



CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL

**OTIMIZAÇÃO NÃO LINEAR E REDES NEURAIS
ARTIFICIAIS: FERRAMENTAS NA CLASSIFICAÇÃO E
LOCALIZAÇÃO DE FALTAS EM LINHAS DE
TRANSMISSÃO**

SIMONE APARECIDA ROCHA

Orientador: Dr. Thiago Gomes de Mattos
CEFET-MG

Coorientador: Dr. Eduardo Gonzaga da Silveira
CEFET-MG

BELO HORIZONTE
FEVEREIRO DE 2020

SIMONE APARECIDA ROCHA

**OTIMIZAÇÃO NÃO LINEAR E REDES NEURAIS
ARTIFICIAIS: FERRAMENTAS NA CLASSIFICAÇÃO E
LOCALIZAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO**

Dissertação apresentada ao programa de Pós-graduação em Modelagem Matemática e Computacional do Centro Federal de Educação Tecnológica de Minas Gerais, como requisito parcial para a obtenção do título de Mestre em Modelagem Matemática e Computacional.

Área de concentração: Modelagem Matemática e Computacional.

Linha de pesquisa: Métodos Matemáticos Aplicados

Orientador: Dr. Thiago Gomes de Mattos
CEFET-MG

Coorientador: Dr. Eduardo Gonzaga da Silveira
CEFET-MG

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL
BELO HORIZONTE
FEVEREIRO DE 2020

R672o Rocha, Simone Aparecida
Otimização não linear e redes neurais artificiais: ferramentas na
classificação e localização de faltas em linhas de transmissão / Simone
Aparecida Rocha. – 2020.
115 f.

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em
Modelagem Matemática e Computacional.
Orientador: Thiago Gomes de Mattos.
Coorientador: Eduardo Gonzaga da Silveira.
Dissertação (mestrado) – Centro Federal de Educação Tecnológica de
Minas Gerais.

1. Redes neurais (Computação) – Teses. 2. Linhas elétricas – Teses.
3. Otimização matemática – Teses. 4. Programação não linear – Teses.
5. Localização de Falhas (Engenharia) – Teses. I. Mattos, Thiago Gomes de.
II. Silveira, Eduardo Gonzaga da. III. Centro Federal de Educação
Tecnológica de Minas Gerais. IV. Título.

CDD 519.72



SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
COORDENAÇÃO DO CURSO DE MESTRADO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL

**“OTIMIZAÇÃO NÃO-LINEAR E REDES NEURAIS ARTIFICIAIS:
FERRAMENTAS NA CLASSIFICAÇÃO E LOCALIZAÇÃO DE FALTAS
EM LINHAS DE TRANSMISSÃO”**

Dissertação de Mestrado apresentada por **Simone Aparecida Rocha**, em 13 de fevereiro de 2020, ao Programa de Pós-Graduação em Modelagem Matemática e Computacional do CEFET-MG, e aprovada pela banca examinadora constituída pelos professores:

Prof. Dr. Thiago Gomes de Mattos (Orientador)
Centro Federal de Educação Tecnológica de Minas Gerais

Prof. Dr. Eduardo Gonzaga da Silveira (Coorientador)
Centro Federal de Educação Tecnológica de Minas Gerais

Prof. Dr. Clever Sebastião Pereira Filho
Universidade Federal de Minas Gerais

Prof. Dr. Douglas Alexandre Gomes Vieira
Centro Federal de Educação Tecnológica de Minas Gerais

Prof. Dr. Rodrigo Tomás Nogueira Cardoso
Centro Federal de Educação Tecnológica de Minas Gerais

Visto e permitida a impressão,

Prof. Dr. Thiago de Souza Rodrigues
Coordenador do Programa de Pós-Graduação em
Modelagem Matemática e Computacional

À minha família...
De ontem, quando eu era menina...
De hoje, esposa e mãe...
De amanhã?
Quem sabe avó...
Maria, minha mãe...
José, oh meu pai!
Por cada colo
em que me embalei
e que hoje embalo...
Forças eternas sempre ao meu lado...
Presença divina, em meu amparo.

Agradecimentos

Gostaria de agradecer àqueles que contribuíram nesta caminhada, dando-me a certeza de que estar junto representa muito mais que estar ao lado. Entre eles, em especial:

Ao meu orientador, professor Thiago Gomes de Mattos, pela dedicação, seriedade, companheirismo, respeito, carinho, disponibilidade e delicadeza com que me acolheu e sempre me orientou. Obrigada pela imensa confiança que depositou em mim, fazendo-me sentir mais autônoma, responsável e capaz.

Aos professores Clever Sebastião Pereira Filho, Douglas Alexandre Gomes Vieira, Paulo Eduardo Maciel de Almeida e Rodrigo Tomás Nogueira Cardoso por compartilharem momentos importantes e relevantes da construção deste trabalho, por aceitarem participar da avaliação do projeto e da defesa desta dissertação, dedicando sua atenção e seu tempo, em prol de orientações que permitiram-me ampliar meus conhecimentos.

Aos professores do CEFET-MG, pelos ensinamentos proporcionados nas disciplinas cursadas, e, também, pela presença solidária, amiga e construtiva. Indiscutivelmente vocês forneceram subsídios relevantes para meu crescimento intelectual e para a elaboração deste trabalho final.

Aos colegas de turma, pelas trocas e horas de conversas, pelos encorajamentos e apoio. Vocês me ajudaram a introduzir mais intensamente, em minha vida, a amizade, a solidariedade, o compartilhamento e a felicidade, patamares seguros em minhas lembranças na construção da vida futura. Em especial, preciso agradecer à Mariana, ao Sinaide e ao Vanderci, amigos ao longo e além dessa trajetória, pessoas que, em certos momentos, acreditaram em mim mais do que eu mesma acreditei, ajudando-me em conquistas que serão eternas em minha vida.

Aos colegas de trabalho da Escola Eleonora Pieruccetti, pelo apoio, atenção, compreensão e solidariedade. Por serem fontes de energia nos momentos difíceis e por compreenderem minhas ausências em função das demandas emergentes para a conclusão deste curso.

À minha família, pelo apoio irrestrito em todas as situações e, em especial, à minha mãe e à minha sogra pelo amor incondicional direcionado aos meus filhos e ao meu esposo, pela guarda dos mesmos nos momentos em que não estive presente.

Aos meus filhos Gabriel e Melise, tesouros que recebi de Deus, que caridosamente me encorajaram, até nos momentos em que isto representava a negação de seus próprios desejos.

Ao Eduardo, meu companheiro de todas as horas, por sua postura comedida na paciência, resiliência, dedicação, pautada na crença em nosso amor e em nossa família, instrumentos maiores que qualquer dificuldade. Você sempre foi meu porto seguro, tenha certeza!

*“Ando devagar porque já tive pressa
e levo esse sorriso porque já chorei demais...”*

*Hoje me sinto mais forte,
mais feliz quem sabe ...
Só levo a certeza de que muito pouco sei,
ou nada sei...”*

Almir Sater e Renato Teixeira

*Conhecer as manhas e as manhãs,
o sabor das massas e das maçãs...*

*É preciso amor pra poder pulsar,
É preciso paz pra poder sorrir,
É preciso a chuva para florir...*

Almir Sater e Renato Teixeira

Resumo

Este trabalho apresenta aplicações de Redes Neurais Artificiais (RNAs) e Técnicas de Otimização Não Linear (ONL) para classificar, localizar faltas em linhas de transmissão e determinar o valor das resistências de defeito, utilizando dados de faltas simuladas em um programa de transitórios eletromagnéticos e de faltas reais ocorridas no sistema elétrico brasileiro. As RNAs implementadas possuem topologia *Multilayer Perceptron*, método de aprendizagem supervisionado *Backpropagation*, algoritmo de treinamento Levenberg-Marquardt e função de ativação tangente-sigmoide, variando-se para cada tarefa o número de redes e neurônios. A etapa de classificação é realizada por uma RNA, a localização de faltas e a determinação da resistência de falta são executadas por 4 RNAs e também pela aplicação de técnicas de Otimização Não Linear mono-objetivo para a minimização de funções objetivo descritivas do problema. As funções objetivo foram definidas em termos dos parâmetros da linha e do tipo de falta obtido na etapa de classificação e submetidas aos métodos de Quasi-Newton, Elipsoidal e Algoritmo Genético Real Polarizado. A localização também é realizada por um método analítico, utilizado como referência para a comparação dos resultados. Na classificação, as respostas mostraram-se corretas em todos os testes realizados. Na localização, a aplicação do teste ANOVA para os dados simulados revelou, com 5% de significância, evidências estatísticas de que o tipo de método utilizado afetou o erro percentual em relação ao comprimento da linha de transmissão. Neste sentido, o teste de Tukey sinalizou erros menores com a utilização das RNAs e maiores com a utilização do método analítico implementado, ficando as técnicas de Otimização Não Linear com erros intermediários. Para casos reais de localização do curto-circuito, diferente da situação verificada em ambientes simulados, o teste de Tukey evidenciou maiores erros percentuais com a utilização das RNAs, sinalizando também a inexistência de evidências estatísticas para rejeitar a igualdade entre a localização de faltas efetuada pelo método analítico e os métodos de Otimização Não Linear.

Palavras-chave: Localização de Faltas, Classificação de Faltas, Linhas de Transmissão, Otimização Não Linear, Redes Neurais Artificiais.

Abstract

This paper describes implementations of Artificial Neural Networks (ANNs) and Non-Linear Optimization techniques (NLO) to classify and locate faults in transmission lines and identify the fault resistance value by using data from simulated faults in an electromagnetic transients program and real faults occurring in the Brazilian transmission line. The ANNs have Multilayer Perceptron topology, supervised Learning Method Backpropagation, Levenberg-Marquardt algorithm training and tangent-sigmoid activation function, varying for each fault the number of networks and neurons. The classification step is performed by an ANN, fault location and fault resistance determination are performed by 4 ANNs and also by the application of mono-objective Nonlinear Optimization techniques to minimize objective descriptive functions of the problem. The objective functions were defined in terms of the line parameters and the fault type obtained in the classification step and submitted to the Quasi-Newton, Ellipsoidal and Real Polarized Genetic Algorithm methods. The location is also performed by the analytical method used as a reference for comparing the findings. During classification, the answers were found to be correct in all tests performed. During location, the application of ANOVA test for the simulated data revealed, with 5% of significance, the existence of statistical evidence which allowed us to conclude that the main effects of the type of method used affect the percentage error in relation to the transmission line length. Thus, the Tukey test signaled lower errors with the use of ANN and higher errors with the use of the analytical method. Techniques of non-Linear optimization yielded intermediate errors. For real cases, different from the conditions observed in simulated conditions, the Tukey test emphasized bigger percentual errors with the use of ANNs, also signaling the lack of statistical evidence to reject the equality between fault location performed through the analytical method and nonlinear optimization methods.

Keywords: Fault Location, Fault Classification, Transmission Lines, Non-Linear Optimization, Artificial Neural Network.

Lista de Figuras

Figura 1.1:	Representação do Sistema Elétrico de Potência.	1
Figura 1.2:	Previsão de evolução do diagrama do SIN.	2
Figura 1.3:	Esquema de obtenção de dados.	6
Figura 2.1:	Representação geométrica do Método Elipsoidal.	28
Figura 3.1:	Modelo de um neurônio artificial.	34
Figura 3.2:	Rede Neural com uma camada.	36
Figura 3.3:	Rede Neural de múltiplas camadas.	36
Figura 3.4:	Funções de ativação.	38
Figura 3.5:	Rede MLP com aprendizagem supervisionada <i>Backpropagation</i> .	40
Figura 4.1:	Pressuposições para a aplicação da ANOVA.	45
Figura 6.1:	Algoritmo de localização de faltas.	63
Figura 6.2:	Etapas do pré-processamento de dados.	64
Figura 6.3:	Tensões e correntes em um dos terminais de uma linha de transmissão.	65
Figura 6.4:	Ondas de tensões de entrada e filtradas para um curto-circuito BT.	65
Figura 6.5:	Ondas de tensão original e com a taxa de amostragem reduzida.	66
Figura 6.6:	Ondas de tensão e corrente de uma falta real BT após redução da frequência de amostragem e aplicação do filtro passa-baixa.	67
Figura 6.7:	Amplitude e fase dos fasores de tensão.	68
Figura 6.8:	Amplitude e fase dos fasores de corrente.	68
Figura 6.9:	Processo de seleção de fasores para a localização de falta.	69
Figura 6.10:	Deteccção do instante de falta através da energia de Parseval e do coeficiente de decomposição cD1 da <i>Wavelet</i> .	70
Figura 7.1:	Modelo do ATP para simulação de curto-circuito.	73
Figura 7.2:	Etapas do processo de classificação e localização de faltas em linhas de transmissão.	74
Figura 7.3:	Modelos de curto-circuito.	75
Figura 7.4:	Etapas do processo para classificação da falta.	75
Figura 7.5:	Estrutura da RNA para classificação de faltas.	76
Figura 7.6:	Processo de localização e determinação da resistência de falta por RNAs.	78
Figura 7.7:	Estrutura modular para determinação da localização e da resistência de falta - RNAs com dados de um terminal da linha de transmissão.	79
Figura 7.8:	Estrutura modular para determinação da localização e da resistência de falta - RNAs com dados dos dois terminais da linha de transmissão.	80

Figura 7.9:	RNAs para a localização de faltas: erros em função do tipo de falta.	80
Figura 7.10:	RNAs para a localização de faltas: erros em função do número de terminais.	81
Figura 7.11:	Circuito para uma falta AT.	82
Figura 7.12:	Processo de localização e determinação da resistência de falta por Otimização.	84
Figura 7.13:	Circuito em falta.	86
Figura 8.1:	Função objetivo: Falta AT (45 km, $R_F = 20 \Omega$).	87
Figura 8.2:	Local e resistência de falta - Quasi-Newton.	88
Figura 8.3:	Local e resistência de falta - Elipsoidal.	88
Figura 8.4:	Local e resistência de falta - AGRP.	88
Figura 8.5:	Curvas de convergência da função objetivo - AGRP.	89
Figura 8.6:	AGRP a cada 10% da linha de transmissão.	90
Figura 8.7:	Balanceamento do número de amostras para as RNAs.	92
Figura 8.8:	Localização de faltas: gráfico de interações por tipo de falta.	93
Figura 8.9:	Localização de faltas: gráfico de interações por tipo de método.	93
Figura 8.10:	Erros de localização por tipo de falta - casos simulados.	94
Figura 8.11:	Erros de localização por tipo de método - casos simulados.	94
Figura 8.12:	Premissas para a aplicação do modelo de análise da variância.	95
Figura 8.13:	Teste de Tukey para comparação entre os tipos de falta - casos simulados.	97
Figura 8.14:	Teste de Tukey para comparação entre os tipos de métodos - casos simulados.	98
Figura 8.15:	Indicação dos locais de falta em 40 execuções das RNAs - casos reais.	99
Figura 8.16:	Indicação dos locais de falta em 40 execuções do AGRP - casos reais.	100
Figura 8.17:	Erros de localização em 40 execuções das RNAs - casos reais.	101
Figura 8.18:	Erros de localização em 40 execuções do AGRP - casos reais.	101
Figura 8.19:	Erros de localização - casos reais.	102
Figura 8.20:	Teste de Tukey em casos reais de localização - comparação entre métodos.	103
Figura 8.21:	Validação para a resistência de falta de $2,5 \Omega$ - casos simulados.	104
Figura 8.22:	Validação para a resistência de falta de $4,5 \Omega$ - casos simulados.	105
Figura 8.23:	Validação para a resistência de falta de 10Ω - casos simulados.	105
Figura 8.24:	Validação para a resistência de falta de 21Ω - casos simulados.	106
Figura 8.25:	Validação para a resistência de falta de 31Ω - casos simulados.	106

Lista de Tabelas

Tabela 1.1:	Linhas de transmissão da rede básica.	3
Tabela 4.1:	Arranjo dos dados para um planejamento de experimentos com um fator.	46
Tabela 4.2:	Análise de Variância - Modelo de efeitos fixos (1 fator).	50
Tabela 4.3:	Arranjo dos dados para um planejamento fatorial com dois fatores.	51
Tabela 4.4:	Análise de Variância - Modelo de efeitos fixos (2 fatores).	52
Tabela 7.1:	Parâmetros da linha e fontes equivalentes para as faltas simuladas.	71
Tabela 7.2:	Variáveis de composição dos cenários de falta.	72
Tabela 7.3:	Saídas da rede neural em função do tipo de falta.	77
Tabela 7.4:	Funções objetivo.	83
Tabela 7.5:	Parâmetros utilizados para a execução dos métodos de otimização.	85
Tabela 8.1:	Tempo de execução dos métodos para a localização de um evento de curto-circuito.	89
Tabela 8.2:	Número de casos por tipo de falta e tipo de método.	91
Tabela 8.3:	Teste ANOVA2 - casos simulados.	96
Tabela 8.4:	Teste para a comparação entre tipos de falta - casos simulados.	97
Tabela 8.5:	Teste para a comparação entre os tipos de métodos - casos simulados.	98
Tabela 8.6:	Caracterização dos cenários reais de falta.	98
Tabela 8.7:	Resultados da localização: faltas reais.	99
Tabela 8.8:	Erros percentuais de localização: faltas reais.	100
Tabela 8.9:	Teste ANOVA2 - casos reais.	102
Tabela 8.10:	Teste para comparação entre os tipos de métodos - casos reais.	103
Tabela 8.11:	Resistência de falta em casos reais.	107

Lista de Abreviaturas e Siglas

AG	Algoritmo Genético
AGRP	Algoritmo Genético Real Polarizado
ANEEL	Agência Nacional de Energia Elétrica
ATP	<i>Alternative Transients Program</i>
BFGS	Broyden - Fletcher - Goldfard - Shanno
BP	<i>Backpropagation</i>
<i>Cbroyden</i>	Método da Família de Broyden
CCEE	Câmara de Comercialização de Energia Elétrica
DFP	Davidson - Fletcher - Powell
EMTP	<i>Eletrromagnetic Transients Program</i>
EPE	Empresa de Pesquisa Energética
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
LM	Levenberg-Marquardt
LVQ	<i>Learning Vector Quantization</i>
MLP	<i>Multilayer Perceptron</i>
MME	Ministério de Minas e Energia
MSE	Erro médio quadrático
ONL	Otimização Não Linear
ONS	Operador Nacional do Sistema
PDE	Plano Decenal de Expansão de Energia
PNN	<i>Probabilistic Neural Network</i>
RDP	Registrador Digital de Perturbações
RNA	Rede Neural Artificial
RNEA	Redes Neurais de Estruturas Adaptativas
SEE	Secretaria de Energia Elétrica
SEP	Sistema Elétrico de Potência
SFE	Superintendência de Fiscalização dos Serviços de Eletricidade
SIN	Sistema Interligado Nacional
SVM	Máquina de Vetores de Suporte
TC	Transformador de Corrente
TDW	Transformada Discreta de <i>Wavelet</i>
TP	Transformador de Potencial
TW	Transformada de <i>Wavelet</i>

Lista de Símbolos

n	Número natural
$\mathbb{N}$	Conjunto dos números naturais
$\mathbb{R}$	Conjunto dos números reais
$\mathbb{R}^n$	Espaço euclidiano de dimensão n
$\emptyset$	Conjunto vazio
$\forall$	Para todo
f	Função objetivo
D_f	Região factível da função objetivo
c_i	Funções de restrição
C^k	Classe C^k
X	Vetor de $\mathbb{R}^n$
x^*	Minimizador da função objetivo
$\frac{\partial f}{\partial x}$	Derivada parcial de f com relação a x
$\frac{\partial^2 f}{\partial x^2}$	Derivada parcial de segunda ordem de f com relação a x
∇f	Vetor gradiente de f
$\nabla^2 f$	Matriz hessiana de f
W	Matriz de pesos
b	Vetor de bias
$\mathcal{V}$	Vizinhança
d_k	Direção de busca da k -ésima iteração
α_k	Passo unidimensional da k -ésima iteração
x_k	Vetor da k -ésima iteração
m_k	Subgradiente da k -ésima iteração
$\mathcal{R}$	Raio da bola S
S	Elipsoide
km	Quilômetro
kV	Quilovolt
Hz	Hertz
V	Volt

Ω	Ohms
MVA	Megavolt ampère
MVA _r	Megavolt ampère reativo
MW	Megawatt
SE	Subestação
ℓ	Extensão total da linha
Z	Impedância da linha em Ω/km
r	resistência
x	reatância
F	Local de falta
R_F	Resistência de falta
FF	Fase-fase
FFF	Fase-fase-fase
FFT	Fase-fase-terra
FT	Fase-terra
AB	Entre as fases A e B
ABC	Entre as fases A, B e C
ABT	Entre fase A, fase B e terra
AC	Entre as fases A e C
ACT	Entre fase A, fase C e terra
AT	Da fase A para a terra
BC	Entre as fases B e C
BCT	Entre fase B, fase C e terra
BT	Da fase B para a terra
CT	Da fase C para a terra
I_A	Corrente na fase A
I_B	Corrente na fase B
I_C	Corrente na fase C
V_A	Tensão na fase A
V_B	Tensão na fase B
V_C	Tensão na fase C

Sumário

1 - Introdução	1
1.1 Descrição do Problema	1
1.2 Justificativa e Motivação	7
1.3 Objetivos	9
1.3.1 Objetivo Geral	9
1.3.2 Objetivos Específicos	9
1.4 Hipóteses de Pesquisa	9
1.5 Metodologia	10
1.6 Organização do Texto	12
1.7 Produção Científica	13
2 - Otimização Não Linear	14
2.1 O Problema de Otimização Não Linear Mono-objetivo	14
2.2 Métodos de Direção de Busca	20
2.2.1 Método Gradiente	21
2.2.2 Método de Newton	21
2.2.3 Métodos de Quasi-Newton	22
2.3 Métodos de Exclusão de Regiões	25
2.3.1 Método Elipsoidal	26
2.4 Métodos Populacionais	29
2.4.1 Algoritmo Genético Real Polarizado	31
3 - Redes Neurais Artificiais	33
3.1 Redes Neurais Artificiais	33
3.2 Arquitetura de Redes Neurais Artificiais	33
3.2.1 Número de Neurônios	34
3.2.2 Número de Camadas	35
3.3 Funcionamento Básico de uma RNA	37
3.4 Métodos de Aprendizagem	39
3.5 Métodos de Treinamento	41

4 - Análise Estatística dos Dados	43
4.1 Análise de Variância	43
4.2 Análise de Variância para Experimentos com 1 Fator (ANOVA1)	46
4.3 Análise de Variância para Experimentos com 2 Fatores (ANOVA2)	50
5 - A Localização de Falhas em Linhas de Transmissão	54
5.1 Localização de Falhas	54
5.2 Detecção e Classificação de Falhas	57
5.3 Classificação e Localização de Falhas	59
5.4 Detecção, Classificação e Localização	61
6 - Rotinas de Pré-processamento de Dados	63
6.1 Entrada dos Dados de Tensão e Corrente	64
6.2 Filtragem Passa-Baixa	65
6.3 Redução do Número de Pontos por Ciclo	66
6.4 Estimação dos Fasores Fundamentais	67
6.5 Seleção dos Fasores para Aplicação nos Algoritmos	69
6.6 Detecção da Falta	69
7 - Classificação e Localização de Falhas	71
7.1 O Sistema Elétrico e a Caracterização dos Cenários de Falta	71
7.2 Classificação da Falta	74
7.3 RNAs para a Localização da Falta e Determinação da Resistência de Falta	77
7.4 Métodos de Otimização Não Linear para a Localização da Falta e Determinação da Resistência de Falta	81
7.5 Método Analítico de Johns e Jamali para a Localização da Falta	85
8 - Resultados	87
8.1 Classificação de Falhas Simuladas e Reais	91
8.2 Localização de Falhas: Casos Simulados	91
8.3 Localização de Falhas: Casos Reais	98
8.4 Resistência de Falta	104
9 - Conclusões	108
9.1 Trabalho Futuros	110
Referências	112

Capítulo 1

Introdução

1.1 Descrição do Problema

O desenvolvimento social e econômico de uma nação tem significativa relação com o setor elétrico e sua expansão, o que torna a energia elétrica e suas diversas aplicações indispensáveis à sociedade moderna. Segundo Santos (2017), a demanda de energia elétrica no Brasil apresenta uma perspectiva de crescimento em função do desenvolvimento econômico esperado para o país e considerando que o aumento no consumo implica na expansão da oferta, tornam-se necessários investimentos em infraestrutura.

O Sistema Elétrico de Potência (SEP) responsável por conduzir a energia gerada até os consumidores, esquematicamente representado na Figura 1.1, é uma estrutura complexa, possuindo elementos interligados para a constituição de uma grande rede elétrica, que pode conter milhares de barramentos e equipamentos, tais como geradores, transformadores, autotransformadores, disjuntores, reatores, capacitores, cargas e linhas de transmissão.




Figura 1.1: Representação do Sistema Elétrico de Potência.

Fonte: Moraes et al. (2010).

Dentre os componentes de um SEP, as linhas de transmissão são responsáveis pelo transporte de energia elétrica desde o ponto de geração até os pontos de distribuição. Chegam a possuir centenas de quilômetros, estando expostas a intempéries como descargas atmosféricas, tempestades, ventos fortes, poluição, altas insolações e vandalismo.

No SEP, a transmissão de energia elétrica está associada ao deslocamento de grandes blocos energéticos, em altas tensões e altas correntes, conectando os centros geradores de energia

elétrica e permitindo que a energia produzida seja encaminhada internamente no país ou entre países vizinhos. Em seus estudos, Santos (2017) destaca que a maior parte do sistema de produção e transmissão de eletricidade no Brasil é interligada, formando uma rede composta basicamente de usinas de geração e centros de consumo ligados por linhas de transmissão. Neste sistema, ocorrem perdas geradas por transferências em longas distâncias e a capacidade de transporte de energia é limitada em função da quantidade e qualidade das linhas de transmissão existentes. Assim, entre os objetivos básicos do planejamento da expansão elétrica destacam-se a construção de usinas de geração, subestações e linhas de transmissão.

Segundo o Plano Decenal de Expansão de Energia (MME/EPE, 2017), a rede básica de transmissão do Sistema Interligado Nacional (SIN), que compreende as tensões de 230 kV a 800 kV, tem como principais funções a transmissão da energia gerada pelas usinas para os grandes centros de carga; a integração entre os diversos elementos do sistema elétrico para garantir estabilidade e confiabilidade da rede; a interligação entre as bacias hidrográficas e regiões com características hidrológicas heterogêneas, de modo a otimizar a geração hidrelétrica e a integração energética com os países vizinhos. No atual contexto brasileiro, a Empresa de Pesquisa Energética (EPE), conforme esquema apresentado na Figura 1.2, prevê a expansão do SIN da configuração referente ao ano 2017 para o sistema planejado até o ano 2027.




