Próximos (k-NN). Usou-se medição de um terminal apenas. No esquema tratado, a DFT foi utilizada para pré-processar os sinais de tensão da linha e para extrair um ciclo de amostras, tanto de pré-falha como de pós-falha, para servirem de entrada para o algoritmo em questão. No experimento realizado pelo simulador RTDS, quatro módulos de k-NN são projetados e testados em quatro tipos de falhas diferentes, apresentando erro médio de 1 %. Os resultados se mostraram significativos, uma vez que estimaram a localização da falha com base na distância mais próxima da amostra vizinha.

[Fei, Qi e Li \(2018\)](#), por sua vez, propuseram um novo esquema de localização de faltas em linhas de transmissão de alta tensão, que se baseou na Regressão Vetorial de Suporte (SVR). Nessa abordagem, foram usadas apenas amplitudes das formas de onda da tensão de

falta, medidas numa única extremidade da linha modelada, que apresentou extensão de 300 Km e tensão de 400 kV, valores que posteriormente foram utilizados para formar o vetor de características. Após a filtragem dos sinais de falha, o SVR os recebeu para estimar o pontos de falta na LT. Os resultados obtidos na simulação realizada mostram que o novo esquema fornece alta precisão e alta velocidade de processamento, ao usar medições de tensão pós-falha de 1/8 de ciclo, com erro relativo de 0,0011 %.

Para Branco, Reis e Pereira (2019), ademais, a localização de faltas em linhas de transmissão seria um problema de grande relevância para os SEP. Atualmente, diversas abordagens que utilizam técnicas modernas de processamento de sinais, além de ferramentas de IC, vêm sendo propostas na literatura correlata. A abordagem proposta nesse trabalho, por sua vez, utilizou uma LS-SVR para estimar a distância de falta. Essa LS-SVR recebeu, como entrada, um vetor de características composto por 20 coeficientes, que foram obtidos por meio da aplicação dos coeficientes MFCC para cada sinal de tensão das 3 fases de cada terminal de uma linha de dois terminais. A abordagem proposta se mostrou promissora, apresentando erro médio de 0,09 % do comprimento da linha e desvio padrão de 0,69 % do comprimento da linha. A utilização dos coeficientes MFCC foi capaz de fornecer informações adequadas para a LS-SVR, a qual foi bastante precisa na localização da grande maioria das situações de falta simuladas.

Em seguida, na proposta idealizada por Hassani et al. (2019), um método de inteligência computacional foi implementado para localizar faltas em linhas de transmissão. As medições de corrente de um lado das LTs defeituosas foram coletadas e, em sequência, enviadas a um módulo de processamento de sinal, que continha unidades de Densidade Espectral de Potência (PSD) e de Decomposição de Modo Variacional (VMD). As características obtidas foram, então, fornecidas aos algoritmos de localização de falhas, para construir modelos preditivos, dentre os quais se encontraram Sistemas de Inferência Neuro-difusa Adaptativos (ANFIS, do inglês *Adaptive Neuro-fuzzy Inference Systems*), SVR e RNAs, a fim de estimar a localização exata da falha. Diversos cenários foram simulados com diferentes parâmetros e, nos resultados obtidos, observa-se que o ANFIS foi superior aos demais, com erro mínimo de 0,123 %.

Recentemente, Teimourzadeh et al. (2021) expuseram um estudo acerca da análise de faltas em LTs monofásicas, cujo uso é mais comum em ambientes reais. Em tal trabalho, propôs-se um método de detecção de falhas em duas etapas: na primeira parte do tratamento do problema, realizou-se um cálculo da função de transferência de cada falta, para auxiliar na determinação da falha no sistema, enquanto que, na segunda parte, tratou-se o problema através de um método de aprendizado por reforço, a fim de tentar identificar a localização exata da falha de curto-circuito monofásica nas LTs tratadas. Dentro do trabalho, definiu-se um método de função de transferência, que foi descrito como um método para analisar, para diagnosticar e para testar defeitos em estados transitórios, com o intuito de detectar erros no sistema da rede de transmissão. Em tal estudo, ainda, foram usadas uma Rede Neural Convolutiva (CNN, do inglês *Convolutional Neural Network*) e um modelo híbrido de DRL (*Deep Reinforcement*

Learning ou Aprendizagem por Reforço Profundo). Nesse último, foram aplicadas faltas de curto-circuito monofásicas, para aterramento, com várias impedâncias de falha, em um sistema de LTs padrão *IEEE*⁵. Em seguida, os traços da função de transferência foram calculados e coletados, para servirem como conjunto de dados de entrada para o modelo proposto. Os resultados da localização da falha para cada rede foram avaliados por meio de várias métricas de desempenho estatísticas, como o coeficiente de correlação (R), o erro quadrático médio e o erro quadrático médio raiz. O valor R dos modelos CNN e DRL, na identificação de falhas, é apresentado como 96,12 % e 98,04 %, respectivamente, demonstrando a prevalência da eficácia da DRL sobre a da CNN para o problema em questão.

Mishra e Ray (2017), no mesmo ano, apresentaram um estudo comparativo envolvendo várias tecnologias de processamento de sinal, voltadas para localização e para classificação de faltas em Linhas de Transmissão. A revisão bibliográfica de diferentes técnicas teve como objetivo auxiliar os pesquisadores no desenvolvimento de pesquisas na área de localização de faltas, através das teorias sobre os métodos de medição baseados em impedância, em fenômenos de ondas viajantes, em inteligência artificial e em algumas tecnologias especiais para detectar, para localizar e para classificar várias faltas nas redes de transmissão. Tal estudo foi limitado a métodos e a técnicas desenvolvidos até agosto de 2017 e fez, em seu desenvolvimento, um comparativo entre várias técnicas, exibindo seus resultados.

Num estudo comparativo, realizado por Mishra e Ray (2018), foi discutida uma série de técnicas de processamento de sinal, assim como métodos de medição baseados em impedância e em ondas viajantes e, além disso, métodos com base em Inteligência Artificial (IA) e algumas técnicas de detecção, de classificação e de localização de faltas em linhas de transmissão. Tal discussão ofereceu uma ótima base para conhecimento dos recursos mais utilizados em relação ao problema específico em comum.

E Considerações Finais do Capítulo

Apresentou-se a revisão bibliométrica aplicada nesta dissertação, além das principais publicações referentes aos métodos de detecção e de localização de faltas em linhas de transmissão. Foram abordados os resultados e os aspectos mais importantes para a aplicação dos algoritmos de detecção de faltas discutidos. Com base nos métodos de análise de sinais e nos algoritmos encontrados na literatura, tendo em vista a grande quantidade de trabalhos publicados nos últimos anos, adotou-se a escolha de trabalhar com coeficientes MFCC e os algoritmos de RNA, SVR e LS-SVR.

⁵ O IEEE é uma sociedade técnico-profissional internacional com sede em Nova Jersey, dedicada ao avanço da teoria e prática da engenharia nos campos da eletricidade, eletrônica e computação.

4 PROCEDIMENTO METODOLÓGICO

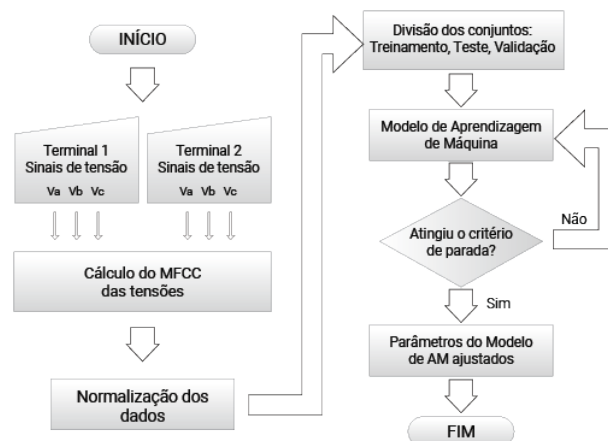
Neste capítulo, inicialmente será detalhada a abordagem proposta nesta pesquisa, que utiliza os coeficientes MFCC como entrada para os modelos de AM. Em seguida, será explorado o processo de experimentação, o qual demonstra como o SEP foi modelado para as validações e para os testes do procedimento metodológico apresentado.

A Abordagem Proposta Para Localização de Faltas

Atualmente, para localização de faltas, buscam-se métodos mais precisos e robustos ou um refinamento na resposta de outras propostas prévias, de forma que possam oferecer respostas mais confiáveis aos usuários (SILVEIRA, 2007). Na abordagem proposta no presente estudo, utilizou-se apenas os sinais de tensão das 3 fases em cada um dos dois terminais da LT, totalizando 6 sinais de tensão. De cada sinal de tensão, foram calculados os coeficientes MFCC, que serviram como entradas para os modelos de AM. Ademais, para o cálculo dos coeficientes MFCC em cada fase, utilizou-se apenas uma janela com 1 ciclo do sinal de tensão, logo após a inserção da falta. Antes de serem fornecidos aos modelos de AM, realizou-se uma normalização dos coeficientes MFCC, de forma que a média tivesse valor 0 e a variância fosse igual a 1. Além disso, dividiu-se o conjunto de dados para as tarefas de treinamento, de teste e de validação. O AM, após ser treinado tendo como padrão de entrada os coeficientes MFCCs, forneceu na sua camada neural de saída a estimativa da distância de falta na linha de transmissão.

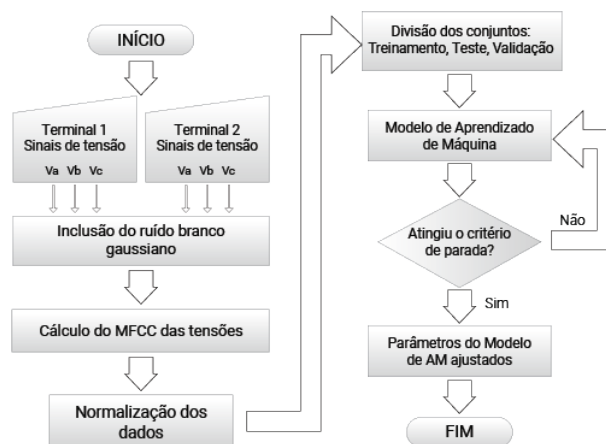
A Figura 20 ilustra as etapas da fase de treinamento do Modelo de AM, no procedimento metodológico proposto, para localização de faltas em linhas de transmissão.

Figura 20 – Fluxograma do procedimento metodológico proposto na fase de Treinamento do Modelo de AM



Na Figura 21, apresentou-se o fluxograma que descreve o momento de adição do ruído branco gaussiano dentro do processo de treinamento do modelo de aprendizado de máquina.

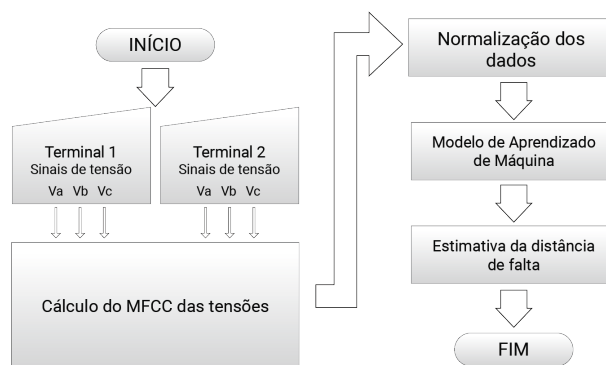
Figura 21 – Fluxograma do procedimento com inclusão de ruído na fase de Treinamento do Modelo de AM



Para a avaliar a eficiência do algoritmo proposto, utilizou-se os cálculos do Erro Médio Absoluto (EMA) e do Erro Médio Relativo (EMR), cujas respectivas equações serão mostradas mais a frente.

A Figura 22 ilustra as etapas do procedimento metodológico, com o Modelo de AM em operação, para a localização de faltas em Linhas de Transmissão.

Figura 22 – Fluxograma do procedimento metodológico proposto para localização de faltas de LT.

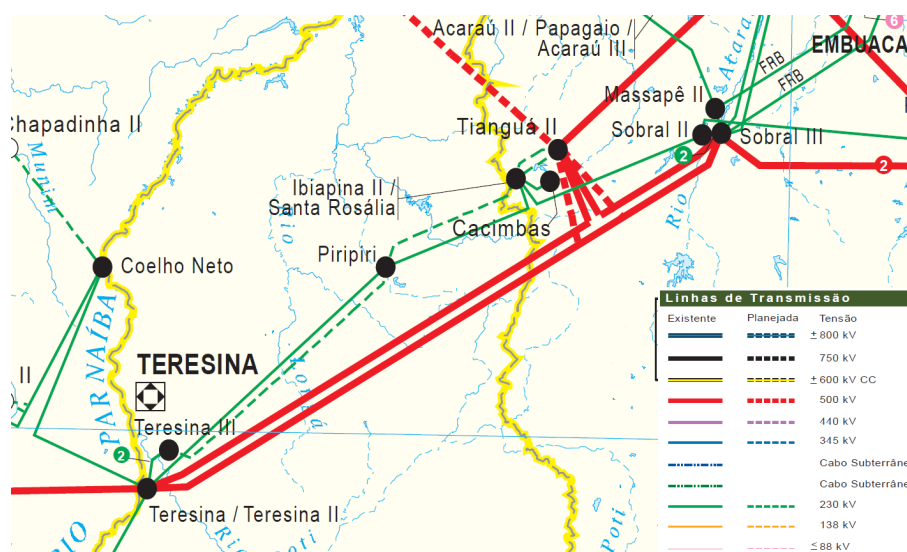


Os trabalhos foram executados em um computador HP ProBook 640 G8 Notebook PC, com processador Intel(R) Core(TM) i5-1145G7 @ 2.6GHz, 2611 Mhz, 4 Núcleos(s), 8 processadores lógicos, com 16 GB de memória física (RAM) e rodando o sistema operacional Microsoft Windows ®10 Pro.

B Sistema Elétrico de Potência Modelado no Software ATP

A fim de tornar o processo de avaliação e de validação mais confiável, para execução desta pesquisa, foi selecionada uma linha de transmissão real de cerca de 330 km, que interliga as subestações de Teresina(PI) II e de Sobral(CE) III, pertencentes ao Sistema Interligado Nacional (SIN), conforme mostrado na Figura 23 .


Figura 23 – Parte das linhas de transmissão da rede de operação Norte/Nordeste.



Fonte: Adaptado do Mapa Geométrico Rede de Operação Norte/Nordeste (ONS, 2019)

Esta linha de transmissão foi foco de outros estudos (OLIVEIRA, 2011; ABREU, 2015; REIS, 2020), que serviram como referência para embasar a construção de um modelo mais confiável para utilização neste trabalho. Destaca-se a importância dessa LT, visto que se localiza no entrocamento de duas regiões importantes do Nordeste, além de fazer parte do Sistema Interligado Nacional (SIN). É um sistema de transmissão de alta tensão real, de 500 kV, que utiliza torres estaiadas do tipo VX. A Figura 24 ilustra a estrutura das torres descritas.

Figura 24 – Modelo de linha com torre em V Feixe Expandido Simétrico (VX – Simétrico) de 500 kV.



Fonte: Adaptado de Machado et al. (2007)

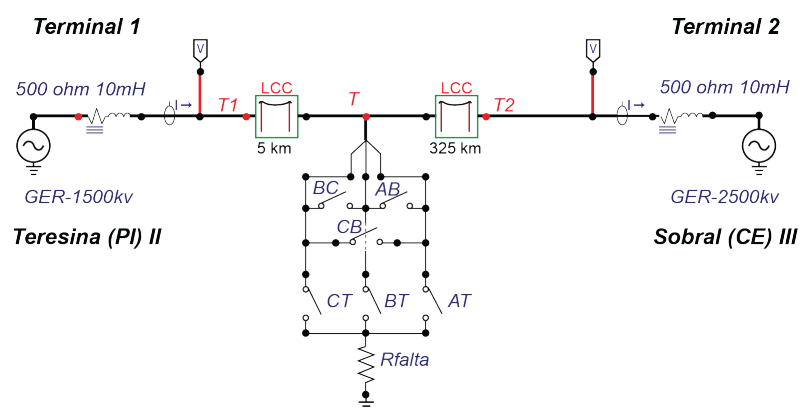
Segundo Machado et al. (2007), as referidas torres possuem três fases, com dois cabos guarda e quatro condutores cada, além de outras características mostradas na Tabela 3.

Tabela 3 – Características da linha de transmissão

Característica	Valor
Disposição horizontal nas fases espaçadas	11 metros
Sub-condutores 954 MCM RAIL	4
External radius of conductors	14,795 mm
Raio interno dos condutores	3,7 mm
Resistência em corrente contínua	0,05995 ohm/km
Altura dos condutores	41 m
Flecha média a meio de vão	13,43 m
Cabos para-raios com condutores EHS 3/8" com raio externo	4,57 mm
Resistência em corrente contínua	4,307 ohm/km
Resistência de solo considerada	1.000 ohm.m

Foi utilizado o software ATP, versão 2010 ®(*Alternative Transient Program*)¹, baseado no EMTP (*Eletromagnetic Transient Program*), para a modelagem da linha de transmissão apresentada, conforme modelo de arquivo de dados mostrado no apêndice A. Essa ferramenta pode ser aplicada em qualquer configuração de LT de modelo concentrado ou distribuído, sendo, portanto, possível avaliar os parâmetros da linha e gerar as tensões terminais das faltas simuladas nesta tese. Por meio da interface gráfica *ATPDraw*², versão 6.2, usada em conjunto com o ATP/EMTP, viabilizou-se a modelagem, as simulações e as análises de diferentes cenários de faltas no SEP. Um número considerável de situações de falta foi testado e validado. O Sistema modelado, ilustrando os parâmetros apresentados acima, é apresentado na Figura 25.

Figura 25 – Sistema de Transmissão modelado no software *ATPDraw*.



¹ O software ATP é uma ferramenta para simulação digital, utilizada por engenheiros e pesquisadores, a qual permite a simulação de redes polifásicas com configuração arbitrária sob transitórios em uma ampla faixa de frequências.

² O ATPDraw contém ampla capacidade de modelos para linhas de transmissão, cabos, disjuntores, cargas, conversores, dispositivos de proteção, elementos não-lineares e acoplamento eletromagnético, permitindo a criação e, posteriormente, a edição das topologias do sistema elétrico.

No modelo apresentado na Figura 25, o primeiro trecho, compreendido entre os pontos $T1$ e T , corresponde à distância do ponto de falta até o Terminal 1. Já o segundo trecho, compreendido entre os pontos T e $T2$, corresponde à distância do ponto de falta até o Terminal 2. O modelo da linha é baseada em parâmetros distribuídos, dependentes da frequência, e com tensão nominal de 500 kV em cada terminal. Utilizou-se dois terminais e taxa de amostragem de 400 Khz nas simulações, conforme apresentado na Figura 25.

No sistema modelado, de acordo com adaptação nas especificações dos estudos supracitados, configurou-se os parâmetros da linha de transmissão da seguinte forma:

a) Para o Terminal 1

a.1) Fonte trifásica *GER-1* (Componente *ACSOURCE*)

Uma fonte trifásica, chamada de *GER-1*, modelada no componente *ACSOURCE* do *ATPDraw*, com tensão de 500 Kv e frequência fundamental de 60 Hz, no Terminal 1, conforme ilustrado na Figura 26.

Figura 26 – Entrada de dados no componente *ACSOURCE* da fonte *GER-1* do Terminal 1.

Component: ACSOURCE

Attributes

DATA	UNIT	VALUE
AmplitudeA	Volt	500000
Frequency	Hz	60
PhaseAngleA	degrees	0
StartA	sec	-1
StopA	sec	1000

NODE	PHASE	NAME
AC	ABC	SBT00

Copy Paste Reset Order: 0 Label: GER-1 500 kv

Comment:

Type of source: Current Voltage

Num phases: Single 3-phase 3*1-phase

Angle units: Degrees Seconds

Amplitude: Peak L-G RMS L-G RMS L-L

Grounding: Grounded Ungrounded

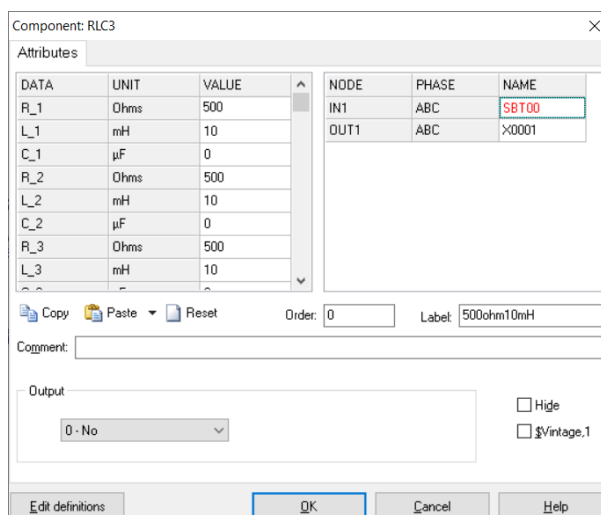
Hide

Edit definitions OK Cancel Help

a.2) Carga Trifásica Equilibrada (Componente *RLC3*)

Uma carga trifásica equilibrada, modelada no componente *RLC3*, com resistência(R) igual a 500 ohm, indutância(L) igual a 10 mH e capacitância(C) igual a 0, no Terminal 1, conforme ilustrado na Figura 27 .

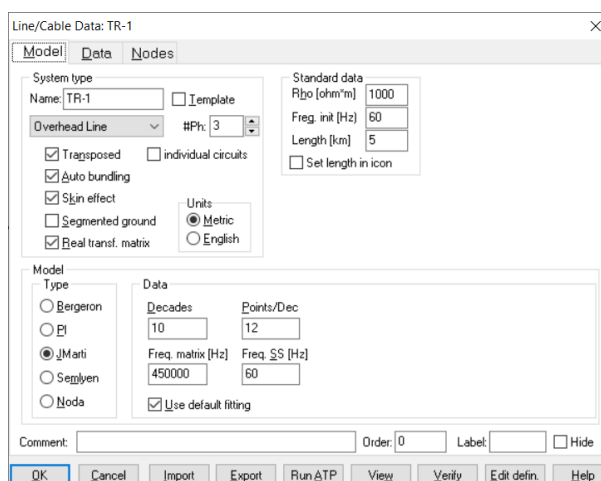
Figura 27 – Entrada de dados no componente *RLC3* da carga trifásica equilibrada do Terminal 1.



a.3) Line Cable Constant (LCC)

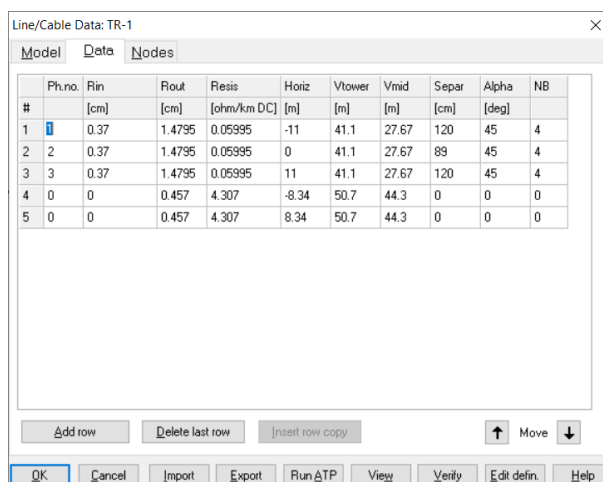
A linha de transmissão foi modelada com a utilização, ainda, de um Line Cable Constant (LCC), para o qual, no sistema modelado na Figura 25, o *Length (km)* é o valor inicial da linha, representado por *TR-1*, equivalente a 5 km. O restante da linha é inserido em *TR-2* e equivale a 325 km, o que completa o total de 330 km que compreende a extensão total da linha simulada, conforme ilustrado na Figura 28.

Figura 28 – Entrada de dados para o modelo *LCC* do Terminal 1.



Na aba de dados do modelo da LT, no *ATPDraw*, a coluna *Rin* corresponde ao raio interno de 3,7 mm ou 0,37 cm, enquanto a coluna *Rout* corresponde ao raio externo dos condutores, de 14,795 mm ou 1,4795 cm, e a coluna *Resis* corresponde a resistência em corrente contínua, de 0,05995 ohm/ km, conforme o ilustrado na Figura 29.

Figura 29 – Entrada de dados da linha de transmissão no Terminal 1.

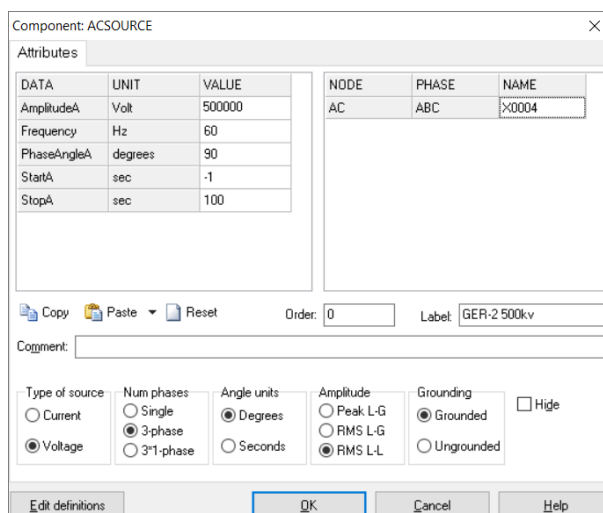


b) Para o Terminal 2

b.1) Fonte trifásica GER-2 (Componente ACSOURCE)

Da mesma forma, usou-se uma fonte trifásica chamada de GER-2, modelada no componente ACSOURCE do ATPDraw, com tensão de 500 Kv e com frequência fundamental de 60 Hz, no Terminal 2, conforme ilustrado na Figura 30.

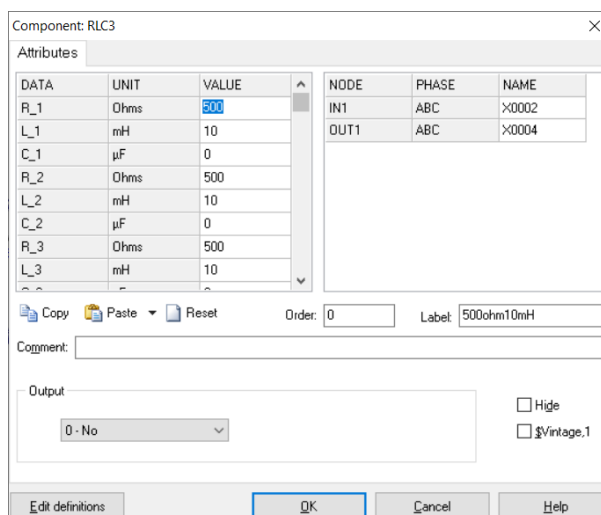
Figura 30 – Entrada de dados no componente ACSOURCE da fonte GER-2 do Terminal 2.



b.2) Carga Trifásica Equilibrada (Componente RLC3)

Uma carga trifásica equilibrada, modelada no componente RLC3, com resistência(R) igual a 500 ohm, indutância(L) igual a 10 mH e capacitância(C) igual a 0, no Terminal 2, conforme ilustrado na Figura 31 .

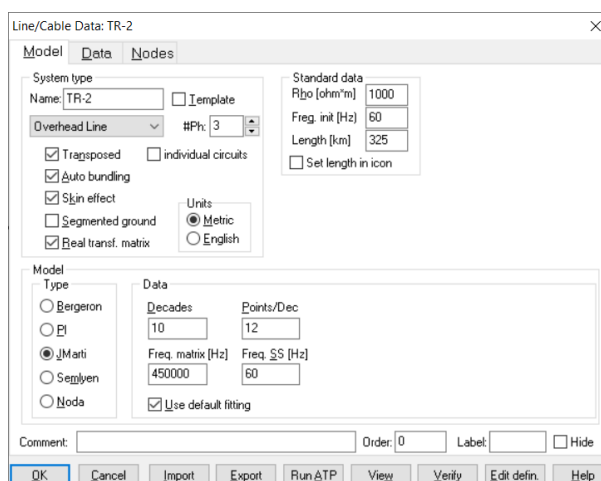
Figura 31 – Entrada de dados no componente *RLC3* da carga trifásica equilibrada do Terminal 2.



b.3) Line Cable Constant (LCC)

A linha de transmissão também foi modelada com a utilização de um Line Cable Constant (LCC), para o qual, no sistema modelado na Figura 25, o *Length (km)* é o valor final da linha, representado por *TR-2*, que equivale a 325 km. O restante da linha é inserido em *TR-1*, que tem valor igual a 5 km, para completar o total de 330 km que compreende a extensão total da linha simulada, conforme ilustrado na Figura 32.

Figura 32 – Entrada de dados para o modelo *LCC* do Terminal 2.



Na aba de dados do modelo da LT, no *ATPDraw*, a coluna *Rin* corresponde ao raio interno, de 3,7 mm ou 0,37 cm, enquanto a coluna *Rout* corresponde ao raio externo dos condutores, de 14,795 mm ou 1,4795 cm, e a coluna *Resis* corresponde a resistência em corrente contínua, de 0,05995 ohm/ km, conforme o ilustrado na Figura 33.

Figura 33 – Entrada de dados da linha de transmissão no Terminal 1.

#	Ph.no.	Rin	Rout	Rres	Horiz	Vtower	Vmid	Separ	Alpha	NB
		[cm]	[cm]	[ohm/km DC]	[m]	[m]	[m]	[cm]	[deg]	
1	1	0.37	1.4795	0.05995	-11	41.1	27.67	120	45	4
2	2	0.37	1.4795	0.05995	0	41.1	27.67	89	45	4
3	3	0.37	1.4795	0.05995	11	41.1	27.67	120	45	4
4	0	0	0.457	4.307	-8.34	50.7	44.3	0	0	0
5	0	0	0.457	4.307	8.34	50.7	44.3	0	0	0

c) Chaves de controle (Componentes *TSWITCH*)

Os dados da simulação são controlados através das chaves de controle, representadas pelos componentes *TSWITCH*, do *ATPDraw*, e configuradas de forma independente para cada tipo de falta, conforme fechamento e abertura do circuito. Essas chaves de controle submetem a LT aos diversos tipos de faltas: Monofásica envolvendo a terra (FT), bifásica (FF), bifásica envolvendo a terra (FFT), trifásica (FFF) e trifásica envolvendo a terra (FFFT). Ademais, insere-se, em *T-cl*, o tempo de incidência do ângulo de 0, de 45 ou de 90 graus para cada simulação, conforme ilustrado na Figura 34.

Figura 34 – Entrada de dados para o componente *TSWITCH* para ângulo de incidência 0°.

DATA	UNIT	VALUE
T-cl	s	
T-op	s	1000
Imar	Amps	0
3-ph	0/1	0

NODE	PHASE	NAME
From	B	T
To	A	T

O período, representado por *T*, é calculado pela Equação 4.1, sendo *F* a faixa de

frequência em Hz.

$$T = \frac{1}{F} \quad (4.1)$$

Então, considerando F como 60 Hz, obtém-se um T equivalente a 0,01666667 para um ângulo de 360°.

Nos casos dos ângulos diferentes de zero graus é necessário calcular o tempo de incidência ($T-cl$) antes de inserir os dados no *TSWITCH*. Para encontrar o tempo correspondente a esse angulo, utilizamos uma regra de três simples:

c.1) Para o ângulo de 45°

Usou-se a regra: 360° está para $T=0,01666667$, assim como 45° está para $X=0,00208333$, o qual foi inserido no $T-cl$.

c.2) Para o ângulo de 90°

Usou-se a regra: 360° está para $T=0,01666667$, assim como 90° está para $X=0,00416667$, o qual foi inserido no $T-cl$.

d) *Probe* Trifásico de Tensão.

Os Transformadores de Corrente (TC) e os de Potencial (TP) não foram modelados. Além disso, os *probes* trifásicos de tensão do simulador foram usados para aquisição dos sinais a serem processados neste trabalho, conforme ilustrado na Figura 35.

Figura 35 – Representação do *probe* trifásico de tensão.



C Aquisição dos Dados

Os dados de entrada para o algoritmo de Aprendizagem de Máquina utilizado para a estimativa da distância de faltas em LT foram os sinais das tensões durante a falta de ambos os terminais, *Terminal 1 e Terminal 2*, da linha de transmissão modelada no ATP (*Alternative Transients Program*). Esses dados foram, ainda, passados por um processo de extração de

características pelos coeficientes MFCC. Nos casos em que se utiliza dados reais, obtidos através de registradores digitais de sinais de alta frequência, torna-se necessário que haja um meio de comunicação entre os terminais, para transferência dos dados, bem como um método para sincronização das medições destes.

A base de dados das faltas na linha de transmissão foi obtida para diferentes distâncias (variadas de 5 em 5 km), variando-se resistência (5 em 5 ohm) e ângulo de incidência (0, 45 e 90 graus) para os seguintes tipos de faltas: Monofásica envolvendo a terra (FT), bifásica (FF), bifásica envolvendo a terra (FFT), trifásica (FFF) e trifásica envolvendo a terra (FFFT). A taxa de amostragem utilizada para as simulações foi de 400 KHz. Nas simulações, também foram variados o ângulo de incidência e a resistência de falta ao longo de toda extensão da LT. Na Tabela 4, detalha-se as quantidades de simulações das faltas na linha de transmissão, considerando os tipos de faltas, as resistências em Ohm, os ângulos de incidência em graus e as distâncias de falta em km. Dessa forma, obteve-se 20.301 simulações cada, para as faltas do tipo monofásica, bifásica e trifásica, todas envolvendo terra, e 20.100 simulações cada, para os tipos de falta bifásica e trifásica, totalizando 101.103 faltas simuladas.

Tabela 4 – Quantidades de simulações por tipo de falta

Tipo de falta	Resistência (Ohm)	Ângulo (Graus)	Distância (KM)	Quantidade
FT	0 a 500	0, 45 e 90	0,9 a 329,1	20.301
FF	-	0, 45 e 90	0,9 a 329,1	20.100
FFT	0 a 500	0, 45 e 90	0,9 a 329,1	20.301
FFF	-	0, 45 e 90	0,9 a 329,1	20.100
FFFT	0 a 500	0, 45 e 90	0,9 a 329,1	20.301
Total de Faltas Simuladas				101.103

Deve-se observar que para faltas sem o terra (FF e FFF), nas quais não tem variação da resistência, obteve-se a quantidade de faltas mostradas na Tabela 4 em virtude de cada tipo de falta ter sido replicada tantas vezes para equilibrar o conjunto de dados.

D Experimentação

Nesta seção, serão apresentados os parâmetros e as configurações das ferramentas utilizadas, bem como a forma como elas foram variadas nos diferentes testes. Os resultados dos testes realizados foram registrados abaixo.

Para extração de características dos sinais com o método MFCC, utilizou-se 10, 20, 30 e 40 filtros. Destaca-se que cada filtro forneceu um coeficiente relacionado à sua faixa de frequência. Uma vez que foram utilizados sinais de tensão das 3 fases dos dois terminais, foram obtidos, respectivamente, 60, 120, 180 e 240 coeficientes MFCC, para serem utilizados como entradas para os Modelos de AM. Observa-se, ainda, que antes da divisão aleatória nos

conjuntos de treinamento, de teste e de validação, foi realizada uma normalização dos valores dos coeficientes MFCC.

D.1 Experimentos com o banco de dados total e sem inserir ruído nos sinais de falta

A partir da base de dados obtida, de acordo com a Tabela 4, de um total de 101.103 entradas, 71.054 (70 %) foram selecionado para o conjunto de treinamento, 15.226 (15 %) para o conjunto de validação e 15.226 (15 %) para o conjunto de teste, todos aleatoriamente separados. O conjunto de teste nunca foi apresentado à rede durante o treinamento e as etapas de validação para garantir que tivesse uma boa resposta. A validação cruzada não foi utilizada devido à grande quantidade de dados gerados nesta proposta, o que proporcionou um bom desempenho das redes treinadas, mesmo com treinamento sem validação cruzada. Em seguida, os 3 algoritmos de regressão foram treinados com os dados: RNA, SVR e LS-SVR. Os ajustes para treinamento são explicados abaixo.

Os parâmetros de treinamento da RNA são mostrados na Tabela 5. Foram testadas diferentes topologias de rede para a abordagem proposta, com entradas variando entre 60 e 240, dependendo do número de coeficientes MFCC obtidos, como descrito anteriormente. Foi realizada, ainda, uma variação de 20 a 100 neurônios na camada oculta. Os critérios de parada para o treinamento das RNAs foram: 1) Erro do conjunto de validação aumentado sucessivamente mais de 6 (seis) vezes; e 2) Número máximo de 500 épocas. Nesta proposta, para impedir que a RNA fique presa no mínimo local, a constante que atualiza os pesos é chamada de constante de momento ou parâmetro de momento (MU).


Tabela 5 – Parâmetros da arquitetura da RNA

Crítérios	Valor
Quantidade de entradas	60, 120, 180 e 240
Número de neurônios na camada oculta	20, 40, 60, 80 e 100
Número de neurônios na camada de saída	1
Função de ativação da camada oculta	Função sigmóide
Função de ativação do neurônio de saída	<i>Purelin</i>
Algoritmo de treinamento da rede neural	<i>Levenberg-Marquardt</i>
Critério de parada	Teste de validação (6) ou número de épocas (500)
Medida de erro adotado	Erro Quadrático Médio (<i>MSE</i>)
MU inicial	0,001
Fator de diminuição MU	0,1
Fator de aumento MU	10

A Figura 36 ilustra as 3 camadas de uma das RNAs implementadas para estimar a distância de falta em uma LT. Nessa figura, é exemplificada a topologia da RNA que contou com

240 entradas e 80 neurônios na camada oculta, com função de ativação sigmoide. A camada neural de saída sempre conta com um neurônio e com função de ativação purelim, fornecendo como saída a estimativa da distância de falta na LT.

Figura 36 – Estrutura de uma das RNAs treinadas.



O SVR foi implementado com kernel Gaussian RBF e seus parâmetros foram ajustados com um método de otimização. Considerando o banco de dados completo, não foi possível executar o LS-SVR com os recursos computacionais disponíveis, pois, após o processo de aprendizado, é necessário armazenar todos os padrões de treinamento, bem como os multiplicadores de Lagrange associados para fins de composição de funções discriminantes.

D.2 Experimentos com subconjuntos de banco de dados sem inserir ruído nos sinais de falta

Para investigar a influência do tamanho do banco de dados usado para treinamento no desempenho dos modelos de AM testados, foram realizados testes alterando o número de situações de falta utilizadas. Subconjuntos do banco de dados original foram selecionados aleatoriamente, mantendo-se as proporções entre os tipos de falta, considerando as porcentagens de 50 %, 25 %, 12,5 % e 6,25 % do banco de dados original, conforme ilustrado na Tabela 6, sem a adição de ruído.

Tabela 6 – Percentuais da base de dados original

Percentual (%)	Quantidade
100	101.103
50	50.552
25	25.276
12,5	12.638
6,25	6.319

Como o objetivo desses testes foi verificar o desempenho e a precisão do método proposto diante de base de dados menores, então, para estimar as distâncias das faltas, a melhor topologia

de RNA encontrada para o banco de dados completo foi retreinada para cada subconjunto da Tabela 6.

D.3 Experimentos utilizando a melhor topologia de RNA com subconjuntos de banco de dados com inserção de ruído gaussiano nos sinais de falta

Araújo (2011) afirma que os sinais medidos nas extremidades das linhas de transmissão reais possuem uma relação sinal-ruído (SNR)³ superior a 60 dB. Nesse sentido, optou-se por avaliar o desempenho do melhor modelo sem ruído, adicionando ruído branco gaussiano⁴ aos sinais de tensão adquiridos, a fim de verificar a robustez do método proposto.