Figura 1.2: Previsão de evolução do diagrama do SIN.
Fonte: (MME/EPE, 2017).

Em 2019, a EPE, em conjunto com o Operador Nacional do Sistema (ONS) e a Câmara de Comercialização de Energia Elétrica (CCEE), entidades ligadas à Agência Nacional de

Energia Elétrica (ANEEL), sinalizaram perspectivas de aumento no consumo de energia elétrica a uma taxa média de 4% ao ano. Corroborando, dados do Boletim Mensal de Monitoramento do Sistema Elétrico Brasileiro, expressos na Tabela 1.1, indicam que em junho de 2019 a extensão total de linhas de transmissão no Brasil pertencentes à rede básica atingiu 147.633 km, com perspectiva de aumento de mais de 30% até o ano de 2023, alcançando uma extensão prevista de 185.484 km.

Tabela 1.1: Linhas de transmissão da rede básica.

Classe de Tensão (kV)	Extensão de linhas de transmissão instaladas (km)	% Total
230	59.097	40,0 %
345	10.319	7,0 %
440	6.758	4,6 %
500	51.791	35,1 %
600 (CC)	12.816	8,7 %
750	2.683	1,8 %
800 (CC)	4.168	2,8 %
Total	147.633	100,0 %

Fonte: (MME/SEE/EPE, 2019).

As linhas de transmissão estão sujeitas a faltas, termo que corresponde à ocorrência de um curto-circuito, capaz de tirá-las de seu funcionamento normal havendo, inclusive, a possibilidade da falência do sistema elétrico. Representam um fenômeno de difícil previsão e podem acarretar às concessionárias de energia elétrica, em caso de demora no restabelecimento ou indisponibilidade da linha, o pagamento de pesadas multas aos órgãos reguladores do sistema elétrico, que no caso do Brasil é representado pela ANEEL.

Fatores fora do controle humano, aliados à inviabilidade de técnicas mais robustas de proteção devido aos custos, colaboram para que atualmente, no Brasil, cerca de 70% dos desligamentos forçados do SEP ocorram no sistema de transmissão. Segundo o relatório da (ANEEL/SFE, 2017), no período de 1º de julho de 2016 a 30 de junho de 2017, foram efetivados 3.768 desligamentos forçados e desses, 75,6% foram verificados em linhas de transmissão. Nesse sentido, os montantes de energia elétrica transportados em linhas de transmissão justificam investimentos em equipamentos e sistemas para a supervisão, gerenciamento e prevenção de faltas, com o intuito de promover a segurança no fornecimento

de energia elétrica. Ao se tratar a questão, diferentes técnicas podem ser desenvolvidas para aperfeiçoar a localização de faltas.

A caracterização de um evento de falta em linhas de transmissão¹ envolve a detecção do instante em que o fenômeno teve início, a classificação do tipo de falta (fase-terra, bifásico, bifásico-terra e trifásico), a indicação do local onde ocorreu e a resistência de falta. Diagnosticada a situação, é de interesse das empresas concessionárias dispor de uma sistemática que permita isolar com rapidez e significativa exatidão a parte do sistema elétrico que está com defeito, garantir seu pronto restabelecimento e atender à demanda de carga existente. Isto implica na redução de custos e dos riscos de colapso no SEP, maior confiabilidade e a satisfação do consumidor com a qualidade do serviço.

Quando há um curto-circuito em uma linha de transmissão a detecção, identificação e sinalização do evento são realizadas pelo relé de proteção. Este dispositivo, funcionando de forma analógica ou digital, fica permanentemente conectado ao sistema elétrico monitorando sinais de tensão e corrente proveniente dos transdutores e, em caso de falta, comanda os disjuntores para retirar de serviço a linha. O *Institute of Electrical and Electronic Engineers* (IEEE) define o relé de proteção como um dispositivo com a função de detectar em sistemas de potência trechos defeituosos, equipamentos falhos, condições anormais ou de natureza perigosa, sendo capaz de iniciar uma ação de controle apropriada, como o desligamento do disjuntor.

Após a atuação do relé de proteção, em seguida, são feitas tentativas de religamento automático, de forma a tentar colocar a linha novamente em funcionamento. A partir daí, podem ocorrer duas situações:

- Em casos de faltas temporárias, normalmente associadas à presença de sobretensões oriundas de descargas atmosféricas, há o sucesso e a linha é reintegrada ao sistema;
- Em casos de faltas permanentes, como quebra ou danificação de cadeia de isoladores, queda de estruturas, rompimento de cabos e outras causas de natureza semelhante, que provocam a deterioração da estrutura física da linha, as tentativas falham e a linha necessita ser desligada até que se corrija o defeito que, neste caso, é considerado permanente.

¹ Nesta dissertação, a linha de transmissão é considerada idealmente transposta ao longo de sua extensão. As matrizes de impedância e admitância possuem termos próprios iguais entre si e também termos mútuos iguais entre si.

Ao ocorrer uma falta permanente, é tarefa dos setores de manutenção da concessionária a execução dos trabalhos de reparo no menor tempo possível e com níveis de confiabilidade adequados. Para atingir estes objetivos, é importante que a equipe tenha uma informação confiável do trecho da linha que contenha o possível local de defeito, o que é feito através da localização da falta.

Ao se trabalhar com a localização de faltas em linhas de transmissão, vários fatores podem contribuir para provocar erros na indicação do local, dentre os quais, segundo Silveira (2007):

- A resistência de falta não é conhecida e pode variar substancialmente. Nos casos de faltas entre fases, essas apresentam valores pequenos, em geral menores que 3Ω . Em faltas envolvendo a terra, podem ter valores maiores que 10Ω . Em alguns casos, podem tornar-se muito elevadas, como em árvores encostadas em cabos (da ordem de 50 a 100Ω), condutores caídos em terrenos de elevada resistividade ou mesmo em queimadas (da ordem de 30 a 60Ω);
- Corrente de contribuição para a falta do terminal remoto da linha, fator ainda mais agravante se essa vier do lado da fonte mais forte, que possuirá menor impedância de curto-circuito e maior corrente;
- Linhas de circuito duplo ou presença de linhas próximas;
- Desequilíbrio na matriz de impedâncias;
- Presença de compensação série;
- Correntes e tensões de falta não puramente senoidais;
- Incorreções nos parâmetros de linha;
- Fluxo de carga pré-falta;
- Erros de transformadores de corrente e potencial.

Em seus estudos, Silveira et al. (2017b), ponderam que esses fatores podem ocorrer simultaneamente e existem diversos algoritmos que buscam minimizar o efeito deles no resultado da localização de faltas. A indicação da distância de falta pode ser feita por relés de proteção. Contudo, normalmente esta representa uma função auxiliar, sem estratégias para compensar os principais fatores que provocam erros de estimativa do local do curto-circuito, não sendo adequada para fins de reparo. Desta forma, é interessante um processamento de dados, com algoritmos mais elaborados e capazes de fornecer melhores resultados. Nesse

sentido, define-se o localizador de falta, objeto de estudo desta dissertação, como um equipamento que tem a função específica de localização, como um *hardware* semelhante a um relé digital, contendo filtros analógicos, circuitos de amostragem, conversores Analógico/Digital e meios de gravação de arquivos, ou como um *software* que contém as rotinas necessárias para a localização de faltas. Neste segundo caso, é usual a utilização de recursos já disponíveis no sistema elétrico. Assim, conforme o esquema apresentado na Figura 1.3, em um sistema elétrico modelado por uma linha de transmissão e fontes equivalentes no terminal emissor (SE-1) e no terminal receptor (SE-2), a amostragem das tensões e das correntes trifásicas nos terminais é obtida por um registrador digital de perturbações (RDP) ou por um relé de proteção, junto aos transformadores de potencial (TP) e corrente (TC). Neste cenário, ocorrido um evento de falta, os dados são transmitidos à sala de controle por um link de comunicação para que, remotamente, os engenheiros de proteção determinem o local do defeito e repassem às equipes de manutenção orientações para o restabelecimento da linha de transmissão.




Figura 1.3: Esquema de obtenção de dados.

No procedimento *off-line* é possível utilizar recursos avançados nos *softwares*, comparações com sistemas de localização de tempestades e até programas de curto-circuito, realizando a detecção, a classificação quanto ao tipo (fase-terra, trifásica, bifásica, bifásica-terra) e a localização, informando em quilômetros, onde a falta ocorreu e ainda determinar a resistência, em ohms, associada à falta.

A localização de faltas, cuja indicação do ponto de defeito necessita ser a mais confiável possível, envolve diversas investigações científicas. Conforme Silveira (2007), os algoritmos de localização de falta podem ser classificados em duas categorias:

- Métodos baseados em medições de fasores²;
- Métodos baseados em ondas viajantes³.

Nos localizadores baseados em fasores, os equipamentos necessários para a sua obtenção (medidores e redes de comunicação) encontram-se normalmente disponíveis nas subestações, sendo necessário o desenvolvimento de algoritmos de localização em linguagens de programação executadas em computadores portáteis. Os localizadores que utilizam ondas viajantes, embora sejam mais precisos que os fasoriais, necessitam de equipamentos específicos, demandando recursos financeiros e técnicos em sua aquisição e instalação. Cada uma dessas categorias pode ser dividida em dois grupos:

- Métodos que utilizam dados de um terminal da linha;
- Métodos que utilizam dados de mais de um terminal da linha.

Os algoritmos que utilizam fasores de um terminal, conforme descrito por Girgis et al. (1992), Novosel (1996), Gopalakrishnan (2000) e Jiang, Yang e Lin (2000), têm a vantagem de não necessitarem de valores medidos de tensão e corrente do lado remoto, que nem sempre encontram-se disponíveis. Contudo, são mais susceptíveis a erros, principalmente devido à resistência de falta, simplificações no equacionamento dos algoritmos e as incertezas associadas aos valores dos equivalentes terminais das fontes, que não são conhecidos ou não são fornecidos com a precisão necessária. Os algoritmos fasoriais que utilizam ambas as extremidades da linha são normalmente mais precisos, possibilitando reduzir algumas incertezas, como as do efeito da resistência de falta e da corrente elétrica do terminal remoto.

1.2 Justificativa e Motivação

Com o advento da tecnologia digital, muitas facilidades foram incorporadas ao serviço de proteção elétrica, tornando disponíveis dados de tensão e corrente que puderam ser utilizados, entre outras aplicações, nos localizadores de faltas. As empresas buscam otimizar seus recursos e, à medida que novos equipamentos vão sendo integrados, cresce a complexidade do sistema elétrico e a necessidade de aprimoramento da análise dos eventos que ocorrem na rede. Neste contexto, visando aumentar a confiabilidade e proporcionar maior capacidade de

² Um fasor é um vetor que representa uma grandeza que varia no tempo com um comportamento senoidal, possuindo uma amplitude e um ângulo de fase.

³ A onda viajante é um sinal transitório de alta frequência gerado na linha de transmissão em função do curto-circuito.

escoamento de energia do sistema, revela-se a importância de investimentos em expansão de novas linhas de transmissão, além da elaboração e execução de planos de modernização, melhorias em processos e assimilação de novos recursos tecnológicos nas subestações e linhas de transmissão já existentes no país. O avanço da tecnologia e o desenvolvimento na área de *software* destinado às aplicações em SEP, resultante da integração entre áreas como a Computação, a Engenharia, a Física e a Matemática, têm favorecido pesquisas sobre diagnóstico de faltas em linhas de transmissão e propiciado a adição de novas técnicas aos algoritmos, tornando-os mais elaborados e capazes de fornecer melhores resultados. Contudo, apesar do desenvolvimento alcançado, em função das várias fontes de erros que podem afetar a eficácia dos diversos métodos existentes, o diagnóstico de faltas não constitui uma tarefa simples. A melhoria dos algoritmos existentes e as propostas de novas metodologias e processos para este fim encontram-se presentes em projetos e investimentos financiados pelas concessionárias de energia elétrica, sendo objeto de pesquisas desenvolvidas pela academia. A indisponibilidade da linha de transmissão pode acarretar, em caso de demora no restabelecimento, além dos prejuízos à sociedade, o pagamento de pesadas multas, razão pela qual as empresas investem grande esforço e dinheiro em tecnologias para o aprimoramento de suas atividades.

Relativo ao campo do conhecimento, pesquisas relacionadas com o diagnóstico de faltas em linhas de transmissão possibilitam a exploração e a integração entre conceitos de várias áreas de conhecimento, permitindo a ampliação da produção intelectual a partir da realização de análises das estruturas dos algoritmos envolvidos e a implementação de novas técnicas de detecção, classificação e localização de faltas.

Existem diferentes estudos aplicando Redes Neurais Artificiais à localização de faltas em linhas de transmissão, como os de Amorim e Huais (2004), Gracia et al. (2005), Lout e Aggarwal (2012), Teklic et al. (2013) e Silveira et al. (2017a). Nesses trabalhos, os autores alcançam resultados significativamente satisfatórios em cenários simulados, o mesmo não ocorrendo em cenários reais de curto-circuito.

Referente à aplicação de técnicas de otimização às funções objetivo elaboradas pelas equações do circuito de linhas de transmissão, o estudo bibliográfico revelou uma carência destas ferramentas. Neste sentido, pretende-se nesta dissertação apresentar um estudo relacionado com a utilização de RNAs e de técnicas de Otimização Não Linear (ONL) para a localização de faltas em linhas de transmissão e a comparação entre estas ferramentas em cenários simulados e reais de curto circuito.

1.3 Objetivos

1.3.1 Objetivo Geral

Este trabalho de pesquisa tem o objetivo geral de apresentar aplicações de Redes Neurais Artificiais e de técnicas de Otimização Não Linear ao problema de localização de faltas em linhas de transmissão utilizando-se dados de dois terminais.

1.3.2 Objetivos Específicos

Especificamente propõe-se o desenvolvimento e a aplicação, para sinais simulados e reais, de métodos matemáticos e computacionais para:

- O processamento de sinais, necessários para a preparação do banco de dados a ser utilizado;
- Um algoritmo de classificação de faltas por meio de RNAs;
- Algoritmos de localização de faltas e determinação da resistência, com a utilização de RNAs e técnicas de ONL a partir dos métodos de Quasi-Newton, Elipsoidal e Algoritmo Genético Real Polarizado (AGRP);
- Um método analítico de localização de faltas proposto por Johns e Jamali (1990), utilizado como referência para comparação dos resultados;
- A análise estatística dos resultados alcançados.

1.4 Hipóteses de Pesquisa

Frente aos objetivos anteriormente apresentados foram definidas as seguintes questões inerentes à temática e norteadoras desta dissertação: Como ferramentas matemáticas e computacionais relacionadas com RNAs e Técnicas de ONL têm sido utilizadas para a localização de faltas em linhas de transmissão? Quais benefícios, dificuldades e limites encontram-se associados à utilização destas ferramentas?

Diante das questões especificadas e a partir do estudo preliminar realizado, levantaram-se as hipóteses de que:

- I. As RNAs possuem capacidade de aproximar funções não lineares no espaço multidimensional e sua utilização, para a tarefa de localização de faltas e determinação da resistência de falta, mostra-se eficaz em cenários simulados. Em

ambientes reais, a restrição de parâmetros de simulação como os valores das tensões nas fontes e suas respectivas impedâncias equivalentes no momento do curto-circuito, pode limitar a capacidade de generalização das RNAs, comprometendo a metodologia proposta;

- II. A partir das funções objetivo descritivas do evento propostas por Silveira et al. (2017b), técnicas de ONL podem ser aplicadas ao problema de localização de falta, tornando possível a utilização dessas ferramentas matemáticas e computacionais em situações simuladas e reais de curto-circuito;
- III. A predominância da utilização prática de métodos analíticos; fundamentados em equações do circuito da linha de transmissão ocorre, em alguns casos, devido às limitações práticas de utilização de métodos de Inteligência Computacional e de ONL.

1.5 Metodologia

Para a compreensão das questões e verificação das hipóteses levantadas, a metodologia utilizada envolveu o desenvolvimento de rotinas utilizando o *software* MatLab e as etapas descritas:

a) Pesquisa Bibliográfica

A pesquisa bibliográfica contemplou estudos referentes à utilização de conhecimentos da Engenharia Elétrica, relacionados ao SEP e aos Métodos Matemáticos e Computacionais. Foram utilizadas, como fontes principais de consulta, publicações de entidades de notória competência como IEEE entre outras. Esta fase teve como objetivo verificar o estado da arte na área de pesquisa de localização de faltas em linhas de transmissão.

b) Definição do sistema elétrico a ser simulado e utilização de programa de transitórios eletromagnéticos

Para testar os algoritmos de classificação e localização das faltas através das RNAs ou da minimização de uma das funções objetivo, é necessário gerar uma base de dados, construída nesta pesquisa a partir do Alternative Transients Program (ATP). Este simulador possui modelos dos componentes elétricos do SEP. Após a simulação, o ATP exporta um arquivo com extensão .txt com dados de tensão e corrente a serem utilizados nas várias etapas que compõem os programas de classificação e localização de faltas. Nesta etapa, foram definidos

quatro sistemas elétricos simulados e os respectivos valores das tensões das fontes, extensão da linha, pontos de ocorrência de curto-circuito e valores da resistência de falta.

c) Implementação da rotina de leitura de dados de tensão e corrente

Esta etapa teve o objetivo de definir um formato padrão para os dados para ser lido por um programa computacional. Os arquivos com os dados de entrada podem ser obtidos através de programas de simulação ou a partir de valores medidos em linhas de transmissão em concessionárias brasileiras, gravados em um formato que não permite a sua leitura direta.

d) Filtragem passa-baixa, redução do número de pontos por ciclo e estimativa dos fasores

Estas etapas referem-se ao pré-processamento dos sinais de tensão e corrente. Para retirada das frequências mais elevadas foi realizada uma filtragem digital passa-baixa e, após esta etapa, foi feita redução da taxa de amostragem, possibilitando a adequação da frequência ao valor desejado de 16 pontos por ciclo da frequência fundamental (60 Hz no caso do Brasil). Para estimação dos fasores associados à frequência fundamental foi utilizado, como proposto por Pereira e Cruz (1999), uma variação do método de mínimos quadrados, obtida a partir da formulação de Sachdev e Baribeau (1979).

e) Aplicação de RNA para a classificação do tipo de falta

A classificação é uma etapa necessária para a localização. A partir do tipo de curto-circuito (monofásico-terra, bifásico, bifásico-terra, trifásico) é acionado um módulo da RNA ou a correspondente função objetivo a ser submetida aos algoritmos de otimização. Nesta etapa, além da definição da arquitetura da rede, foi utilizado o conceito de modularidade, como tratado por Pradhan et al. (2006). Com a informação obtida, foi possível reduzir a complexidade da rede e o tempo de treinamento sem prejuízo na precisão dos resultados.

f) Aplicação de RNAs para a localização de faltas

Na identificação do local de falta e do valor da resistência de falta foram utilizadas RNAs treinadas com os dados das simulações do ATP, contendo variações do tipo de curto-circuito, local de ocorrência da falta e valores de resistência da falta. Arquivos de faltas reais ocorridas em linhas do sistema elétrico brasileiro também foram utilizados para testar a robustez da metodologia desenvolvida.

g) Aplicação de técnicas de Otimização Não Linear para a localização de faltas

A partir de leis que regem circuitos elétricos para diferentes tipos de faltas e dos valores de tensões e correntes dos terminais da linha de transmissão, foram utilizadas funções mono-objetivo implementadas por Silveira et al. (2017b), tendo como variáveis o local e a resistência de falta. Após as etapas de detecção e classificação da falta, as funções objetivo foram aplicadas em casos simulados e reais de curto-circuito de linhas de transmissão e, através de técnicas de minimização, foram determinadas a distância até o ponto de falta e a resistência de falta.

h) Análise estatística dos resultados

Para a análise dos resultados foram realizadas comparações estatísticas entre os resultados alcançados pelos métodos implementados com a utilização de dados coletados em cenários simulados e reais. Para esta análise também foi considerado os resultados obtidos pelo método analítico de Johns e Jamali (1990).

1.6 Organização do Texto

Esta dissertação está estruturada em 9 capítulos. O presente capítulo compreende uma introdução geral do tema com a descrição do problema, a justificativa do estudo proposto, a definição dos objetivos da pesquisa e a metodologia utilizada.

Nos capítulos 2 e 3 são apresentadas, respectivamente, técnicas de Otimização Não Linear e Redes Neurais Artificiais. Estas ferramentas envolvem conhecimentos matemáticos e computacionais e são utilizadas em algoritmos que tratam do diagnóstico de faltas em linhas de transmissão.

No capítulo 4, são apresentadas as técnicas estatísticas utilizadas para análise dos dados simulados e reais obtidos pelos métodos localização de faltas em linhas de transmissão, implementados por RNAs, técnicas de ONL aplicadas às funções objetivo descritivas do processo e por um método analítico de referência.

No capítulo 5, está apresentada uma breve revisão da literatura, que trata de temas centrais como detecção, classificação e localização de faltas.

No capítulo 6, são explicitados os procedimentos de coleta de dados e as rotinas de processamento dos dados de entrada relacionados ao pré-condicionamento dos sinais de

entrada (filtragem e redução do número de pontos por ciclo) e à estimação dos fasores de frequência fundamental.

No capítulo 7 é descrita a topologia do sistema elétrico utilizado, a definição dos parâmetros necessários às simulações e as funções objetivo. A classificação do tipo de falta é proposta pela aplicação de uma RNA. Na sequência detalha-se o processo de localização de faltas e determinação da resistência de falta com a utilização de RNAs e de técnicas de ONL, apresentando-se também a localização da falta através de um método analítico de referência.

No capítulo 8, são apresentados os resultados obtidos pelos algoritmos implementados para a classificação, a localização da falta e a determinação da resistência de falta em casos simulados e reais de curto-circuito do sistema elétrico brasileiro.

Por fim, no capítulo 9, são apresentadas as conclusões envolvendo a análise geral do trabalho desenvolvido, as considerações finais e as sugestões para trabalhos futuros.

1.7 Produção Científica

Com base nos estudos apresentados nesta dissertação, os seguintes artigos foram produzidos.

- ROCHA, S.A; MATTOS, T.G.; SILVEIRA, E.G. (2019a). Otimização Não Linear e Redes Neurais Artificiais: Ferramentas na Localização de Faltas em Linhas de Transmissão. LI Simpósio Brasileiro de Pesquisa Operacional (SBPO 2019), FCA-UNICAMP. Disponível em: <<https://proceedings.science/sbpo-2019/papers/otimizacao-nao-linear-e-redes-neurais-artificiais--ferramentas-na-localizacao-de-faltas-em-linhas-de-transmissao>>. Acesso em 20 dez 2019.
- ROCHA, S.A.; MATTOS, T.G.; SILVEIRA, E.G. (2019b). Redes Neurais Artificiais Para Localização de Faltas em Linhas de Transmissão: Casos Simulados e Reais. The XXIV Congreso sobre Métodos Numéricos y sus Aplicaciones (ENIEF 2019). Santa Fé. Argentina. Disponível em: <<https://amcaonline.org.ar/enief2019-pdf/paper-6264.pdf>>. Acesso em: 18 dez. 2019.
- ROCHA, S.A.; CARDOSO, R.T.N; MATTOS, T.G.; SILVEIRA, E.G. (2020). Localização de Faltas em Casos Simulados e Reais em Linhas de Transmissão Utilizando Otimização Não Linear e Redes Neurais Artificiais. VIII Simpósio Brasileiro de Sistemas Elétricos (SBSE 2020). Santo André, São Paulo. Brasil (submetido).

Capítulo 2

Otimização Não Linear

Neste capítulo são apresentados conceitos relacionados às técnicas de Otimização Não Linear, modelos matemático-computacionais utilizados no processo de localização de faltas em linhas de transmissão. Além da definição do problema, são abordados procedimentos para a minimização irrestrita de uma função não linear mono-objetivo que utilizam a direção de busca, a exclusão de regiões e a dinâmica evolutiva de populações, respectivamente representados pelos métodos de Quasi-Newton, Elipsoidal e pelo Algoritmo Genético Real Polarizado, utilizados neste trabalho.

2.1 O Problema de Otimização Não Linear Mono-objetivo

Seja $x \in \mathbb{R}^n$, $n \in \mathbb{N}$, um vetor com n elementos reais. Um problema de otimização consiste em minimizar ou maximizar a função objetivo $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$ sobre todos os vetores x pertencentes à região factível D_f . O conjunto D_f pode ser descrito por equações e/ou inequações de restrições, conduzindo o problema a uma situação restrita ou pode contemplar todo o $\mathbb{R}^n$, caracterizando um problema de otimização irrestrito. Quando a função f e/ou suas restrições são não lineares tem-se um problema de Otimização Não Linear.

Nesta dissertação, apresenta-se apenas o problema de minimização visto que, por convenção, formular um problema de otimização é formular um problema de minimização. Na formulação geral do problema de minimização x^* é o minimizador da função f , obtido segundo a Equação 2.1, podendo estar sujeita às funções de restrição c_i :

$$x^* = \min_{x \in \mathbb{R}^n} f(x) \text{ sujeita a } \begin{cases} c_i(x) = 0, i \in I \\ c_i(x) \leq 0, i \in D \end{cases} \quad (2.1)$$

em que I e D são, respectivamente, dois conjuntos de índices das restrições de igualdade e de desigualdade. Quando $I = D = \emptyset$, o problema de otimização é irrestrito. Se $I \neq \emptyset$ ou $D \neq \emptyset$, o problema é dito restrito, nestes casos são incluídas restrições explícitas sobre as variáveis. Nesta dissertação são tratados apenas os problemas de minimização irrestritos.

A ONL irrestrita de $f: \mathbb{R}^n \rightarrow \mathbb{R}$, apresentada na Equação 2.2, e utilizada nos métodos desta dissertação, relaciona-se com localização dos pontos que minimizam a função em seu conjunto admissível.

$$\min f(x), \quad x \in \mathbb{R}^n. \quad (2.2)$$

A solução ótima do problema de minimização envolve a análise de características da função objetivo e das definições:

Definição 2.1. Um vetor $x^* \in \mathbb{R}^n$ é mínimo local de $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$ se existe uma vizinhança $\mathcal{V}$ de x^* tal que $f(x^*) \leq f(x)$, $\forall x \in \mathcal{V}$ e $x^* \in D_f$.