Apesar da literatura apontar que a relação sinal-ruído é geralmente superior a 60db, também foram realizados testes com sinais com menores relação sinal-ruído. As relações sinal-ruído utilizadas foram 100 dB, 75 dB, 50 dB e 25 dB. Além disso, foi formado um conjunto de dados em que a relação sinal-ruído em cada situação poderia variar de 25 dB a 100 dB aleatoriamente.

Os experimentos sempre foram realizados se utilizando a topologia da RNA que teve o melhor desempenho nos experimentos sem ruído. As redes foram retreinadas para cada subconjunto da base original, agora considerando a inserção de diferentes níveis de ruído. Em seguida, os testes foram realizados novamente com sinais contendo ruído.

Antes da extração dos Coeficientes de Frequência Mel *Cepstrais*, o ruído foi adicionado ao sinal de tensão original obtido com a falta na LT nos dois terminais, de acordo com a Tabela 4. A intensidade do SRN foi dada pela Equação 4.2:

$$SNR_{dB} = 10 \cdot \log_{10} \left(\frac{P_s}{P_n} \right) \quad (4.2)$$

Sendo:

- SNR_{dB} a relação sinal-ruído em decibel
- P_s a potência média do sinal
- P_n a potência média do ruído

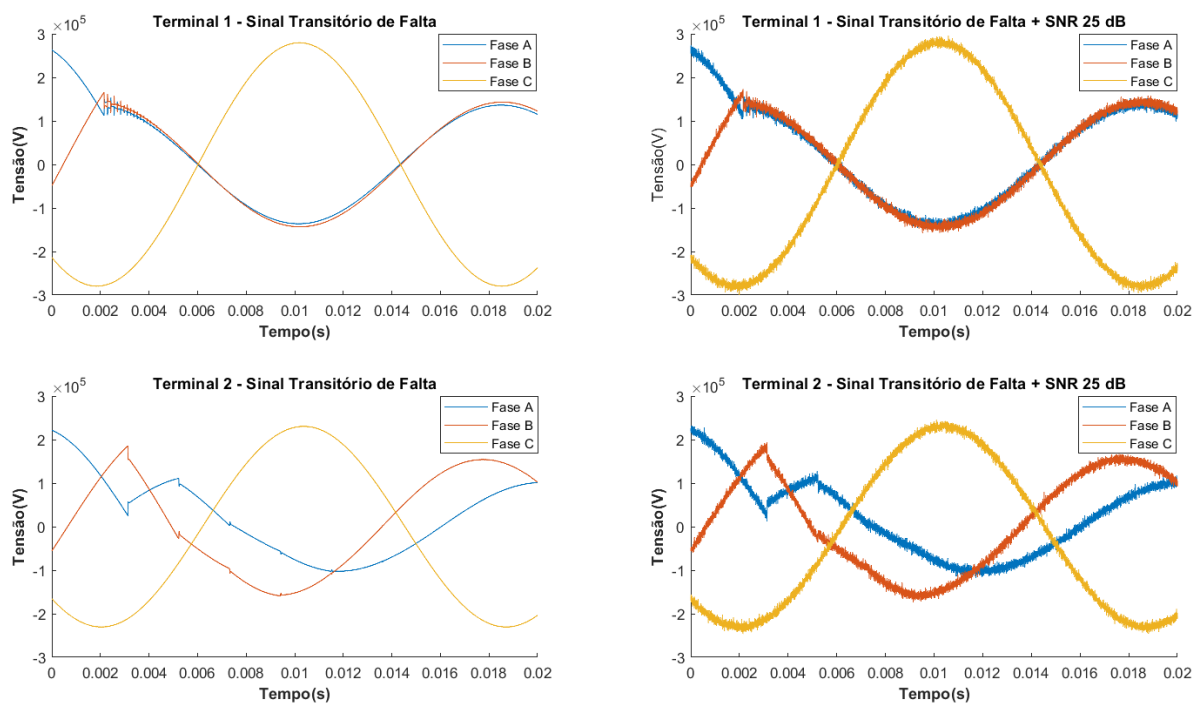
A Figura 37 ilustra o sinal transitório de tensão em ambos os terminais da linha. Trata-se de uma falta bifásica que ocorreu a 20 km do primeiro terminal. Essa falta ocorreu com um ângulo de incidência de 45 graus e com uma janela de dados com um ciclo, para uma frequência

³ O SNR é a razão da potência de um sinal e a potência do ruído sobreposto ao sinal, geralmente expressa em Decibel.

⁴ O ruído branco gaussiano é adicionado aos sinais de tensão ou de corrente com o intuito de aproximar o sinal proveniente de simulações computacionais dos sinais encontrados em oscilografias reais.

de amostragem de 400 kHz. Os gráficos mostram os sinais de tensões sem e com a influência de ruído branco gaussiano, adicionado com razão sinal-ruído (SNR) de 25 dB.

Figura 37 – Sinal Transitório de Falta Sem e Com Ruído Branco Gaussiano de SNR 25 dB.



D.4 Análise do desempenho do melhor modelo frente à variação dos parâmetros de falta

Após analisar o desempenho de todos os modelos de AM com diferentes tamanhos de subconjuntos do banco de dados original, foi realizada uma análise do desempenho do modelo que obteve o melhor resultado para investigar a influência de parâmetros como: tipo de falta, resistência da falta, ângulo de inserção da falta e distância de falta. Nessa análise, foram considerados apenas os resultados obtidos com os sinais sem adição de ruído.

D.5 Avaliação de desempenho

Para avaliar o desempenho do método proposto, usou-se o Erro Médio Absoluto (EMA) e o Erro Médio Relativo (EMR), com os seus respectivos desvios padrões, calculados da seguinte forma:

$$EMA = \frac{1}{N} \sum_{i=1}^N E_i \quad (4.3)$$

$$EMR = \frac{1}{N} \sum_{i=1}^N \frac{E_i}{L} * 100 \quad (4.4)$$

Sendo, nesse cálculo, o erro de localização da falta representado por E_i , dado pelo módulo da diferença entre a distância real e a distância estimada, N , a quantidade de faltas, e L , o comprimento da linha de transmissão (330 km).

E Considerações Finais do Capítulo

Este capítulo apresentou a abordagem proposta, demonstrando os fluxos dos algoritmos de localização. Em seguida, mostrou-se o SEP que foi modelado para viabilizar as simulações realizadas, no intuito de se obter os resultados principais almejados por este estudo. Apresentou-se, ainda, os parâmetros e as configurações das ferramentas utilizadas, além da variação de seus valores nos diversos testes realizados.

A seguir, serão apresentados os resultados dos testes realizados e as discussões embasadas em tais testes, os quais mostraram-se adequados à concretização dos resultados pretendidos para o trabalho em questão.

5 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados os resultados de cada um dos experimentos realizados. Por fim, é feita uma comparação com resultados apresentados em outros trabalhos recentes na literatura relacionada.

A Resultados de experimentos com o banco de dados total e sem inserir ruído nos sinais de falta

A partir do método utilizado nesta pesquisa se obteve os resultados mostrados na Tabela 7, usando-se o conjunto de testes de várias topologias MLP, variando-se, conforme Tabela 5, as quantidades de entradas e o número de neurônios na camada neural oculta. Para se obter a Tabela 7, primeiro se utilizou 10 coeficientes MFCC obtidos para cada um dos 6 sinais de tensão, que forneceram 60 entradas para a RNA. Variou-se, ainda, a quantidade de neurônios da camada oculta para 20, 40, 60, 80 e 100 unidades, sucessivamente. Em seguida, utilizou-se 20, 30 e 40 coeficientes obtidos de cada sinal de tensão, que forneceram, respectivamente, 120, 180 e 240 entradas para a RNA.

Dentre os resultados apresentados, o Erro Médio Absoluto (EMA), em quilômetros, mostrado na Tabela 7, foi calculado de acordo com a Equação 4.3. Por sua vez, o Erro Médio Relativo (EMR), mostrado na mesma tabela, mas em porcentagem, foi calculado de acordo com a Equação 4.4. Destaca-se que foram utilizadas redes com uma maior quantidade de neurônios na camada oculta, entretanto, na mesma proporção em que foi aumentado o número de neurônios, o desempenho das redes diminuiu progressivamente.

Na Tabela 7, é possível perceber que, utilizando-se uma quantidade de 40 coeficientes MFCC de cada um dos 6 sinais de tensão, que forneceram 240 entradas para a RNA, obteve-se, com 80 neurônios na camada neural oculta, o resultado de maior acurácia e precisão do EMA. Esse resultado foi de 0,00013 km, com desvio padrão de 0,00189 km. Em termos de erro relativo, obteve-se um EMR de 0.00004 %, com desvio padrão de 0,00057 %.


Tabela 7 – Resultado geral do uso de diferentes quantidades de coeficientes MFCC e de diferentes quantidades de neurônios na camada oculta de uma RNA

FF	E	NN	EMA (KM)	Desvio Padrão (KM)	EMR (%)	Desvio Padrão (%)
10	60	20	0,12247	0,17163	0,03711	0,05201
10	60	40	0,11977	0,17632	0,03629	0,05343
10	60	60	0,01253	0,02881	0,00380	0,00873
10	60	80	0,00832	0,02463	0,00252	0,00746
10	60	100	0,02078	0,06087	0,00630	0,01845
20	120	20	0,01533	0,03476	0,00465	0,01053
20	120	40	0,00428	0,01176	0,00130	0,00356
20	120	60	0,00215	0,00766	0,00065	0,00232
20	120	80	0,00086	0,00118	0,00026	0,00036
20	120	100	0,00460	0,00751	0,00139	0,00227
30	180	20	0,00429	0,00879	0,00130	0,00266
30	180	40	0,00228	0,00545	0,00069	0,00165
30	180	60	0,00158	0,05082	0,00048	0,01540
30	180	80	0,00087	0,00162	0,00026	0,00049
30	180	100	0,00361	0,00733	0,00109	0,00222
40	240	20	0,00412	0,01039	0,00125	0,00315
40	240	40	0,00161	0,05576	0,00049	0,01690
40	240	60	0,00149	0,01359	0,00045	0,00412
40	240	80	0,00013	0,00189	0,00004	0,00057
40	240	100	0,00167	0,01402	0,00051	0,00425

FF: faixas de frequência, E: Entradas (MFCC) e NN: números de neurônios

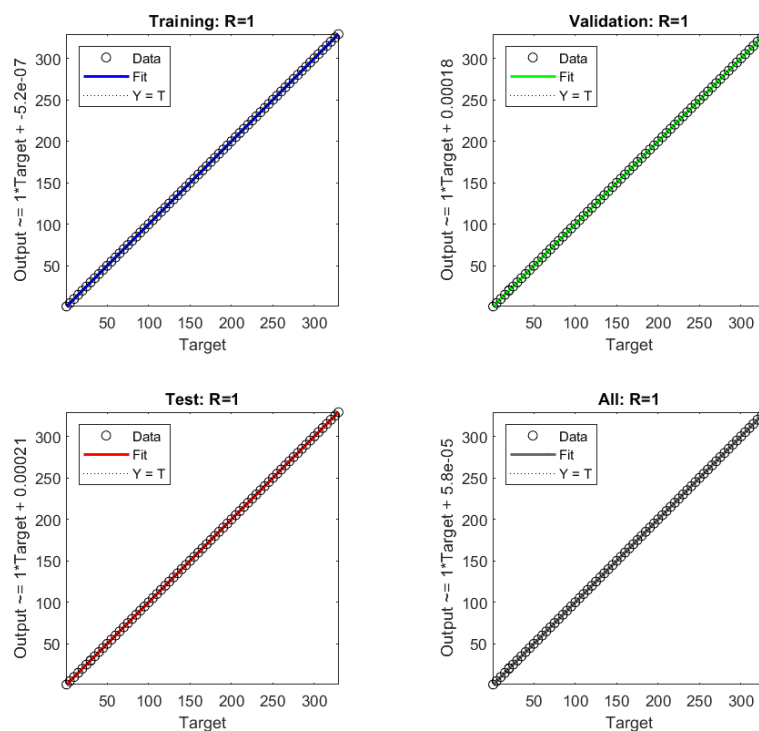
O gráfico de desempenho da Figura 38 ilustra o Erro Quadrático Médio (MSE) dos conjuntos de treino, de validação e de teste para a topologia da RNA com melhor desempenho. O gráfico mostra uma convergência rápida da rede, que sugere que as características selecionadas como entrada e a topologia selecionada têm um bom desempenho para a solução do problema. Além disso, observou-se um MSE tendendo a zero, o que indica a alta precisão do método proposto para localização de falta na LT. A topologia de rede escolhida, com 240 entradas e 80 neurônios na camada oculta, alcançou o melhor desempenho no conjunto de validação, com 500 épocas e MSE de 1.1449e-09.

Figura 38 – Desempenho de treinamento da rede neural.



O gráfico de regressão linear da RNA, ilustrado na Figura 39, mostra o ajuste entre o valor real e o estimado, refletindo a alta precisão do método baseado em RNA proposto.

Figura 39 – Regressão linear para o algoritmo de treinamento (RNA).



Na Tabela 8, são apresentados desempenhos com conjuntos de testes de diversos SVRs, variando-se as quantidades de coeficientes MFCC de sinais de tensões utilizados como entrada. Mais uma vez, pode-se observar que o modelo que possuía 240 entradas, ou seja, 40 coeficientes MFCC de cada uma das três fases em dois terminais, foi o que apresentou melhor desempenho. O melhor modelo SVR teve o EMA de 0,02192 km, com desvio padrão de 0,01615 km. Para esse modelo, o EMR foi de 0,00664 %, com desvio padrão de 0,00489 %.

Tabela 8 – Resultado geral da utilização de diferentes quantidades de coeficientes MFCC com entrada de SVRs, para todos os conjuntos de dados.

FF	E	EMA (KM)	Desvio Padrão (KM)	EMR (%)	Desvio Padrão (%)
10	60	0,11843	0,07381	0,03589	0,02237
20	120	0,04524	0,03034	0,01371	0,00919
30	180	0,02701	0,02020	0,00819	0,00612
40	240	0,02192	0,01615	0,00664	0,00489

FF: faixas de frequência e E: Entradas (MFCC)

Os resultados apresentados nas Tabela 7 e 8 evidenciam a eficiência do método proposto para estimar a localização de faltas em LT, na medida em que se apresentam muito perto dos valores das distâncias de falta originais. Adicionalmente, percebeu-se que, quanto maior for o número de coeficientes MFCC utilizado, ou seja, quanto mais detalhada for a informação sobre as frequências dos sinais de tensão devido ao uso de uma maior quantidade de filtros mel triangulares, melhor será o desempenho dos algoritmos de regressão.

Dentre as topologias testadas, a que apresentou melhor desempenho para a RNA foi a que possuía 240 entradas e 80 neurônios na camada oculta. Para a SVR, por sua vez, foi a que possuía 240 entradas. Essas topologias serão utilizadas para apresentar os detalhes dos resultados obtidos, a fim de verificar a variação do desempenho frente à variação do tamanho do banco de dados utilizado para treinamento e para testes. Os resultados obtidos pela topologia da RNA com 240 entradas e 80 neurônios na camada oculta foram utilizados para identificar a influência dos tipos de falta, da variação da resistência de falta, do ângulo de falta e da distância de falta nos resultados fornecidos pelo modelo. Usou-se esses resultados, ainda, para verificar o comportamento das respostas fornecidas pelo modelo quando os sinais adquiridos para treinamento e para testes apresentaram ruído.

B Resultados de experimentos com subconjuntos do banco de dados original sem inserir ruído nos sinais de falta

A Tabela 9 mostra os resultados das estimativas das distâncias de falta obtidas pelos algoritmos de aprendizado de máquina LS-SRV, RNA e SRV, quando esses modelos são treinados e testados considerando subconjuntos com tamanhos da base de dados original de 6,25 %, 12,5 %, 25 %, 50 %, 75 % e 100 %.

25 %, 50 %, e 100 %. É importante lembrar que, para esses testes, os modelos que consideraram as topologias de melhor desempenho para a base original foram retreinados. É importante destacar que, nos treinamentos, a RNA teve o menor tempo médio de processamento em relação a SVR e a LS-SVR.

Observa-se que a RNA, em comparação com o SVR, obteve melhores resultados com todos os tamanhos de subconjunto testados. No entanto, é possível afirmar que todos os modelos SVR fornecem uma alta precisão para a estimativa da distância da falta, para sinais sem adição de ruído, com EMA maior de 0,18471 Km e EMR de 0,05597 %.

Tanto para os modelos baseados em RNA quanto para os baseados em SVR, observa-se que, na medida em que o tamanho do conjunto de dados para treinamento/teste diminui, o desempenho dos modelos também diminui. A maior depreciação de desempenho é observada para os modelos baseados em RNA para conjuntos menores, apesar de ainda apresentarem melhor desempenho que os modelos baseados em SVR. Os modelos baseados em ambas as ferramentas já apresentam resultados semelhantes. A maior estabilidade de desempenho dos modelos baseados em SVR, frente à diminuição do tamanho das bases de treinamento, provavelmente está relacionada às características do algoritmo SVR, que trabalha com vetores de suporte e com regularização.

Tabela 9 – Influência do tamanho da base de dados no desempenho da localização de falta considerando diferentes algoritmos

FF	E	NN	EMA (KM)	Desvio Padrão(KM)	EMR (%)	Desvio Padrão(%)	Subconjunto (%)	Algoritmo de AM
40	240	-	0,11381	0,50912	0,03449	0,15428	6,25	LS-SVR
40	240	80	0,13286	0,78606	0,04026	0,23820	6,25	RNA
40	240	-	0,18471	0,51347	0,05597	0,15560	6,25	SVR
40	240	-	NP	NP	NP	NP	12,50	LS-SVR
40	240	80	0,03486	0,28808	0,01056	0,08730	12,50	RNA
40	240	-	0,04922	0,36058	0,01492	0,10927	12,50	SVR
40	240	-	NP	NP	NP	NP	25,00	LS-SVR
40	240	80	0,01243	0,08863	0,00377	0,02686	25,00	RNA
40	240	-	0,03445	0,09221	0,01044	0,02794	25,00	SVR
40	240	-	NP	NP	NP	NP	50,00	LS-SVR
40	240	80	0,00738	0,04232	0,00224	0,01282	50,00	RNA
40	240	-	0,02161	0,03407	0,00655	0,01032	50,00	SVR
40	240	-	NP	NP	NP	NP	100,00	LS-SVR
40	240	80	0,00013	0,00189	0,00004	0,00057	100,00	RNA
40	240	-	0,02192	0,01615	0,00664	0,00489	100,00	SVR

FF: Faixas de Frequência, E: Entradas (MFCC), NN: Números de Neurônios, Subconjunto (%): tamanho do subconjunto utilizado em relação ao banco de dados original e NP: Não Processada (Memória)

Ainda em relação aos modelos treinados com subconjuntos de diferentes tamanhos, observou-se que foi possível treinar um modelo baseado em LS-SVR com um subconjunto

com 6319 situações de falta, o que representa 6,25 % da base original. O modelo baseado em LS-SVR apresentou o melhor desempenho para esse tamanho de banco de dados. Provavelmente, esse desempenho está relacionado à forma como a ferramenta encontra o vetor de suporte, considerando todas as amostras do conjunto de treinamento como parte dele. Essa mesma característica impediu o treinamento e o teste da ferramenta com bancos de dados com maior número de situações de falta, pois, a partir do subconjunto de 12,5 % da base de dados original, esse algoritmo não foi mais processado, devido ao erro de estouro de memória.


Considerando que os modelos baseados em RNA tiveram melhor desempenho para a maioria dos subconjuntos de treinamento/teste e considerando que foi possível realizar treinamento baseado em RNA para todos os tamanhos de base, os demais experimentos foram realizados considerando os modelos baseados em RNA.