Definição 2.2. Um vetor $x^* \in \mathbb{R}^n$ é mínimo local estrito de $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$ se existe uma vizinhança $\mathcal{V}$ de x^* tal que $f(x^*) < f(x)$, $\forall x \in \mathcal{V}$, com $x \neq x^*$ e $x^* \in D_f$.

Nas definições anteriores uma vizinhança $\mathcal{V}$ de x^* é um conjunto aberto que contém x^* .

Definição 2.3. Um vetor $x^* \in \mathbb{R}^n$ é mínimo global de $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$ se, e somente se, $f(x^*) \leq f(x)$, $\forall x \in D_f$ e $x^* \in D_f$.

Definição 2.4. Um vetor $x^* \in \mathbb{R}^n$ é mínimo global estrito de $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$ se, e somente se, $f(x^*) < f(x)$, $\forall x \in D_f$, $x \neq x^*$ e $x^* \in D_f$.

Definição 2.5. Uma função $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$ definida em um subconjunto de D_f é convexa se, e somente se, para quaisquer dois pontos distintos $x', x'' \in D_f$ e $\forall \alpha \in \mathbb{R} : 0 \leq \alpha \leq 1$, for verificado que $f[\alpha.x' + (1 - \alpha).x''] \leq \alpha.f(x') + (1 - \alpha).f(x'')$.

Definição 2.6. Uma função $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}^m$ definida em um subconjunto de D_f aberto é de classe C^k se todas as k -derivadas parciais de f , simbolizadas por $\nabla^k f$, existirem e forem contínuas nesse conjunto aberto.

Definição 2.7. Uma função f de classe C^1 definida em um subconjunto de D_f é convexa se, e somente se, para quaisquer dois pontos distintos $x', x'' \in D_f$ e $\forall \alpha \in \mathbb{R} : 0 \leq \alpha \leq 1$, for verificado que $f(x') \geq f(x'') + \nabla f(x'')(x' - x'')$.

Geometricamente, a Definição 2.7 indica que toda reta tangente à função convexa f , definida em um intervalo $I \subset D_f$, encontra-se abaixo ou coincide com o gráfico de f . Assim, se a

função f for convexa, todo ponto de mínimo local representa também um ponto de mínimo global.

É comum em um problema de otimização não saber se o ponto mínimo existe. Para tanto, o Teorema de Weierstrass, demonstrado em Bortolossi (2002) e enunciado a seguir, garante a existência de um mínimo global quando certas condições são satisfeitas.

Teorema 2.1. (Teorema de Weierstrass para a existência de mínimos) *Se $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$ é uma função contínua em um conjunto não vazio $D_f \subset \mathbb{R}^n$ fechado e limitado, então $f(x)$ tem um mínimo global em D_f .*

Quando as hipóteses do teorema são satisfeitas, a existência do mínimo global é garantida. Assim, caso o problema caracterizado pela Equação 2.2 satisfaça o teorema, o ponto ótimo será o ponto no qual o valor de f é o menor possível. Contudo o teorema não exclui a possibilidade de existência de um mínimo global caso as condições não sejam atendidas.

Para funções de classe C^1 o problema irrestrito, conforme demonstrado em Bortolossi (2002), pode ocorrer a partir do Teorema de Fermat, expresso pela Equação 2.3.

Teorema 2.2. (A regra de Fermat) *Sejam $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$ uma função de classe C^1 , definida em um subconjunto D_f de $\mathbb{R}^n$ e $D \subset D_f$. Se $x^* \in D$ é um ponto de máximo ou de mínimo local de f em D e x^* é um ponto interior de D , então x^* é um ponto crítico de f , isto é a matriz jacobiana de f em x^* é uma matriz nula ou, analogamente, o gradiente da função f em x^* é o vetor nulo,*

$$\nabla f(x^*) = \left[\frac{\partial f}{\partial x_1}(x^*) \quad \frac{\partial f}{\partial x_2}(x^*) \quad \dots \quad \frac{\partial f}{\partial x_n}(x^*) \right] = [0 \quad 0 \quad \dots \quad 0]_{1 \times n}. \quad (2.3)$$

Intuitivamente, o gradiente da função f em x^* deve ser nulo, caso contrário, indica uma direção em que f cresce. Este resultado representa uma condição necessária para que o ponto x^* seja um ponto ótimo da solução do problema de minimização. A recíproca do Teorema não é verdadeira.

Segundo Bortolossi (2002), a forma quadrática associada à matriz quadrada $A_{n \times n}$, formada por números reais, é a função escalar representada pela Equação 2.4,

$$\begin{aligned} Q: \mathbb{R}^n &\rightarrow \mathbb{R}, \\ v &\rightarrow Q(h) = v^T \cdot A \cdot v. \end{aligned} \quad (2.4)$$

A matriz A associada à forma quadrática Q é semidefinida positiva se $Q(v) = v^T \cdot A \cdot v \geq 0$, $\forall v \in \mathbb{R}^n$, tal que $v \neq 0$. A convexidade de f pode ser verificada através de sua matriz hessiana, $\nabla^2 f$, que sendo semidefinida positiva deverá satisfazer a condição estabelecida pela Inequação 2.5 para qualquer vetor $v^T = [v_1 \ v_2 \ \dots \ v_n]$:

$$[v_1 \ v_2 \ \dots \ v_n] \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \dots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \dots & \dots & \dots & \dots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \\ \dots \\ v_n \end{bmatrix} \geq 0. \quad (2.5)$$

Pode-se analisar a condição de $\nabla^2 f(x^*)$ a partir de seus autovalores:

- Se todos os autovalores de $\nabla^2 f(x^*)$ são positivos, a matriz é uma forma definida positiva;
- Se todos os autovalores de $\nabla^2 f(x^*)$ são negativos, a matriz é uma forma definida negativa;
- Se $\nabla^2 f(x^*)$ tem autovalores com sinais diferentes, então ela é indefinida.

O estudo das propriedades analíticas de uma solução local do problema possibilita a confirmação das condições de otimalidade a serem satisfeitas por uma solução. As condições necessárias de otimalidade são obtidas assumindo que x^* é um mínimo local e que são conhecidos o gradiente da função e sua matriz hessiana. As condições suficientes, se satisfeitas por um ponto x^* , garantem que este ponto é um mínimo local de f .

Teorema 2.3. (Condição necessária de 1ª ordem) *Se x^* é um mínimo local e f é continuamente diferenciável em uma vizinhança aberta de x^* , então $\nabla f(x^*) = 0$.*

Teorema 2.4. (Condição necessária de 2ª ordem) *Se x^* é um mínimo local de f e $\nabla^2 f(x^*)$ existe e é contínua em uma vizinhança aberta de x^* , então $\nabla f(x^*) = 0$ e $\nabla^2 f(x^*)$ é semidefinida positiva.*

Teorema 2.5. (Condição suficiente de 2ª ordem) *Suponha que $\nabla^2 f(x^*)$ seja contínua em uma vizinhança aberta de x^* com $\nabla f(x^*) = 0$ e $\nabla^2 f(x^*)$ definida positiva. Então, x^* é um mínimo local estrito de f .*

Um resultado constantemente utilizado em métodos determinísticos de otimização é a aproximação de funções continuamente diferenciáveis por série de Taylor demonstrado, por exemplo, em Bortolossi (2002), a partir da junção do Teorema do Valor Médio com uma variação do Teorema Fundamental do Cálculo.

Teorema 2.6. (Teorema de Taylor) *Suponha que $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$ é continuamente diferenciável e que $p \in \mathbb{R}^n$. Sejam $\nabla f(x)$ e $\nabla^2 f$, respectivamente, o gradiente e a matriz hessiana desta função. Então $f(x + p) = f(x) + \nabla f(x + tp)^T p$, para algum $t \in \mathbb{R} : 0 \leq t \leq 1$. Se f é duas vezes diferenciável, tem-se que $\nabla f(x + p) = \nabla f(x) + \int_0^1 \nabla^2 f(x + tp) p dt$ e $f(x + p) = f(x) + \nabla f(x)^T p + \frac{1}{2} p^T \nabla^2 f(x + tp) p$.*

A condição necessária de 1ª ordem, descrita no Teorema 2.3., pode ser verificada considerando-se um vetor arbitrário $d \in \mathbb{R}^n$ e uma função auxiliar $g: \mathbb{R} \rightarrow \mathbb{R}$, tal que $g(\alpha) = f(x^* + \alpha d)$. Como x^* é um minimizador local de f , $\alpha = 0$ é um minimizador local de $g(\alpha)$, o que indica que $g'(\alpha) = 0$. Como $g'(\alpha) = \nabla f(x^* + \alpha d) = 0$, tem-se que $\nabla f(x^*)^T d = 0$, logo $\nabla f(x^*)$ deve ser ortogonal a todos os outros vetores do espaço.

Pela Definição 2.1., se $d \in \mathbb{R}^n$ e x^* é um mínimo local de $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$, existe ε suficientemente pequeno, tal que $0 \leq |\alpha| \leq \varepsilon$, $f(x^* + \alpha d) - f(x^*) \geq 0$. Considerando-se f continuamente diferenciável, pela expansão em série de Taylor, chega-se à Equação 2.6,

$$f(x^* + \alpha d) = f(x^*) + \alpha d^T \nabla f(x^*) + O(\alpha). \quad (2.6)$$

Sendo $\lim_{\alpha \rightarrow 0} \frac{\alpha d^T \nabla f(x^*) + O(\alpha)}{\alpha} = \lim_{\alpha \rightarrow 0} d^T \nabla f(x^*) + \lim_{\alpha \rightarrow 0} \frac{O(\alpha)}{\alpha} \geq 0$ e $\lim_{\alpha \rightarrow 0} \frac{O(\alpha)}{\alpha} = 0$, tem-se que $f(x^* + \alpha d) - f(x^*) = \alpha d^T \nabla f(x^*) \geq 0$. Para $\alpha > 0$, como d pode representar valores positivos ou negativos e $\alpha d^T \nabla f(x^*) \geq 0$, que o gradiente da função objetivo no ponto de mínimo local é nulo, como expresso na Equação 2.7,

$$\nabla f(x^*) = 0. \quad (2.7)$$

Referente à condição necessária de 2ª ordem, descrita no Teorema 2.4., considerando-se que x^* é um ponto de mínimo da função, $\nabla^2 f(x^*) \geq 0$. Aplicando-se a regra da cadeia em $g(\alpha) = f(x^* + \alpha d)$ tem-se que $g''(\alpha) = d^T \nabla^2 f(x^* + \alpha d) d$.

Assim, $g''(0) = d^T \nabla^2 f(x^*) d \geq 0$, o que ocorre se $\nabla^2 f(x^*) \geq 0$.

Se f é duas vezes continuamente diferenciável em x^* , utilizando-se o Teorema de Taylor tem-se, pela Equação 2.8, que:

$$f(x^* + \alpha d) = f(x^*) + \alpha d^T \nabla f(x^*) + \frac{1}{2} \alpha^2 d^T \nabla^2 f(x^*) d + O(\alpha^2). \quad (2.8)$$

Pela Definição 2.1., a otimalidade local de x^* indica que $\exists \varepsilon > 0$, suficientemente pequeno, tal que $0 \leq \alpha^2 \leq \varepsilon$. Como $\nabla f(x^*) = 0$, considerando-se o Teorema de Taylor, percebe-se que:

$$\frac{1}{2} \cdot \frac{\alpha^2 d_k^T \nabla^2 f(x^*) d_k + O(\alpha^2)}{\alpha^2} = \frac{d_k^T \nabla^2 f(x^*) d_k}{2} + \frac{O(\alpha^2)}{\alpha^2} = \frac{f(x^* + \alpha d_k) - f(x^*)}{\alpha^2} \geq 0.$$

Como $\lim_{\alpha \rightarrow 0} \frac{O(\alpha^2)}{\alpha^2} = 0$, $d_k^T \nabla^2 f(x^*) d_k \geq 0$, a matriz $\nabla^2 f(x^*)$ é semidefinida positiva, atendendo a condição da Equação (2.9),

$$\nabla^2 f(x^*) \geq 0. \quad (2.9)$$

Os Teoremas anteriormente apresentados são fundamentais para os algoritmos de otimização irrestrita, suas demonstrações são encontradas em Bortolossi (2002). Eles indicam que, assumindo que x^* seja solução ótima de $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$, uma primeira condição de otimalidade - condição geométrica - é obtida analisando o ângulo de $\nabla f(x^*)$ com direções que apontam para o interior do conjunto admissível. Para que x^* seja um mínimo local da função f , diferenciável em x^* , é necessário que $\nabla f(x^*)$ seja o vetor nulo (condição necessária de primeira ordem). Para que x^* seja um mínimo local da função f , duas vezes diferenciável em x^* , é necessário que $\nabla f(x^*)$ seja nulo e que $\nabla^2 f(x^*)$ seja semidefinida positiva (condição necessária de segunda ordem). Estas condições são apenas necessárias porque os termos de primeira e segunda ordem podem estar nulos, deixando ainda dúvida sobre a natureza de x^* . Se f for duas vezes diferenciável em x^* , tal que $\nabla f(x^*)$ seja nulo e $\nabla^2 f(x^*)$ seja positiva definida tem-se a condição suficiente para que x^* seja um mínimo local estrito. Se a função f é convexa, todo mínimo local representa também um mínimo global e o Teorema 2.2., referenciado como condições necessárias de primeira ordem, é suficiente para indicar a solução do problema de minimização.

A seguir são apresentadas as principais ideias de alguns métodos de otimização irrestrita dependentes da direção de busca.

2.2 Métodos de Direção de Busca

Os métodos de direção de busca são métodos determinísticos em que a indicação do ponto ótimo é realizada a partir da minimização da função objetivo em sucessivas direções. A solução do problema ocorre iterativamente e, a partir de um ponto inicial x_0 , fornecido pelo usuário, gera-se uma sequência de aproximações $\{x_k\}_{k=0}^{\infty}$ que converge para o ponto ótimo. O processo termina quando o algoritmo atinge o número máximo de iterações pré-estabelecidas ou quando a aproximação $\{x_k\}$ satisfaz algum critério de parada previamente definido. Os novos pontos são determinados a partir de informações sobre a função objetivo no ponto atual e/ou pontos anteriores, sendo necessário que f seja contínua. Para um escalar fixo pequeno $\varepsilon > 0$, podem ser utilizados os seguintes critérios de parada:

- Número máximo de iterações dado: $k > k_{max}$;
- Estabilização das variáveis de decisão: $\|x_{k+1} - x_k\| \leq \varepsilon$;
- Estabilização do valor da função objetivo: $\|f(x_{k+1}) - f(x_k)\| \leq \varepsilon$;
- Anulação do vetor gradiente: $\|\nabla f(x_{k+1})\| \leq \varepsilon$.

Geralmente, o ponto da sequência que minimiza a função objetivo é obtido a partir da fórmula de recorrência expressa na Equação 2.10,

$$x_{k+1} \approx x_k + \alpha d_k, \quad (2.10)$$

em que x_k é a posição atual, x_{k+1} é a próxima posição a ser testada na função objetivo, α é um escalar positivo que representa o comprimento do passo que conduz ao próximo ponto da sequência, d_k é a direção de busca e k é o índice que identifica a iteração corrente.

A obtenção das direções de busca envolve o cálculo de derivadas ou suas respectivas aproximações que podem ser realizadas numericamente por diferenças finitas. A diferença entre os métodos de direção de busca encontra-se na estratégia adotada para a determinação do vetor d_k , sendo considerados de ordem zero aqueles que não utilizam informações das derivadas, de ordem um aqueles cujas informações dos vetores gradientes são utilizadas e de ordem dois aqueles que utilizam as informações das matrizes hessianas.

Quando a direção de minimização está disponível, é preciso definir o tamanho do passo α para determinar-se o ajuste de parâmetros naquela direção. A definição de um escalar α que conduza a uma redução satisfatória de f pode custar muito em termos de tempo. Conhecida a

direção de busca, a escolha do passo ideal para avaliar o próximo ponto da sequência conduz à solução do problema unidimensional definido pela Equação 2.11,

$$\alpha_k = \arg \min f(x_k + \alpha_k d_k), \text{ com } \alpha \geq 0. \quad (2.11)$$

Pelo procedimento, a função $f(x_k + \alpha_k d_k)$ é minimizada em um intervalo fechado e limitado, encontrando-se um valor ótimo para o passo a partir da redução contínua do intervalo de incerteza. A cada iteração, o intervalo de busca é reduzido por um fator, chamado de razão áurea, o que possibilita a redução do número de cálculos.

2.2.1 Método Gradiente

Dentre os métodos que utilizam direção de busca, o método Gradiente, também conhecido como método de direção de máxima descida, é o mais simples. É um método linear ao longo da direção oposta à do gradiente de f , que localmente representa a direção na qual a função decresce mais rapidamente. Por ele se elege uma direção de busca d_k e, ao longo desta direção, partindo-se de x_k busca-se x_{k+1} , de forma a obter o decréscimo de f . O método utiliza o Teorema de Taylor para o cálculo da função nos pontos da sequência $x_k + \alpha d_k$, como apresentado na Equação 2.12,

$$f(x_k + \alpha d_k) \approx f(x_k) + \alpha d_k^T \nabla f(x_k). \quad (2.12)$$

O coeficiente $d_k^T \nabla f(x_k)$ representa a razão com que a função muda ao longo da direção d_k . A direção unitária d_k de decréscimo mais rápido é obtida pela solução do problema apresentado na Equação 2.13,

$$\min_{d_k} d_k^T \nabla f(x_k), \text{ sujeito a } \|d_k\| = 1. \quad (2.13)$$

Como $d_k^T \nabla f(x_k) = \|d_k\| \|\nabla f(x_k)\| \cos \theta$, com θ representado pelo ângulo entre d_k e $\nabla f(x_k)$, a minimização ocorre se $\cos \theta = -1$, ou seja, se $d_k = -\frac{\nabla f(x_k)}{\|\nabla f(x_k)\|}$.

2.2.2 Método de Newton

No método de Newton a direção de busca é obtida pela aproximação de $f(x_k + \alpha d_k)$ por uma série de Taylor de 2ª ordem, dada pela Equação 2.14,

$$f(x_k + \alpha d_k) \approx f(x_k) + \alpha d_k^T \nabla f(x_k) + \frac{1}{2} \alpha^2 d_k^T \nabla^2 f(x_k) d_k := m_k(\alpha d_k). \quad (2.14)$$

Considerando-se que a matriz $\nabla^2 f(x_k)$ seja semidefinida positiva, a direção é obtida encontrando-se o vetor αd_k que minimiza $m_k(\alpha d_k)$. Assim, fazendo-se nula a derivada de $m_k(\alpha d_k)$, tem-se $0 = \frac{\partial m_k(\alpha d_k)}{\partial \alpha d_k} = \nabla f(x_k) + \nabla^2 f(x_k) d_k$.

Quando a diferença entre $f(x_k + \alpha d_k)$ e $m_k(\alpha d_k)$ não é significativa, a direção de busca e o cálculo da função nos pontos da sequência $x_k + \alpha d_k$ são dados, respectivamente, pelas Equações 2.15 e 2.16,

$$d_k = -[\nabla^2 f(x_k)]^{-1} \nabla f(x_k), \quad (2.15)$$

$$f(x_k + \alpha d_k) \approx f(x_k) - \alpha [\nabla^2 f(x_k)]^{-1} \nabla f(x_k). \quad (2.16)$$

O método de Newton pode ser considerado como um método local que utiliza informações de segunda ordem. Neste método, que é baseado na aproximação quadrática para a escolha da direção de busca, faz-se necessária a obtenção da hessiana da função objetivo e de sua inversa, o que além de acumular erros de arredondamento pode ter significativo custo computacional. O método não apresenta garantia de convergência, pois nada pode ser afirmado sobre o sinal da matriz hessiana, que deve ser semidefinida positiva para garantir que a aproximação quadrática tenha um mínimo. A cada iteração, a condição necessária para resolver as equações do método, envolve o cálculo da inversa da matriz hessiana, o que não necessariamente existe.

2.2.3 Métodos de Quasi-Newton

Os métodos de Quasi-Newton situam-se como métodos de direção de busca e geram uma aproximação da derivada segunda da função objetivo. Podem ser utilizados quando a matriz hessiana da função objetivo não se encontra disponível. Nestes métodos, procura-se estimar recursivamente o cálculo da inversa da hessiana da função objetivo presente no método de Newton, utilizando-se apenas informações do gradiente da função f . Como as segundas derivadas não são necessárias, em alguns casos, os métodos tornam-se mais eficientes que o método de Newton.

O primeiro método Quasi-Newton a utilizar a aproximação numérica para a inversa da matriz hessiana foi o método DFP (Davidson - Fletcher - Powell), o modelo foi modificado por

BFGS (Broyden - Fletcher - Goldafard - Shanno). Nesta pesquisa, utiliza-se o método conhecido como Família de Broyden representado pela conexão entre os métodos DFP e BFGS. Para a compreensão dos modelos, assim como no método de Newton, a direção de busca é obtida pela aproximação dada pela Equação 2.17,

$$m_k(\alpha d_k) = f(x_k) + (\nabla f(x_k))^T \alpha d_k + \frac{1}{2}(\alpha d_k)^T Q_k^H \alpha d_k, \quad (2.17)$$

em que Q_k^H representa uma aproximação da matriz hessiana, atualizada a cada passo, levando-se em consideração informações da curvatura do modelo m_k .

O minimizador d_k deste modelo quadrático é dado pela Equação 2.18,

$$d_k = -(Q_k^H)^{-1} \nabla f(x_k), \quad (2.18)$$

em que $(Q_k^H)^{-1}$ fornece uma aproximação para a inversa da matriz hessiana. O próximo ponto da sequência que aproxima o mínimo da função é dado por $x_{k+1} \approx x_k + \alpha d_k$.

O processo é semelhante ao utilizado no método de Newton, diferenciando-se por utilizar a aproximação Q_k^H em substituição da verdadeira hessiana $\nabla^2 f(x_k)$. Supondo-se que a aproximação x_{k+1} tenha sido obtida, o novo modelo quadrático é definido pela Equação 2.19,

$$m_{k+1}(d_k) = f(x_{k+1}) + (\nabla f(x_{k+1}))^T d_k + \frac{1}{2}(d_k)^T Q_{k+1}^H d_k. \quad (2.19)$$

Nas duas últimas iterações, x_k e x_{k+1} , assumindo-se que o gradiente do novo modelo coincida com o gradiente da função objetivo, ou seja, $\nabla m_{k+1} = \nabla f(x_{k+1})$ e $\nabla m_{k+1} = \nabla f(x_k)$, chega-se à Equação 2.20,

$$Q_{k+1}^H(x_{k+1} - x_k) = \nabla f(x_{k+1}) - \nabla f(x_k), \quad (2.20)$$

conhecida como Equação da Secante. Dado o deslocamento $(x_{k+1} - x_k)$ e a variação do gradiente $(\nabla f(x_{k+1}) - \nabla f(x_k))$, essa equação requer a aplicação da matriz simétrica positiva definida Q_{k+1}^H na variação do deslocamento e, consequentemente, satisfazendo-se a condição expressa na Equação 2.21,

$$(x_{k+1} - x_k)^T (\nabla f(x_{k+1}) - \nabla f(x_k)) > 0, \quad (2.21)$$

que tem solução única dada no método DFP pela Equação 2.22,

$$Q_{k+1}^H = (I - \rho_k r^k (v^k)^T) Q_k^H (I - \rho_k v^k (r^k)^T) + \rho_k r^k (r^k)^T, \quad (2.22)$$

em que $r^k = \nabla f(x_{k+1}) - \nabla f(x_k)$, $v^k = x_{k+1} - x_k$ e $\rho_k = \frac{1}{(r^k)^T v^k}$.

No método BFGS, a aproximação da inversa da hessiana, G_k^H , deve ser simétrica positiva definida e a Equação da Secante é dada pela Equação 2.23,

$$G_{k+1}^H (\nabla f(x_{k+1}) - \nabla f(x_k)) = x_{k+1} - x_k. \quad (2.23)$$

A solução do problema é dada pela Equação 2.24,

$$G_{k+1}^H = (I - \rho_k v^k (r^k)^T) G_k (I - \rho_k r^k (v^k)^T) + \rho_k v^k (v^k)^T \quad (2.24)$$

Para aproximação da hessiana da função objetivo utilizou-se nesta dissertação, como descrito por Luenberger (2008), a combinação dos métodos DFP e BFGS, conforme indicado nas Equações 2.25 a 2.28:

$$DFP = \frac{v * v'}{v' * r} - \frac{H * r * r' * H}{r' * H * r}, \quad (2.25)$$

$$BFGS = \left(\frac{r' * v + r' * H * r}{r' * v} \right) * \left(\frac{v * v'}{v' * r} \right) - \frac{(v * r' * H + H * r * v')}{(r' * v)}, \quad (2.26)$$

$$Cbroyden = \gamma * DFP + (1 - \gamma) * BFGS, \quad (2.27)$$

$$H = H + Cbroyden. \quad (2.28)$$

Nessas equações, o coeficiente γ relaciona-se com o peso utilizado para os métodos *DFP* e *BFGS*, *Cbroyden* a relação estabelecida entre os métodos e *H* a aproximação para a hessiana da função objetivo. Pelo Algoritmo 1 é possível acompanhar as etapas do método utilizado.

Na execução do método, a partir de uma função não linear f , do ponto inicial de minimização x e do peso γ obtém-se a aproximação numérica para um mínimo local de f . Durante o processo, iterativamente, calcula-se o gradiente da função no ponto x , resolve-se o problema de otimização unidimensional α_k , o próximo ponto da sequência é calculado e a hessiana da função f é aproximada numericamente pelos métodos apresentados nas Equações 2.25 a 2.28.

Algoritmo 1: QUASI-NEWTON(γ, x)

```
1 início
2    $n \leftarrow |x|$ 
3    $H \leftarrow I_n$ 
4    $g \leftarrow \text{gradiente}(x)'$ 
5    $x_{ant} \leftarrow x$ 
6    $g_{ant} \leftarrow g$ 
7   enquanto (critério de parada não atendido) faça
8      $d \leftarrow (-Hg)'$ 
9      $\alpha \leftarrow \text{unidimensional}(x, d)$ 
10     $x \leftarrow x_{ant} + \alpha d$ 
11     $g \leftarrow \text{gradiente}(x)'$ 
12     $v \leftarrow (x - x_{ant})'$ 
13     $r \leftarrow g - g_{ant}$ 
14     $DFP \leftarrow \frac{v v'}{v' r} - \frac{H r r' H}{r' H r}$ 
15     $BFGS \leftarrow \left(1 + \frac{r' H r}{r' v}\right) \frac{v v'}{v' r} - \frac{v r' H + H r v'}{r' v}$ 
16     $C \leftarrow (1 - \gamma) DFP + \gamma BFGS$ 
17     $H \leftarrow H + C$ 
18     $x_{ant} \leftarrow x$ 
19     $g_{ant} \leftarrow g$ 
20  fim
21  retorne  $x$ 
22 fim
```

Há que se destacar que os métodos de Quasi-Newton possuem velocidade de convergência maior do que o método Gradiente, porém menor que a do Método de Newton. Além disso, os métodos Gradiente e de Quasi-Newton requerem que a função seja de classe C^1 , já o Método de Newton só pode ser aplicado em funções de classe C^2 . Esses métodos, quando aplicados em funções convexas, convergem para o mínimo local, que também representa, para este caso, o mínimo global. Caso a função não seja convexa, não se pode afirmar que o mínimo local também seja o mínimo global. Se a função objetivo é multimodal, ter-se-ão várias bacias de atração. O problema de determinação de mínimos globais, mesmo dentro de um conjunto de mínimos locais bem definidos, será difícil devido à impossibilidade de reconhecer-se um mínimo global utilizando-se apenas informações locais. Em caso de função unimodal, a escolha de um ponto distante do ponto ótimo fará com que a convergência seja mais demorada, pelo fato de ter-se uma única bacia de atração. Contudo, nesse caso, não haverá o risco do método ficar mudando de bacia de atração.

2.3 Métodos de Exclusão de Regiões

Os métodos de exclusão de regiões são métodos determinísticos aplicáveis para funções quasi-convexas, unimodais, diferenciáveis, ou não diferenciáveis. Consistem em criar um

plano que divide o espaço em dois semiespaços, um deles contendo a solução mínima do problema de ONL. Os métodos mais conhecidos desse grupo são o Plano de Corte e Elipsoidal. Nesta dissertação é aplicado o método elipsoidal.

2.3.1 Método Elipsoidal

Pelo Método elipsoidal encontra-se um ponto em um conjunto convexo com interior não vazio, em um número finito de passos. A ideia intuitiva do algoritmo consiste em cercar o ponto procurado com elipsoides. Segundo Bland et al. (1981), mediante a exclusão de semi-espaços e averiguação dos subgradientes da função objetivo, o algoritmo constrói iterativamente uma sequência de elipsoides. A partir de um elipsoide inicial, que contenha o ponto a ser alcançado são feitos cortes gerando sempre elipsoides de volumes decrescentes por uma razão fixa, que depende apenas da dimensão do espaço. Após um número finito de iterações é obtido o elipsoide de menor volume sobre o ponto procurado, dado pelo centro deste elipsoide.

Algebricamente, como apresentado na Equação 2.29, o elipsoide E_k pode ser caracterizado por seu centro x_k e sua matriz característica Q_k simétrica definida positiva,

$$E_k = \{(x - x_k)^T Q_k^{-1} (x - x_k) \leq 1\}. \quad (2.29)$$

O algoritmo, aplicado à ONL, é obtido pela utilização iterativa de um operador linear de dilatação espacial, cuja principal propriedade é a de transformar esferas em elipsoides, podendo ser geometricamente descrito da seguinte forma:

Considere o problema de minimizar uma função objetivo não linear convexa $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$ sobre todos os vetores $x \in \mathbb{R}^n$. Suponha que x^* seja um mínimo de f e que exista $\mathcal{R}$ tal que $x^* \in \|x - x_1\| \leq \mathcal{R}$ para algum $x_1 \in \mathbb{R}^n$. Considere uma bola de centro x_1 e raio $\mathcal{R}_1$, $S_1 = \{x; \|x - x_1\| \leq \mathcal{R}_1\}$ e seja $m(x_1)$ o subgradiente de f no ponto x_1 . Inicialmente teste o subgradiente da função para o centro da bola S_1 . Se $m(x_1) = 0$, então x_1 é um mínimo de f . Caso contrário, constrói-se um hiperplano que secciona a bola inicial em duas partes, uma das quais contém x^* , o hiperplano formado é tal que $m(x - x_1) = 0$. Em seguida, por intermédio de um operador de dilatação espacial apropriado, constrói-se um elipsoide $\bar{S}$ que envolva a parte onde se encontra o mínimo da função, ou seja, $x^* \in \bar{S} \equiv S_1 \cap \{m_1 \cdot (x - x_1) \leq 0\}$. O procedimento conduz a um novo elipsoide de centro $x_2 = x_1 - t_2 d_1$,

no qual $d_1 = \frac{m_1}{\|m_1\|}$. Esse novo elipsoide e seu centro são indicados respectivamente por E_{k+1} e x_{k+1} . Dilata-se o espaço na direção d_1 e, com isso, o novo elipsoide é transformado numa bola de raio $\mathcal{R}_2$ e centro y_2 , $S_2 = \{y; \|y - y_2\| \leq \mathcal{R}_2\}$. Desta forma, retorna-se à situação inicial, onde se deseja determinar se um ponto pertencente a um conjunto convexo contido numa bola de centro e raio conhecidos. Em seguida, aplica-se o algoritmo no novo espaço e repetem-se os procedimentos, sucessivamente, até o critério de parada ser alcançado.

O algoritmo Elipsoidal é descrito pelas fórmulas recursivas que geram uma sequência de pontos x_k , expressas pelas Equações 2.30, 2.31 e 2.32:

$$x_{k+1} = x_k - \beta_1 \frac{Q_k m_k}{(m_k^T Q_k m_k)^{1/2}}, \quad (2.30)$$

$$Q_{k+1} = \beta_2 \left(Q_k - \frac{\beta_3 (Q_k m_k)(Q_k m_k)^T}{m_k^T Q_k m_k} \right), \quad (2.31)$$

$$\beta_1 = \frac{1}{n+1}, \quad \beta_2 = \frac{n^2}{n^2-1}, \quad \beta_3 = \frac{2}{n+1} \quad (2.32)$$

Onde x_k representa o centro de cada elipsoide gerado, n a dimensão do ponto inicial, Q_k representa a matriz da elipse que cerca, a cada iteração, o ponto ótimo a ser obtido e o vetor m_k é o subgradiente da função objetivo naquele ponto.

Se a matriz Q_k é um múltiplo da matriz identidade, então E_k é uma bola e, nesse sentido, como verificado por Bland et al. (1981) e apresentado na Figura 2.1, o elipsoide E_{k+1} é encolhido na direção a pelo fator $\sqrt{\beta_2(1-\beta_3)} = \frac{n}{(n+1)}$ e expandido em todas as direções ortogonais pelo fator $\sqrt{\beta_2} = \frac{n}{\sqrt{n^2-1}}$.

No decorrer da execução do algoritmo, é intuitivo que um elipsoide menor, E_{k+1} , possa ser utilizado, já que é necessário apenas que o novo elipsoide contenha a seção de E_k . Também é possível construir outra bola E_{k+1} de menor volume que E_k .




Figura 2.1: Representação geométrica do Método Elipsoidal.

Fonte: Adaptado de Bland et al. (1981).

Pelo Algoritmo 2 é possível acompanhar as etapas do método Elipsoidal, que ocorre iterativamente até que a condição de parada estabelecida seja alcançada. Para iniciá-lo considera-se o ponto inicial $x_0 \in \mathbb{R}^n$, Q_0 uma matriz não singular, por exemplo, a matriz identidade e toma-se $k = 1$. Na k -ésima iteração, obtém-se $m_k \in df(x_k)$ e define-se o próximo ponto sobre f , ou seja, $x_{k+1} = x_k - \beta_1 \frac{Q_k m_k}{(m_k^T Q_k m_k)^{1/2}}$. Para a atualização da matriz, considera-se que $Q_{k+1} = \beta_2 \left(Q_k - \frac{\beta_3 (Q_k m_k)(Q_k m_k)^T}{m_k^T Q_k m_k} \right)$.

Algoritmo 2: ELIPSOIDAL(x, Q)

```

1 início
2    $n \leftarrow |x|$ 
3    $\beta_1 = \frac{1}{n+1}$ 
4    $\beta_2 = \frac{n^2}{n^2-1}$ 
5    $\beta_3 = \frac{2}{n+1}$ 
6   enquanto (critério de parada não atendido) faça
7      $m \leftarrow \text{subgradiente}(f(\cdot), x)$ 
8      $x \leftarrow x - \beta_1 \frac{Qm}{\sqrt{m^T Qm}}$ 
9      $Q \leftarrow \beta_2 \left( Q - \beta_3 \frac{(Qm)(Qm)^T}{m^T Qm} \right)$ 
10  fim
11  retorne  $x$ 
12 fim
```

2.4 Métodos Populacionais

Os métodos populacionais são métodos computacionais inspirados na evolução natural das espécies. O formato básico destes métodos consiste em criar uma população que é um conjunto de pontos (indivíduos) pertencentes ao espaço de parâmetros, uma função para avaliação da função objetivo nesses pontos e outra função que determina a transição entre uma população atual e a futura. A evolução da população ao longo das iterações conduz o conjunto de indivíduos para uma região próxima do ponto ótimo.

Entre os métodos populacionais, destacam-se os Algoritmos Genéticos (AG), conceito introduzido por Holland (1975) ao explicar como aplicar processos evolutivos a sistemas artificiais. Para o autor, qualquer problema de otimização pode ser modelado em termos genéticos considerando-se que o indivíduo é uma solução do problema, a população é um conjunto de soluções do problema, o cromossomo é a representação de uma solução e o gene é um trecho da representação de uma solução. De acordo com Goldberg (1989), um AG é um método de busca populacional inspirado em processos naturais de evolução, onde os indivíduos mais aptos possuem maior probabilidade de sobrevivência. Para a utilização do método, conforme Takahashi e Martins (2004), não são necessários o conhecimento prévio de soluções iniciais, o cálculo de gradientes ou de subgradientes. No sentido apresentado por esses autores, as características genéricas do método e as possibilidades de sua adaptação em diferentes situações-problema contribuíram com a crescente importância atribuída ao método enquanto mecanismo de otimização. Os autores destacam também que o método fornece soluções de boa qualidade e em tempos computacionais aceitáveis, sendo de fácil implementação computacional.

A solução de um problema de minimização de uma função não linear $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$, através da utilização do AG básico, inicia-se com a geração aleatória de um conjunto de indivíduos que compõem a população inicial em estudo, ou seja, um conjunto de pontos que representam as possíveis soluções para determinado problema. Durante o processo são aplicados os operadores genéticos de cruzamento e mutação, seguidos dos processos de avaliação e seleção para geração da população sobrevivente, como descrito por Cunha et al. (2013):

- *Cruzamento*: operador que efetua a troca de material genético entre dois progenitores, conduzindo à criação de dois novos indivíduos.

- *Mutação*: operador unitário que “perturba” um indivíduo, alterando ligeiramente algumas de suas características, com o objetivo de manter um nível de diversidade adequado na população.
- *Avaliação*: Função que atribui a cada indivíduo da população gerada um valor denominado fitness ou adequabilidade, de acordo com sua adaptabilidade ao ambiente. Quanto melhor o fitness de um indivíduo, maior a chance dele permanecer na população sobrevivente. Nessa dissertação, o objetivo a ser alcançado é representado pela minimização da função objetivo, sendo que o melhor fitness é representado pelo menor valor da função objetivo.
- *Seleção*: Processo que identifica quais indivíduos permanecerão na população sobrevivente, a partir de um critério de escolha aplicado à população corrente. Nesta etapa é atribuída maior probabilidade aos indivíduos com melhor função-objetivo.

Conforme descritas no Algoritmo 3, a cada iteração, essas etapas são sequencialmente aplicadas até a convergência para um ponto considerado ótimo e o processo é finalizado segundo um critério de parada estabelecido.

Algoritmo 3: AG(x)

```

1 início
2    $\mathcal{P} \leftarrow$  Gerar população inicial()
3   Avaliação( $\mathcal{P}$ )
4   enquanto (critério de parada não atendido) faça
5      $\mathcal{P}' \leftarrow$  Seleção( $\mathcal{P}$ )
6      $\mathcal{P}'' \leftarrow$  Cruzamento( $\mathcal{P}'$ )
7      $\mathcal{P}'' \leftarrow$  Mutação( $\mathcal{P}''$ )
8     Avaliação( $\mathcal{P}''$ )
9      $\mathcal{P} \leftarrow$  População Sobrevivente( $\mathcal{P} \cup \mathcal{P}''$ )
10    Atualiza ( $x$ ,  $\mathcal{P}$ )
11  fim
12  retorne  $x$ 
13 fim
```

Para aumentar a eficiência dos AGs podem ser utilizados outros operadores genéticos adicionais. Alguns desses, de acordo com Takahashi e Martins (2004), possuem aplicabilidade genérica e ao serem incorporados ao método não restringem a aplicabilidade do AG básico. A experiência de seu uso ao longo dos anos tem mostrado que eles tendem a melhorar as propriedades de convergência do algoritmo. Entre estes está o *Elitismo*, que promove a seleção determinística de parte da população corrente, usualmente os melhores indivíduos, para integrarem a nova população.

Algumas características distinguem os AGs das técnicas de ONL por direção de busca e por exclusão de regiões. Para Goldberg (1989), os AGs pesquisam soluções ótimas a partir de um conjunto de soluções e não a partir de uma única, possuindo várias estimativas da solução ao mesmo tempo, que podem ser utilizadas para fazer a transição do estado corrente para o próximo estado do espaço de soluções e, para a convergência, não utilizam informações do gradiente ou do subgradiente da função objetivo.

Considerando-se as características dos AGs, entre elas as anteriormente apresentadas, pondera-se que estes métodos são indicados para o tratamento de funções e restrições de difícil modelagem e classificação matemática, não garantindo a obtenção da otimalidade local. Em comparação com outros métodos de otimização, segundo Takahashi e Martins (2004), geralmente os algoritmos genéticos apresentam um desempenho inferior. Quando o processo de otimização encontra-se no estágio em que já se possuem boas aproximações do ponto de ótimo, é necessário o refinamento das aproximações, até a determinação de uma solução com erro suficientemente pequeno.

Conforme a representação das variáveis, o processo de cruzamento pode ser binário, real ou real polarizado. No primeiro caso, a partir de um ou mais pontos escolhidos aleatoriamente, troca-se os segmentos entre os indivíduos (pais), e são gerados novos indivíduos (filhos). Na segunda situação, une-se dois pontos (indivíduos) formando um segmento de reta e, no terceiro caso, o *cruzamento real-polarizado* proposto por Takahashi et al. (2003), um indivíduo (filho) é gerado sem polarização e o outro com polarização. Para o último caso, levando-se em consideração a diferença existente entre os valores da função objetivo dos pais, ocorre maior chance do filho “nascer” mais próximo do pai com melhor valor de função objetivo. Este caso é utilizado nessa pesquisa, estando detalhado na sequência do texto.

2.4.1 Algoritmo Genético Real Polarizado

O AGRP descrito por Takahashi et al. (2003) adota codificação real dos parâmetros de otimização e possui a operação de cruzamento polarizado. Esquemáticamente representado no Algoritmo 3, o método inicia-se com a geração aleatória de uma população e posterior avaliação dos seus indivíduos. Na sequência realizam-se o cruzamento, a mutação, a avaliação, o cálculo da função de ajuste (*fitness function*), a seleção e a elitização. Ao final, uma nova população com o mesmo tamanho da anterior é gerada e o algoritmo é finalizado quando é atingido algum critério de parada.

No processo de cruzamento, a população é dividida em duas partes para a formação de pares. A probabilidade de ocorrência de cruzamento para cada par formado é de 50% e, caso seja efetivada, dois novos indivíduos são gerados conforme a lei expressa na Equação 2.33, onde x_g é o novo indivíduo gerado e x_1 e x_2 os indivíduos ancestrais,

$$x_g = \alpha x_1 + (1 - \alpha)x_2 \text{ com } -0,1 < \alpha < 1,1. \quad (2.33)$$

Para determinar o valor de α , deve-se observar se o cruzamento é polarizado ou não, sendo 30% a probabilidade de processo ocorrer de forma polarizada. Se o cruzamento não for polarizado, adota-se α com distribuição uniforme de probabilidade dentro do intervalo de valores possíveis para os novos indivíduos gerados. Caso o cruzamento seja polarizado então, para um dos novos indivíduos, escolhe-se $\alpha = 1,4\beta_1\beta_2 - 0,2$. Nesta situação, β_1 e β_2 são escolhidos de maneira aleatória e independente, mas com distribuição uniforme de probabilidade, dentro do intervalo $[0, 1]$. Já o outro indivíduo sempre é escolhido sem polarização.

Conforme a Equação 2.33, os novos indivíduos são gerados dentro do segmento de reta que contém os pontos x_1 e x_2 , podendo ultrapassá-los em até 0,1. Caso uma solução se localize fora do espaço de busca, ela é refletida para dentro da região admissível de valores, operação conhecida como reflexão. Em seguida, são realizados procedimentos de:

- Muta    : gera indiv  duos ao redor de um j   existente, a probabilidade de isso ocorrer    de 2%;
- Avalia    : analisa a fun     objetivo de cada indiv  duo;
- Fun     de ajuste: acerta a fun     objetivo de cada indiv  duo;
- Sele     de uma nova popula    : considera todos os indiv  duos existentes, podendo cada um deles ser escolhido mais de uma vez. Essa escolha    realizada de forma aleat  ria por  m, a probabilidade de obter uma popula     que contenha pontos de m  nimo da fun        maior do que a probabilidade de cria     das demais;
- Elitiza    : introduz o melhor indiv  duo na popula    , caso esse n  o tenha sido escolhido, com a exclus     de um elemento qualquer escolhido anteriormente.

Capítulo 3

Redes Neurais Artificiais

Neste capítulo são apresentados conceitos relacionados com as Redes Neurais Artificiais. Além da definição, são apresentados tópicos referentes à arquitetura, funcionamento básico, aprendizagem e treinamento, detalhando-se a rede *Multilayer Perceptron* (MLP) com aprendizado supervisionado *Backpropagation* (BP) e Algoritmo de Treinamento Levenberg-Marquardt (LM).

3.1 Redes Neurais Artificiais

Redes Neurais Artificiais são sistemas computacionais inspirados na estrutura neural de organismos vivos. Conforme Braga et al. (2007), são capazes de aprender os padrões existentes em um conjunto de dados, generalizando-os, classificando-os, interpolando-os ou extrapolando-os. Por não necessitarem da utilização de modelos complexos para solucionar determinado problema, oferecem possibilidades de estimativas robustas com aplicações envolvendo diferentes áreas de conhecimento, onde se abordam a solução de problemas de classificação, categorização de dados, aproximação, previsão e controle não linear quando modelos fenomenológicos não estão disponíveis.

A capacidade de reconhecer e reproduzir relações de causa e efeito, bem como a possibilidade de trabalhar com múltiplos vetores de entrada e de saída, possibilita sua utilização na modelagem de processos complexos, destacando-se na aproximação de funções não lineares em espaços multidimensionais. No campo da engenharia elétrica, a literatura tem reportado várias aplicações, descrevendo o uso de RNAs em detecção de faltas, processamento de sinais, entre outras.

3.2 Arquitetura de Redes Neurais Artificiais

O projeto de uma RNA deve ser estruturado de acordo com o problema a ser resolvido. Segundo Haykin (2001) é necessário definir a quantidade de neurônios das camadas de entrada, ocultas e de saída; treinar a rede, a partir de um conjunto de dados iniciais; validar a rede treinada a partir da avaliação de suas respostas mediante a apresentação de dados não

utilizados durante o treinamento. Nesse processo, a arquitetura da rede, também denominada de topologia, refere-se à organização dos neurônios e das camadas.

3.2.1 Número de Neurônios

Estruturalmente uma RNA é formada por neurônios artificiais, também chamados de nós, ordenados em camadas interligadas. Um neurônio artificial é um modelo matemático que compila em si habilidades funcionais de um neurônio biológico, a partir da representação artificial das faculdades cognitivas deste último. É comum na literatura referir aos neurônios artificiais como perceptron, nome dado ao primeiro modelo de neurônio artificial criado por Rosenblatt (1957). Na Figura 3.1, como proposto por Demuth e Beale (2015), são identificados alguns elementos básicos em um neurônio artificial.




Figura 3.1: Modelo de um neurônio artificial.

A determinação da quantidade adequada de neurônios é um dos desafios do processo de investigação. A quantidade inadequada de neurônios pode comprometer a capacidade de generalização e convergência da RNA, mas uma rede com grande número de neurônios, em relação à quantidade de dados disponíveis para treinamento, pode perder sua boa representação, tendo sua capacidade comprometida. Conforme Tetko et al. (1995), RNAs superdimensionadas geram uma boa representação apenas do conjunto de treinamento, ou seja, ela passa a ter sua capacidade de generalizar comprometida, situação conhecida como *overfitting* ou *overtraining*, caracterizados por erros muito baixos para os dados de treinamento, e elevados quando novos dados são validados.

Não há uma regra exclusiva que possibilita determinar o número de neurônios de cada camada. Para Lippmann (1987), havendo uma segunda camada oculta na rede neural, esta

deve ter o dobro de neurônios da camada de saída e no caso de uma rede neural com apenas uma camada, deverá ter $s(i + 1)$ neurônios, onde s é o número de neurônios de saída e i , o número de elementos do vetor de entrada. Alguns autores como Hecht-Nielsen (1989), afirmam que com apenas uma camada oculta é possível calcular uma função arbitrária qualquer a partir de dados fornecidos, e que a camada oculta deve ter por volta de $(2i + 1)$ neurônios, onde i é o número de elementos do vetor de entrada. Em seus estudos, Maier e Dandy (2001) reportam que o número máximo de neurônios na camada oculta deve ser o menor dos obtidos entre as equações anteriores. Registram ainda que, de uma forma geral, o uso de tentativas e erros é muito comum, sendo que em muitos casos se obtém bom desempenho da rede com número de neurônios muito menores que os limites indicados das equações anteriores. Para garantir que a rede não apresente o problema de sobreajuste, Rogers e Dowla (1994) apud Maier e Dandy (2001) sugerem que a relação entre o número j de dados para treinamento, o número i de elementos do vetor de entrada e a quantidade de neurônios utilizados deve ser considerada, recomendando-se que o limite máximo de neurônios n na camada oculta seja dado pela razão $n = \frac{j}{(i+1)}$. Thomas et al. (2015) publicaram alternativas e métodos, citando desde regras gerais como “o número de neurônios na camada oculta é um valor entre o número de neurônios de entrada e de saída” até equações sofisticadas de aplicação. Uma prática comum, adotada por pesquisadores, é determinar o número de neurônios e de camadas ocultas de forma experimental. O processo, adotado neste trabalho, consiste em começar com números menores de neurônios por camada e ir aumentando até que a rede neural apresente bons resultados.

3.2.2 Número de Camadas

Em uma RNA, o número de unidades de entrada e saída está associada às variáveis do problema a ser resolvido. O número de camadas ocultas depende da complexidade das relações a serem estabelecidas entre as entradas e as saídas. Para Feng et al. (2005) e Braga et al. (2007), a maioria dos problemas necessita de apenas uma camada oculta. A camada de entrada da rede não é contabilizada no número de camadas da RNA, a função de seus neurônios é distribuir cada uma das entradas da rede, sem modificá-las, a todos os neurônios da camada seguinte. Existem basicamente três possibilidades de topologia que variam entre si em função do número de camadas e da forma de interação entre os neurônios: redes alimentadas adiante (*Feedforward*) de uma única camada, redes alimentadas adiante de múltiplas camadas (*Multilayer Feedforward Networks*) e redes recorrentes (*Feedback*). Na

Figura 3.2 apresenta-se uma rede neural com uma única camada, com **R** elementos no vetor de entrada **P** e com uma quantidade **S** de neurônios na camada oculta.




Figura 3.2: Rede Neural com uma camada.
Fonte: Demuth e Beale (2015).

As RNAs alimentadas adiante de múltiplas camadas diferem-se da anteriormente descrita pela presença de uma ou mais camadas intermediárias. Na Figura 3.3 está representada uma rede neural com múltiplas camadas de neurônios. Esse tipo de rede é uma expansão da rede neural com camada única, onde cada camada tem uma matriz de peso **W**, um vetor bias **b** e um vetor de saída **a**. Nota-se que as saídas de cada camada intermediária são as entradas para a camada seguinte. Essa rede neural possui **R¹** entradas, **S¹** neurônios na primeira camada, o número sobrescrito refere-se à camada de referência. Assim, observa-se a ocorrência de **S²** neurônios na segunda camada e **S³** neurônios na terceira camada. É comum que as camadas possuam diferentes números de neurônios.




Figura 3.3: Rede Neural de múltiplas camadas.
Fonte: Demuth e Beale (2015).

As diferentes camadas são designadas como de saída (camada 3) e ocultas (camadas 1 e 2) e a estrutura da rede pode ser referida como $\mathbf{R-S^1-S^2-S^3}$. De forma geral, RNAs com configurações simples, por exemplo, com duas camadas, onde a primeira camada possui função de ativação sigmoide e a segunda camada possui função de ativação linear, pode ser treinada e proporcionar boa aproximação para qualquer função. Em outra arquitetura de RNA, as redes recorrentes, descrita por Braga et al. (2007), os sinais de saída dependem não somente dos sinais de entrada, mas também do seu valor atual. Pode ser formada, por exemplo, por uma camada de neurônios, com cada um alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios.

Um detalhe relevante ao se definir a topologia da RNA relaciona-se com as conexões estabelecidas entre os neurônios. Uma rede é dita totalmente conectada quando cada um dos nós de uma camada da rede está conectado a todos os nós da camada adjacente seguinte. Entretanto, se algumas conexões sinápticas estiverem faltando na rede, pode-se dizer que está parcialmente conectada. Para modelagem de processos não lineares, entre as diferentes topologias possíveis para a implementação de uma RNA, segundo Haykin (2001), geralmente utiliza-se a rede neural *Feedforward* com ativação sigmoideal, caracterizada por guiar as informações, exclusivamente, a partir de cada neurônio de uma camada para todos os neurônios da camada seguinte, desde os nós da entrada até os da saída.

A rede neural com múltiplas camadas apresentada na Figura 3.3, também conhecida como *Multilayer Perceptron*, conforme Hornik et al. (1989), é a arquitetura de rede mais comum e discutida amplamente na maioria dos livros. As saídas de seus neurônios, em qualquer camada, são conectadas unicamente às entradas dos neurônios da camada seguinte, sem presença de laços de realimentação. Nesse trabalho, a rede MLP foi escolhida por ter capacidade de resolver problemas de reconhecimento de padrões (Classificação de falta), problemas do tipo em que se deseja estimar valores (determinar locais de falta e resistências de falta) e por ser amplamente contemplada pelo *software* MatLab.