C Resultados de experimentos utilizando a melhor topologia de RNA com subconjuntos de banco de dados e inserção de ruído gaussiano nos sinais de falta

A Figura 40 mostra a variação do EMR de estimativa de distância de falta com a adição de diferentes níveis de ruído, quais sejam, SNRs de 100 dB, de 75 dB, de 50 dB, de 25 dB e de 25-100 dB, aos sinais de falta para diferentes tamanhos de subconjuntos de treinamento e de teste, ou seja, 100 %, 50 %, 25 %, 12,5 % e 6,25 % da base original. Os mesmos EMR são apresentadas na Tabela 10, com seus respectivos desvios-padrão.

Já foi observado que, sem ruído nos sinais, a abordagem proposta apresenta erros baixos. A partir da Tabela 10, além de se confirmar esse fato, notou-se também que o uso do banco de dados de simulação completo manteve um bom desempenho do modelo de AM baseado em RNA, mesmo na presença de sinais altamente ruidosos. Observou-se também que, quando o tamanho do subconjunto utilizado para os testes é reduzido, à medida que o ruído no sinal aumenta, o erro aumenta gradativamente.

Figura 40 – Desempenho de modelos baseados em RNA com 240 entradas e 80 neurônios na camada oculta, para treinamento com diferentes subconjuntos de diferentes tamanhos e diferentes níveis de ruído.



Então, através da Figura 40, de forma geral, observa-se que:

- Por mais ruidoso que seja o sinal de tensão, existe um tamanho de subconjunto da base em que o erro é muito pequeno;
- Para qualquer relação sinal-ruído, usando-se 100 % da base de dados original, o desempenho do método é muito preciso;
- Quando se reduz o tamanho da base e a relação sinal-ruído, o erro aumenta gradativamente;
- e
- Para sinais sem ruído, mesmo os modelos treinados com o menor subconjunto de dados, obteve uma excelente precisão na localização de faltas, com erro de 0,04026% e Desvio padrão de 0,23820%.

Tabela 10 – Influência do desempenho de modelos baseados em RNA com subconjuntos de banco de dados e inserção de ruído gaussiano nos sinais de falta

FF	E	NN	EMA (KM)	Desvio Padrão(KM)	EMR (%)	Desvio Padrão(%)	Subconjunto (%)	SNR (dB)
40	240	80	0,00013	0,00189	0,00004	0,00057	100,00	-
40	240	80	0,00738	0,04232	0,00224	0,01282	50,00	-
40	240	80	0,01243	0,08863	0,00377	0,02686	25,00	-
40	240	80	0,03486	0,28808	0,01056	0,08730	12,50	-
40	240	80	0,13286	0,78606	0,04026	0,23820	6,25	-
40	240	80	0,00180	0,02804	0,00054	0,00850	100,00	100
40	240	80	0,03633	0,33565	0,01101	0,10171	50,00	100
40	240	80	0,08761	0,56704	0,02655	0,17183	25,00	100
40	240	80	0,11309	1,36676	0,03427	0,41417	12,50	100
40	240	80	0,24385	1,22559	0,07389	0,37139	6,25	100
40	240	80	0,02573	0,10796	0,00780	0,03272	100,00	75
40	240	80	0,06777	0,44339	0,02054	0,13436	50,00	75
40	240	80	0,14524	0,97142	0,04401	0,29437	25,00	75
40	240	80	0,21628	1,70487	0,06554	0,51663	12,50	75
40	240	80	0,60154	4,26516	0,18229	1,29247	6,25	75
40	240	80	0,07087	0,26844	0,02148	0,08134	100,00	50
40	240	80	0,29630	0,78207	0,08979	0,23699	50,00	50
40	240	80	0,72022	1,80908	0,21825	0,54821	25,00	50
40	240	80	1,14385	2,50289	0,34662	0,75845	12,50	50
40	240	80	1,74734	4,36754	0,52950	1,32350	6,25	50
40	240	80	0,18585	0,40113	0,05632	0,12155	100,00	25
40	240	80	2,02036	4,72242	0,61223	1,43104	50,00	25
40	240	80	5,24064	9,45494	1,58807	2,86513	25,00	25
40	240	80	8,13247	14,41047	2,46438	4,36681	12,50	25
40	240	80	9,57924	17,98679	2,90280	5,45054	6,25	25
40	240	80	0,15178	1,28230	0,04599	0,38858	100,00	25 - 100
40	240	80	0,64700	2,90815	0,19606	0,88126	50,00	25 - 100
40	240	80	1,17678	4,55296	0,35660	1,37968	25,00	25 - 100
40	240	80	1,95130	5,90378	0,59130	1,78902	12,50	25 - 100
40	240	80	2,78765	7,38596	0,84474	2,23817	6,25	25 - 100

FF: Faixas de Frequência, E: Entradas (MFCC), NN: Números de Neurônios e Subconjunto (%): tamanho do subconjunto utilizado em relação ao banco de dados original

As estimativas de distância de falta a partir de sinais de tensão com relação sinal-ruído entre 75 dB e 100 dB apresentaram erros absolutos médios inferiores a 600 metros, ou EMR de 0,18 %, para qualquer tamanho de subconjunto utilizado para treinamento dos modelos de AM. Isso mostra que a presença de ruído em níveis próximos aos 60 dB indicados pela literatura (ARAÚJO, 2011) não causa grandes danos à localização da falta pelos métodos propostos, pois em uma situação prática, na maioria dos casos, já seria possível identificar visualmente a localização exata da falha a 600 metros de distância. Mesmo para sinais de tensão com relação sinal-ruído de 50 dB, o erro encontrado para todos os subconjuntos ainda é aceitável para

qualquer tamanho de subconjunto usado no treinamento do modelo, apesar dos erros absolutos na linha modelada estarem entre 1 km e 2 km e o MRE estar entre 0,34 % e 0,53 % para subconjuntos de treinamento com 12,5 % e 6,25 % do conjunto de dados original. Para sinais muito ruidosos, por exemplo, com relação sinal-ruído de 25 dB, percebeu-se que é necessário um banco de dados relativamente grande para treinar o modelo, para que as distâncias possam ser estimadas satisfatoriamente. Uma alternativa, na presença de sinais ruidosos, quando não for possível obter um grande banco de dados de treinamento, é utilizar filtros passa-baixa na aquisição dos sinais, aliado a uma metodologia semelhante à proposta por (ALMEIDA, 2017), eliminando o ruído do sinal.

D Resultados da análise do desempenho do melhor modelo frente à variação dos parâmetros de falta

Nesta seção, foi realizada uma análise de desempenho do modelo de AM baseado em RNA, que obteve o melhor resultado, para investigar a influência de parâmetros como: tipo de falta, resistência da falta, ângulo de inserção da falta e distância de falta. Nesta análise, foram considerados apenas os resultados obtidos com os sinais sem adição de ruído.

D.1 Influência dos Tipos de Faltas

Nota-se, na Tabela 11, o registro da influência do tipo de falta na abordagem proposta. Verifica-se que as faltas FT e FFT apresentaram um maior EMR, de 0,00010 % e de 0,0008 %, respectivamente, e que os menores EMR foram verificados nas faltas FF, FFF e FFFT, todos com 0,00001 %. Conforme apresentado na supracitada tabela, é possível deduzir que o procedimento metodológico proposto apresenta resultados com alta precisão para todos os tipos de faltas. Além disso, é possível deduzir que a resistência de falta ou sua variação em faltas desequilibradas pode ter influência no desempenho da abordagem, uma vez que as faltas que não envolvem terra têm um desempenho melhor do que os observados nas faltas do tipo FT e principalmente FFT. As piores situações, envolvendo faltas FT, apresentam um Erro Médio Absoluto (MAE) de aproximadamente 0,00034 km, que é um erro aceitável, mostrando o bom desempenho do método proposto.

Tabela 11 – Influência do tipo de falta

Tipo de falta	EMA (KM)	Desvio Padrão (KM)	EMR (%)	Desvio Padrão (%)
FT	0,00034	0,00355	0,00010	0,00108
FF	0,00001	0,00001	0,00001	0,00001
FFT	0,00028	0,00229	0,00008	0,00069
FFF	0,00002	0,00003	0,00001	0,00001
FFFT	0,00002	0,00002	0,00001	0,00001

D.2 Influência das Resistências de Faltas

Os grupos representados na Tabela 12 foram estratificados de acordo com a resistência de falta. Optou-se por dividir os dados da seguinte forma: 0 Ω , 5 Ω , 10 Ω , 15 Ω , 20 Ω , 25 Ω a 30 Ω , 35 Ω a 40 Ω , 45 Ω a 50 Ω , 55 Ω a 250 Ω e 255 Ω a 500 Ω . Assim, foi possível observar que os resultados associados às resistências maiores ou iguais a 55 Ω tiveram melhores EMR, de aproximadamente 0,00004 %, e poucas variações. Observa-se que os valores de resistência inferiores ou iguais a 5 Ω são responsáveis pelos maiores erros médios absolutos. No entanto, mesmo nas faltas de baixa resistência, os erros de estimativa observados não são tão relevantes, representando em média valores entre 1 e 5,12 metros, com desvio padrão de até 24,17 metros. Faltas com resistências entre 10 Ω e 50 Ω tiveram suas distâncias estimadas com erro ligeiramente superior ao obtido para ausências com impedâncias superiores ou iguais a 55 Ω . Destaca-se que, quanto menor a resistência de falta, maior o transitório associado. Quanto maior a resistência de falta, menor o transitório associado e menor será a alteração percebida na forma de onda da tensão. Então, percebe-se que resistências de falta maiores, que provocam uma menor alteração nas ondas de tensão, proporcionam erros menores para a abordagem proposta.

Tabela 12 – Influência da resistência de falta

Resistência de falta Ω	EMA (KM)	Desvio Padrão (KM)	EMR (%)	Desvio Padrão (%)
0	0,00106	0,00418	0,00032	0,00127
5	0,00512	0,02417	0,00155	0,00732
10	0,00030	0,00054	0,00009	0,00017
15	0,00047	0,00134	0,00014	0,00041
20	0,00028	0,00037	0,00009	0,00011
25 a 30	0,00026	0,00045	0,00008	0,00014
35 a 40	0,00028	0,00142	0,00008	0,00043
45 a 50	0,00018	0,00025	0,00006	0,00008
55 a 250	0,00014	0,00019	0,00004	0,00006
255 a 500	0,00015	0,00019	0,00004	0,00006

D.3 Influência dos Ângulos de Faltas

Um comportamento um pouco diferente é observado em relação ao ângulo de inserção de falta. Normalmente, as faltas ocorridas a 90° estão associadas a transitórios um pouco mais severos do que aquelas ocorridas a zero graus. Contudo, essas alterações, devido a sua natureza transitória, persistem no sinal por um tempo menor do que as alterações provocadas pela resistência de falta, que permanecem no sinal até a extinção da falha. Nos testes realizados, o procedimento metodológico proposto apresenta um desempenho melhor para localizar faltas com ângulo de inserção de 90°, sendo os piores resultados associados com faltas ocorridas a 0°. Assim, observa-se que as maiores alterações do sinal de tensão, que são provocadas pela variação do ângulo de tensão e que permanecem por pouco tempo no sinal, são favoráveis ao método de

localização proposto. Considerando a influência do ângulo de falta nesta proposta, representada na Tabela 13, observou-se que faltas ocorridas com o ângulo 0° apresentaram um maior EMR, de 0,00007 %. Esse valor diminui com o aumento do ângulo, até ser obtido o menor valor de EMR, para o ângulo de 90°, que foi de 0,00002 %. Observa-se que o ângulo de 0°, mesmo com o pior resultado de MAE, de 0,23 m, ainda é bastante preciso.

Tabela 13 – Influência do ângulo de falta

Ângulo de falta (°)	EMA (KM)	Desvio Padrão (KM)	EMR (%)	Desvio Padrão (%)
0	0,00023	0,00327	0,00007	0,00099
45	0,00011	0,00063	0,00003	0,00019
90	0,00007	0,00022	0,00002	0,00007

D.4 Influência das Distâncias de Faltas

Em seguida, a Tabela 14 apresenta os resultados do uso de diferentes distâncias de ocorrência de faltas. Optou-se por dividir os dados em parcelas de 30 km, com exceção das extremidades, que foram de 29,10 km, para se realizarem as análises. Com isso, foi possível constatar que as faltas ocorridas em distâncias intermediárias (31 km a 300 km) tiveram EMR menores, que variaram de 0,00002 % a 0,00004 % em relação àquelas mais próximas aos terminais. Ademais, verificou-se que a distância de falta também interfere no comportamento do método de localização de faltas sugerido. Contudo, as respostas apresentadas ainda possuem EMR bastante pequenos, mesmo nas piores das situações, que, em termos absolutos, não superaram a 0,36 m, para as faltas ocorridas próximo aos dois terminais da LT.

Tabela 14 – Influência da distância de falta

Distância de falta	EMA (KM)	Desvio Padrão (KM)	EMR (%)	Desvio Padrão (%)
0,9 a 30	0,00036	0,00520	0,00011	0,00158
31 a 60	0,00010	0,00044	0,00003	0,00013
61 a 90	0,00010	0,00052	0,00003	0,00016
91 a 120	0,00008	0,00041	0,00003	0,00012
121 a 150	0,00011	0,00027	0,00003	0,00008
151 a 180	0,00010	0,00023	0,00003	0,00007
181 a 210	0,00010	0,00039	0,00003	0,00012
211 a 240	0,00008	0,00014	0,00002	0,00004
241 a 270	0,00008	0,00014	0,00002	0,00004
271 a 300	0,00013	0,00076	0,00004	0,00023
301 a 329,1	0,00025	0,00347	0,00007	0,00105

E Considerações Finais do Capítulo

Apesar de algumas das condições discriminadas nas tabelas 11, 12, 13 e 14 influenciarem positivamente ou negativamente no desempenho do método proposto, fica claro, analisando o desvio padrão dos erros, que tal influência não é relevante. Os resultados alcançados sugerem que o método proposto, tendo o melhor modelo de AM encontrado, é capaz de identificar a localização de faltas com erros médios absolutos inferiores a 1 m para todas as situações. No geral o erro médio absoluto foi de 0,00013 Km e erro médio relativo de 0,00004 %. Já o desvio padrão geral foi de 0,00189 km ou 0,00057 %, em termos relativos.

Com o objetivo de verificar o desempenho do procedimento metodológico proposto frente a outros métodos já apresentados na literatura, elaborou-se a Tabela 15, que resume o desempenho de diversas abordagens. É possível observar que o método proposto, com a RNA de 240 coeficientes MFCC como entrada da RNA e 80 neurônios na camada oculta, foi o que apresentou menor EMR dentre todos os métodos listados na Tabela 15. Esse resultado pode ser atribuído principalmente ao fato de os coeficientes MFCC terem fornecido boas características para a RNA, facilitando a estimativa da distância de falta.

Tabela 15 – Comparação dos resultados de técnicas que usam inteligência computacional

Metodologia	Extração de Características	Ferramenta de IC	EMR (%)	Ciclos
Yusuff et al., 2011	WPT, sobre tensões e correntes em um terminal	SVR	0,00210	0,50
Uyar, 2012	S-Transformer, sobre correntes em um terminal	LS-SVR	0,00170	1,00
Yusuff, Jimoh e Munda, 2014	SWT, sobre tensões e correntes em um terminal	SVR	0,00210	0,25
Yadav e Swetapadma, 2015	SWT, sobre tensões e correntes em um terminal	SVR	0,00100	1,00
Almeida et al., 2017	ICA e TW, sobre tensões em um terminal	SVM	0,15687	1,00
Nagam, Koley and Ghosh, 2017	DFT, sobre tensões e correntes em um terminal	RNA	0,90000	1,00
Fei, Qi and Li, 2018	Sem extração e uso de tensões em um terminal	SVR	0,00090	0,25
Hassani, Razavi-Far e Saifm, 2019	PSD e VMD, sobre correntes em um terminal	Neuro-Fuzzy, SVR e RNA	0,00160	1,00
Proposta	MFCC, sobre as tensões em dois terminais	RNA	0,00004	1,00

Ressalta-se que o método proposto neste trabalho utilizou apenas sinais de tensão, enquanto todos os outros documentados na Tabela 15 utilizaram sinais de tensão e de corrente como entradas para seus algoritmos. Por outro lado, as demais propostas apresentadas na Tabela 15 utilizaram sinais de apenas 1 terminal. Assim, novas pesquisas devem ser desenvolvidas

investigando o desempenho de modelos AM que utilizam tanto sinais de tensão quanto de corrente, mas com apenas 1 terminal e com as ferramentas propostas neste trabalho. Ressalta-se também que quatro dos trabalhos apresentados utilizaram uma janela de dados menor (de 0,5 e 0,25 ciclos) do que a utilizada nesta proposta (1 ciclo) e, ainda assim, apresentaram resultados bastante satisfatórios. Apesar do tamanho da janela de dados utilizada (1 ciclo a 60 Hz) não ser um parâmetro que poderia influenciar no tempo total gasto no reparo de uma linha de transmissão, é interessante investigar propostas com janelas menores, a fim de propor estratégias que demandem menor processamento dos algoritmos utilizados para extração de características e da estimação da distância de falta.

6 CONCLUSÕES E TRABALHOS FUTUROS

A Conclusões

Faltas em LT causam grandes prejuízos aos usuários e aos mantenedores de Sistemas Elétricos de Potência (SEP). Dessa forma, é de suma importância tornar o processo de localização de tais faltas cada vez mais eficiente, para que estas possam ser reparadas o mais rápido possível. A partir da revisão bibliográfica realizada, percebe-se que as tendências mais atuais dos métodos de localização de faltas se relacionam com os métodos baseados em AM. Este trabalho apresentou um procedimento metodológico que utiliza um modelo de AM para estimar a distância de falta. As entradas do modelo AM foram os coeficientes MFCC obtidos dos sinais de tensão das três fases da tensão, medidas nos dois terminais da linha de transmissão.

As diversas situações de falta foram aplicadas às simulações de um sistema elétrico protótipo, modelado conforme os dados da linha de transmissão real de cerca de 330 km que interliga as subestações de Teresina(PI) II e de Sobral(CE) III, pertencentes ao SIN. Tal modelagem foi executada no programa ATP/EMTP e resultou em uma grande variabilidade da dinâmica transitória dos sinais faltosos. Além disso, proporcionou um banco de dados consistente para uma validação satisfatória do algoritmo de localização. Este método utiliza os sinais de tensão de dois terminais que foram amostrados na frequência de 400 KHz. Foram utilizados tanto dados sem ruído, como também dados com adição de ruído branco gaussiano aos sinais de tensão. O objetivo de se adicionar o ruído branco gaussiano foi de aproximar o sinal da falta simulada aos sinais de oscilografia reais.

Para avaliar o método de localização de faltas apresentado, realizou-se, inicialmente, várias simulações para se obter a arquitetura de melhor desempenho do modelo de AM. Os resultados oriundos das simulações com o modelo abordado trazem um Erro Médio Absoluto de 0,00013 km, com desvio padrão de 0,00189 km. Ao mesmo tempo, para os mesmos dados, obteve-se um Erro Médio Relativo (EMR) de 0,00004 %, com desvio padrão de 0,00057 %, para um modelo de AM baseado em RNA, que contou com 240 entradas e com 80 neurônios na camada oculta. Esses resultados apontam que o procedimento metodológico proposto é uma boa alternativa para localização de faltas em LT. A comparação com os resultados da literatura pesquisada até então mostrou que a metodologia proposta apresenta acurácia equivalente ou superior às relatadas em outros trabalhos que utilizam técnicas de AM para localização de falhas em LT. Os coeficientes MFCC, principalmente aqueles calculados diretamente sobre os sinais de tensão e de corrente, são pouco explorados na área de EPS, mas os resultados encontrados neste trabalho indicam que esta é uma ferramenta que pode ser útil para esta e outras aplicações de

EPS.

Posteriormente, foi feita uma comparação do método proposto, utilizando-se os algoritmos LS-SVR, RNA e SVR, para uma base de dados sem ruído e com diferentes subconjuntos. Todas as simulações apresentaram resultados precisos e próximos. Entretanto, a LS-SVR não foi processada em subconjuntos maiores que 6,25 % da base original, devido ao estouro de memória do equipamento utilizado para os treinamentos.

Após isso, foram feitas várias análises em relação ao uso de diferentes subconjuntos de coeficientes MFCCs. Observou-se que os modelos obtiveram respostas um pouco melhores quando foram utilizados 40 filtros MEL triangulares. Ou seja, a ferramenta de extração de características utilizada é útil para a redução de atributos utilizados no treinamento. No entanto, é importante que as informações no domínio da frequência sejam um pouco mais detalhadas, com o uso de mais filtros. Avaliou-se, ainda, o método a partir da adição de várias relações sinais-ruídos aos sinais de tensão. Observou-se, através de diferentes testes, que o ruído presente no sinal, se dentro de limites aceitáveis, com relação sinal-ruído de até 70 dB, tem influência numérica na precisão apresentada pela abordagem proposta. No entanto, esses valores não são relevantes na prática, pois cada um deles permitiria a identificação visual do ponto de falha. Para linhas com relação sinal/ruído entre 50 dB e 25 dB, embora o erro percentual também não seja tão alto com conjuntos de treinamento menores de modelos de AM, o desempenho tende a melhorar com o aumento das amostras fornecidas para treinamento, o que possibilita obter o mesmo nível de precisão para sinais sem ruído se o banco de dados for grande o suficiente. Outra alternativa para sinais de linha muito ruidosos é aplicar técnicas de filtragem e outras abordagens de redução de ruído.

Finalizando, foram verificadas as influências do tipo de falta, das resistências de faltas, dos ângulos de faltas e das distâncias de faltas no método de localização, utilizando-se os resultados da melhor arquitetura da RNA.

A comparação com resultados da literatura pesquisada até a data da elaboração deste trabalho, registrada na Tabela 15, apontou que o procedimento metodológico proposto apresentou resultados com precisão equivalente ou superior ao reportado em outros trabalhos que utilizam técnicas de AM para localização de faltas em LT. Acredita-se que o bom desempenho obtido na proposta está associado à ferramenta de extração de características dos coeficientes MFCC, que são pouco explorados na área de SEP. Contudo, os resultados encontrados nesta pesquisa indicam que essa é uma ferramenta que pode ser útil para esta e outras aplicações em SEP.

B Trabalhos Futuros

Como trabalhos futuros, pretende-se investigar o emprego dos dados de tensão obtidos em um único terminal para a localização de falta, utilizando-se das mesmas ferramentas propostas neste trabalho. Pretende-se, também, investigar a aplicação do procedimento metodológico que

utilize as correntes medidas em um e em ambos os terminais, associadas ou não com os sinais de tensão. Pretende-se, ainda, propor a aplicação de algoritmos com janelas inferiores a 1 ciclo, também utilizando modelos de AM e coeficientes MFCC. Por fim, pretende-se também investigar o desempenho da abordagem proposta em outras linhas de transmissão modeladas no ATP.

Referências

- ABREU, F. Localização de faltas em linhas de transmissão utilizando ondas viajantes e transformada Wavelet sob influência de ruído branco. 2015. Disponível em: <<http://www.repositorio.ufc.br/handle/riufc/13873>>. Citado 3 vezes nas páginas 21, 28 e 48.
- ABU-SIADA, A.; MIR, S. A new on-line technique to identify fault location within long transmission lines. *Engineering Failure Analysis*, v. 105, p. 52–64, 2019. ISSN 1350-6307. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1350630719306223>>. Citado na página 38.
- AHMED, A. S. et al. Comparison between genetic algorithm and whale optimization algorithm in fault location estimation in power systems. In: *2017 Nineteenth International Middle East Power Systems Conference (MEPCON)*. [S.l.: s.n.], 2017. p. 631–637. Citado 2 vezes nas páginas 1 e 5.
- AJAEI, F. B.; SANAYE-PASAND, M. Minimizing the impact of transients of capacitive voltage transformers on distance relay. In: *Joint International Conference on Power System Technology and IEEE Power India Conference*. [S.l.: s.n.], 2008. p. 1–6. Citado na página 4.
- AKMAZ, D. et al. Transmission line fault location using traveling wave frequencies and extreme learning machine. *Electric power systems research*, Elsevier B.V, v. 155, p. 1–7, 2017. ISSN 0378-7796. Citado na página 42.
- ALMEIDA, A. R. *O Uso de Análise de Componentes Independentes na Extração de Características dos Sinais Transitórios de Faltas em Linhas de Transmissão de Energia Elétrica*. Tese (Doutorado em Engenharia Elétrica) — Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza, 2017. Citado na página 70.
- ALMEIDA, A. R. et al. Ica feature extraction for the location and classification of faults in high-voltage transmission lines. *Electric Power Systems Research*, v. 148, p. 254–263, 2017. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S037877961730130X>>. Citado 4 vezes nas páginas 4, 5, 38 e 42.
- ALVES, M. H. et al. Teoria das ondas viajantes e filtragem adaptativa de sinais para localização de faltas em linhas de transmissão. In: *12º Congresso Brasileiro de Inteligência Computacional/2º Latin-American Conference on Computational Intelligence, Curitiba, Paraná, Brasil*. Curitiba, PR: ABRICOM, 2015. p. 1–6. Citado na página 19.
- ANACE, A. N. dos Consumidores de E. *Linha de Belo Monte falha e Norte e NE têm apagão*. 2018. Disponível em: <<http://www.anacebrasil.org.br/noticias/linha-de-belo-monte-falha-e-norte-e-ne-tem-apagao/>>. Acesso em: 30 de janeiro de 2022. Citado 2 vezes nas páginas 2 e 3.
- ARAÚJO, M. d. S. *Influência de famílias wavelets e suas ordens no desempenho de um localizador de faltas em linhas aéreas de transmissão de energia elétrica*. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-graduação em Engenharia Elétrica, Belém, 2011. Citado 3 vezes nas páginas 29, 59 e 69.

ASHOK, V. et al. An Intelligent Fault Locator for 400-kV Double-Circuit Line of Chhattisgarh State: A Comparative Study. In: NAYAK, J. et al. (Ed.). *Soft Computing in Data Analytics*. Singapore: Springer Singapore, 2019. p. 39–49. ISBN 978-981-13-0514-6. Citado 2 vezes nas páginas 4 e 36.

ASLAN, Y.; YAĞAN, Y. E. Artificial neural-network-based fault location for power distribution lines using the frequency spectra of fault data. *Electrical Engineering*, v. 99, n. 1, p. 301–311, 2017. ISSN 1432-0487. Disponível em: <<https://doi.org/10.1007/s00202-016-0428-8>>. Citado na página 41.

BELLO, A. C. D.; CORRÊA, G. R. Análise de sinais provocados por defeitos em linhas de transmissão utilizando técnicas de telecomunicação e processamento de sinais. In: . [S.l.: s.n.], 2008. Citado na página 5.

BEWLEY, L. Traveling waves on transmission systems. *Transactions of the American Institute of Electrical Engineers*, IEEE, v. 50, n. 2, p. 532–550, 1931. Citado 3 vezes nas páginas 19, 23 e 24.

BIRLASEKARAN, S.; LI, H. Detection of faulty insulators on power transmission line. In: *2000 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No.00CH37077)*. [S.l.: s.n.], 2000. v. 4, p. 2817–2821 vol.4. Citado na página 5.

BIRVINSKAS, D. et al. Fast dct algorithms for eeg data compression in embedded systems. p. 49–62, 2015. Citado na página 18.

BO, Z. et al. Transient based protection for power transmission systems. In: *2000 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No.00CH37077)*. [S.l.: s.n.], 2000. v. 3, p. 1832–1837 vol.3. Citado na página 29.

BOTELHO, L. L. R. et al. Revisão Bibliométrica sobre Mudança Organizacional e Aprendizagem Gerencial em uma Organização Intensiva em Conhecimento. *ENANPAD*, 2011. Disponível em: <<http://www.anpad.org.br/admin/pdf/EOR13.pdf>>. Citado na página 34.

BRANCO, H. M. C.; REIS, J. B.; PEREIRA, L. M. Localização de faltas em linha de transmissão utilizando coeficientes de frequência mel cesptrais e ls-svr. 2019. ISSN 2447-8326. Citado na página 44.

BREGA, J. R. F. et al. A utilização de redes neurais artificiais em um sistema de gerência de pavimentos. 2018. Disponível em: <https://teses.usp.br/teses/disponiveis/18/18137/tde-14032018-114100/publico/Tese_Brega_JoseRF.pdf>. Citado na página 30.

BRENT, W. *Physical and perceptual aspects of percussive timbre*. [S.l.]: University of California, San Diego, 2010. Citado na página 28.

CARNEIRO, S. M.; RABELO, R. d. A. L.; BRANCO, H. M. G. C. A Multi-objective Approach for Optimized Monitoring of Voltage Sags in Distribution Systems. *Journal of Control, Automation and Electrical Systems*, v. 29, n. 3, p. 371–380, 2018. ISSN 2195-3899. Disponível em: <<https://doi.org/10.1007/s40313-018-0371-1>>. Citado na página 1.

CHEN, K.; HUANG, C.; HE, J. Fault detection, classification and location for transmission lines and distribution systems: a review on the methods. *High Voltage*, v. 1, n. 1, p. 25–33, 2016. Disponível em: <<https://ietresearch.onlinelibrary.wiley.com/doi/abs/10.1049/hve.2016.0005>>. Citado 2 vezes nas páginas 3 e 4.

CLARKE, E. *Circuit analysis of AC power systems*. [S.l.]: New York: John Wiley & Sons, 1993. Citado na página 24.

COLQUI, J. S. et al. Modelo de linha de transmissão a parâmetros concentrados: Uma abordagem otimizada. *Simpósio Brasileiro de Sistemas Elétricos-SBSE*, v. 1, n. 1, 2020. Citado na página 9.

COSTA, F. B. *Detecção e Classificação de Falhas em Linhas de Transmissão Baseadas na Transformada Wavelet*. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal de Campina Grande, PB - Brasil, 2006. Disponível em: <<http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/9482>>. Citado na página 1.

COSTA, F. B. *Uma técnica de diagnóstico em tempo real de distúrbios transitórios baseada na transformada wavelet para uso em registradores digitais de perturbação*. Tese (Doutorado em Engenharia Elétrica) — Universidade Federal de Campina Grande. Centro de Engenharia Elétrica e Informática, Campina Grande, 2010. Citado 3 vezes nas páginas 28, 29 e 30.

COSTA, F. B. Fault-induced transient detection based on real-time analysis of the wavelet coefficient energy. *IEEE Transactions on Power Delivery*, v. 29, n. 1, p. 140–153, 2014. Citado 2 vezes nas páginas 4 e 29.

DAVOUDI, M. G.; SADEH, J.; KAMYAB, K. Time domain fault location on transmission lines using genetic algorithm. In: *2012 11th International Conference on Environment and Electrical Engineering*. [S.l.: s.n.], 2012. p. 1087–1092. Citado na página 5.

DELLER, J. R.; HANSEN, J. H. L.; PROAKIS, J. G. Discrete-time processing of speech signals. Philadelphia, PA, p. 936, 2000. Disponível em: <<https://ieeexplore.ieee.org/servlet/opac?bknumber=5266102>>. Citado 2 vezes nas páginas 25 e 26.

DOBAKHSHARI, A. S. Fast accurate fault location on transmission system utilizing wide-area unsynchronized measurements. *International Journal of Electrical Power & Energy Systems*, v. 101, p. 234–242, 2018. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061518300735>>. Citado 2 vezes nas páginas 4 e 43.

DOMMEL, H. *Electromagnetic Transients Program: Reference Manual (EMTP Theory Book)*. [S.l.]: Bonneville Power Administration, 1986. Citado na página 19.

EKICI, S. Support vector machines for classification and locating faults on transmission lines. *Applied Soft Computing*, v. 12, p. 1650–1658, 06 2012. Citado na página 39.

ESCOTO, E. F. Desenvolvimento de modelos matemáticos para o diagnóstico de falta em sistemas de transmissão de energia elétrica. Universidade Estadual Paulista (UNESP), 2020. Citado na página 14.

FATHABADI, H. Novel filter-based ann approach for short-circuit faults detection, classification and location in power transmission lines. *International Journal of Electrical Power & Energy Systems*, v. 74, p. 374–383, 2016. ISSN 0142-0615. Citado 2 vezes nas páginas 40 e 41.

FAYBISOVICH, V.; FEIGINOV, M.; KHOROSHEV, M. I. Investigation of frequency domain traveling wave fault location methods. In: *IEEE PES T D 2010*. [S.l.: s.n.], 2010. p. 1–9. Citado 2 vezes nas páginas 4 e 15.

- FEI, C.; QI, G.; LI, C. Fault location on high voltage transmission line by applying support vector regression with fault signal amplitudes. *Electric Power Systems Research*, v. 160, p. 173–179, 2018. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779618300427>>. Citado 3 vezes nas páginas 4, 5 e 43.
- FURUI, S. Digital speech processing: synthesis, and recognition. *CRC Press*, 11 2000. Citado 3 vezes nas páginas 24, 25 e 27.
- GADELHA, A. A. B. Estimativa de parâmetros geotécnicos de resíduos sólidos urbanos utilizando algoritmos de aprendizado de máquina. 2021. Disponível em: <https://repositorio.ufc.br/bitstream/riufc/63731/1/2021_dis_aabgadelha.pdf>. Citado na página 33.
- GLOVER, J.; SARMA, M.; OVERBYE, T. *Power System Analysis and Design*. 5ª edição. ed. [S.l.]: Cengage Learning, 2011. ISBN 9781111425777. Citado 2 vezes nas páginas 9 e 13.
- GUO, Y.; KEZUNOVIC, M.; CHEN, D. Simplified algorithms for removal of the effect of exponentially decaying dc-offset on the fourier algorithm. *IEEE Transactions on Power Delivery*, v. 18, n. 3, p. 711–717, 2003. Citado na página 4.
- HASHEMINEJAD, S. et al. Ultra-high-speed protection of transmission lines using traveling wave theory. *Electric Power Systems Research*, v. 132, p. 94–103, 2016. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779615003478>>. Citado na página 4.
- HASSANI, H. et al. Robust interval type-2 fuzzy observer for fault detection of networked control systems subject to immeasurable premise variables. *IEEE Systems Journal*, v. 13, n. 3, p. 2954–2965, 2019. Citado 4 vezes nas páginas 3, 5, 31 e 44.
- HAYKIN, S. O. Neural networks: A comprehensive foundation. *Person Prentice Hall*, v. 2, p. 900, 2001. Citado na página 31.
- IURINIC, L. Accurate fault location technique for power transmission lines. *International Conference on Power Systems Transients*, 07 2013. Citado na página 4.
- JUNIOR, C. A. S. Localização e classificação de faltas em linhas de transmissão utilizando o método dos mínimos quadrados e inteligência computacional. Universidade Federal de Minas Gerais, 2013. Citado na página 15.
- KHALEGHI, A.; Oukati Sadegh, M. Single-Phase Fault Location in Four-Circuit Transmission Lines Based on Wavelet Analysis Using ANFIS. *Journal of Electrical Engineering & Technology*, v. 14, n. 4, p. 1577–1584, 2019. ISSN 2093-7423. Disponível em: <<https://doi.org/10.1007/s42835-019-00209-7>>. Citado na página 37.
- LEE, D.-G.; KANG, S.-H.; NAM, S.-R. New modified fourier algorithm to eliminate the effect of the dc offset on phasor estimation using dft. In: *2008 IEEE/PES Transmission and Distribution Conference and Exposition*. [S.l.: s.n.], 2008. p. 1–6. Citado na página 4.
- LEVENBERG, K. A method for the solution of certain problems in least squares. *Quarterly of Applied Mathematics*, Brown University, v. 2, n. 2, p. 164–168, 1944. ISSN 0033569X, 15524485. Disponível em: <<http://www.jstor.org/stable/43633451>>. Citado na página 31.

- LIANG, F.; JEYASURYA, B. Transmission line distance protection using wavelet transform algorithm. *IEEE Transactions on Power Delivery*, v. 19, n. 2, p. 545–553, 2004. Citado na página 4.
- LIN, D. et al. Fault location for transmission line based on traveling waves using correlation analysis method. In: *2008 International Conference on High Voltage Engineering and Application*. [S.l.: s.n.], 2008. p. 681–684. Citado na página 4.
- LIVANI, H.; EVRENOSOGLU, C. Y. A Machine Learning and Wavelet-Based Fault Location Method for Hybrid Transmission Lines. *IEEE Transactions on Smart Grid*, v. 5, n. 1, p. 51–59, 2014. Citado 3 vezes nas páginas 4, 21 e 36.
- LOPES, F. V. *Localização de faltas em tempo real baseada na teoria de ondas viajantes usando dados não sincronizados de dois terminais*. Tese (Doutorado em Engenharia Elétrica) — Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, Campina Grande, 2014. Citado 6 vezes nas páginas 10, 11, 12, 15, 23 e 24.
- LOPES, F. V. et al. Accurate two-terminal transmission line fault location using traveling waves. *IEEE Transactions on Power Delivery*, IEEE, v. 33, n. 2, p. 873–880, 2017. Citado na página 42.
- LOPES, F. V. et al. Accurate two-terminal transmission line fault location using traveling waves. *IEEE Transactions on Power Delivery*, v. 33, n. 2, p. 873–880, 2018. Citado 2 vezes nas páginas 4 e 38.
- LOPES, F. V.; FERNANDES, D.; NEVES, W. L. A. A traveling-wave detection method based on park's transformation for fault locators. *IEEE Transactions on Power Delivery*, v. 28, n. 3, p. 1626–1634, 2013. Citado na página 4.
- LOPES, F. V. et al. Fault location on transmission lines little longer than half-wavelength. *Electric Power Systems Research*, v. 114, p. 101–109, 2014. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779614001540>>. Citado 4 vezes nas páginas 1, 3, 36 e 37.
- LOPES, F. V. et al. An adaptive fault location method for smart distribution and transmission grids. In: *2011 IEEE PES CONFERENCE ON INNOVATIVE SMART GRID TECHNOLOGIES LATIN AMERICA (ISGT LA)*. [S.l.: s.n.], 2011. p. 1–7. Citado na página 4.
- LOPES, F. V. et al. Real-time traveling-wave-based fault location using two-terminal unsynchronized data. *IEEE Transactions on Power Delivery*, v. 30, n. 3, p. 1067–1076, 2015. Citado na página 37.
- MACHADO, V. G. et al. Lt 500 kv interligação norte / sul iii — trecho 2 solução estrutural com torre estaiada monomastro e feixe expandido. *Rio de Janeiro: Seminário Nacional de Produção e Transmissão de Energia Elétrica — XIX SNPTEE GLT 01,*, 2007. Citado 2 vezes nas páginas 48 e 49.
- MAMIS, M. S.; ARKAN, M.; KELEŞ, C. Transmission lines fault location using transient signal spectrum. *International Journal of Electrical Power & Energy Systems*, v. 53, p. 714–718, 2013. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061513002512>>. Citado na página 4.