3.3 Funcionamento Básico de uma RNA

Após a organização de sua arquitetura, a partir de dados e algoritmos de treinamento representativos, a RNA é capaz de aprender a estrutura dos dados, podendo ser aplicada em situações onde ocorra uma relação entre as entradas e as variáveis previstas. Na Figura 3.3, as sinapses introduzem os valores das variáveis de entrada, compondo um vetor de P entradas

com R elementos, que correspondem às conexões sinápticas ocorridas no neurônio biológico dado por $P_1, P_2, P_3, \dots P_R$. No início do processo de funcionamento, cada entrada P_R é multiplicada por um peso sináptico $W_{1,R}$ representado por $W_{1,1}, W_{1,2}, W_{1,3}, \dots W_{1,R}$. Os valores ponderados, com representação simplificada por WP , são somados e ao resultado adiciona-se o sinal denominado bias b , para formar o argumento n , representado pela Equação 3.1.

$$n = W_{1,1}P_1 + W_{1,2}P_2 + W_{1,3}P_3 + \dots + W_{1,R}P_R + b. \quad (3.1)$$

Matricialmente, o argumento n_s , de cada neurônio, é representado pela Equação 3.2

$$\begin{bmatrix} n_1 \\ n_2 \\ \vdots \\ n_s \end{bmatrix} = \begin{bmatrix} w_{1,1} & w_{1,2} & w_{1,R} \\ w_{2,1} & w_{2,2} & w_{2,R} \\ \vdots & \vdots & \vdots \\ w_{s,1} & w_{s,2} & w_{s,R} \end{bmatrix} \cdot \begin{bmatrix} P_1 \\ P_2 \\ \vdots \\ P_R \end{bmatrix} + \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_s \end{bmatrix}. \quad (3.2)$$

Os índices de linha dos elementos da matriz W indicam o neurônio de destino do peso e os índices de coluna indicam à qual elemento R do vetor de entrada P está relacionado à origem do peso. Finalmente, as saídas de todos os neurônios formam um vetor coluna a , dado pela Equação 3.3

$$a = f(n) = f(wp + b). \quad (3.3)$$

A utilização do bias visa evitar o surgimento de erros quando os dados de entrada são nulos. O termo age de forma a transladar a função de ativação em torno da origem. A função de ativação $f(n)$ é utilizada para restringir a amplitude do valor de saída do neurônio, indicando o que deve se feito com o valor resultante do somatório das entradas ponderadas, modelando a forma como o neurônio responde ao vetor de entrada e definindo a saída da rede neural. Conforme Haykin (2001) existem diferentes tipos de funções de ativação, como degrau, linear, rampa, sigmoide e tangente hiperbólica. As funções de ativação linear, sigmoide e tangente hiperbólica, apresentadas na Figura 3.4, estão entre as mais utilizadas.




Figura 3.4: Funções de ativação.

A função de ativação linear é utilizada nas situações em que se deseja que o neurônio retorne um valor aproximado. Já a função de ativação sigmoide limita a resposta do neurônio entre os valores 0 e 1. Alternativamente pode ser usada função de ativação tangente hiperbólica, que gera resposta entre os valores -1 e 1. Essas duas últimas funções são frequentemente utilizadas em problemas de reconhecimento de padrões.

3.4 Métodos de Aprendizagem

As RNAs possuem, como característica relevante, a capacidade de aprender a partir de exemplos e melhorar gradualmente o desempenho de sua classificação. Seu aprendizado consiste em um processo iterativo de ajuste de parâmetros, podendo ocorrer, conforme Menezes (2008), de forma supervisionada ou não supervisionada. No aprendizado não supervisionado o conjunto de padrões de alvos desejados não é conhecido, utilizam-se apenas padrões de entrada para o treinamento. O ajuste dos pesos entre as camadas de neurônios deve ocorrer de acordo com regularidades estatísticas dos dados de entrada, sem possibilidade de se confrontar os resultados gerados.

Para o aprendizado supervisionado, na fase de treinamento, um conjunto de padrões contendo os elementos do vetor de entrada e outro conjunto de padrões com os elementos do vetor de saída desejada (d_R) são apresentados à rede. A cada iteração ocorre a conferência entre a saída desejada e a saída obtida pela rede, gerando-se um erro que é retornado ao sistema de aprendizagem e, através da adaptação dos pesos entre os neurônios, procura-se uma menor diferença entre a resposta obtida e a resposta desejada. Esse tipo de aprendizado é usado para resolução de problemas de previsão e aproximação de funções. Aplicando-se os cálculos com os pesos iniciais, a saída obtida para o padrão de entrada P_R é dada por y_R e o erro e_R da rede pode ser determinado pela Equação 3.4

$$e_{R(sx1)} = d_R - y_R. \quad (3.4)$$

Devido à capacidade de aprendizado, a RNA modifica seus pesos até uma condição que permita, pela comparação entre os valores, que o resultado desejado seja alcançado. Nesse processo a rede adquire conhecimento através da alteração dos valores dos pesos sinápticos entre os neurônios. O aprendizado ocorre a uma taxa de aprendizagem α , considerado como uma busca de otimização a partir do ajuste dos pesos e do vetor bias para minimizar alguma medida de erro no conjunto de treinamento, sendo indicado pelas Equações 3.5 e 3.6

$$W_{(S \times R)} \leftarrow W_{(S \times R)} + \alpha e_R P_R, \quad (3.5)$$

$$b_{(S \times 1)} \leftarrow b_{(S \times 1)} + \alpha e_R. \quad (3.6)$$

Com o uso da Regra Delta elabora-se um treinamento supervisionado, que equivale a um algoritmo para modificar os pesos sinápticos da rede de forma iterativa, visando que esta retorne um padrão inicialmente estabelecido. A generalização desse algoritmo para redes MLP, conforme Demuth e Beale (2015), é conhecida como regra delta generalizada ou *Backpropagation*. Consiste na aplicação do gradiente descendente que minimiza a função erro a partir da determinação de um mínimo global, através de incrementos dos valores dos pesos por uma quantidade proporcional à primeira derivada do erro entre o valor desejado e o valor calculado pela rede. A arquitetura da rede MLP com algoritmo de aprendizagem supervisionado *Backpropagation* é apresentada na Figura 3.5.




Figura 3.5: Rede MLP com aprendizagem supervisionada *Backpropagation*.
Fonte: Menezes (2008).

Nesse algoritmo, os pesos $\mathbf{W}$ são inicializados de forma aleatória. Em seguida, um padrão de entrada $\mathbf{P}$ é aplicado aos neurônios da primeira camada da rede que é propagado adiante por cada uma das outras camadas intermediárias até que seja gerado o vetor de saída $\mathbf{a}$. Então o vetor de saída $\mathbf{a}$ é comparado com o conjunto de padrão de saída desejado $\mathbf{d}$, gerando um sinal de erro para cada elemento do vetor de saída. O sinal de erro é propagado para trás, da camada de saída em direção à camada de entrada, ajustando os pesos $\mathbf{W}$, para que o erro seja mínimo entre as saídas desejadas $\mathbf{d}$ e o vetor de saída obtido $\mathbf{a}$.

3.5 Métodos de Treinamento

As RNAs possuem a capacidade de aprender através de exemplos e fazer interpolações e extrapolações do que aprenderam. Sua utilização depende da existência de relação entre as entradas e saídas propostas. A quantidade e a qualidade dos conjuntos de treinamento são essenciais para as simulações da rede. Antes de passar pelo algoritmo de treinamento, o banco de dados que compõe o problema é dividido em três conjuntos disjuntos para treinamento, validação e teste. Os padrões do conjunto de validação não são usados para treinar a rede, possuem função específica de mensurar a capacidade de generalização da rede, servindo de referência para avaliar o comportamento do algoritmo quando submetido a dados incertos. Ao se treinar uma RNA, geralmente deseja-se obter uma rede com a melhor capacidade de generalização possível, ou seja, a maior capacidade de responder corretamente a dados que não foram utilizados no processo de treinamento. Durante o treinamento ocorrem as funções de ajuste de pesos para a obtenção daqueles que conduzam à saída desejada. Após o treinamento da rede neural por um número predefinido de épocas, a rede é testada com os dados de validação.

Definida a topologia, prossegue-se com o algoritmo de treinamento da rede. Como comentado por Hagan et al. (1996), existem diferentes possibilidades de algoritmos de treinamentos, que podem ser baseadas nos métodos do Gradiente e Jacobiano entre eles o de Levenberg-Marquardt, GradientDescent, GradientDescentwith Momentum, Quasi-Newton. Neste trabalho foi adotado o algoritmo de treinamento Levenberg-Marquardt. O método é eficiente e rápido para as dimensões de rede utilizada, representando também uma técnica comumente utilizada em situações em que a função possui características não lineares, sendo também utilizado em problemas de interpolação, quando se dispõe de pontos e deseja-se encontrar uma função que a eles se ajuste. A solução para ajuste de pesos da rede é encontrada minimizando-se a soma dos quadrados dos erros de uma forma iterativa a partir das expressões dadas pelas Equações 3.7 a 3.11

$$\min_x \frac{1}{2} f(x)^2 = \frac{1}{2} f(y(x) - b)^2, \quad (3.7)$$

aproximando $y(x)$ por $y(x_0) + y'(x_0)(x - x_0)$, chega-se em

$$\frac{(y(x_0) + y'(x_0)(x - x_0) - b)^2}{2}. \quad (3.8)$$

Para obter o mínimo do problema, deriva-se a expressão, igualando o resultado a zero:

$$y'(x_0)(y(x_0) + y'(x_0)(x - x_0) - b) = 0. \quad (3.9)$$

A generalização para um problema multidimensional de mínimos quadrados considera a Equação 3.10

$$J^T(x_0)(y(x_0) + J^T(x_0)(x - x_0) - b) = 0, \quad (3.10)$$

em que J é o jacobiano de y (matriz das derivadas de primeira ordem) dado por $J_{i,j} = \partial_{x_j} y_i$.

Pelo método Gauss Newton obtém-se a iteração

$$J^T(x_i)J(x_i)(x_{i+1} - x_i) = J^T(x_i)f(x_i). \quad (3.11)$$

Este método representa uma aproximação do método de Newton para o problema de mínimos quadrados, pois $J^T J$ é uma aproximação da hessiana da função (matriz das derivadas de segunda ordem), onde os termos que envolvem segundas derivadas são desprezados e $J^T f$ é o gradiente da função que se deseja minimizar. Como no método de Newton, o cálculo da inversa de hessiana da forma $J^T J$ pode ser numericamente instável e a direção calculada pode não ser de descida. Para solucionar este problema, perturba-se a aproximação hessiana da forma $J^T J + \lambda D$, em que D é uma matriz diagonal e λ um escalar que deve ser escolhido a cada passo. Se o algoritmo está convergindo, o valor de λ diminui a cada iteração e o método se comporta com o de Gauss-Newton. Caso o algoritmo não esteja convergindo, o valor de λ é elevado e o método passa a se comportar como o método do Gradiente.

Definido o número de camadas e seus respectivos neurônios, os pesos da rede devem ser fixados, de modo a minimizar o erro de predição. O erro de uma configuração particular da rede pode ser determinado através da execução de todos os casos de formação da rede, comparando os resultados reais gerados com os produtos desejados. Por conseguinte, o algoritmo progride de forma iterativa, através de um número de épocas. Em cada época, os passos de formação são submetidos à rede e saídas alvo, sendo comparados com o erro calculado. Este erro é usado para ajustar os pesos. Em seguida, o processo é finalizado quando um determinado número de épocas decorre ou quando se alcança o erro pré-definido. Vale ressaltar que o algoritmo de treinamento Levenberg-Marquardt é uma técnica de otimização numérica que demanda uma grande quantidade de memória e elevada complexidade computacional, o que pode tornar sua utilização ineficiente para redes muito grandes.

Capítulo 4

Análise Estatística dos Dados

Segundo Montgomery e Runger (2016), experimentos encontram-se envolvidos em processos de tomada de decisão em engenharia e em ciência. Métodos, teorias, técnicas e modelos estatísticos desempenham papel importante nos estágios da pesquisa científica e possibilitam a comparação entre processos aplicados para a solução de determinado problema. Existem diferentes abordagens estatísticas e, para a correta escolha do método a ser utilizado, é necessário conhecer a natureza da variável em análise (contínua ou discreta), informações sobre o processo de amostragem (tamanho da amostra, independência, aleatoriedade, representatividade, entre outras), as distribuições a serem empregadas (como binomial, normal e Poisson), além da teoria e dos pressupostos do modelo aplicado. Neste capítulo são apresentadas as técnicas estatísticas utilizadas para análise dos dados obtidos pelos métodos de localização de faltas em linhas de transmissão, implementados por RNAs, técnicas de ONL aplicadas às funções objetivo descritivas do processo e por um método analítico de referência. O processo envolveu além das etapas de conjectura (apresentada pelas hipóteses de pesquisa) e de experimento (implementação e aplicação dos métodos em casos simulados e reais de curto-circuito e a análise estatística dos dados obtidos com o experimento) e a conclusão alcançada frente à conjectura inicialmente apresentada.

4.1 Análise de Variância

A análise de variância (ANOVA) é um teste estatístico amplamente difundido, que foi desenvolvido e introduzido por Ronald A. Fisher em 1925. Envolve um teste de hipótese de fácil interpretação e visa, a partir da análise das variâncias amostrais, testar a igualdade entre três ou mais médias populacionais e verificar se as variáveis independentes (fatores) exercem influência em alguma variável dependente. No modelo, um efeito principal refere-se a um efeito direto de uma variável independente sobre a variável dependente e, um efeito de interação, relaciona-se com o efeito de duas ou mais variáveis independentes sobre a variável dependente.

A ANOVA utiliza a distribuição F (de Fisher - Snedecor) para validar estatisticamente a igualdade entre médias. A estatística F representa uma razão entre duas variabilidades, em que o numerador corresponde à variabilidade observada entre as médias do grupo e o denominador à variabilidade das observações dentro dos grupos. Com a aplicação do teste, espera-se que as variações sejam aproximadamente iguais sob a hipótese nula (H_0), que por sua vez produz uma estatística F de valor aproximadamente um. Caso contrário, considera-se a existência de diferença de variações, sustentada pela hipótese alternativa (H_1). A aplicação do teste encontra-se sujeita à possibilidade de se cometer um erro do tipo I (rejeitando-se a hipótese nula quando é verdadeira) ou do tipo II (não se rejeitando a hipótese nula quando é falsa). O poder do teste é definido como a probabilidade de rejeitar a hipótese nula, dado que a mesma é falsa, ou seja, refere-se à capacidade de evitar o erro do tipo II.

A ANOVA é regida por pressuposições que precisam ser testadas e atendidas para os resíduos, que representam as diferenças obtidas entre cada observação experimental e seu respectivo valor estimado a partir do modelo estatístico, ou seja, a diferença entre uma observação e a média do tratamento correspondente. Nesse sentido os resíduos necessitam:

- ser independentes e identicamente distribuídos;
- ter distribuição normal com média $\mu = 0$ e variância σ^2 ;
- ser homocedásticos, termo utilizado para indicar a variância constante dos resíduos, ou seja, a dispersão dos erros deve ser semelhante entre os tratamentos.

A verificação destes pressupostos pode ocorrer pela análise gráfica. Em relação à independência ou aleatoriedade dos resíduos, plotando-se o gráfico de resíduos contra a ordem de coleta das observações, se os resíduos estiverem situados, aproximadamente, em torno de uma faixa horizontal centrada no valor nulo do eixo das ordenadas, será obtida uma indicação da validade da suposição de independência. Para a verificação da normalidade dos resíduos é comum o emprego dos gráficos quantil-quantil (Q-Q Plot) ou de probabilidade normal dos resíduos. No eixo horizontal deste gráfico têm-se os valores obtidos para os resíduos e, no eixo vertical, os valores esperados caso os resíduos tenham distribuição normal. Uma boa aderência dos dados à distribuição Normal se verifica quando os pontos estão próximos à reta de referência. Referente à homocedasticidade, ao se plotar os resíduos por nível, se os pontos estão aleatoriamente distribuídos em torno do valor nulo do eixo das ordenadas, sem nenhum comportamento ou tendência, há indícios de que a variância dos

resíduos é homoscedástica. Um aspecto gráfico de atendimento das pressuposições é verificado pela Figura 4.1.




Figura 4.1: Pressuposições para a aplicação da ANOVA.

A análise gráfica embora não permita, com valores numéricos, a validação dos pressupostos anteriormente indicados, representa uma possibilidade subjetiva e possui aplicação auxiliar para outras metodologias. A constatação das premissas pode ser realizada a partir de diferentes testes estatísticos de hipóteses. Nessa dissertação, a verificação da aleatoriedade ocorreu pela aplicação do teste de Durbin-Watson e a normalidade dos resíduos foi verificada pelo teste de Shapiro-Wilk (de grande poder estatístico). Para testar a homocedasticidade foram usados o teste de Bartlett (que não é afetado pelo tamanho da amostra e deve ser utilizado quando os resíduos apresentam distribuição normal) e o teste de Levene (que embora tenha aplicação limitada a amostras balanceadas, possui maior poder do teste e não requer a pressuposição de normalidade).

A pressuposição mais crítica é a da independência dos dados, atributo garantido pela correta casualização do experimento, em que os resíduos encontram-se alinhados em função da ordem e do arranjo estrutural do experimento. A dependência entre resíduos afeta o teste F , proporcionando altas taxas de erros dos tipos I e II. Diferentes relatos na literatura destacam a robustez da ANOVA frente a uma pequena violação na normalidade dos resíduos. Nestas situações os erros dos tipos I e II são pouco afetados, contudo, quando as premissas da normalidade são significativamente violadas, devem ser utilizados testes não paramétricos. Referente aos pressupostos de homocedasticidade do modelo, caso não sejam atendidos, sugere-se a aplicação de testes não paramétricos que, além de serem menos eficientes, necessitam de maiores amostras ou diferenças para a rejeição da hipótese nula. Nestes testes os dados numéricos são reduzidos a uma forma qualitativa, com isso, tende-se a perder a informação da amostra. O teste de Kruskal-Wallis é um teste não paramétrico frequentemente

utilizado para o estudo das diferenças entre três ou mais amostras independentes, representando a versão não paramétrica da ANOVA.

4.2 Análise de Variância para Experimentos com 1 Fator (ANOVA1)

O método utiliza a estimação das médias de diversas populações, assumidas como independentes, homocedásticas e normalmente distribuídas. Conforme Montgomery e Runger (2016), cada nível do fator em estudo é chamado de um tratamento e a resposta para cada um dos k tratamentos é uma variável aleatória. Quando o método é utilizado para níveis diferentes de um único fator, o mesmo é denominado ANOVA1, estando seu banco de dados representado na Tabela 4.1, onde y_{ij} representa a j -ésima observação sujeita ao i -ésimo tratamento.

Tabela 4.1: Arranjo dos dados para um planejamento de experimentos com um fator.

Tratamento	Observações					
	1	2	...	n	Totais	Médias
1	y_{11}	y_{12}		y_{11}	$y_{1.}$	$\bar{y}_1.$
2	y_{21}	y_{22}		y_{2n}	$y_{2.}$	$\bar{y}_2.$
$\vdots$						
a	y_{a1}	y_{a1}		y_{an}	$y_{a.}$	$\bar{y}_a.$
					$y_{..}$	$\bar{y}_{..}$

O modelo linear estatístico associado à ANOVA1, como descrito por Montgomery e Runger (2016), pode ser descrito pela Equação 4.1 em que Y_{ij} é uma variável aleatória denotando a ij -ésima observação, μ é um parâmetro comum a todos os tratamentos, chamado de média global, τ_i é um parâmetro associado com o i -ésimo tratamento, sendo chamado de efeito do i -ésimo tratamento, e ε_{ij} é um componente do erro aleatório associado a observação da repetição j no tratamento i .

$$Y_{ij} = \mu + \tau_i + \varepsilon_{ij} \begin{cases} i = 1, 2, \dots, a \\ j = 1, 2, \dots, n \end{cases} \quad (4.1)$$

Considerando que as observações sejam normalmente e independentemente distribuídas, com média zero e variância σ^2 , cada tratamento pode ser tratado como uma população normal com média $(\mu + \tau_i)$ e variância σ^2 . Um resíduo representa a diferença entre uma observação y_{ij} e seu valor estimado $\hat{y}_{ij}$, ou seja, $\hat{\varepsilon}_{ij} = y_{ij} - \hat{y}_{ij}$. Segundo Montgomery e Runger (2016),

as observações devem ser tomadas em uma ordem aleatória de forma que, as unidades experimentais em que os tratamentos são usados sejam tão uniformes quanto possível. O planejamento experimental será completamente aleatorizado se $\hat{y}_{ij} = \bar{y}_{ij}$.

No experimento, os a níveis do fator podem ser escolhidos de duas maneiras diferentes: testando-se as hipóteses acerca das médias dos tratamentos sem estender as conclusões a tratamentos similares que não tenham sido considerados (modelo com efeitos fixos) ou, alternativamente, considerando-se que os a tratamentos venham de uma amostra aleatória, a partir de uma população maior de tratamentos, nessas situações os efeitos dos tratamentos τ_i são considerados variáveis aleatórias. Na análise de variância do modelo com efeitos fixos, os efeitos dos tratamentos τ_i são definidos como desvios da média global μ de modo que a Equação 4.2 seja atendida.

$$\sum_{i=1}^a \tau_i = 0 \quad (4.2)$$

Na Equação 4.3, considerando-se que $y_{i.}$ e $\bar{y}_{i.}$ sejam respectivamente o total e a média das observações do i -ésimo tratamento e que $y_{..}$ e $\bar{y}_{..}$ representem o total e a média global de todas as N observações realizadas num experimento em que o subscrito “ponto” implica soma no subscrito que ele representa, tem-se:

$$y_{i.} = \sum_{j=1}^a y_{ij} \quad \bar{y}_{i.} = \frac{y_{i.}}{n} \quad i = 1, 2, \dots, a \quad y_{..} = \sum_{i=1}^a \sum_{j=1}^n y_{ij} \quad \bar{y}_{..} = \frac{y_{..}}{N} \quad (4.3)$$

Testar a igualdade das médias dos a tratamentos, $\mu_1, \mu_2, \mu_3, \dots, \mu_a$ equivale à verificação do teste de hipóteses apresentado em 4.4.

$$\begin{cases} H_0: \tau_1 = \tau_2 = \dots = \tau_a = 0; \\ H_1: \exists i / \tau_i \neq 0 \end{cases} \quad (4.4)$$

Pelo teste, se a hipótese nula (H_0) não for rejeitada, cada observação consistirá na média global μ mais um componente do erro aleatório ε_{ij} , o que equivale a dizer que todas as N observações são tomadas de uma distribuição normal com média μ e variância σ^2 . Nesse sentido, a mudança nos níveis do fator não tem efeito na resposta média.

A análise de variância divide a variabilidade total nos dados da amostra em dois componentes. Então, o teste de hipótese apresentado na Equação 4.4 é baseado na

comparação das duas estimativas independentes da variância da população. A variabilidade total nos dados é descrita pela soma quadrática total (SQT), dada pela Equação 4.5.

$$SQT = \sum_{i=1}^a \sum_{j=1}^n (y_{ij} - \bar{y}_{..})^2 \quad (4.5)$$

A identidade da soma quadrática é dada pela Equação 4.6.

$$\sum_{i=1}^a \sum_{j=1}^n (y_{ij} - \bar{y}_{..})^2 = n \sum_{i=1}^a (\bar{y}_{i.} - \bar{y}_{..})^2 + \sum_{i=1}^a \sum_{j=1}^n (y_{ij} - \bar{y}_{i.})^2 \quad (4.6)$$

A variabilidade nos dados, medida pela soma quadrática total corrigida, pode ser dividida em uma soma quadrática das diferenças entre as médias dos tratamentos e a média global em uma soma quadrática das diferenças das observações dentro de um tratamento, a partir da média dos tratamentos. As diferenças entre as médias observadas nos tratamentos e a média global medem as diferenças entre os tratamentos, enquanto as diferenças das observações dentro de um tratamento a partir da média dos tratamentos podem ser devidas somente ao erro aleatório. Simbolicamente a Equação 4.6 pode ser representada segundo a Equação 4.7

$$SQT = SQTrat + SQE \quad (4.7)$$

Em que a soma quadrática dos tratamentos ($SQTrat$) e a soma quadrática do erro (SQE) são dadas pelas Equações 4.8 e 4.9

$$SQTrat = n \sum_{i=1}^a (\bar{y}_{i.} - \bar{y}_{..})^2 \quad (4.8)$$

$$SQE = \sum_{i=1}^a \sum_{j=1}^n (y_{ij} - \bar{y}_{i.})^2 \quad (4.9)$$

Na análise de variância com amostras de mesmo tamanho, a Equação 4.8 pode ser reescrita como em 4.10

$$SQTrat = \sum_{i=1}^n \frac{y_{i.}^2}{n} - \frac{y_{..}^2}{N} \quad (4.10)$$

A análise de variância funciona através do exame dos valores esperados de $SQTrat$ e SQE , sendo uma estatística para testar a hipótese de nenhuma diferença entre as médias dos tratamentos ($\tau_i = 0$). O valor esperado da soma quadrática dos tratamentos é dado pela Equação 4.11

$$E_{SQTrat} = (a - 1)\sigma^2 + n \sum_{i=1}^a \tau_i^2 \quad (4.11)$$

Caso a hipótese nula da Equação 4.4 seja verdadeira, cada τ_i será igual a zero e a variância será dada pela Equação 4.12.

$$E\left(\frac{SQTrat}{a - 1}\right) = \sigma^2 \quad (4.12)$$

Caso contrário, a hipótese alternativa H_1 será verdadeira, chegando-se à Equação 4.13.

$$E\left(\frac{SQTrat}{a - 1}\right) = \sigma^2 + \frac{n \sum_{i=1}^a \tau_i^2}{a - 1} \quad (4.13)$$

A razão $MQTrat = SQTrat / (a - 1)$ é chamada de média quadrática dos tratamentos. Se H_0 for verdadeira, $MQTrat$ é um estimador não tendencioso de σ^2 . Caso contrário, se H_1 for verdadeira, $MQTrat$ estimará σ^2 somado a um termo positivo que incorpora a variação devido à diferença sistemática nas médias dos tratamentos. O valor esperado da soma quadrática dos erros é dada por $E(SQE) = a(n - 1)/\sigma^2$ e a média quadrática do erro, $MQE = SQE / [a(n - 1)]$, é um estimador não tendencioso de σ^2 , independente de H_0 ser ou não verdadeira.