- MARQUARDT, D. W. An Algorithm for Least-Squares Estimation of Nonlinear Parameters. *Journal of the Society for Industrial and Applied Mathematics*, Society for Industrial and Applied Mathematics, v. 11, n. 2, p. 431–441, 1963. ISSN 03684245. Disponível em: <<http://www.jstor.org/stable/2098941>>. Citado na página 31.
- MISHRA, D. P.; RAY, P. Fault detection, location and classification of a transmission line. *Neural computing & applications*, Springer London, London, v. 30, n. 5, p. 1377–1424, 2017. ISSN 0941-0643. Citado 2 vezes nas páginas 4 e 45.
- MISHRA, D. P.; RAY, P. Fault detection, location and classification of a transmission line. *Neural Computing and Applications*, v. 30, n. 5, p. 1377–1424, 2018. ISSN 1433-3058. Disponível em: <<https://doi.org/10.1007/s00521-017-3295-y>>. Citado na página 45.
- MOSAVI, M. R.; TABATABAEI, A. Traveling-wave fault location techniques in power system based on wavelet analysis and neural network using gps timing. *Wireless Personal Communications*, Springer London, United States, v. 86, n. 5, p. 835–850, 2016. ISSN 1572-834X. Citado na página 41.
- NAGAM, S. S.; KOLEY, E.; GHOSH, S. Artificial neural network based fault locator for three phase transmission line with statcom. In: *2017 IEEE International Conference on Computational Intelligence and Computing Research (ICIC)*. [S.l.: s.n.], 2017. p. 1–4. Citado na página 42.
- NAIDU, S. *Transitórios Eletromagnéticos em Sistemas de Potência*. [S.l.]: Campina Grande, PB: Ed. Grafset Ltda, 1985. Citado 5 vezes nas páginas 11, 12, 19, 20 e 24.
- NELWAMONDO, F. V.; MARWALA, T. Faults detection using gaussian mixture models, mel-frequency cepstral coefficients and kurtosis. In: *2006 IEEE International Conference on Systems, Man and Cybernetics*. [S.l.: s.n.], 2006. v. 1, p. 290–295. Citado na página 24.
- NGU, E. E.; RAMAR, K. A combined impedance and traveling wave based fault location method for multi-terminal transmission lines. *International Journal of Electrical Power & Energy Systems*, v. 33, n. 10, p. 1767–1775, 2011. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061511002018>>. Citado na página 4.
- OLIVEIRA, D. d. S. d. *Classificação e Localização de Faltas em Sistemas de Transmissão com Compensação Série Utilizando Redes Neurais Artificiais*. Dissertação (Mestrado em Engenharia Elétrica) — UFRJ-COPPE-Programa de Engenharia Elétrica, Rio de Janeiro: UFRJ/COPPE, 2016. Citado 2 vezes nas páginas 31 e 40.
- OLIVEIRA, L. V. F. d. *Otimização metaheurística de linhas de transmissão pela avaliação do vetor de Poynting utilizando o método dos elementos de contorno*. Dissertação (Mestrado em Engenharia Elétrica) — Universidade de Juiz de Fora, Juiz de Fora-MG, 2011. Citado na página 48.
- ONS, O. N. do S. E. *ONS ATUALIZA RESULTADOS DA ANÁLISE DA OCORRÊNCIA QUE AFETOU O NORTE E O NORDESTE*. 2018. Disponível em: <http://www.ons.org.br/Paginas/Noticias/20180506-analiseocorrencia_norte_nordeste.aspx>. Acesso em: 30 de janeiro de 2022. Citado na página 2.
- ONS, O. N. do S. E. *Mapa Geoelétrico Rede de Operação Norte/Nordeste - 2024*. 2019. Disponível em: <<http://www.ons.org.br/paginas/sobre-o-sin/mapas>>. Acesso em: 06 de fevereiro de 2022. Citado na página 48.

ONS, O. N. do S. E. *Resultados da Operação: Qualidade do Suprimento*. 2021. Disponível em: <<http://www.ons.org.br/paginas/resultados-da-operacao/qualidade-do-suprimento>>. Acesso em: 19 de janeiro de 2022. Citado na página 1.

ONS, O. N. do S. E. *Indicadores de desempenho do SIN*. 2022. Disponível em: <<http://www.ons.org.br/Paginas/resultados-da-operacao/qualidade-do-suprimento-paineis.aspx>>. Acesso em: 19 de janeiro de 2022. Citado na página 2.

PARMAR, S. Fault location algorithms for electrical power transmission lines. In: . [S.l.: s.n.], 2015. Citado na página 14.

PEIXOTO, J. Métodos de extração de atributos para detecção de crises epiléticas: uma abordagem comparativa. 2019. Disponível em: <<http://www.repositorio.ufc.br/handle/riufc/40928>>. Citado 4 vezes nas páginas 24, 25, 26 e 27.

PHADKEDR, A. G.; THORP, J. S. Computer relaying for power systems. *John Wiley and Sons Inc*, 2009. Citado 4 vezes nas páginas 4, 17, 18 e 21.

RAJENDRA, S.; MCLAREN, P. *Travelling-wave techniques applied to the protection of teed circuits:-multi-phase/multi-circuit system*. [S.l.], 1985. Citado na página 22.

REDDY, M. J. B.; MOHANTA, D. K. Performance evaluation of an adaptive-network-based fuzzy inference system approach for location of faults on transmission lines using monte carlo simulation. *IEEE Transactions on Fuzzy Systems*, v. 16, n. 4, p. 909–919, 2008. Citado na página 5.

REIS, J. B. O. *Localização de Falta em Linha de Transmissão utilizando Coeficiente de Frequência Mel Cepstrais e LS-SVR*. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal do Piauí, Programa de Pós-Graduação em Engenharia Elétrica e Área de Concentração em Eletrônica de potência e Acionamentos Elétricos, Teresina-PI, 2020. Citado 2 vezes nas páginas 22 e 48.

REIS, T. N. F. *Um Recomendador de Alocação de Recursos em Computação em Nuvem usando Algoritmos Genéticos e SVR*. Dissertação (Mestrado) — PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO/CCET, 2018. DEPARTAMENTO DE INFORMÁTICA/CCET. Disponível em: <<https://tedebc.ufma.br/jspui/handle/tede/2323>>. Citado na página 32.

RODRIGUES Jr, W. L. et al. A methodology for detection and classification of power quality disturbances using a real-time operating system in the context of home energy management systems. *International Journal of Energy Research*, v. 44, n. 3, p. 5183–1, 2020. Citado na página 1.

SADINEZHAD, I.; AGELIDIS, V. G. An adaptive precise one-end power transmission line fault locating algorithm based on multilayer complex adaptive artificial neural networks. In: *2009 IEEE International Conference on Industrial Technology*. [S.l.: s.n.], 2009. p. 1–6. Citado na página 5.

SAHA, M.; IZYKOWSKI, J.; ROSOLOWSKI, E. *Fault Location on Power Networks*. [S.l.]: Springer London, 2010. (Power Systems). ISBN 9781848828858. Citado 4 vezes nas páginas 9, 10, 13 e 23.

SALAT, R.; OSOWSKI, S. Accurate fault location in the power transmission line using support vector machine approach. *IEEE Transactions on Power Systems*, v. 19, n. 2, p. 979–986, 2004. Citado na página 39.

SAMANTARAY, S. R. A systematic fuzzy rule based approach for fault classification in transmission lines. *Applied Soft Computing*, v. 13, n. 2, p. 928–938, 2013. ISSN 1568-4946. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1568494612004309>>. Citado 2 vezes nas páginas 4 e 5.

SANTOS, C. C. F. Estudo da implementação em sistemas embarcados de algoritmos para interfaces cérebro-máquina. 2020. Citado na página 36.

SATO, F.; FREITAS, W. *Análise de curto-circuito e princípios de proteção em sistemas de energia elétrica*. 1ª edição. ed. [S.l.]: Rio de Janeiro: Elsevier, 2015. ISBN 978-85-352-6886-7. Citado na página 14.

SHAIK, A. G.; PULIPAKA, R. R. V. A new wavelet based fault detection, classification and location in transmission lines. *International Journal of Electrical Power & Energy Systems*, v. 64, p. 35–40, 2015. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061514004232>>. Citado na página 40.

SHI, Q.; TROELTZSCH, U.; KANOUN, O. Detection and localization of cable faults by time and frequency domain measurements. In: *2010 7th International Multi-Conference on Systems, Signals and Devices*. [S.l.: s.n.], 2010. p. 1–6. Citado na página 4.

SHU, X.; WU, X.; LIU, B. A study on quantization effects of dct based compression. p. 3500–3504, 2017. Citado na página 18.

SIDHU, T. et al. Discrete-fourier-transform-based technique for removal of decaying dc offset from phasor estimates. *IEE Proceedings - Generation, Transmission and Distribution*, v. 150, n. 6, p. 745–752, 2003. Citado na página 4.

SILVA, M. d.; OLESKOVICZ, M.; COURRY, D. V. Uma nova ferramenta baseada na transformada wavelet para localização digital de faltas. *Controle & automação : revista da Sociedade Brasileira de Automática*, Sociedade Brasileira de Automática, v. 16, n. 3, p. 345–358, 2005. ISSN 0103-1759. Citado na página 19.

SILVA, M. da et al. An alternative fault location algorithm based on wavelet transforms for three-terminal lines. In: *2008 IEEE Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century*. [S.l.: s.n.], 2008. p. 1–7. Citado na página 4.

SILVEIRA, E. G. da. *Localização em faltas em linhas de transmissão: desenvolvimento de novos algoritmos e implementação de sistema computacional para aplicações práticas*. Tese (Doutorado) — Universidade Federal de Minas Gerais, Belo Horizonte, 2007. Citado 2 vezes nas páginas 21 e 46.

STEVENSON Jr., W. D. *Elementos de Análise de Sistemas de Potência*. 2ª edição. ed. [S.l.]: São Paulo: McGraw-Hill, 1986. ISBN 012815117X. Citado na página 16.

SUYKENS, J.; VANDEWALLE, J. Least squares support vector machine classifiers. *Neural Processing Letters, Springer Netherlands*, v. 9, p. 293–300, 1999. ISSN 1573-773X. Disponível em: <<https://link.springer.com/article/10.1023/A:1018628609742?noAccess=true#article-info>>. Citado na página 33.

- SWETAPADMA, A.; YADAV, A. A novel single-ended fault location scheme for parallel transmission lines using k-nearest neighbor algorithm. *Computers & Electrical Engineering*, v. 69, p. 41–53, 2018. ISSN 0045-7906. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0045790617307802>>. Citado 4 vezes nas páginas 4, 5, 36 e 43.
- TEIMOURZADEH, H. et al. High impedance single-phase faults diagnosis in transmission lines via deep reinforcement learning of transfer functions. *IEEE Access*, v. 9, p. 15796–15809, 01 2021. Citado na página 44.
- TINOCO, J. A. B.; CORREIA, A. G.; CORTEZ, P. Uso de algoritmos genéticos e redes neurais artificiais na identificação do nível de estabilidade de taludes rochosos. 2021. Disponível em: <<http://hdl.handle.net/1822/75404>>. Citado na página 31.
- TLEIS, N. *Power Systems Modelling and Fault Analysis: Theory and Practice*. 2ª edição. ed. [S.l.]: Academic Press, 2019. ISBN 012815117X. Citado na página 14.
- UYAR, M. St and lssvr-based the fault location algorithm for the series compensated power transmission lines. *Energy Educ. Sci. Technol. Part A: Energy Sci. Res*, v. 30, n. 1, p. 75–88, 10 2012. Citado 2 vezes nas páginas 5 e 39.
- VAPNIK, V. The support vector method of function estimation. In: _____. *Nonlinear Modeling: Advanced Black-Box Techniques*. Boston, MA: Springer US, 1998. p. 55–85. ISBN 978-1-4615-5703-6. Disponível em: <https://doi.org/10.1007/978-1-4615-5703-6_3>. Citado na página 31.
- YADAV, A.; SWETAPADMA, A. A single ended directional fault section identifier and fault locator for double circuit transmission lines using combined wavelet and ANN approach. *International Journal of Electrical Power & Energy Systems*, v. 69, p. 27–33, 2015. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061515000046>>. Citado 5 vezes nas páginas 4, 5, 21, 36 e 40.
- YUMURTACI, M. et al. Classification of short-circuit faults in high-voltage energy transmission line using energy of instantaneous active power components-based common vector approach. *Turkish Journal of Electrical Engineering & Computer Sciences*, v. 24, n. 1, p. 43–48, 2016. ISSN 1901–1915. Disponível em: <<https://doi.org/10.3906/elk-1312-131>>. Citado na página 4.
- YUSUFF, A. A. et al. Fault location in a series compensated transmission line based on wavelet packet decomposition and support vector regression. *Electric Power Systems Research*, v. 81, n. 7, p. 1258–1265, 2011. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779610003391>>. Citado na página 5.
- YUSUFF, A. A.; JIMOH, A. A.; MUNDA, J. L. Fault location in transmission lines based on stationary wavelet transform, determinant function feature and support vector regression. *Electric Power Systems Research*, v. 110, p. 73–83, 2014. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779614000066>>. Citado 2 vezes nas páginas 5 e 40.
- ZANETTA Jr., L. C. *Transitórios Eletromagnéticos em Sistemas de Potência*. 2ª edição. ed. [S.l.]: Editora da Universidade de São Paulo (EDUSP), 2020. ISBN 13: 9788531417399. Citado 5 vezes nas páginas 10, 11, 12, 13 e 14.

ZHANG, G.; SHU, H.; LIAO, Y. Automated double-ended traveling wave record correlation for transmission line disturbance analysis. *Electric Power Systems Research*, v. 136, p. 242–250, 2016. ISSN 0378-7796. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378779616300384>>. Citado 2 vezes nas páginas 4 e 38.

ZIMATH, S.; RAMOS, M. et al. Comparison of impedance and travelling wave fault location using real faults. In: IEEE. *IEEE PES T&D 2010*. [S.l.], 2010. p. 1–5. Citado na página 23.

APÊNDICE A – Arquivos de entrada para o programa ATP/EMTP

Seguem abaixo exemplos de arquivos com formatos utilizados pelo programa ATP/EMTP, para o cálculo dos parâmetros de uma linha de transmissão de 330Km, tratado nessa tese.

A Tipo de Falta AB, a 25 km, com 0 grau (taxa de amostragem de 400khz)

O arquivo abaixo serve para entrada do programa ATP/EMTP, representando o Tipo de Falta AB, ocorrida a 25 km do Terminal 1, com ângulo de incidência de 0 grau e taxa de amostragem de 400Khz.

```
BEGIN NEW DATA CASE
C -----
C Generated by ATPDRAW maio, sexta-feira 15, 2020
C A Bonneville Power Administration program
C by H. K. Høidalen at SEFAS/NTNU - NORWAY 1994-2016
C -----
POWER FREQUENCY                60.
$DUMMY, XYZ000
C dT >> Tmax >> Xopt >> Copt >> Epsiln>
  2.5E-6      .02
    500      1      1      1      1      0      0      1      0
C      1      2      3      4      5      6      7      8
C 34567890123456789012345678901234567890123456789012345678901234567890
/BRANCH
C < n1 >> n2 >>ref1>>ref2>> R >> L >> C >
C < n1 >> n2 >>ref1>>ref2>> R >> A >> B >>Leng><><>0
  SBT00AX0001A      500.  10.      0
  SBT00BX0001B      500.  10.      0
  SBT00CX0001C      500.  10.      0
  X0002AX0004A      500.  10.      0
  X0002BX0004B      500.  10.      0
  X0002CX0004C      500.  10.      0
  XX0003      5.      0
$INCLUDE, C:\ATPDraw\ATP\simulacao\25\TR-1.lib, T1A###, T1B###, T1C### $$
, TA####, TB####, TC####
$INCLUDE, C:\ATPDraw\ATP\simulacao\25\TR-2.lib, TA####, TB####, TC#### $$
, T2A###, T2B###, T2C###
/SWITCH
C < n 1>< n 2>> Tclose >>Top/Tde >> Ie >>Vf/CLOP >> type >
  X0001AT1A      MEASURING      1
  X0001BT1B      MEASURING      1
  X0001CT1C      MEASURING      1
  TC      TB      5.      1.E3      0
```

```

TB   XX0003      5.    1.E3      0
TB   TA          1.E3      0
TC   XX0003      5.    1.E3      0
TA   XX0003      5.    1.E3      0
TC   TA          5.    1.E3      0
T2A  X0002A          MEASURING  1
T2B  X0002B          MEASURING  1
T2C  X0002C          MEASURING  1
/SOURCE
C < n 1><< Ampl. >> < Freq. ><Phase/T0>< A1 >< T1 >< TSTART >< TSTOP >
14SBT00A  408248.29    60.      -1.    1.E3
14SBT00B  408248.29    60.    -120.  -1.    1.E3
14SBT00C  408248.29    60.    -240.  -1.    1.E3
14X0004A  408248.29    60.      90.   -1.   100.
14X0004B  408248.29    60.     -30.  -1.   100.
14X0004C  408248.29    60.    -150.  -1.   100.
/OUTPUT
  T1A  T1B  T1C  T2A  T2B  T2C
BLANK BRANCH
BLANK SWITCH
BLANK SOURCE
BLANK OUTPUT
BLANK PLOT
BEGIN NEW DATA CASE
BLANK

```

B Tipo de Falta ABT, a 35 km, com 10 ohms e 45 graus (taxa de amostragem de 400khz)

O arquivo abaixo serve para entrada do programa ATP/EMTP, representando o Tipo de Falta ABT, ocorrida a 35 km do Terminal 1, com resistência de falta de 10 ohms e ângulo de incidência de 45 graus e taxa de amostragem de 400Khz.

```

BEGIN NEW DATA CASE
C -----
C Generated by ATPDRAW maio, sexta-feira 15, 2020
C A Bonneville Power Administration program
C by H. K. Høidalen at SEFAS/NTNU - NORWAY 1994-2016
C -----
POWER FREQUENCY          60.
$DUMMY, XYZ000
C dT >< Tmax >< Xopt >< Copt ><Epsiln>
  2.5E-6    .02
    500    1    1    1    1    0    0    1    0
C    1    2    3    4    5    6    7    8
C 34567890123456789012345678901234567890123456789012345678901234567890
/BRANCH
C < n1 >< n2 ><ref1><ref2>< R >< L >< C >
C < n1 >< n2 ><ref1><ref2>< R >< A >< B ><Leng><><>0
  SBT00AX0001A          500.  10.      0
  SBT00BX0001B          500.  10.      0
  SBT00CX0001C          500.  10.      0
  X0002AX0004A          500.  10.      0
  X0002BX0004B          500.  10.      0

```

```

X0002CX0004C          500.  10.          0
XX0003                10.          0
$INCLUDE, C:\ATPDraw\ATP\simulacao\35\TR-1.lib, T1A###, T1B###, T1C### $$
, TA####, TB####, TC####
$INCLUDE, C:\ATPDraw\ATP\simulacao\35\TR-2.lib, TA####, TB####, TC#### $$
, T2A###, T2B###, T2C###
/SWITCH
C < n 1>< n 2>< Tclose ><Top/Tde >< Ie ><Vf/CLOP >< type >
X0001AT1A                                MEASURING          1
X0001BT1B                                MEASURING          1
X0001CT1C                                MEASURING          1
TC    TB          5.      1.E3          0
TB    XX00030.00208333  1.E3          0
TB    TA          5.      1.E3          0
TC    XX0003        5.      1.E3          0
TA    XX00030.00208333  1.E3          0
TC    TA          5.      1.E3          0
T2A   X0002A                                MEASURING          1
T2B   X0002B                                MEASURING          1
T2C   X0002C                                MEASURING          1
/SOURCE
C < n 1><>< Ampl. >< Freq. ><Phase/T0>< A1 >< T1 >< TSTART >< TSTOP >
14SBT00A  408248.29      60.          -1.      1.E3
14SBT00B  408248.29      60.      -120.    -1.      1.E3
14SBT00C  408248.29      60.      -240.    -1.      1.E3
14X0004A  408248.29      60.          90.     -1.     100.
14X0004B  408248.29      60.         -30.    -1.     100.
14X0004C  408248.29      60.      -150.    -1.     100.
/OUTPUT
T1A  T1B  T1C  T2A  T2B  T2C
BLANK BRANCH
BLANK SWITCH
BLANK SOURCE
BLANK OUTPUT
BLANK PLOT
BEGIN NEW DATA CASE
BLANK