A divisão do número de graus de liberdade corresponde à identidade da soma quadrática na Equação 4.6 e, nesse sentido, considerando-se que se tenham $an = N$ observações, SQT terá $an - 1$ graus de liberdade. Como o fator em estudo tem a níveis, $SQTrat$ tem $a - 1$ graus de liberdade e, dentro de qualquer tratamento, existem réplicas fornecendo $n - 1$ graus de liberdade, com os quais se estima o erro experimental. Também, como existem a tratamentos, temos $a(n - 1)$ graus de liberdade para o erro e a divisão dos graus de liberdade é $an - 1 = a - 1 + a(n - 1)$. Como a distribuição F de uma variável aleatória representa uma razão entre duas variáveis aleatórias independentes qui-quadrado, cada uma sendo dividida pelo seu número de graus de liberdade, considerando que cada uma das a populações apresente uma distribuição normal e que a hipótese H_0 seja verdadeira, a razão apresentada na Equação 4.14 terá uma distribuição F com $(a - 1)$ graus de liberdade. Do valor esperado da média quadrática tem-se que MQE é um estimador não tendencioso de σ^2 . Também, sob a hipótese nula, $MQTrat$ é um estimador não tendencioso de σ^2 .

$$f_0 = \frac{SQTrat/(a-1)}{SQE/[a(n-a)]} = \frac{MQTrat}{MQE} \quad (4.14)$$

Caso H_0 seja falsa, o valor esperado de $MQTrat$ será maior do que σ^2 , o valor esperado do numerador da Equação 4.14 será maior do que o valor esperado do denominador. Consequentemente, H_0 será rejeitada se $f_0 > f_{\alpha, a-1, a(n-1)}$, com f_0 calculado pela Equação 4.14 e $f_{\alpha, a-1, a(n-1)}$ correspondendo ao valor tabelado para pontos percentuais da distribuição F com a significância α indicada pela pesquisa. Na Tabela 4.2 apresenta-se a síntese da análise de variância para um experimento com um único fator.

Tabela 4.2: Análise de Variância - Modelo de efeitos fixos (1 fator).

Fonte de variação	Soma quadrática	Grau de liberdade	Média quadrática	f_0
Tratamentos	$SQTrat$	$a - 1$	$MQTrat = SQTrat/(a - 1)$	$MQTrat/MQE$
Erro	SQE	$a(n - 1)$	$MQE = SQE/(a(n - 1))$	
Total	SQT	$an - 1$		

A análise da estatística do teste também pode ocorrer em função do p-valor, também denominado nível descritivo do teste. Geralmente presente em programas computacionais, o p-valor testa a hipótese nula para cada termo e representa a probabilidade da estatística do teste (como variável aleatória) apresentar valor extremo em relação ao valor observado (estatística) quando H_0 é verdadeira. Sendo α a significância adotada para o teste, um p-valor inferior a α indica a rejeição da hipótese nula. Assim, quando um fator possui p-valor baixo, provavelmente será uma adição significativa ao seu modelo, porque as alterações no valor do fator estão relacionadas a alterações na variável resposta. Por outro lado, um p-valor maior (insignificante) sugere que as mudanças no fator não estão associadas a mudanças na resposta.

4.3 Análise de Variância para Experimentos com 2 Fatores (ANOVA2)

O estudo anteriormente apresentado pode ser expandido para testar hipóteses sobre os efeitos principais em situações em que se tenha mais de um fator em estudo. Nesse sentido, em um experimento com dois fatores indicados por A e B, considere que o fator A tenha a níveis de tratamento e o fator B tenha b níveis de tratamento. Para a situação, apresentada na Tabela 4.3, $y_{i..}$ representa o total de observações no i -ésimo nível do fator A, $y_{.j.}$ o total de

observações no j -ésimo nível do fator B, y_{ij} , o total de observações na ij -ésima célula e $y_{...}$ o total global de todas as observações. Também $\bar{y}_{i..}$, $\bar{y}_{.j.}$, $\bar{y}_{...}$ são definidos como as médias respectivamente correspondentes às linhas, colunas e global.

Tabela 4.3: Arranjo dos dados para um planejamento fatorial com dois fatores.

Fator B							
Tratamento		1	2	...	b	Totais	Médias
Fator A	1	$y_{111}, y_{112}, \dots, y_{11n}$	$y_{121}, y_{122}, \dots, y_{12n}$	...	$y_{1b1}, y_{1b2}, \dots, y_{1bn}$	$y_{1..}$	$\bar{y}_{1..}$
	2	$y_{211}, y_{212}, \dots, y_{21n}$	$y_{221}, y_{222}, \dots, y_{22n}$	...	$y_{2b1}, y_{2b2}, \dots, y_{2bn}$	$y_{2..}$	$\bar{y}_{2..}$
	$\vdots$	$\vdots$	$\vdots$	...	$\vdots$	$\vdots$	$\vdots$
	a	$y_{a11}, y_{a12}, \dots, y_{a1n}$	$y_{a21}, y_{a22}, \dots, y_{a2n}$	...	$y_{ab1}, y_{ab2}, \dots, y_{abn}$	$y_{a..}$	$\bar{y}_{a..}$
Totais		$y_{.1.}$	$y_{.2.}$	...	$y_{.b.}$	$y_{...}$	
Médias		$\bar{y}_{.1.}$	$\bar{y}_{.2.}$	...	$\bar{y}_{.b.}$		$\bar{y}_{...}$

O modelo estatístico de experimento com dois fatores, seguindo distribuição normal, com média $\mu = 0$ e variância σ^2 é descrito na Equação 4.15.

$$y_{ijk} = \mu + \tau_i + \beta_j + \varepsilon_{ijk} \quad \begin{cases} i = 1, 2, \dots, a \\ j = 1, 2, \dots, b \\ k = 1, 2, \dots, n \end{cases} \quad (4.15)$$

No modelo, considera-se μ como o efeito médio global dos erros, τ_i o efeito do i -ésimo nível do fator A, β_j o efeito do j -ésimo nível do fator B, $(\tau\beta)_{ij}$ o efeito da interação entre os fatores A e B, i o número de níveis do fator A, j o número de níveis do fator B e n o número de amostras recolhidas para cada nível e ε_{ijk} um componente do erro aleatório. Analogamente aos procedimentos realizados para o ANOVA1, obtém-se a variabilidade total a partir da soma total dos quadrados das observações (SQT). Situação expressa pela Equação 4.16.

$$SQT = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n y_{ijk}^2 - \frac{y_{...}^2}{abn} \quad (4.16)$$

A identidade da soma dos quadrados para o ANOVA2 pode ser representada pela Equação 4.17

$$SQT = SQA + SQB + SQAB + SQE \quad (4.17)$$

Sendo SQA , SQB , $SQAB$ e SQE respectivamente representantes da soma dos quadrados do fator A, do fator B, da interação entre os fatores A e B e do erro. Estes valores são obtidos pelas Equações 4.18 a 4.21.

$$SQA = \sum_{i=1}^a \frac{y_{i..}^2}{bn} - \frac{y_{...}^2}{abn} \quad (4.18)$$

$$SQB = \sum_{j=1}^b \frac{y_{.j.}^2}{an} - \frac{y_{...}^2}{abn} \quad (4.19)$$

$$SQAB = \sum_{i=1}^a \sum_{j=1}^b \frac{y_{ij.}^2}{n} - \frac{y_{...}^2}{abn} - SQA - SQB \quad (4.20)$$

$$SQE = SQT - SQA - SQB - SQAB \quad (4.21)$$

Dividindo-se cada uma das somas quadráticas pelos correspondentes graus de liberdade obtêm-se as médias quadráticas para os fatores A, B e para a interação entre eles. A próxima etapa, apresentada na Tabela 4.4, relaciona-se com o cálculo do valor f_0 para a aplicação do teste de F .

Tabela 4.4: Análise de Variância - Modelo de efeitos fixos (2 fatores).

FATOR	Soma dos Quadrados	Graus de Liberdade	Média Quadrática	f_0
A	SQA	$a - 1$	$MQA = SQA/(a - 1)$	MQA/MQE
B	SQB	$b - 1$	$MQB = SQB/(b - 1)$	MQB/MQE
AB	$SQAB$	$(a - 1)(b - 1)$	$MQAB = SQA/((a - 1)(b - 1))$	$MQAB/MQE$
Erro	SQE	$ab(n - 1)$	$MQE = SQE/(ab(n - 1))$	
Total	SQT	$abn - 1$		

Os testes de hipóteses possibilitam a verificação dos efeitos dos fatores A, B e da interação entre eles, sendo descritos nas Equações 4.22, 4.23 e 4.24 com i correspondendo aos níveis do fator A e j aos níveis do fator B.

$$\begin{cases} H_0 : \tau_1 = \dots = \tau_i = 0; \\ H_1 : \exists i / \tau_i \neq 0 \end{cases} \quad (4.22)$$

$$\begin{cases} H_0 : \beta_1 = \dots = \beta_j = 0; \\ H_1 : \exists j / \tau_j \neq 0 \end{cases} \quad (4.23)$$

$$\begin{cases} H_0 : (\tau\beta)_{ij} = 0 \quad \forall i, j; \\ H_1 : \exists i, j / (\tau\beta)_{ij} \neq 0 \end{cases} \quad (4.24)$$

A partir da análise dos valores esperados das médias quadráticas pode-se inferir que caso H_0 seja verdadeira para o fator A, B ou para a interação entre os fatores, a média quadrática associada à respectiva situação será um estimador não tendencioso da variância σ^2 .

Vale destacar que, como descrito por Montgomery e Runger (2016), a ANOVA2 requer um número igual de observações n , em cada tratamento e que os fatores propostos podem ser de origem qualitativa ou quantitativa, mas a variável dependente necessariamente deverá ser contínua.

Quando é feita a ANOVA de um experimento de um fator com apenas dois tratamentos é possível identificar, apenas pela média qual o melhor tratamento. Contudo, quando há mais de dois tratamentos, a ANOVA embora indique a existência de um tratamento discrepante dentre os demais, não situa a diferença observada. Neste caso, é necessário aplicar um teste de comparação de médias dos tratamentos para concluir qual o melhor (ou pior) tratamento.

Existem diferentes testes de comparação de médias que servem de complemento para o estudo da ANOVA. O teste de Tukey, utilizado nessa dissertação para este fim, foi criado em 1953 por John Tukey e é conhecido também como teste de Tukey da Diferença Honestamente Significativa (*Honestly Significant Difference* - HSD). Por ele executa-se a diferença mínima exata entre um conjunto de médias, fazendo com que, diante de uma significância α fixada, as comparações par a par das médias sejam avaliadas pela maior diferença encontrada.

Capítulo 5

A Localização de Faltas em Linhas de Transmissão

As linhas de transmissão são basicamente constituídas por fios condutores metálicos, suspensos em torres metálicas, por meio de materiais altamente isolantes. Estendem-se por longas distâncias, conectando usinas geradoras aos centros consumidores. Buscando precisão e robustez nos métodos desenvolvidos, desde a década de 1970, pesquisadores têm estudado algoritmos para a análise de faltas em linhas de transmissão. Este capítulo tem como objetivo verificar, no atual cenário brasileiro, as demandas por ampliação e investimentos nessas estruturas e apresentar uma revisão da literatura, com a finalidade de situar, a partir da apresentação de artigos escolhidos, a utilização de Redes Neurais Artificiais e técnicas de Otimização Não Linear no processo de detecção, classificação, localização de faltas e determinação de resistências de faltas em linhas de transmissão. A sequência de disposição do estudo foi organizada considerando-se a categorização por temática central abordada e ano de publicação. Assim, inicialmente, são apresentados trabalhos que versam exclusivamente a localização de faltas, na sequência trabalhos que abordam a detecção e a classificação, posteriormente são apresentados trabalhos com foco na classificação e na localização e, ao final, trabalhos envolvendo as etapas de detecção, classificação e localização de faltas em linhas de transmissão. A temática determinação da resistência de falta perpassa pela maior parte dos estudos selecionados, contudo não foi utilizada como referência para a organização dos textos.

5.1 Localização de Faltas

Em seus estudos, Chen e Maun (2000) descreveram a aplicação de um algoritmo baseado em RNAs com a utilização de dados de tensão e corrente de um terminal, para localizar curtos-circuitos e determinar resistências de falta em linhas de transmissão. A topologia das redes *feedforward* utilizadas possuía três camadas, função de ativação tangente hiperbólica para as camadas ocultas, função linear para a camada de saída, método de aprendizagem supervisionado *Backpropagation* e algoritmo de treinamento de *Levenberg-Marquardt*. Como entrada para rede neural, utilizaram-se fasores de tensão e corrente de todas as fases dos circuitos pré-falta e de falta. As saídas da rede forneciam a posição da falta e a resistência de

falta. Como resultado preliminar, as RNAs foram treinadas e testadas categorizando-se as impedâncias da fonte do terminal remoto como forte, média ou fraca, e definindo-se a impedância da fonte do terminal emissor como fraca. Para cada uma das impedâncias da fonte do terminal remoto (fraca, média, forte), 540 casos de treinamentos e 4.319 testes foram aplicados nas RNAs. As linhas de transmissão foram submetidas somente à falta fase-terra e os resultados mostraram a capacidade das redes neurais implementadas para estimar a posição da falta com erros menores que 1%, obtendo erros da resistência de falta menores do que 3%. Em uma segunda análise, a impedância da fonte remota foi submetida a grandes variações, foram realizados 1.080 treinamentos e 3.000 testes. Os resultados permitiram concluir que as RNAs foram capazes de se adaptarem às novas condições, localizando a posição da falta com erro menor que 3,5%. Como conclusão, os autores pontuaram positivamente a convergência, a velocidade e a precisão do método.

Utilizando RNAs para mapear a relação entre sinais elétricos e locais de defeitos em linhas de transmissão, Souza et al. (2007) analisaram uma linha de transmissão de 300 km de comprimento, com uma fonte de tensão de 400 kV, com medições de tensão e corrente realizadas em um terminal. Visando construir um conjunto de dados para os treinamentos e os testes das redes neurais, simularam usando o *software Alternative Transients Program*: locais de falta variando de 20 km até 270 km, com incremento de 50 km; resistência de falta variando aleatoriamente entre 1 e 50 Ω ; cargas de 150 e 250 MVA por fase (equilibrado); fator de potência de 0,85 e 0,95; ângulo de incidência da falta de 0°, 90°, 180° e 270°; e apenas faltas fase-terra, por ser o tipo mais frequente. Destaque relevante deste estudo relacionou-se com o processamento de sinais e seu impacto à localização de faltas. Os sinais de tensões e correntes, antes de serem enviados aos módulos de localização de falta, passaram por três formas diferentes de processamento de sinais: no primeiro método as informações dos sinais de tensão e corrente foram extraídas com base na transformada de Fourier, considerando os dados de regime transitório; no segundo método também foram considerados os dados de regime transitório, extraíndo-se as informações de tensão e corrente com base na Transformada de *Wavelet* (TW) e, por fim, no terceiro método consideraram-se informações de tensão e corrente extraídas com base na transformada de Fourier, registrados no primeiro ciclo do período pré-falta (regime permanente) e também no primeiro ciclo do período de falta (regime transitório). Para localização de faltas, foram programadas 3 RNAs com topologia *Multilayer Perceptron*, método de aprendizagem supervisionado BP e algoritmo de treinamento LM e também outras 3 RNAs foram desenvolvidas a partir da teoria de Máquina

de Vetores de Suporte (SVM). Com base nos resultados, os autores concluíram que, para a localização de faltas, as RNAs do tipo MLP são mais precisas do que a topologia SVM, ressaltando também que as redes SVM fornecem erros pequenos.

A Transformada Discreta de *Wavelet* (TDW) e RNAs do tipo *feedforward*, com método de aprendizagem BP e algoritmo de treinamento LM foram propostas por Ngaopitakkul e Pothisarn (2009) para localização de falta em linha de transmissão de circuitos simples, utilizando-se como referência prática de estudo uma linha de transmissão de 325 km e nível de tensão de 500 kV, do sistema elétrico da Tailândia. Os sinais de tensão e corrente importados para o MatLab foram obtidos por diferentes simulações de falta usando o ATP, mantendo-se a resistência fixa no valor de 10 Ω , variando-se os tipos de falta, os locais de falta a cada 10% do comprimento da linha e o ângulo de incidência da onda com incremento de 30° em um intervalo de 0° a 330°. Posteriormente, através da matriz de transformada de Clark, calcularam-se as correntes e as tensões sequenciais dos terminais. Para a detecção da falta, foram utilizados os sinais de corrente e de tensão de sequência positiva de um dos terminais. Utilizando-se dados dos dois terminais, a localização de falta foi estudada em duas situações. Na primeira, os coeficientes de pico das correntes de sequência positiva, obtidos pela TDW, foram utilizados para treinar a RNA com dois neurônios de entrada (coeficientes de pico das correntes de sequência positiva dos terminais), duas camadas ocultas (dois e seis neurônios respectivamente) e um neurônio de saída (corresponde ao ponto de defeito medido a partir do barramento emissor). Na segunda situação, os coeficientes de pico dos sinais de corrente e tensão de falta das fases A, B, C e sequência zero, obtidos por TDW aplicada a 1/4 de ciclo, foram usados para treinar as RNAs compostas por oito neurônios de entradas (coeficientes de pico dos sinais de corrente e tensão pós-falta das fases A, B, C e sequência zero), duas camadas ocultas (seis e dez neurônios, respectivamente) e um neurônio de saída (corresponde ao ponto de defeito medido a partir do barramento emissor). Os resultados, segundo os autores, permitiram 100% de precisão para a detecção de falta e um processo de localização satisfatório para todas as variações de parâmetros utilizadas (ângulo de incidência da onda de falta, diferentes pontos de falta e tipos de falta).

Para descrever a aplicação de RNAs na localização de faltas e determinação de resistência de falta em linhas de transmissão, Teklic et al. (2013) utilizaram uma linha de transmissão de 110 kV e comprimento de 60 km. Para avaliação do algoritmo desenvolvido, a linha de transmissão foi modelada no software *Eletromagnetic Transients Program* (EMTP), pela teoria de parâmetros distribuídos. Os valores de correntes e tensões trifásicas, necessários para

treinamentos e testes das RNA, foram obtidos a partir de dados dos dois terminais da linha, variando-se os locais de falta (0 km, 20 km, 30 km, 40 km, 50 km e 60 km), as condições de fluxo de carga (energia ativa entre 0 e 100 MW e energia reativa entre 10 e 30 MVar) e os valores de resistência de falta (0 Ω , 10 Ω , 25 Ω e 50 Ω). Os valores obtidos, enviados ao *software* MatLab, foram treinados em uma RNA *feedforward*, com uma camada de entrada, duas camadas ocultas e uma camada de saída (24-3-2-2). A primeira camada recebia os módulos e ângulos dos sinais de corrente e tensão e a camada de saída fornecia o local da falta e o valor da resistência de falta. Utilizando-se o método de aprendizagem supervisionado BP e algoritmo de treinamento do Gradiente Descendente, na maioria das vezes, foram obtidos resultados de localização da falta e estimativa da resistência de falta com erro percentual inferior a 10 %. O valor médio do erro percentual para localização de faltas foi igual a 6,6 % e para a estimativa da resistência de falta foi igual a 4,3 %. Os resultados, aplicados a diferentes condições de operação do sistema de energia, possibilitaram a localização de faltas e a estimativa de resistências de falta mesmo com a utilização de arquitetura simples de RNA.

5.2 Detecção e Classificação de Faltas

Introduzindo o conceito de rede neural modular para classificação de faltas em linhas de transmissão, Pradhan et al. (2006) propuseram a classificação da falta realizada por um conjunto de módulos de RNAs (três módulos para os sinais de tensão e corrente das fases A, B e C e um módulo para os sinais de tensão e corrente que envolvem a terra). No estudo, a solução global foi obtida posteriormente, combinando-se o resultado de cada módulo. Para a simulação, feita a partir do MatLab, foram desenvolvidas redes com topologia *Probabilistic Neural Network* (PNN). No estudo, foi utilizada uma de linha de transmissão de 230 kV, frequência de 50 Hz, comprimento de 200 km e duas fontes de 50 GVA de potência cada. O conjunto de dados de treinamento e testes foram obtidos por simulação e abrangeram variações de 48 Hz a 52 Hz na frequência da rede elétrica, condição pré-falta, ângulo de incidência da falta, resistência de falta, localização e tipos de falta. Conforme os autores, o conceito modular simplifica um problema complexo dividindo-o em tarefas menores. A técnica, utilizada para a classificação de faltas em linhas de transmissão possibilita maior precisão e menor tempo de treinamento.

Outro modelo para a detecção e a classificação de faltas em linhas de transmissão, formado por dois módulos, foi proposto por Silva et al. (2006). No módulo de detecção, a partir de registros oscilográficos, antes de se calcular a TDW, normalizam-se as amostras de tensão e

corrente. A partir de um conjunto de regras baseado na análise das formas de onda de corrente no domínio do tempo e na energia do coeficiente de *Wavelet* da corrente, realizava-se ou não a detecção da falta. Se a falta fosse detectada, os dados registrados entre o início e fim da falta (tempo de eliminação) eram transferidos para o módulo de classificação, indicando-se as fases envolvidas. Para isso, uma RNA MLP, implementada em linguagem C++, executava os padrões de entrada por janelas de amostras dentro do tempo de eliminação da falta, juntando-se cinco amostras consecutivas de tensão e corrente (fases e componente de sequência zero) em um único padrão de entrada. O conjunto de dados para treinamento da RNA foi obtido através de simulações no software ATP, com diferentes tipos de falta, ângulos de incidência, locais e resistências de falta. As simulações, realizadas em 720 tipos de falta, com os dados de uma linha de transmissão pertencente à Companhia Hidrelétrica de São Francisco (CHESF), localizada na região nordeste do Brasil, de tensão nominal de 230 kV e comprimento de 188 km, indicaram que o método proposto foi eficiente, alcançando 100% de sucesso para os módulos de detecção e classificação. Para casos reais, o método proposto pelos autores foi validado utilizando-se diferentes registros com e sem distúrbios em diferentes linhas do sistema de transmissão da CHESF, capturados por RDPs com diferentes frequências de amostragem. Para o módulo de detecção, os resultados evidenciaram possibilidade de generalização na maior parte das situações, exceto para alguns afundamentos de tensão. No módulo de classificação de falta o método forneceu resultado inadequado para uma falta fase-terra que foi classificada como fase-fase-terra.

Um esquema de proteção baseado na TDW e SVM, denominado Classificador de Faltas, foi proposto por Panigrahi e Maheshwari (2011) com o objetivo de detectar e classificar diferentes tipos de faltas em linhas de transmissão. Para avaliação do esquema de proteção proposto, um sistema de transmissão com nível de tensão 400 kV, operando na frequência de 50 Hz, com duas fontes e extensão de 128 km foi simulado, empregando o *software* PSCAD / EMTDC. Na geração do conjunto de dados necessários para treinamentos e testes, variaram-se o tipo de falta, o local de falta, o ângulo de incidência de falta e a variação do ângulo de carga. Os sinais de tensões e correntes trifásicas foram decompostos em coeficientes aproximação (A1) e coeficientes de detalhe (D1) utilizando-se *Wavelet* mãe db4. Em comparação com o período pré-falta, os coeficientes de detalhes extraídos pela TDW apresentaram energia transitória significativamente maior no período de falta, realizando-se assim a detecção. Em seguida, os valores de energia transitória de corrente foram exportados para treinamento de três SVM (fases A, B e C), indicando como saída a fase envolvida no

defeito. O conjunto de parâmetros escolhidos para os SVM foi utilizado com função *kernel* (núcleo) de Base Radial Gaussiana, $C = 10$ e $\sigma = 20$. O envolvimento da terra na falta foi identificado através da detecção da componente de sequência zero da corrente. Os resultados mostraram que o esquema proposto representa um classificador robusto para relés digitais de proteção, rápido e com precisão entre 90 e 100%.

5.3 Classificação e Localização de Faltas

Verificando a viabilidade de aplicação de Redes Neurais Artificiais para classificação e localização de falta em linhas de transmissão, com a utilização de sinais de tensões e correntes registrados em um terminal da linha, Amorim e Huais (2004) propuseram uma RNA a ser utilizada para classificação da falta e outras quatro RNAs, utilizadas para localização, uma para cada tipo de falta. Na fase de treinamento das redes, os dados de tensão e corrente foram registrados através do relé numérico modelo P442 da Alstom. No processo foram desenvolvidas diferentes arquiteturas de RNAs para a classificação e a localização de faltas, com topologia MLP e método de aprendizagem supervisionado BP, resultando em 100% de sucesso na identificação do tipo de falta e erros menores que 2% na localização do ponto de ocorrência de defeito.

Diferentes estruturas de RNAs também foram aplicadas por Gracia et al. (2005) para classificação, localização de faltas e determinação de resistências de falta em linhas de transmissão aéreas de dois terminais, com circuitos simples e duplos. Como resultado, a classificação da falta foi obtida por uma RNA que, recebendo os valores de tensão e corrente em condições pré-falta e de falta, medidos em um dos terminais da linha, determinava o tipo de falta. Já a localização das faltas permitia obter a posição do defeito a partir dos mesmos valores usados no processo de classificação, aplicados em outra RNA. Os dados, utilizados nos processos de classificação e localização foram filtrados através da técnica Transformada Rápida de Fourier. Para o processo de classificação duas topologias de RNAs foram analisadas, o MLP e *Learning Vector Quantization* (LVQ). A topologia MLP apresentou menores erros e menor tempo de treinamento supervisionado pelo algoritmo de BP com otimização de LM. Os testes envolveram seis linhas de transmissão, sendo 3 de circuitos simples e 3 de circuitos duplos. Os resultados obtidos não apresentaram erros no processo de classificação de faltas para as linhas de transmissão de circuitos simples. Já para as linhas de transmissão de circuito duplo os erros foram menores que 1%.

A classificação e a localização de faltas em linhas de transmissão foram propostas por Lout e Aggarwal (2012) a partir de medições de corrente em apenas um terminal. Um algoritmo baseado em RNAs com topologia *feedforward*, aprendizagem supervisionada BP e algoritmo de treinamento LM foi aplicado a uma linha de transmissão de 132 kV, frequência de operação 50 Hz, comprimento de 100 km, alimentada em dois terminais por fontes de tensão com capacidades de 550 MVA e 450 MVA. Para o treinamento, o sistema mencionado foi simulado através do *software* ATP, gerando um conjunto de dados necessários às entradas dos processos de classificação e localização de faltas, processados com o auxílio da Transformada de Fourier. Pelos resultados mostrou-se que a RNA1 (12-24-4) foi precisa e robusta para classificação de faltas e os valores esperados não foram afetados por mudanças de ângulos de incidência de falta. Para localização foram desenvolvidas 4 RNAs (12-24-1), uma para cada tipo de falta (RNA2: fase-terra, RNA3: bifásico, RNA4: bifásico-terra e RNA5: trifásico). Ao considerar ângulos de incidência de falta de 0° e 90°, as RNAs obtiveram resultados precisos, com erros menores que 1%. No entanto, quando o ângulo de incidência de falta foi modificado para 45°, verificou-se que as distâncias estimadas apresentavam erros de 3 quilômetros de diferença do ponto de falta, imprecisão explicada pelo fato de que as RNAs utilizadas para localização de faltas não foram treinadas com vários ângulos de incidência de falta (valores entre 0° e 90°). Posteriormente, a fim de avaliar melhor o algoritmo desenvolvido, as RNAs foram testadas considerando as seguintes variações: impedância de falta (4 Ω , 6 Ω e 10 Ω), comprimento da linha ($\pm$ 5% do comprimento da linha) e capacidade das fontes. A classificação de faltas foi imune às variações citadas e a localização apresentou erros maiores.

Silveira et al. (2017a) propuseram um algoritmo para classificar, localizar faltas e determinar resistências de faltas em linhas de transmissão com compensação em série. Para a aquisição de dados foram gerados, a partir do *software* ATP, 504 cenários de falta variando-se os locais, os tipos e as resistências de falta. Os valores de tensão e corrente obtidos nas simulações passaram pela etapa de pré-processamento, os módulos dos fasores fundamentais de 60 Hz foram extraídos e utilizados para treinamento de RNAs com topologia MLP, método de aprendizagem supervisionado BP e algoritmo de treinamento LM. A função de classificação foi realizada por uma RNA e para a execução das funções de localização de faltas e determinação das resistências de falta foram utilizadas RNAs de estrutura modular. As RNAs implementadas foram submetidas a testes com mudança do ângulo de falta para 90°, aumento do comprimento da linha e da capacitância série em 5%. Segundo os autores as redes

implementadas forneceram resultados satisfatórios, com 100% de acerto para a tarefa de classificação e erros médios de localização inferiores a 1% do comprimento da linha, mesmo diante condições não contempladas no processo de treinamento.

5.4 Detecção, Classificação e Localização

Um módulo de pré-processamento de sinais, baseado em TDW combinado com RNAs treinadas de forma supervisionada pelo algoritmo BP foi desenvolvido por Martín e Aguado (2003) para detectar, classificar e localizar faltas em linhas de transmissão. O sistema em estudo foi simulado no *software* ATP, composto por dois geradores e três linhas de transmissão em série (modelo a parâmetros distribuídos). Várias simulações foram realizadas incluindo diferentes pontos de falta (20, 40, 60, 80 e 90 km), resistência de falta (0, 10, 20, 30 e 40 Ω) e ângulos de incidência da falta (0, 20, 40 e 60°). A TDW decompunha cada sinal transitório de tensão e corrente das três fases, em duas novas ondas denominadas detalhes (sinais de alta frequência) e aproximações (sinais de baixa frequência), tendo cada onda 16 pontos por ciclo. Na sequência, as RNAs eram alimentadas com os dados denominados detalhes (três correntes e três tensões), extraídos da janela de 1/4 de ciclo, totalizando 24 dados de entrada. Na detecção a RNA possuía um neurônio de saída que indicava a existência de uma falta, apresentando um sucesso de 100%. A RNA para classificação apresentava quatro neurônios de saída, indicativos das fases (A, B, C) e do neutro envolvidos no evento de falta. Para a tarefa de localização, a rede possuía um neurônio de saída indicando o local do curto-circuito. As redes de identificação do tipo e do local da falta apresentaram erros inferiores a 1%.

Uma metodologia proposta por Jiang et al. (2011) para desenvolver um sistema de proteção em linhas de transmissão, baseada em módulos de detecção, classificação e localização de faltas simuladas e reais, foi capaz de analisar faltas ocorridas entre dois barramentos equipados com unidades de medição de correntes e tensões trifásicas. A detecção indicava a presença de falta em tempo real no sistema de energia, a partir do cálculo das componentes de sequência negativa dos sinais de corrente e tensão, com o auxílio de algumas funções matemáticas (triangulares e Heaviside). Referente à classificação, realizava-se a medição tensões de fase e correntes de linha sob a condição de falta ao longo de um ciclo. Estes sinais, analisados com o auxílio da Transformada de *Wavelet* e Máquina de Vetores de Suporte, indicavam o tipo de falta ocorrido (fase-terra, bifásico, bifásica terra, trifásico, trifásica terra e alta impedância). Por fim, o módulo de localização de faltas determinava o ponto de

ocorrência, utilizando um conjunto de Redes Neurais de Estruturas Adaptativas (RNEA), que possuíam técnicas de treinamento *runtime*. Para uma linha de transmissão de dois terminais, o sistema de proteção apresentou 99,9% de precisão na detecção de falta, 99,84% e 99,9% na sensibilidade e especificação da classificação da falta e erro médio de 0,54% na localização da falta. Para um segundo sistema estudado (IEEE 14 barramentos), o sistema de proteção apresentou 99,9% de precisão na detecção de falta, 99,73% e 99,9% na sensibilidade e especificação da classificação da falta e erro médio de 0,61% na localização da falta. De acordo com os resultados obtidos, o sistema de proteção proposto possuía tempo de resposta global rápido (aproximadamente 1,28 ciclos).

Um método de localização de faltas em linhas de transmissão, com aplicação de uma técnica de otimização mono-objetivo, utilizando o algoritmo Elipsoidal com dados de tensão e corrente dos dois terminais foi apresentado por Silveira et al. (2017b). No processo, a detecção da falta foi efetivada através da Transformada *Wavelet* Estacionária e do Teorema de Parseval e a classificação da falta foi realizada por meio de RNAs. A função objetivo elaborada pelos autores foi definida para os modelos de linha curta e longa da linha de transmissão. Através da minimização, as funções fornecem a distância ao ponto de defeito e o valor da resistência de falta. Várias situações de curto-circuito foram simuladas no software ATP, com variações no tipo de falta, no local e na resistência de falta. O processo também foi aplicado à faltas reais ocorridas no sistema elétrico brasileiro e os resultados foram comparados aos valores obtidos por um algoritmo clássico de localização de faltas. A proposta apresentada alcançou os objetivos pré-estabelecidos, com erros médios de localização de falta nos casos reais inferiores a 2% do comprimento da linha.

Neste capítulo foi apresentada uma revisão da literatura a partir de diferentes estudos sobre detecção, classificação e localização de faltas em linhas de transmissão. Verificou-se que a *Transformada de Wavelet* discreta em associação com o teorema de Parseval, tem sido um método matemático bastante utilizado em processos de detecção de faltas. Nos processos para classificação, localização e determinação das resistências de faltas, os estudos apontam para o uso preferencial de inteligência computacional com a utilização de RNAs em faltas simuladas. Há que se destacar que o estudo da produção intelectual relacionado com a temática desta dissertação evidenciou a carência de textos envolvendo situações reais de faltas em linhas de transmissão, o mesmo ocorrendo para pesquisas que utilizam técnicas de ONL no processo de localização de faltas.

Capítulo 6

Rotinas de Pré-processamento de Dados

Os estágios de um algoritmo de localização de faltas podem variar conforme as informações requeridas, sendo que, neste trabalho, são utilizadas as rotinas listadas na Figura 6.1. Inicialmente, é necessária a obtenção dos dados digitalizados de tensões e correntes que, antes de serem utilizados nos algoritmos, necessitam passar pelas rotinas de pré-processamento. Neste capítulo, são descritas as técnicas aplicadas aos dados, desde sua entrada até o momento da utilização dos algoritmos que identificam o tipo de falta ocorrida e a que distância o evento ocorreu.




Figura 6.1: Algoritmo de localização de faltas.

Os dados obtidos por simulações ou junto aos registradores instalados nas subestações não se encontram representados de uma forma adequada e também não possuem todas as informações necessárias para sua utilização imediata nos algoritmos de classificação e de localização. É necessário submetê-los às etapas de filtragem digital passa-baixa, redução do número de pontos por ciclo e estimação dos fasores de frequência fundamental.

A localização de faltas é um procedimento que pode ser executado *off-line*, não estando sujeita à limitação de tempo imposta pela proteção do sistema. Neste sentido, é possível desenvolver ou melhorar os algoritmos que, mesmo exigindo maior esforço computacional, possam fornecer o local da falta com maior precisão, viabilizando também, pela análise das ocorrências, melhor entendimento das contingências do sistema elétrico.

As etapas do pré-processamento de dados são mostradas na Figura 6.2.




Figura 6.2: Etapas do pré-processamento de dados.

6.1 Entrada dos Dados de Tensão e Corrente

Os dados relativos às tensões e às correntes do sistema elétrico monitorado são obtidos de um arquivo. No caso de faltas simuladas, provêm de um arquivo de saída do ATP ou de outro formato semelhante. Em casos reais, os dados registrados pelos RDPs são fornecidos em formato COMTRADE, como descrito em (IEEE, 1999). Destes arquivos devem ser previamente removidas as linhas referentes a quaisquer comentários, mantendo-se somente os registros necessários. Na Figura 6.3 apresenta-se parte de um arquivo de dados de entrada onde a primeira coluna refere-se ao número da amostra, a segunda, aos tempos (em segundos), da terceira à quinta, tensões de fase (em V) e da sexta à oitava, correntes (em A).

0	0.0	271298.544	-45574.533	-225724.01	155.824047	-30.955411	-124.86864
1	.1E-4	270904.511	-44492.413	-226412.1	155.618533	-30.344249	-125.27428
2	.2E-4	270506.628	-43409.66	-227096.97	155.410807	-29.732656	-125.67815
3	.3E-4	270104.9	-42326.291	-227778.61	155.200872	-29.12064	-126.08023
4	.4E-4	269699.334	-41242.319	-228457.01	154.988731	-28.50821	-126.48052
5	.5E-4	269289.935	-40157.762	-229132.17	154.774388	-27.895376	-126.87901
6	.6E-4	268876.708	-39072.634	-229804.07	154.557845	-27.282144	-127.2757
7	.7E-4	268459.66	-37986.951	-230472.71	154.339106	-26.668525	-127.67058
8	.8E-4	268038.797	-36900.728	-231138.07	154.118173	-26.054527	-128.06365
9	.9E-4	267614.124	-35813.98	-231800.14	153.89505	-25.440159	-128.45489
10	.1E-3	267185.648	-34726.723	-232458.92	153.669739	-24.825429	-128.84431
11	.11E-3	266753.374	-33638.973	-233114.4	153.442245	-24.210346	-129.2319
12	.12E-3	266317.31	-32550.745	-233766.56	153.21257	-23.594919	-129.61765
13	.13E-3	265877.46	-31462.054	-234415.41	152.980717	-22.979157	-130.00156
14	.14E-3	265433.832	-30372.916	-235060.92	152.74669	-22.363068	-130.38362
15	.15E-3	264986.431	-29283.346	-235703.08	152.510492	-21.746661	-130.76383

Figura 6.3: Tensões e correntes em um dos terminais de uma linha de transmissão.

6.2 Filtragem Passa-Baixa

Conforme destacado por Phadke e Thorp (1998), os valores de falta de correntes e tensões podem apresentar transitórios de altas frequências, que conduzem a erros na localização da falta, sendo essencial um correto pré-processamento destes dados.

Inicialmente, para o tratamento dos dados, como realizado por Pereira e Cruz (1999), pode-se utilizar uma filtragem passa-baixa, sendo geralmente utilizado o filtro de Butterworth de 2ª ordem, em razão de sua simplicidade, efetividade e por ser um dos mais utilizados na área, com frequência de corte de 100 Hz.

Um exemplo desse processo é representado na Figura 6.4, para uma falta da fase B para a terra (BT) ocorrida a 50 km do terminal de uma linha trifásica. As altas frequências das tensões foram eliminadas ao serem submetidas ao filtro.




Figura 6.4: Ondas de tensões de entrada e filtradas para um curto-circuito BT.

6.3 Redução do Número de Pontos por Ciclo

No processo de localização de faltas com fasores, os dados são utilizados com uma frequência de amostragem menor que as disponibilizadas nos arquivos de entrada. Em faltas reais as taxas de amostragem são diferentes, dependentes das características do equipamento utilizado e, no caso de faltas simuladas, do valor escolhido para gerar o arquivo de saída.

Após a filtragem, a redução dos pontos é realizada padronizando-se a frequência de amostragem em 960 Hz, o que equivale a 16 pontos por ciclo. O processo ocorre de acordo com a Equação 6.1, onde NPC indica o número de pontos amostrados por ciclo da frequência fundamental e f_0 a frequência fundamental dada em Hz,

$$f_a = NPC f_0. \quad (6.1)$$

Na Figura 6.5 é apresentada uma onda de entrada amostrada em 100000 Hz e a onda resultante da redução da taxa para 960 Hz.




Figura 6.5: Ondas de tensão original e com a taxa de amostragem reduzida.

6.4 Estimação dos Fasores Fundamentais

A ocorrência de uma falta na linha de transmissão causa o aumento da corrente e a mudança da tensão, caracterizando alterações nestas variáveis.

A localização de faltas utilizando informações da frequência fundamental requer a correta extração dos fasores fundamentais das ondas de entrada. Contudo, mesmo após a filtragem passa-baixa, os valores de corrente e tensão das ondas de falta podem apresentar componente contínua e algum conteúdo harmônico, que fazem com que a estimativa da distância da falta seja influenciada negativamente.

Nesta dissertação, as técnicas apresentadas têm como característica a utilização de fasores de frequência fundamental de tensão e corrente, obtidos a partir de simulações e de dados reais dos terminais da linha. Para a determinação dos fasores de frequência fundamental utilizou-se o processo proposto por Pereira e Cruz (1999), que representa uma variação do método dos erros mínimos quadrados de Sachdev e Baribeau (1979). Na Figura 6.6 são apresentadas as ondas de tensão e corrente de uma falta real tipo BT que se inicia no instante 0,29 s. A abertura do disjuntor ocorre no instante 0,36 s.




Figura 6.6: Ondas de tensão e corrente de uma falta real BT após redução da frequência de amostragem e aplicação do filtro passa-baixa.

Na Figura 6.7 e 6.8 tem-se a amplitude e a fase dos fasores estimados relativos às ondas de tensão e corrente da Figura 6.6.




Figura 6.7: Amplitude e fase dos fasores de tensão.




Figura 6.8: Amplitude e fase dos fasores de corrente.

6.5 Seleção dos Fasores para Aplicação nos Algoritmos

O conceito de fasor está intimamente relacionado à condição de regime permanente senoidal, sendo importante selecionar, no período de falta, quais fasores estimados serão utilizados para a localização do defeito. Nos instantes iniciais de curto-circuito os valores estimados dos fasores apresentam oscilações, devido ao fato da janela de dados (de um ciclo) do estimador de fasores apresentar valores pré-falta e de falta, comprometendo as estimativas de localização. Assim, nesta dissertação, conforme ilustrado na Figura 6.9, a partir do instante de início de curto-circuito, desprezam-se os fasores iniciais, utilizando-se os restantes anteriores à abertura do disjuntor.




Figura 6.9: Processo de seleção de fasores para a localização de falta.

6.6 Detecção da Falta

Os algoritmos implementados nesta dissertação possuem uma etapa em comum, denominada pré-processamento. Essa etapa é responsável por identificar o instante de início da falta, determinar módulos e ângulos das fontes equivalentes e gerar os cenários de falta através do software ATP, necessários para treinamento das redes neurais artificiais e validação dos métodos utilizados.

Para a localização de faltas, é necessário que se determine seu instante de início, obtendo dois conjuntos de dados bem definidos, caracterizados pelos períodos pré-falta e de falta. Com o desenvolvimento das tecnologias de proteção de SEP, diferentes técnicas puderam ser

desenvolvidas para esta função. Após a obtenção dos sinais trifásicos de corrente e tensão (sinais de entrada) registrados durante um evento de falta, procede-se com os processos de redução do número de pontos por ciclo, normalização e detecção de falta.

Na detecção pelos métodos baseados em análise de sinais, ferramentas matemáticas como a Transformada *Wavelet* estacionária em seu primeiro nível de decomposição, em conjunto com a energia de Parseval, utilizada por Silveira et al. (2017b), são empregadas para extrair os transitórios de alta frequência das ondas de entrada para um sinal de corrente, conforme ilustrado na Figura 6.10.




Figura 6.10: Detecção do instante de falta através da energia de Parseval e do coeficiente de decomposição cD1 da *Wavelet*.

O detector de falta, além de possibilitar a separação dos sinais em conjuntos de dados pré-falta e de falta é também relevante para definir o instante da ocorrência da falta (ângulo de incidência de falta). Para a realização da detecção, há também métodos baseados em sistemas inteligentes, que entre outras técnicas, utilizam RNAs, Lógica *Fuzzy* ou Redes *Neurofuzzy*, como nos trabalhos de Gayathri e Kumarappan (2008), Dash et al. (2000) e Wang e Keerthipala (1998). Neste trabalho o instante de falta é considerado dado de entrada, sendo fornecido aos algoritmos.

Capítulo 7

Classificação e Localização de Faltas

Neste capítulo, apresenta-se a aplicação de Redes Neurais Artificiais e de técnicas de Otimização Não Linear em algoritmos desenvolvidos para classificar, localizar faltas e determinar resistências de faltas em linhas de transmissão. São explicitados os procedimentos efetivados na condução dos objetivos específicos propostos para o estudo. Inicialmente, são mostradas a descrição das características do sistema elétrico selecionado para o estudo e dos cenários de falta a serem utilizados. Na sequência, detalha-se a forma como os sinais simulados e reais foram obtidos e os métodos matemáticos e computacionais desenvolvidos os quais possibilitaram, a partir de um arquivo de entrada, a caracterização do evento. Finalizando o capítulo, apresenta-se o método analítico utilizado como referência para a validação dos métodos propostos.

7.1 O Sistema Elétrico e a Caracterização dos Cenários de Falta

Para as simulações e análises de situações reais de falta foi considerada uma linha de transmissão real de 74,4 km e 345 kV de uma concessionária de energia elétrica brasileira, modelo RL série, a mesma utilizada por Silveira et al. (2017b). Os parâmetros dessa linha e os dados de suas fontes equivalentes⁴ terminais encontram-se listados na Tabela 7.1.

Tabela 7.1: Parâmetros da linha e fontes equivalentes para as faltas simuladas.

Elemento	Sequência Positiva		Sequência Zero	
	$r_1 (\Omega)$	$x_1 (\Omega)$	$r_0 (\Omega)$	$x_0 (\Omega)$
Linha	2,69	27,97	26,94	106,58
Fonte Local	4,0007	34,110	4,0692	33,603
Fonte Remota	6,3318	53,845	2,7307	39,363

Para o treinamento e validação das RNAs de classificação, localização da falta e indicação da resistência de falta, e também para a validação dos algoritmos de ONL é necessário um conjunto de cenários que contemplem diversas possibilidades de falta no sistema elétrico

⁴ Os valores das impedâncias equivalentes das fontes foram obtidos a partir de um programa de curto-circuito da concessionária.

utilizado. Nesse sentido, o banco de dados de referência para as experimentações foi simulado pelo programa ATP a partir dos parâmetros da linha de transmissão real selecionada para o estudo.

Visando explorar as características do fenômeno de ocorrência de falta, na obtenção dos 1672 cenários de treinamento e dos 182 cenários de validação dos métodos, variaram-se o ponto de defeito, o tipo de falta e a resistência de falta, contemplando casos de faltas do tipo monofásica-terra (FT), bifásicas-terra (FFT), bifásicas (FF) e trifásicas (FFF), como especificado na Tabela 7.2. Destaca-se que para sistemas reais, existem características difíceis de serem consideradas em um programa de simulação, como o comportamento não linear da resistência de falta e o modelo exato do solo e da linha de transmissão.

Tabela 7.2: Variáveis de composição dos cenários de falta.

Treinamento RNA	Local de Falta (km)	Casos FT - FFT - FF - FFF Faltas simuladas a cada 5% da linha			Total 19 locais	
	Resistência de Falta (Ω)	Casos FT - FFT 0 - 4 - 8 - 12 - 16 - 20 - 24 - 28 - 32 - 36			Caso FF - FFF 0 - 1 - 2 - 3 - 4 - 5 - 6	
	Número de Casos	Casos FT e FFT 2·3·10·19 = 1140	Caso FF 3·7·19 = 399	Caso FFF 1·7·19 = 133	Total 1672 cenários	
Validação: todos os métodos	Dados Gerais das Validações					
	Local de Falta (km)	Casos FT - FFT - FF - FFF 4 - 11 - 26 - 40 - 50 -59 - 68			7 locais	
	Resistência de Falta (Ω)	Casos FT - FFT 10, 21, 31		Caso FF - FFF 2,5 e 4,5	5 valores de resistência	
	Ponto de referência para a inicialização dos métodos de otimização: (L, R_F) = (40, 60)					
	Método	Número de Casos				Total
		FT	FFT	FF	FFF	
	Johns	3·3·7 = 63	3·3·7 = 63	3·2·7 = 42	1·2·7 = 14	182 cenários
	Quasi-Newton	3·3·7 = 63	3·3·7 = 63	3·2·7 = 42	1·2·7 = 14	182 cenários
	Elipsoidal	3·3·7 = 63	3·3·7 = 63	3·2·7 = 42	1·2·7 = 14	182 cenários
	RNA	40·3·3·7=2520	40·3·3·7=2520	40·3·2·7=1680	40·1·2·7 = 560	182 cenários
Genético	40·3·3·7=2520	40·3·3·7=2520	40·3·2·7=1680	40·1·2·7 = 560	182 cenários	
Total de execuções					15106	

Para a obtenção de dados simulados, os valores das Tabelas 7.1 e 7.2 foram inseridos no ATP, conforme indicado na Figura 7.1. Os índices 1 e 2 encontram-se associados, respectivamente, às subestações 1 e 2 dos terminais da linha de transmissão, SE à fonte e Z_{eq} a impedância equivalente, 52 ao código representativo de um disjuntor, Line RL à impedância da linha (modelo impedância série) dos terminais ao local do curto-circuito e R_F à resistência de falta no local de curto-circuito.




Figura 7.1: Modelo do ATP para simulações de curto-circuito.

Como não existem registros reais de todas estas situações propostas, tais condições são simuladas nessa etapa. Combinando recursos do ATP e do MatLab foram gerados os cenários de falta para o treinamento e para a validação, como indicado na Tabela 7.2. Para a efetivação do processo, utilizou-se um método para automatizar a tarefa. O método consiste em usar arquivos com extensão .bat e permite a simulação em batelada através do *software* ATP, como sugerido por Su et al. (2008).

Para a validação, foi possível também para esta linha a realização de dois testes com casos reais de curto-circuito, cujas amostras de tensão e corrente foram obtidas de uma concessionária brasileira de energia elétrica.

O banco de dados gerado pelo conjunto de cenários de treinamento das RNAs de classificação e de localização, ou criado para a validação de todos os métodos utilizados ou ainda disponibilizado pela concessionária, deve ser submetido às etapas indicadas na Figura 7.2.




Figura 7.2: Etapas do processo de classificação e localização de faltas em linhas de transmissão.

7.2 Classificação da Falta

Esta etapa tem a função de determinar o tipo de curto-circuito ocorrido e as fases envolvidas. Na Figura 7.3 detalham-se os tipos de faltas investigadas, onde o local da falta (F), a distância (d) do terminal (S) e a resistência no local da falta (R_F) são representadas.




Figura 7.3: Modelos de curto-circuito.

As etapas do processo para classificação da falta são especificadas na Figura 7.4.




Figura 7.4: Etapas do processo para classificação da falta.

Para a classificação das faltas, foi aplicada uma RNA treinada a partir de dados do terminal emissor da linha de transmissão, como apresentado por Silveira et al. (2017b). Nas entradas da RNA foram empregadas as médias dos módulos dos fasores das tensões V_A , V_B , V_C e das correntes I_A , I_B e I_C resultantes do pré-processamento.

A RNA *Multilayer Perceptron* foi implementada utilizando o *Toolbox Neural Network* do MatLab, como descrito por Demuth e Beale (2015), com método de aprendizagem supervisionado *Backpropagation* e algoritmo de treinamento Levenberg Marquardt. O treinamento foi encerrado quando o erro médio quadrático (MSE) atingiu um valor inferior a 1×10^{-10} ou 1000 iterações. Sua arquitetura, indicada na Figura 7.5, foi determinada de forma experimental, sendo composta por 6 entradas, 16 neurônios na primeira camada oculta, 12 neurônios na segunda camada oculta e 4 neurônios na camada de saída. A função de ativação utilizada foi a tangente-sigmoide.




Figura 7.5: Estrutura da RNA para classificação da falta.

Para o treinamento da rede de classificação foram utilizados 570 casos de faltas fase-terra e fase-fase-terra, 399 casos de faltas fase-fase e 133 casos de faltas trifásicas, totalizando 1672 cenários.

Na validação da RNA, convencionou-se que as saídas S_i observadas com valores menores que 0,5 indicariam uma situação de funcionamento normal do sistema e, as saídas com $S_i \geq 0,5$ uma situação de curto-circuito. Para alguns casos simulados e para dois casos reais, são apresentadas as respostas esperadas e as saídas obtidas na rede neural em função do tipo de falta na etapa de validação, conforme mostrado na Tabela 7.3.

Tabela 7.3: Saídas da rede neural em função do tipo de falta.

Faltas		Esperado				Saída			
		S ₁	S ₂	S ₃	S ₄	S ₁	S ₂	S ₃	S ₄
Simuladas	AT	1	0	0	1	1.0000	0.0001	0.0000	1.0020
	AB	1	1	0	0	1.0000	1.0000	0.0000	0.0179
	ABT	1	1	0	1	1.0000	1.0000	0.0000	0.9990
	ABC	1	1	1	0	1.0000	1.0000	1.0000	-0.0001
Reais	AT	1	0	0	1	1.0000	0.0000	0.0000	1.0001
	BT	0	1	0	1	0.0003	0.9999	0.0000	0.9986

A localização de faltas e determinação da resistência de falta ocorre após a etapa de classificação e, nesta pesquisa, foram obtidas a partir da utilização de RNAs e também pela utilização de três técnicas de ONL mono-objetivo.

7.3 RNAs para a Localização da Falta e Determinação da Resistência de Falta

Aplicaram-se RNAs para localização da falta e determinação da resistência de falta, treinadas separadamente, conforme o tipo de curto-circuito: fase-terra, fase-fase, fase-fase-terra e trifásico. Neste sentido, foram utilizadas redes modulares a serem ativadas de acordo com a saída da rede de classificação de falta. A Figura 7.6 ilustra o processo.