```

C Tipo de Falta ABC, a 55 km, com 90 graus (taxa de amostragem de 400khz)

O arquivo abaixo serve para entrada do programa ATP/EMTP, representando o Tipo de Falta ABC, ocorrida a 55 km do Terminal 1, com ângulo de incidência de 90 graus e taxa de amostragem de 400Khz.

```

BEGIN NEW DATA CASE
C -----
C Generated by ATPDRAW maio, sexta-feira 15, 2020
C A Bonneville Power Administration program
C by H. K. Høidalen at SEFAS/NTNU - NORWAY 1994-2016
C -----
POWER FREQUENCY          60.
$DUMMY, XYZ000
C dT >< Tmax >< Xopt >< Copt ><Epsiln>

```

```

2.5E-6      .02
      500      1      1      1      1      0      0      1      0
C      1      2      3      4      5      6      7      8
C 34567890123456789012345678901234567890123456789012345678901234567890
/BRANCH
C < n1 >< n2 ><ref1><ref2>< R >< L >< C >
C < n1 >< n2 ><ref1><ref2>< R >< A >< B ><Leng><><>0
  SBT00AX0001A      500.  10.      0
  SBT00BX0001B      500.  10.      0
  SBT00CX0001C      500.  10.      0
  X0002AX0004A      500.  10.      0
  X0002BX0004B      500.  10.      0
  X0002CX0004C      500.  10.      0
  XX0003      5.      0
$INCLUDE, C:\ATPDraw\ATP\simulacao\55\TR-1.lib, T1A###, T1B###, T1C### $$
, TA####, TB####, TC####
$INCLUDE, C:\ATPDraw\ATP\simulacao\55\TR-2.lib, TA####, TB####, TC#### $$
, T2A###, T2B###, T2C###
/SWITCH
C < n 1>< n 2>< Tclose ><Top/Tde >< Ie ><Vf/CLOP >< type >
  X0001AT1A      MEASURING      1
  X0001BT1B      MEASURING      1
  X0001CT1C      MEASURING      1
  TC      TB      5.      1.E3      0
  TB      XX00030.00416667      1.E3      0
  TB      TA      5.      1.E3      0
  TC      XX00030.00416667      1.E3      0
  TA      XX00030.00416667      1.E3      0
  TC      TA      5.      1.E3      0
  T2A      X0002A      MEASURING      1
  T2B      X0002B      MEASURING      1
  T2C      X0002C      MEASURING      1
/SOURCE
C < n 1><>< Ampl. >< Freq. ><Phase/TO>< A1 >< T1 >< TSTART >< TSTOP >
14SBT00A      408248.29      60.      -1.      1.E3
14SBT00B      408248.29      60.      -120.      -1.      1.E3
14SBT00C      408248.29      60.      -240.      -1.      1.E3
14X0004A      408248.29      60.      90.      -1.      100.
14X0004B      408248.29      60.      -30.      -1.      100.
14X0004C      408248.29      60.      -150.      -1.      100.
/OUTPUT
  T1A      T1B      T1C      T2A      T2B      T2C
BLANK BRANCH
BLANK SWITCH
BLANK SOURCE
BLANK OUTPUT
BLANK PLOT
BEGIN NEW DATA CASE
BLANK

```

D Tipo de Falta ABCT, a 75 km, com 40 ohms e 0 grau (taxa de amostragem de 400khz)

O arquivo abaixo serve para entrada do programa ATP/EMTP, representando o Tipo de Falta ABCT, ocorrida a 75 km do Terminal 1, com resistência de falta de 40 ohms e ângulo de incidência de 0 grau e taxa de amostragem de 400Khz.

```

BEGIN NEW DATA CASE
C -----
C Generated by ATPDRAW maio, sexta-feira 15, 2020
C A Bonneville Power Administration program
C by H. K. Høidalen at SEFAS/NTNU - NORWAY 1994-2016
C -----
POWER FREQUENCY                60.
$DUMMY, XYZ000
C dT >< Tmax >< Xopt >< Copt ><Epsiln>
  2.5E-6      .02
    500      1      1      1      1      0      0      1      0
C      1      2      3      4      5      6      7      8
C 34567890123456789012345678901234567890123456789012345678901234567890
/BRANCH
C < n1 >< n2 ><ref1><ref2>< R >< L >< C >
C < n1 >< n2 ><ref1><ref2>< R >< A >< B ><Leng><><>0
  SBT00AX0001A          500.  10.          0
  SBT00BX0001B          500.  10.          0
  SBT00CX0001C          500.  10.          0
  X0002AX0004A          500.  10.          0
  X0002BX0004B          500.  10.          0
  X0002CX0004C          500.  10.          0
  XX0003                40.              0
$INCLUDE, C:\ATPDraw\ATP\simulacao\75\TR-1.lib, T1A###, T1B###, T1C### $$
, TA####, TB####, TC####
$INCLUDE, C:\ATPDraw\ATP\simulacao\75\TR-2.lib, TA####, TB####, TC#### $$
, T2A###, T2B###, T2C###
/SWITCH
C < n 1>< n 2>< Tclose ><Top/Tde >< Ie ><Vf/CLOP >< type >
  X0001AT1A                                MEASURING          1
  X0001BT1B                                MEASURING          1
  X0001CT1C                                MEASURING          1
  TC    TB                                1.E3                0
  TB    XX0003          5.                1.E3                0
  TB    TA                                1.E3                0
  TC    XX0003          5.                1.E3                0
  TA    XX0003          5.                1.E3                0
  TC    TA                                1.E3                0
  T2A   X0002A                                MEASURING          1
  T2B   X0002B                                MEASURING          1
  T2C   X0002C                                MEASURING          1
/SOURCE
C < n 1><><> Amp1. >< Freq. ><Phase/T0>< A1 >< T1 >< TSTART >< TSTOP >
14SBT00A  408248.29      60.          -1.          1.E3
14SBT00B  408248.29      60.         -120.        1.E3
14SBT00C  408248.29      60.        -240.        1.E3
14X0004A  408248.29      60.           90.         100.
14X0004B  408248.29      60.          -30.         100.
14X0004C  408248.29      60.        -150.         100.

```

```

/OUTPUT
  T1A  T1B  T1C  T2A  T2B  T2C
BLANK BRANCH
BLANK SWITCH
BLANK SOURCE
BLANK OUTPUT
BLANK PLOT
BEGIN NEW DATA CASE
BLANK

```

E Tipo de Falta AT, a 105km, com 440 ohms e 90 graus (taxa de amostragem de 400khz)

O arquivo abaixo serve para entrada do programa ATP/EMTP, representando o Tipo de Falta AT, ocorrida a 105 km do Terminal 1, com resistência de falta de 440 ohms e ângulo de incidência de 90 graus e taxa de amostragem de 400Khz.

```

BEGIN NEW DATA CASE
C -----
C Generated by ATPDRAW maio, sexta-feira 15, 2020
C A Bonneville Power Administration program
C by H. K. Høidalen at SEFAS/NTNU - NORWAY 1994-2016
C -----
POWER FREQUENCY          60.
$DUMMY, XYZ000
C dT >> Tmax >> Xopt >> Copt >> Epsiln>
  2.5E-6      .02
      500      1      1      1      1      0      0      1      0
C      1      2      3      4      5      6      7      8
C 34567890123456789012345678901234567890123456789012345678901234567890
/BRANCH
C < n1 >> n2 >>ref1><ref2>< R >< L >< C >
C < n1 >> n2 >>ref1><ref2>< R >< A >< B ><Leng><><>0
  SBT00AX0001A          500.  10.          0
  SBT00BX0001B          500.  10.          0
  SBT00CX0001C          500.  10.          0
  X0002AX0004A          500.  10.          0
  X0002BX0004B          500.  10.          0
  X0002CX0004C          500.  10.          0
  XX0003                440.             0
$INCLUDE, C:\ATPDraw\ATP\simulacao\105\TR-1.lib, T1A###, T1B###, T1C### $$
, TA####, TB####, TC####
$INCLUDE, C:\ATPDraw\ATP\simulacao\105\TR-2.lib, TA####, TB####, TC#### $$
, T2A###, T2B###, T2C###
/SWITCH
C < n 1>< n 2>< Tclose ><Top/Tde >< Ie ><Vf/CLOP >< type >
  X0001AT1A                      MEASURING          1
  X0001BT1B                      MEASURING          1
  X0001CT1C                      MEASURING          1
  TC      TB          5.      1.E3          0
  TB      XX0003      5.      1.E3          0
  TB      TA          5.      1.E3          0
  TC      XX0003      5.      1.E3          0
  TA      XX00030.00416667      1.E3          0
  TC      TA          5.      1.E3          0

```



```
T2A X0002A MEASURING 1
T2B X0002B MEASURING 1
T2C X0002C MEASURING 1
/SOURCE
C < n 1><< Ampl. >< Freq. ><Phase/T0>< A1 >< T1 >< TSTART >< TSTOP >
14SBT00A 408248.29 60. -1. 1.E3
14SBT00B 408248.29 60. -120. -1. 1.E3
14SBT00C 408248.29 60. -240. -1. 1.E3
14X0004A 408248.29 60. 90. -1. 100.
14X0004B 408248.29 60. -30. -1. 100.
14X0004C 408248.29 60. -150. -1. 100.
/OUTPUT
T1A T1B T1C T2A T2B T2C
BLANK BRANCH
BLANK SWITCH
BLANK SOURCE
BLANK OUTPUT
BLANK PLOT
BEGIN NEW DATA CASE
BLANK
```

APÊNDICE B – Programas no MATLAB para gerar a base de dados e a extração dos coeficientes MFCC

Seguem abaixo programas em MATLAB utilizados para gerar a base de dados e a extração dos coeficientes MFCC, tratado nesta tese.

```
%% Programa para a gerar o casos seguindo um modelo do .atp

%% Instituição.
%UNIVERSIDADE FEDERAL DO PIAUÍ - UFPI
%PRO-REITORIA DE ENSINO E PÓS-GRADUÇÃO
%CENTRO DE TECNOLOGIA
%PROGRAMA DE PÓS-GRADUÇÃO EM ENGENHARIA ELÉTRICA
%ORIENTADOR: Professor Dr. Hermes Manoel G. Castelo Branco
%ALUNO: José de Anchieta Araújo Marques

%% Especificações do trabalho.
%Gerar arquivos com dados de faltas para dois terminais. Serão usados o
%tempo(t), tensões (vT1a, vT1b, vT1c, vT1a, vT1b e vT1c) e
%correntes (iX0001aT1a, iX0001bT1b, iX0001bT1b , iT2aX0002a, iT2bX0002b e
%iT2cX0002c)
%Arquivo ATP básico: LINE_F.atp
%1km_1ohm_AB_0_400khz.MAT
%Distância da falta      : Varia de 5 em 5 km (0 até 330)
%Resistência da falta   : Varia 5 em 5 ohm (0 até 500)
%Tipo de falta          : AT, AB, ABT, ABC e ABCT
%Ângulo de incidência   : Varia de 0, 45 e 90 graus
%Frequência de Amostragem : 400khz
%Nome do Arquivo        : Dkm_Rohm_T_A_Fkhz.mat
%% Processo seguido
%a) Gerar
%% Inicializações do ambiente.
clear;clc;clf;close all;

%% Variáveis auxiliares.
atividades=[1 1 1 1]; % Gerar Casos/Gerar .pl4/Gerar .mat
arqDefault='LINE_F.atp'; %Nome do arquivo modelo
Path=pwd;
dadosPath=strcat('D:\OneDrive\UFPI\Mestrado\TrabalhoFinal\Sistemas\dados');
dadosPathMAT=strcat('D:\OneDrive\UFPI\Mestrado\TrabalhoFinal\Sistemas\dados');
PathSistema=strcat('D:\OneDrive\UFPI\Mestrado\TrabalhoFinal\Sistemas');
DirExe='C:\ATP_CBUE_2010\main'; %Diretório dos arquivos executáveis
disF=0:5:330; % Distância da Falta
[~,nDF]=size(disF);
resF=0:5:500; % Resistência da falta
[~,nRF]=size(resF);
angI=[0,45,90]; % Ângulo de incidência
```

```

[~,nAI]=size(angI);
tipF=["AT","AB","ABT","ABC","ABCT"]; % Tipo de falta
[~,nTF]=size(tipF);
dA=1; %265

%Calcular valores para os ângulos
angIV=zeros(1,nAI);
for i=1:nAI
    angIV(1,i)=angI(i)*(1/60)/360;
end

%% Início da Atividade 1
% Gerar casos variando distância, resistência, tipo e ângulo
if atividades(1)==1

cont=1;
tic
for d=dA:nDF
    arqPath=strcat(dadosPath,'\',int2str(disF(d)));
    for r=1:nRF
        for a=1:nAI
            for f=1:nTF
                criaArqFalta(arqPath,arqDefault,disF(d),resF(r),tipF(f),angI(a));
                fprintf('%d D:%5.0f R:%5.0f T:%s A:%5.0f \n',...
                    cont,disF(d),resF(r),tipF(f),angI(a));
                cont=cont+1;
            end
        end
    end
end
tempo=toc;
total=tempo * 67;
fprintf('Total de tempo para gerar os casos (s): %10.2f s',total);
end %Fim da atividade 1

%% Início da atividade 2
% Gerar os arquivos .pl4 rodando o runAPT
if atividades(2)==1

cont=1;
tic
for d=dA:nDF
    arqPath=strcat(dadosPath,'\',int2str(disF(d)));
    for r=1:nRF
        for a=1:nAI
            for f=1:nTF
                gerarDadosPL4(arqPath,Path,disF(d),resF(r),tipF(f),angI(a));
                fprintf('%d D:%5.0f R:%5.0f T:%s A:%5.0f \n',...
                    cont,disF(d),resF(r),tipF(f),angI(a));
                cont=cont+1;
            end
        end
    end
end
tempo=toc;
total=tempo * 1515 * 67;
fprintf('Total de tempo para gerar os .pl4 (s): %10.2f s',total);

```

```
end %fim da atividade 2

%% Início da atividade 3
% Gerar os arquivos .mat usando o .pl4 e rodando o Pl42mat.exe
if atividades(3)==1

cont=1;
tic
for d=dA:nDF
    arqPath=strcat(dadosPathMAT,'\',int2str(disF(d)));
    for r=1:nRF
        for a=1:nAI
            for f=1:nTF
                gerarDadosMAT(arqPath,Path,disF(d),resF(r),tipF(f),angI(a));
                fprintf('%d D:%5.0f R:%5.0f T:%s A:%5.0f \n',...
                    cont,disF(d),resF(r),tipF(f),angI(a));
                cont=cont+1;
            end
        end
    end
end
tempo=toc;
total=tempo;
fprintf('Total de tempo para gerar os .mat (s): %10.2f s',total);

end %fim da atividade 3

%% Início da atividade 4
% Confere se todos os arquivos .mat foram gerados
if atividades(4)==1

cont=1;

for d=dA:nDF
    arqPath=strcat(dadosPathMAT,'\',int2str(disF(d)));
    for r=1:nRF
        for a=1:nAI
            for f=1:nTF
                fprintf('%d D:%5.0f R:%5.0f T:%s A:%5.0f \n',...
                    cont,disF(d),resF(r),tipF(f),angI(a));
                arqNome=strcat('ARQ_',int2str(disF(d)),'KM_',...
                    int2str(resF(r)),'OHM_',tipF(f),'_',...
                    int2str(angI(a)),'_400KHZ.mat');
                arq=strcat(arqPath,'\ ',arqNome);
                E=exist(arq,'file');
                if E==0
                    criaArqFalta(arqPath,arqDefault,disF(d),resF(r),tipF(f),angI(a));
                    gerarDadosPL4(arqPath,Path,disF(d),resF(r),tipF(f),angI(a));
                    gerarDadosMAT(arqPath,Path,disF(d),resF(r),tipF(f),angI(a));
                end
                cont=cont+1;
            end
        end
    end
end
end
end
```

```
end %fim da atividade 4

function []=criaArqFalta(arqPath,arqDefault,disF,resF,tipF,angI)
%Cria um arquivo de falta seguindo um arquivo default para criar um novo

arq1=strcat(arqPath,'\ ',arqDefault);
fid1=fopen(arq1,'r');
arqNome=strcat('Arq_',int2str(disF),'km_',...
              int2str(resF),'ohm_',tipF,'_',...
              int2str(angI),'_400khz.atp');
arq2=strcat(arqPath,'\ ',arqNome);
fid2=fopen(arq2,'w');
angIV=angI*(1/60)/360;
cont=1;
if angI==0
    txtA= repmat(' ',1,10);
else
    txtA=sprintf('%0.8f',angIV);
end
%Percorrer o arquivo default para gerar um novo linha a linha
while(~feof(fid1))
    linha=fgets(fid1);
    if cont==23
        if resF==0
            txt=' .001';
        else
            txt=sprintf('%5.0f.',resF);
        end
        linha=replaceBetween(linha,27,32,txt);
    end
    switch tipF
        case "AT"
            if cont==37
                linha=replaceBetween(linha,15,24,txtA);
            end
        case "AB"
            if cont==35
                linha=replaceBetween(linha,15,24,txtA);
            end
        case "ABT"
            if (cont==34) || (cont==37)
                linha=replaceBetween(linha,15,24,txtA);
            end
        case "ABC"
            if (cont==33) || (cont==35)
                linha=replaceBetween(linha,15,24,txtA);
            end
        case "ABCT"
            if (cont==34) || (cont==36) || (cont==37)
                linha=replaceBetween(linha,15,24,txtA);
            end
    end
    fprintf(fid2,'%s',linha);
    cont=cont+1;
end
fclose(fid1);
fclose(fid2);
```

```
end
```

```
function []=gerarDadosPL4(arqPath,Path,disF,resF,tipF,angI)
%Cria um arquivo de dados .pl4 rodando o runATP
```

```
cd(arqPath);
arqNome=strcat('Arq_',int2str(disF),'km_',...
              int2str(resF),'ohm_',tipF,'_',...
              int2str(angI),'_400khz.atp');
exe=sprintf('runATP %s',arqNome);
system(exe);
cd(Path);
```

```
end
```

```
function []=gerarDadosMAT(arqPath,Path,disF,resF,tipF,angI)
%Cria um arquivo de dados .pl4 rodando o runATP
```

```
cd(arqPath);
arqNome=strcat('ARQ_',int2str(disF),'KM_',...
              int2str(resF),'OHM_',tipF,'_',...
              int2str(angI),'_400KHZ.pl4');
exe=sprintf('C:\\ATP_CBUE_2010\\main\\pl42mat %s',arqNome);
system(exe);
cd(Path);
```

```
end
```

```
%% Programa para a extração de características com o método MFCC
```

```
%% Instituição.
```

```
%UNIVERSIDADE FEDERAL DO PIAUÍ - UFPI
```

```
%PRO-REITORIA DE ENSINO E PÓS-GRADUÇÃO
```

```
%CENTRO DE TECNsOLOGIA
```

```
%PROGRAMA DE PÓS-GRADUÇÃO EM ENGENHARIA ELÉTRICA
```

```
%ORIENTADOR: Professor Dr. Hermes Manoel G. Castelo Branco
```

```
%ALUNO: José de Anchieta Araujo Marques
```

```
%% Especificações do trabalho.
```

```
%Gerar arquivos com dados de faltas para dois terminais. Serão usados o
```

```
%tempo(t), tensões (vT1a, vT1b, vT1c, vT1a, vT1b e vT1c) e
```

```
%correntes (iX0001aT1a, iX0001bT1b, iX0001bT1b , iT2aX0002a, iT2bX0002b e
```

```
%iT2cX0002c)
```

```
%Arquivo ATP básico: LINE_F.atp
```

```
%1km_1ohm_AB_0_400khz.MAT
```

```
%Distância da falta : Varia de 5 em 5 km (0 até 330)
```

```
%Resistência da falta : Varia 5 em 5 ohm (0 até 500)
```

```
%Tipo de falta : AT, AB, ABT, ABC e ABCT
```

```
%Ângulo de incidência : Varia de 0, 45 e 90 graus
```

```
%Frequência de Amostragem : 400khz
```

```
%Nome do Arquivo : Dkm_Rohm_T_A_Fkhz.mat
```

```
%% Processo seguido
```

```

%a) Gerar
%% Inicializações do ambiente.
clear;clc;clf;close all;

addpath(genpath('rastamat'));

%% Variáveis auxiliares.
Path=pwd;
dadosPath=strcat('dados');
dadosPathMAT=strcat('dados');
PathSistema=strcat('Sistemas');
DirExe='C:\ATP_CBUE_2010\main'; %Diretório dos arquivos executáveis
disF=0:5:330; % Distância da Falta
[~,nDF]=size(disF);
resF=0:5:500; % Resistência da falta
[~,nRF]=size(resF);
angI=[0,45,90]; % Ângulo de incidência
[~,nAI]=size(angI);
tipF=["AT","AB","ABT","ABC","ABCT"]; % Tipo de falta
[~,nTF]=size(tipF);
sr=400000; %MFCC-Frequência de Simulação
numcep=40; %MFCC- Testar de acordo com a quantidade de bandas
numband=40; %%MFCC-Testar com 10, 20, 30 e 40
mm=[]; %MFCC - Para receber as respostas
aspc=[]; %MFCC - Para receber as respostas
Entradas=[];
EntradasR=[];
dAjustada=0;
SNR=40; %Ruído branco de em DB 10,20,30,40,50,60,70

%% Leitura de dados
% load('C:\Temp\330\Arq_330km_500ohm_AT_90_400khz.MAT');
% Entradas(1,:,:)=[vT1a vT1b vT1c vT2a vT2b vT2c ...
%                  iT2aX0002a iT2bX0002b iT2cX0002c iX0001aT1a iX0001bT1b iX0001cT1c];

tic
for f=4:4 %nTF      %nTF %tipo de falta
    falta=1;
    for d=1:nDF    %distância
        arqPath=strcat(dadosPath,'\',int2str(disF(d)));
        for r=1:1 %nRF %resistências
            for a=1:nAI %ângulo
                arqNome=strcat('ARQ_',int2str(disF(d)),'KM_',...
                    int2str(resF(r)),'OHM_',tipF(f),'_',...
                    int2str(angI(a)),'_400KHZ.mat');
                arq=strcat(arqPath,'\',arqNome);
                load(arq);

                %Ajustar os dados das entradas
                Entradas(:,:,:)= [vT1a vT1b vT1c vT2a vT2b vT2c ...
                    iX0001aT1a iX0001bT1b iX0001cT1c ...
                    iT2aX0002a iT2bX0002b iT2cX0002c];

                %Inserir ruído branco SNR de forma aleatório entre 25
                % a 100 dB. Comente caso queira gerar sem ruído
                SNR = 25 + (100-25).*rand(1,1);
                EntradasR=awgn(Entradas,SNR,'measured');
            end
        end
    end
end

```

```

for SinaisV=1:12
    [mm(:,SinaisV),aspc(:,SinaisV)]=...
        melfcc(EntradasR(:,SinaisV),sr,...
            'maxfreq',sr/2,'numcep',numcep,'dcttype',1,...
            'wintime',0.016666666666666666,'hoptime',0.01,...
            'preemph',0,'nbands',numband);
end

%Ajustanto os coeficientes para 1 e 2 terminais
melfcc1T(falta,:)= [mm(:,1)' mm(:,2)' mm(:,3)' ...
    mm(:,7)' mm(:,8)' mm(:,9)'];
melfcc2T(falta,:)= [mm(:,1)' mm(:,2)' mm(:,3)'...
    mm(:,4)' mm(:,5)' mm(:,6)' mm(:,7)' mm(:,8)'...
    mm(:,9)' mm(:,10)' mm(:,11)' mm(:,12)'];
dAjustada=disF(d);
switch disF(d)
    case 0
        dAjustada=0.9;
    case 330
        dAjustada=329.10;
end
if (f==2) || (f==4)
    saida(falta,:)= [dAjustada -(resF(r)+1) angI(a) f];
    fprintf('%d D:%5.0f R:%5.0f T:%s A:%5.0f \n',...
        falta,disF(d),-(resF(r)+1),tipF(f),angI(a));
else
    saida(falta,:)= [dAjustada resF(r) angI(a) f];
    fprintf('%d D:%5.0f R:%5.0f T:%s A:%5.0f \n',...
        falta,disF(d),resF(r),tipF(f),angI(a));
end
falta=falta+1;
end
end

cd(dadosPath);
switch tipF(f)
    case "AT"
        save(strcat('Entrada1TAT',int2str(numcep)),'melfcc1T','-double');
        save(strcat('Entrada2TAT',int2str(numcep)),'melfcc2T','-double');
        save(strcat('SaidaAT',int2str(numcep)),'saida','-double');
    case "AB"
        save(strcat('Entrada1TAB',int2str(numcep)),'melfcc1T','-double');
        save(strcat('Entrada2TAB',int2str(numcep)),'melfcc2T','-double');
        save(strcat('SaidaAB',int2str(numcep)),'saida','-double');
    case "ABT"
        save(strcat('Entrada1TABT',int2str(numcep)),'melfcc1T','-double');
        save(strcat('Entrada2TABT',int2str(numcep)),'melfcc2T','-double');
        save(strcat('SaidaABT',int2str(numcep)),'saida','-double');
    case "ABC"
        save(strcat('Entrada1TABC',int2str(numcep)),'melfcc1T','-double');
        save(strcat('Entrada2TABC',int2str(numcep)),'melfcc2T','-double');
        save(strcat('SaidaABC',int2str(numcep)),'saida','-double');
    case "ABCT"
        save(strcat('Entrada1TABCT',int2str(numcep)),'melfcc1T','-double');
        save(strcat('Entrada2TABCT',int2str(numcep)),'melfcc2T','-double');

```



```
        save(strcat('SaidaABCT',int2str(numcep)),'saida','-double');
    end
    cd(Path);
end
toc
```

APÊNDICE C – Análises mais detalhadas sobre uso de subconjuntos da base principal e adição de várias relações sinais ruídos na precisão dos Métodos Localizadores de Faltas

Seguem abaixo resultados mais detalhados sobre os resultados do modelo AM baseado em RNA.

A Avaliação do Método Proposto com Subconjuntos da Base de Dados Original de 50 %, 25 %, 12,5 % e 6,25 %

Na tentativa de investigar se a quantidade de dados repassados para treinamento da rede modelada impactaria nos resultados obtidos pelo método, foram feitos testes alterando a quantidade da base de dados, selecionadas aleatoriamente de forma homogênea dentro das possibilidades dos tipos de falta.

Então, o intuito desta seção é abordar os resultados obtidos, mostrados na Tabela 16, considerando os subconjuntos com 50 %, 25 %, 12,5 % e 6,25 % da base de dados original, sem ruído, para a estimativa da distância de falta em LT. Essas estimativas foram feitas com auxílio da melhor arquitetura dentre as RNAs treinadas com os dados sem ruído, ou seja, usou-se uma quantidade de 40 coeficientes MFCC de cada um dos 6 sinais de tensão, que forneceram 240 entradas para a RNA, com 80 neurônios na camada neural oculta.

Tabela 16 – Resultado com o uso da base de dados reduzida

FF	E	NN	EMA (KM)	Desvio Padrão(KM)	EMR (%)	Desvio Padrão(%)	Subconjuntos (%)	Quantidade
40	240	80	0,00013	0,00189	0,00004	0,00057	100	101.103
40	240	80	0,00738	0,04232	0,00224	0,01282	50	50.552
40	240	80	0,01243	0,08863	0,00377	0,02686	25	25.276
40	240	80	0,03486	0,28808	0,01056	0,08730	12,5	12.638
40	240	80	0,13286	0,78606	0,04026	0,23820	6,25	6.319

FF: faixas de frequência, E: Entradas (MFCC) e NN: números de neurônios

Os resultados documentados na Tabela 16 demonstram que a precisão de estimativa de falta de LT desta proposta metodológica diminui gradativamente com a diminuição crescente da base de dados inicial.

B Avaliação do Método Proposto Considerando Dados na Presença de Ruído Branco Gaussiano

Na tentativa de investigar se um ambiente ruidoso impactaria nos resultados obtidos pelo método, foram feitos testes com várias relações sinais-ruídos.

Então, o intuito desta seção é abordar os resultados, mostrados na Tabela 17, considerando a adição de ruído branco gaussiano nos dados originais, com relação sinal-ruído *SNR* de 25 dB, 50 dB, 75 dB e 100 dB, para a estimativa da distância de falta em LT. Foi feita também a adição aleatória de relações sinal-ruído *SNR* variáveis de 25 dB a 100 dB. Essas estimativas foram feitas com auxílio da melhor arquitetura dentre as RNAs treinadas com os dados sem ruído, isto é, com o uso de uma quantidade de 40 coeficientes MFCC de cada um dos 6 sinais de tensão, que forneceram 240 entradas para a RNA, com 80 neurônios na camada neural oculta.

O ruído branco gaussiano foi adicionado aos sinais de tensão com o objetivo de aproximar o sinal proveniente de simulações computacionais aos sinais reais.

Tabela 17 – Resultado com a adição de ruído branco gaussiano na base de tensões originais

FF	E	NN	EMA (KM)	Desvio Padrão (KM)	EMR (%)	Desvio Padrão (%)	SNR (%)
40	240	80	0,00013	0,00189	0,00004	0,00057	Ausente
40	240	80	0,00180	0,02804	0,00054	0,00850	100
40	240	80	0,02573	0,10796	0,00780	0,03272	75
40	240	80	0,07087	0,26844	0,02148	0,08134	50
40	240	80	0,18585	0,40113	0,05632	0,12155	25
40	240	80	0,15178	1,28230	0,04599	0,38858	25-100

FF: faixas de frequência, E: Entradas (MFCC) e NN: números de neurônios

O resultado de maior precisão na presença de ruído gaussiano, conforme Tabela 17, contou com um *SNR* de 100 dB, com Erro Médio Absoluto (EMA) de 0,0018 km e com desvio padrão de 0,02804 km. Ao mesmo tempo, para os mesmos dados, obteve-se um Erro Médio Relativo (EMR) de 0,00054 %, com desvio padrão de 0,00850 %. Os resultados alcançados demonstram que esta proposta metodológica sofre influência da adição de ruído branco ao sinal. Entretanto, a estimativa de Erro Médio Relativo (EMR) ainda é aceitável para a Relação Sinal Ruído (*SNR*) a partir de 25 dB, sendo o maior erro médio absoluto não superior a 152 metros.

B.1 Variando o tamanho da base de dados com *SNR* de 100 dB

A Tabela 18 mostra os Erros Médios Absolutos (EMAs), os Erros Médios Relativos (EMRs) e os seus respectivos desvios padrões, que evidenciam a influência do uso de subconjuntos com 50 %, 25 %, 12,5 % e 6,25 % da base original em conjunto a uma relação sinal-ruído (*SNR*) de 100 dB nas estimativas das distâncias de faltas em LT.

Tabela 18 – Resultado com o uso da base de dados reduzida e *SNR* de 100 dB

FF	E	NN	EMA (KM)	Desvio Padrão(KM)	EMR (%)	Desvio Padrão(%)	Subconjuntos (%)	Quantidade
40	240	80	0,00180	0,02804	0,00054	0,00850	100	101.103
40	240	80	0,03633	0,33565	0,01101	0,10171	50	50.552
40	240	80	0,08761	0,56704	0,02655	0,17183	25	25.276
40	240	80	0,11309	1,36676	0,03427	0,41417	12,5	12.638
40	240	80	0,24385	1,22559	0,07389	0,37139	6,25	6.319

FF: faixas de frequência, E: Entradas (MFCC) e NN: números de neurônios

Através da Tabela 18, infere-se que, para qualquer percentual da base de dados igual ou acima de 6,25 %, as estimativas da distância de faltas foram precisas, com erros médios absolutos inferiores a 244 metros para SNR de 100 dB. Essa observação mostra o bom desempenho do método proposto. A pior situação foi a do subconjunto da base de 6,25 %, que apresentou um Erro Médio Absoluto (MAE) de 0,24385 km, com desvio padrão de 1,22559 km, e um Erro Médio Relativo (EMR) de 0,073894 %, com desvio padrão de 0,37139 %.

B.2 Variando o tamanho da base de dados com SNR de 75 dB

A Tabela 18 mostra os Erros Médios Absolutos (EMAs), os Erros Médios Relativos (EMRs) e os seus respectivos desvios padrões, que evidenciam a influência do uso de subconjuntos com 50 %, 25 %, 12,5 % e 6,25 % da base original em conjunto a uma relação sinal-ruído (SNR) de 75 dB nas estimativas das distâncias de faltas em LT.

Tabela 19 – Resultado com o uso da base de dados reduzida e SNR de 75 dB

FF	E	NN	EMA (KM)	Desvio Padrão(KM)	EMR (%)	Desvio Padrão(%)	Subconjunto (%)	Quantidade
40	240	80	0,02573	0,10796	0,00780	0,03272	100	101.103
40	240	80	0,06777	0,44339	0,02054	0,13436	50	50.552
40	240	80	0,14524	0,97142	0,04401	0,29437	25	25.276
40	240	80	0,21628	1,70487	0,06554	0,51663	12,5	12.638
40	240	80	0,60154	4,26516	0,18229	1,29247	6,25	6.319

FF: faixas de frequência, E: Entradas (MFCC) e NN: números de neurônios

Através da Tabela 18, percebe-se que, para qualquer subconjunto da base de dados igual ou acima de 12,5 %, as estimativas da distância de faltas foram precisas, com erros médios absolutos inferiores a 217 metros para SNR de 75 dB. Entretanto, mesmo os de EMA maiores ainda são aceitáveis. Essas observações mostram o bom desempenho do método proposto. A pior situação, dentre as consideradas precisas, foi a do subconjunto da base de 12,5 %, que apresentou um Erro Médio Absoluto (MAE) de 0,21628 km, com desvio padrão de 1,70487 km, e um Erro Médio Relativo (EMR) de 0,06554 %, com desvio padrão de 0,51663 %. O pior caso, por sua vez, apresentou cerca de 602 metros.

B.3 Variando o tamanho da base de dados com SNR de 50 dB

A Tabela 18 mostra os Erros Médios Absolutos (EMAs), os Erros Médios Relativos (EMRs) e os seus respectivos desvios padrões, que evidenciam a influência do uso dos subconjuntos com 50 %, 25 %, 12,5 % e 6,25 % da base original em conjunto a uma relação sinal-ruído (SNR) de 50 dB nas estimativas das distâncias de faltas em LT.

Tabela 20 – Resultado com o uso da base de dados reduzida e SNR de 50 dB

FF	E	NN	EMA (KM)	Desvio Padrão(KM)	EMR (%)	Desvio Padrão(%)	Subconjunto (%)	Quantidade
40	240	80	0,07087	0,26844	0,02148	0,08134	100	101.103
40	240	80	0,29630	0,78207	0,08979	0,23699	50	50.552
40	240	80	0,72022	1,80908	0,21825	0,54821	25	25.276
40	240	80	1,14385	2,50289	0,34662	0,75845	12,5	12.638
40	240	80	1,74734	4,36754	0,52950	1,32350	6,25	6.319

FF: faixas de frequência, E: Entradas (MFCC) e NN: números de neurônios

Através da Tabela 20, percebe-se que, para qualquer subconjunto da base de dados igual ou acima de 50 %, as estimativas da estimativa de faltas foram precisas, com erros médios absolutos inferiores a 297 metros para SNR de 50 dB. Entretanto, mesmo os de EMA maiores ainda são aceitáveis. Essas observações mostram o bom desempenho do método proposto. A pior situação, dentre os considerados precisos, foi a do percentual da base de 50 %, que apresentou um Erro Médio Absoluto (MAE)

de 0,29630 km, com desvio padrão de 0,78207 km, e um Erro Médio Relativo (EMR) de 0,08979 %, com desvio padrão de 0,23699 %. Os piores casos, por sua vez, apresentaram valores entre 720 e 1.748 metros.

B.4 Variando o tamanho da base de dados com SNR de 25 dB

A Tabela 18 mostra os Erros Médios Absolutos (EMAs), os Erros Médios Relativos (EMRs) e os seus respectivos desvios padrões, que evidenciam a influência do uso dos subconjuntos com 50 %, 25 %, 12,5 % e 6,25 % da base original em conjunto a uma relação sinal-ruído (SNR) de 25 dB nas estimativas das distâncias de faltas em LT.

Tabela 21 – Resultado com o uso da base de dados reduzida e SNR de 25 dB

FF	E	NN	EMA (KM)	Desvio Padrão(KM)	EMR (%)	Desvio Padrão(%)	Subconjunto (%)	Quantidade
40	240	80	0,18585	0,40113	0,05632	0,12155	100	101.103
40	240	80	2,02036	4,72242	0,61223	1,43104	50	50.552
40	240	80	5,24064	9,45494	1,58807	2,86513	25	25.276
40	240	80	8,13247	14,41047	2,46438	4,36681	12,5	12.638
40	240	80	9,57924	17,98679	2,90280	5,45054	6,25	6.319

FF: faixas de frequência, E: Entradas (MFCC) e NN: números de neurônios

Através da Tabela 21, percebe-se que apenas o percentual de 100 % da base de dados tem estimativa de distância de falta precisa. O erro médio absoluto foi inferior a 186 metros para SNR de 25 dB. Entretanto, mesmo os de EMA maiores ainda são aceitáveis. Essas observações mostram o bom desempenho do método proposto. A única estimativa precisa apresentou um Erro Médio Absoluto (MAE) de 0,18585 km, com desvio padrão de 0,40113 km, e um Erro Médio Relativo (EMR) de 0,05632 %, com desvio padrão de 0,12155 %. Os piores casos, por sua vez, apresentaram valores entre 2.021 e 9.580 metros.

B.5 Variando o tamanho da base de dados com SNR de 25 a 100 dB

A Tabela 22 mostra os Erros Médios Absolutos (EMAs), os Erros Médios Relativos (EMRs) e os seus respectivos desvios padrões, que evidenciam a influência do uso de subconjuntos com 50 %, 25 %, 12,5 % e 6,25 % da base original, adicionando-se aleatoriamente relações sinal-ruído (SNR) variáveis de 25 dB a 100 dB nas estimativas das distâncias de faltas em LT.

Tabela 22 – Resultado com o uso da base de dados reduzida e SNR de 25 dB a 100 dB

FF	E	NN	EMA (KM)	Desvio Padrão(KM)	EMR (%)	Desvio Padrão(%)	Subconjunto (%)	Quantidade
40	240	80	0,15178	1,28230	0,04599	0,38858	100	101.103
40	240	80	0,64700	2,90815	0,19606	0,88126	50	50.552
40	240	80	1,17678	4,55296	0,35660	1,37968	25	25.276
40	240	80	1,95130	5,90378	0,59130	1,78902	12,5	12.638
40	240	80	2,78765	7,38596	0,84474	2,23817	6,25	6.319

FF: faixas de frequência, E: Entradas (MFCC) e NN: números de neurônios

Através da Tabela 22, percebe-se que apenas o percentual de 100 % da base de dados tem estimativa precisa, com erro médio absoluto inferior a 152 metros para SNR de 25 dB a 100 dB. Entretanto, mesmo os de EMA maiores ainda são aceitáveis. Essas observações mostram o bom desempenho do método proposto. A única estimativa precisa apresentou um Erro Médio Absoluto (MAE) de 0,15178 km, com desvio padrão de 1,28230 km e um Erro Médio Relativo (EMR) de 0,04599 %, com desvio padrão de 0,38858 %. Os piores casos, por sua vez, foram em torno de 647 a 2.788 metros.