Assim como na rede de classificação, as RNAs de localização e determinação da resistência de falta foram implementadas a partir do *Toolbox Neural Network* do MatLab como realizado por Demuth e Beale (2015), com método de aprendizagem supervisionado *Backpropagation* e algoritmo de treinamento Levenberg Marquardt. O treinamento foi encerrado quando se atingiu o erro médio quadrático com valor inferior a 1×10^{-10} ou 1000 iterações foram verificadas.

Para essas redes foi utilizada a função de ativação tangente sigmoide, sendo a topologia para o módulo de localização e de determinação da resistência de falta determinada de forma experimental, possuindo duas camadas ocultas com 30 e 20 neurônios. Inicialmente, os mesmos fasores de entrada da etapa de classificação foram utilizados como dados de entrada

para a localização da falta e determinação da resistência de falta, porém cada módulo foi treinado separadamente de acordo com o tipo de falta.




Figura 7.6: Processo de localização e determinação da resistência de falta por RNAs.

Conforme a Figura 7.7, utilizando-se dados de um dos terminais da linha, seis valores de tensões e correntes (V_A , V_B , V_C) e (I_A , I_B , I_C) foram aplicados às entradas de cada rede de localização da falta, que forneceu como saída a distância (d) da falta, em quilômetros, a partir

do ponto de medição. Estrutura interna semelhante foi utilizada para as RNAs de obtenção da resistência de falta (R_F).




Figura 7.7: Estrutura modular para determinação da localização e da resistência de falta - RNAs com dados de um terminal da linha de transmissão.

O método analítico de Johns e Jamali (1990) também foi implementado e aplicado aos casos de validação para comparações de seus resultados com os fornecidos pelas RNAs. Nesse método, utilizado como referência, o local da falta é obtido a partir de funções hiperbólicas, descritivas do circuito elétrico, capazes de representar as variações de tensão e corrente ao longo da linha transmissão a partir de seus dois terminais.

Para comparar os resultados de localização das redes implementadas com aqueles fornecidos pelos métodos de ONL e pelo método analítico de Johns e Jamali (1990), também foram implementadas RNAs que receberam como entrada dados dos dois terminais da linha de transmissão. Nesse sentido, como indicado na Figura 7.8, as RNAs de localização de falta e de determinação da resistência de falta foram ativadas de forma modular, por tipo de falta, e utilizaram como dados de entrada os valores de tensão e corrente advindos do terminal local (L) e do terminal remoto (R) da linha de transmissão.




Figura 7.8: Estrutura modular para determinação da localização e da resistência de falta - RNAs com dados dos dois terminais da linha de transmissão.

Para a comparação entre as médias e as variâncias dos valores de localização da falta e de resistência de falta das RNAs alimentadas com dados de um terminal e de dois terminais da linha, devido às características estocásticas do experimento, como descrito por Montgomery e Runger (2016), para cada simulação foram realizadas 40 execuções das RNAs. Os erros de localização obtidos pelas RNAs, tomados em relação ao comprimento total da linha de transmissão, foram identificados e os resultados representados nas Figuras 7.9 e 7.10.




Figura 7.9: RNAs para a localização de falhas: erros em função do tipo de falta.




Figura 7.10: RNAs para a localização de faltas: erros em função do número de terminais.

Pelos resultados apresentados nas Figuras 7.9 e 7.10 é possível verificar, para todos os tipos de faltas simuladas, que o erro cometido pelas RNAs que utilizam dados dos 2 terminais da linha é menor que o erro cometido pelas redes que utilizam dados de apenas um dos terminais. Contudo, torna-se relevante ponderar que, em virtude das características práticas do processo de localização de faltas, o custo computacional advindo da utilização do dobro de dados de entrada não se justifica frente à melhoria dos erros percentuais de simulação situados na terceira casa decimal.

7.4 Métodos de Otimização Não Linear para a Localização da Falta e Determinação da Resistência de Falta

Formalmente, as diferentes técnicas de minimização de uma função objetivo $f: D_f \subset \mathbb{R}^n \rightarrow \mathbb{R}$, procuram identificar uma solução particular $x^* \in D_f \subset \mathbb{R}^n$ tal que para todo $x \in D_f$, $f(x^*) \leq f(x)$.

A formulação de um problema de ONL, como descrito anteriormente no Capítulo 2, envolve a composição de uma função objetivo, que relacione as diferentes variáveis consideradas em cada contexto. Uma vez construído o modelo do problema, chega-se à formulação característica do problema de otimização, consistindo na identificação da solução que minimize o valor da função objetivo, de forma que, respeitadas as restrições do problema, nenhuma outra solução atribua um valor menor à função objetivo.

As funções objetivo $f(x, R_f)$ propostas por Silveira et al. (2017b) possuem como variáveis o local da falta e a resistência de falta, fundamentadas nas correntes e tensões dos terminais da linha de transmissão e dependem dos diferentes tipos de faltas existentes.

Como exemplo para a obtenção de uma das funções objetivo em uma linha de transmissão trifásica, considera-se uma falta AT, representada esquematicamente no diagrama da Figura 7.11. Os subscritos 0, 1 e 2 indicam, respectivamente, as grandezas de sequência zero, positiva e negativa; Z a impedância longitudinal unitária em Ω/km da linha; x a distância do terminal S ao local de falta; ℓ a extensão total da linha de transmissão; I_S , I_R , V_S e V_R as respectivas correntes e tensões nos terminais S e R.




Figura 7.11: Circuito para uma falta AT.

Aplicando-se a lei de Kirchhoff para as tensões do ponto A até o ponto B tem-se as Equações 7.1 a 7.8

$$V_{S0} + V_{S1} + V_{S2} - xZ_1(I_{S1} + I_{S2}) - xZ_0I_{S0} - 3R_F(I_{S1} + I_{R1}) = 0 \quad (7.1)$$

$$V_{S0} + V_{S1} + V_{S2} - xZ_1(I_{S0} + I_{S1} + I_{S2}) - xI_{S0}(Z_0 - Z_1) - 3R_F(I_{S1} + I_{R1}) = 0 \quad (7.2)$$

$$V_{S0} + V_{S1} + V_{S2} = V_S \quad (7.3)$$

$$I_{S0} + I_{S1} + I_{S2} = I_S \quad (7.4)$$

$$V_S - xZ_1 \left(I_S + \frac{Z_0 - Z_1}{Z_1} I_{S0} \right) - 3R_F(I_{S1} + I_{R1}) = 0 \quad (7.5)$$

Como V_S^M e V_S^C representam as tensões medida e calculada em S

$$V_S^M - V_S^C = 0 \quad (7.6)$$

$$V_S^C = xZ_1 \left(I_S + \frac{Z_0 - Z_1}{Z_1} I_{S0} \right) + 3R_F(I_{S1} + I_{R1}) \quad (7.7)$$

Tomando-se o quadrado do módulo desta última equação, chega-se em:

$$F(x, R_F) = Re \left(\left(V_S - xZ_1 \left(I_S + \frac{Z_0 - Z_1}{Z_1} I_{S0} \right) - 3R_F(I_{S1} + I_{R1}) \right) \right)^2 + Im \left((V_S - xZ_1 \left(I_S + \frac{Z_0 - Z_1}{Z_1} I_{S0} \right) - 3R_F(I_{S1} + I_{R1})) \right)^2 \quad (7.8)$$

Na Tabela 7.4 são apresentadas as funções objetivo de duas variáveis $F(x, R_F)$ segundo o tipo de falta, conforme apresentado por Silveira et al. (2017b). Essas funções expressam a soma das quedas de tensão no circuito fechado em falta que, de acordo com a lei de Kirchhoff, se anulam para o local da falta e o valor da resistência de falta, ou seja, $F(x, R_F) = 0$.

Tabela 7.4: Funções objetivo.

Falta	$F(x, R_F)$
AT, BT, CT	$ V_S - xZ_1 \left(I_S + \left(\frac{Z_0 - Z_1}{Z_1} \right) I_{S0} \right) - 3R_F(I_{S1} + I_{R1}) ^2$
AB, BC, CA	$ V_{S1} - V_{S2} - xZ_1(I_{S1} + I_{S2}) - 2R_F(I_{S1} + I_{R1}) ^2$
ABT, BCT, CAT	$ V_{S1} - V_{S0} - xZ_1 I_{S1} + xZ_0 I_{S0} + 3R_F(I_{S0} + I_{R0}) ^2$
ABC	$ V_{S1} - xZ_1 I_{S1} - R_F(I_{S1} + I_{R1}) ^2$

Após as etapas de detecção e de classificação da falta, foram implementados dois algoritmos de otimização determinísticos (Quasi-Newton e Elipsoidal) e um não determinístico (Genético Real Polarizado). Minimizando-se a função objetivo, de acordo com o tipo de falta, foi obtida

a distância até o ponto de ocorrência do curto-circuito em relação ao terminal da linha e também o valor da resistência de falta.

Vale ressaltar que especificamente, no método AGRP aplicado ao problema de localização de faltas em linhas de transmissão, um indivíduo corresponde ao ponto (x, R_F) , representando respectivamente o local e a resistência de falta. A cada geração, os indivíduos fornecem um conjunto de soluções da função objetivo descritiva do processo e, após serem efetivadas as etapas de cruzamento, mutação, avaliação e seleção em função da minimização de $f(x, R_F)$, contribuem para a determinação de uma nova população mais adaptada ao problema de localização.

As etapas necessárias para a efetivação da localização de faltas a partir da minimização da função objetivo associada ao tipo de falta ocorrido podem ser acompanhadas pela Figura 7.12.




Figura 7.12: Processo de localização e determinação da resistência de falta por Otimização.

Os parâmetros utilizados para a execução dos métodos encontram-se registrados na Tabela 7.5.

Tabela 7.5: Parâmetros utilizados para a execução dos métodos de otimização.

Algoritmo de Quasi-Newton
• $[a, b] = [0, 1]$: cálculo do passo do método da seção áurea • $eps = 0,001$: erro de tolerância do gradiente • $kmax = 2000$: número máximo de iterações • $\gamma = 0,5$: parâmetro da combinação convexa dos métodos de Quasi-Newton
Algoritmo Elipsoidal
• $eps = 0,001$: erro de tolerância em relação aos vetores x
Algoritmo Genético Real Polarizado
• Centro da circunferência gerada: (40, 60) • Raio de desvio padrão: 30 • Número de indivíduos: 200 • Número máximo de gerações: 50 • Número máximo de gerações sem melhoria: 50 • Tolerância do vetor de parâmetro: 0 • Tolerância da função objetivo: 0 • Raio de nicho: 0,8 • Número de nichos: 20
Ponto de referência para a inicialização dos métodos de ONL: $(x, R_F) = (40, 60)$

7.5 Método Analítico de Johns e Jamali para a Localização da Falta

O método elaborado por Johns e Jamali (1990) foi utilizado como referência para o estudo desenvolvido nesta dissertação. No artigo, os autores apresentam um método de localização de faltas em linhas de transmissão utilizando fasores de tensão e corrente dos dois terminais. Baseia-se no princípio de que as tensões calculadas ao longo da linha de transmissão, a partir dos terminais emissor e receptor, são iguais no ponto de falta.

Ao considerar uma linha monofásica com parâmetros distribuídos, conforme a Figura 7.13, a tensão no ponto de falta F pode ser expressa em função das tensões e correntes medidas nas extremidades da linha, de acordo com as Equações 7.9 e 7.10,




Figura 7.13: Circuito em falta.

$$V_F = \cosh(\gamma x) V_S - Z_C \sinh(\gamma x) I_S \quad (7.9)$$

$$V_F = \cosh(\gamma(\ell - x)) V_R - Z_C \sinh(\gamma(\ell - x)) I_R \quad (7.10)$$

em que x representa a distância do local da falta em relação à barra emissora S , ℓ é o comprimento da linha de transmissão, V_F a tensão no ponto de falta, V_S tensão na barra emissora S , V_R a tensão na barra receptora R , I_S a tensão na barra emissora S , I_R a tensão na barra receptora R , Z_C a impedância característica e γ a constante de propagação. As grandezas Z_C e γ são calculadas a partir dos parâmetros da linha de transmissão, dadas pelas Equações 7.11 e 7.12,

$$Z_C = \sqrt{\frac{Z}{Y}} = \sqrt{\frac{R + j\omega L}{G + j\omega C}} \quad (7.11)$$

$$\gamma = \sqrt{ZY} \quad (7.12)$$

Sendo R e L a resistência e indutância longitudinais unitárias, G e C a condutância e a capacitância transversais unitárias. Igualando-se as equações (7.9) e (7.10) e rearranjando os termos, determina-se a distância para a falta, expressa pela Equação 7.13.

$$x = [\tanh^{-1}(-B/A)] / \gamma$$

$$A = Z_C \cosh(\gamma \ell) I_R - \sinh(\gamma \ell) V_R + Z_C I_S \quad (7.13)$$

$$B = \cosh(\gamma \ell) V_R - Z_C \sinh(\gamma \ell) I_R - V_S$$

Em linhas trifásicas, os valores de sequência positiva podem ser utilizados para a solução do problema, eliminando as incertezas dos parâmetros de sequência zero. A distância é calculada independentemente do tipo de falta e das impedâncias das fontes.

Capítulo 8

Resultados

Conhecidas as características do evento de ocorrência de um curto-circuito em linhas de transmissão, as etapas necessárias para a caracterização da falta e os algoritmos desenvolvidos para a classificação do tipo de defeito, a localização do local de falta e a determinação da resistência de falta associada, este capítulo é destinado à apresentação dos resultados obtidos pela execução das Redes Neurais Artificiais, dos métodos de Otimização Não Linear (Quasi-Newton, Elipsoidal e AGRP) e do método de Johns e Jamali a partir dos arquivos para validação apresentados anteriormente na Tabela 7.2.

As funções objetivo descritivas do processo são mono-objetivo com duas variáveis reais, dadas por $f(x, R_F)$, em que x representa a estimativa fornecida para o local de falta e R_F a resistência de falta para qual o curto-circuito ocorreu. O gráfico da função objetivo de um evento de falta AT, ocorrido a 45 km, com resistência de falta de 20 Ω , para a linha de 74,4 km, é apresentado na Figura 8.1.




Figura 8.1: Função objetivo: Falta AT (45 km, $R_F = 20 \Omega$).

Para uma falta ocorrida a 40% do terminal emissor da linha de transmissão (29,76 km do terminal local) com resistência de falta de 20 Ω , os gráficos das buscas para x e R_F , obtidos a partir das execuções dos algoritmos, encontram-se representados nas Figuras 8.2, 8.3 e 8.4.




Figura 8.2: Local e resistência de falta - Quasi-Newton.




Figura 8.3: Local e resistência de falta - Elipsoidal.




Figura 8.4: Local e resistência de falta - AGRP.

A execução computacional de um processo estocástico é efetivada por um número finito de execuções, tratadas a partir de uma técnica que permita generalização para os demais pontos. Nesse sentido, para cada um dos 182 cenários de validação de falta das simulações de curto-circuito referentes às RNAs e ao AGRP, detalhados na Tabela 7.2, foram realizadas 40 execuções.

Na Tabela 8.1 é registrado o tempo de execução demandado por cada método desenvolvido, considerando-se a localização de uma falta AT, simulada na linha de 74,4 km, ocorrida a 45 km, com resistência de falta de 20 Ω . Destaca-se que o tempo considerado para a RNA e para o AGRP corresponde à média de tempo das 40 execuções dos métodos.

Tabela 8.1: Tempo de execução dos métodos para a localização de um evento de curto-circuito.

Aspecto Computacional	RNA	Quasi-Newton	Elipsoidal	AGRP	Johns
Tempo de execução (s)	579	0,7	0,8	16	0,6

A seleção dos parâmetros de entrada do algoritmo AGRP envolveu testes experimentais, entre eles, como exemplificado na Figura 8.5, a convergência máxima, mínima e média do valor da função objetivo.




Figura 8.5: Curvas de convergência da função objetivo - AGRP.

O gráfico apresentado na Figura 8.6 refere-se à última geração de uma execução do método AGRP, para 9 simulações de curto-circuito realizadas a cada 10% do comprimento da linha de transmissão, com uma resistência de falta de 20Ω .




Figura 8.6: AGRP a cada 10% da linha de transmissão.

Com a utilização de diferentes técnicas de ONL obteve-se o ponto mínimo das funções objetivo de duas variáveis, diferenciáveis, convexas e unimodais, situações verificadas pelas leis obtidas e também pelo estudo gráfico. As técnicas de otimização empregadas se diferenciaram principalmente pela lógica utilizada para a procura da solução do problema.

O método de direção de busca Quasi-Newton realizou buscas locais dependentes a cada iteração do gradiente da função para a aproximação da hessiana da função objetivo nos pontos obtidos. Aplicado às funções convexas propostas na pesquisa, o método convergiu para o mínimo local que também representa, nestes casos, o mínimo global. Se as funções não fossem convexas, não se poderia afirmar que o mínimo local fosse também o mínimo global, e que a solução encontrada representasse, de fato, o local de ocorrência da falta. Se as funções objetivo fossem multimodais, ter-se-iam várias bacias de atração. O problema de determinação de mínimos globais, mesmo dentro de um conjunto de mínimos locais bem definidos seria difícil, devido à impossibilidade de reconhecer-se um mínimo global utilizando-se apenas informações locais.

Em relação ao método Elipsoidal, a exclusão de regiões ocorreu a partir do subgradiente das funções objetivo. O método requer que a função objetivo seja convexa ou quasi-convexa e unimodal, o que se verifica com as funções objetivo utilizadas para a localização de faltas e a

determinação da resistência de falta em linhas de transmissão. Estas condições, caso não fossem atendidas, conduziriam o algoritmo a uma situação imprevisível.

Os métodos populacionais, diferentemente dos métodos de direção de busca e dos métodos de exclusão de regiões, não utilizaram informações que envolvessem derivadas da função objetivo. O AGRP Indicou soluções ótimas a partir de um conjunto de soluções e convergiu para o mínimo local esperado.

8.1 Classificação de Faltas Simuladas e Reais

A classificação das faltas feita pela RNA alcançou 100% de acerto nos 182 eventos simulados, fornecendo a classificação correta também em casos reais de curto-circuito, situação já exemplificada na Tabela 7.3.

8.2 Localização de Faltas: Casos Simulados

Após a execução dos algoritmos para a etapa de localização, foram calculados os erros percentuais em relação ao comprimento da linha. Os quantitativos expressos na Tabela 8.2 relacionam-se com as características do evento de falta e as diferentes formas de obtenção de bancos de dados em métodos estocásticos (RNA e AGRP) e determinísticos (Quasi-Newton, Elipsoidal, Johns).

Tabela 8.2: Número de casos por tipo de falta e tipo de método.

Tipo de Falta	RNA	Genético	Quasi-Newton	Elipsoidal	Johns
FFT	2520	2520	63	63	63
FT	2520	2520	63	63	63
FF	1680	1680	42	42	42
FFF	560	560	14	14	14

Visando analisar estatisticamente os resultados dos erros percentuais da localização, aplicou-se o balanceamento do número de amostras por classes, apresentado na Figura 8.7. O procedimento realizado relaciona-se com uma técnica necessária à aplicação do teste estatístico ANOVA. No processo, a quantidade de amostras das classes é igualada, aleatoriamente, à quantidade identificada na classe com menor número de observações o que, no presente estudo, corresponde a 14 amostras por classe.




Figura 8.7: Balanceamento do número de amostras para as RNAs.

Após o balanceamento do número de amostras por classe foram construídos os gráficos de interações, representados nas Figuras 8.8 e 8.9, possibilitando visualizar que, em dados simulados, os resultados dos erros fornecidos pelas RNAs foram menores que os apresentados pelos outros métodos.




Figura 8.8: Localização de faltas: gráfico de interações por tipo de falta.




Figura 8.9: Localização de faltas: gráfico de interações por tipo de método.

Na sequência, a análise dos Boxplots dos erros percentuais, representados nas Figuras 8.10 e 8.11, revelou o melhor desempenho das RNAs, reforçando o resultado anteriormente observado. Indicou também significativa diferença nos erros da falta do tipo fase-terra calculada pelo método de Johns e nos erros do Algoritmo Genético para as faltas do tipo fase-fase.




Figura 8.10: Erros de localização por tipo de falta - casos simulados.




Figura 8.11: Erros de localização por tipo de método - casos simulados.

Analisando os resultados obtidos para casos simulados de localização de faltas em linhas de transmissão como um experimento com dois fatores, o tipo de falta (monofásica, bifásica, bifásica terra, trifásica) e o tipo de método utilizado (Quasi-Newton, Elipsoidal, AGRP, Johns) situam-se como variáveis independentes e, o erro cometido ao estimar-se o local de falta situa-se como variável dependente.

Para a verificação da existência de diferenças entre os fatores tipo de falta e tipo de simulação foi utilizado o modelo estatístico de experimento com dois fatores, ANOVA2, seguindo distribuição normal, com media $\mu = 0$ e variância σ^2 . O modelo, utilizado para verificar os efeitos principais dos fatores tipo de falta e tipo de método sobre a determinação do local de curto circuito, é descrito na Equação 8.1.

$$y_{ijk} = \mu + \tau_i + \beta_j + \varepsilon_{ijk} \quad \begin{cases} i = 1, 2, \dots, 4 \\ j = 1, 2, \dots, 4 \\ k = 1, 2, \dots, 14 \end{cases} \quad (8.1)$$

No modelo, como em Montgomery e Runger (2016), considerou-se μ como o efeito médio global dos erros, τ_i o efeito do i -ésimo nível do fator tipo de falta, β_j o efeito do j -ésimo nível do fator tipo de método, $(\tau\beta)_{ij}$ o efeito da interação entre os fatores tipo de falta e tipo de método, i o número de níveis do fator tipo de falta, j o número de níveis do fator tipo de método e n o número de amostras recolhidas para cada nível.

A aplicação do teste ANOVA2 em um modelo proposto assume que as observações são independentes e normalmente distribuídas, mantendo a mesma variância em cada tratamento. Conforme Montgomery (2005), os resultados gráficos expressos na Figura 8.12, possibilitaram aceitar que essas premissas foram atendidas, permitindo a utilização do teste ANOVA2 ao modelo proposto.




Figura 8.12: Premissas para a aplicação do modelo de análise da variância.

Conforme a Figura 8.12, no gráfico quantil-quantil da Normal (Qqplot) a configuração de pontos se aproximou de uma reta, o que indica que os resíduos apresentam distribuição

normal. Em relação ao gráfico de resíduos por observação, esses se situaram aproximadamente em torno de uma faixa horizontal, sinalizando a validade da suposição de independência. Referente à homocedasticidade, essa foi verificada para os níveis tipo de falta e tipo de método, sendo que o estudo gráfico residual dos erros não evidenciou a existência de um padrão para a mudança de nível em ambos os fatores.

Para a aplicação do teste ANOVA2 foram consideradas as hipóteses apresentadas nas Equações 8.2, 8.3 e 8.4, em que i corresponde aos 4 tipos de falta e j aos 4 tipos de método.

$$\begin{cases} H_0 : \tau_1 = \dots = \tau_i = 0 \\ H_1 : \exists i / \tau_i \neq 0 \end{cases} \quad (8.2)$$

$$\begin{cases} H_0 : \beta_1 = \dots = \beta_j = 0 \\ H_1 : \exists j / \tau_j \neq 0 \end{cases} \quad (8.3)$$

$$\begin{cases} H_0 : (\tau\beta)_{ij} = 0 \quad \forall i, j \\ H_1 : \exists i, j / (\tau\beta)_{ij} \neq 0 \end{cases} \quad (8.4)$$

Como orientado em Montgomery (2005), comparando os resultados da estatística do teste ANOVA2, registrados na penúltima coluna da Tabela 8.3, com os resultados da distribuição F , como $11.50 > f(0.05; 3; 208) = 2.65$; $14.50 > f(0.05; 3; 208) = 2.65$ e também $4.50 > f(0.05; 9; 208) = 1.93$, efeitos principais do tipo de método, do tipo de falta utilizados e também da interação entre os fatores afetam o erro percentual para o local de falta.

Tabela 8.3: Teste ANOVA2 - casos simulados.

	sum_sq	df	F	PR(>F)
C(Tipo_Falta)	0.165180	3.0	11.496516	5.266466e-07
C(Tipo_Metodo)	0.215074	3.0	14.969157	7.363211e-09
C(Tipo_Falta):C(Tipo_Metodo)	0.193004	9.0	4.477702	2.192318e-05
Residual	0.996167	208.0	NaN	NaN

Uma análise equivalente pode ser realizada a partir dos dados da última coluna da Tabela 8.3. Pelo teste, os erros ocorridos em razão do tipo de falta, do tipo de método e da interação entre os fatores são estatisticamente significativos. Nestes casos, os resultados do p-valor obtido são consideravelmente menores que a significância 0,05, indicando a rejeição da hipótese nula e a existência de diferença entre os tipos de métodos, os tipos de falta e a interação entre estes fatores.

Pela aplicação do teste de Tukey, conforme Montgomery (2005), podem ser destacadas comparações significativas e não significativas entre os tipos de falta e os tipos de método. O teste, como apresentado no capítulo 4, consiste na construção de intervalos de confiança para todos os pares de médias de tal forma que o conjunto de todos os intervalos tenha um determinado grau de confiança. Ao nível de significância de 5%, considerando-se como referência o tipo de falta, a aplicação do teste em situações simuladas de curto-circuito forneceu os resultados expressos na Tabela 8.4 e na Figura 8.13. Pelo teste, é possível perceber a existência de diferença significativa entre os erros percentuais de localização da falta fornecidos para o tipo de falta FFF e FFT em relação ao tipo FT.

Tabela 8.4: Teste para a comparação entre tipos de falta - casos simulados.

Multiple Comparison of Means - Tukey HSD, FWER=0.05

group1	group2	meandiff	lower	upper	reject
FF	FFF	0.0387	-0.0004	0.0778	False
FF	FFT	0.0096	-0.0295	0.0487	False
FF	FT	-0.0373	-0.0764	0.0018	False
FFF	FFT	-0.0291	-0.0682	0.01	False
FFF	FT	-0.076	-0.1151	-0.0369	True
FFT	FT	-0.0469	-0.086	-0.0078	True




Figura 8.13: Teste de Tukey para comparação entre os tipos de falta - casos simulados.

Referente ao tipo de método utilizado, a aplicação do teste Tukey em situações simuladas é apresentada na Tabela 8.5 e na Figura 8.14. Pelo teste é possível perceber a existência de diferença significativa entre os erros percentuais fornecidos pelo método de Johns e os erros fornecidos pelos três métodos de ONL utilizados. Pelo resultado do teste, também é possível verificar que resultados de localização fornecidos pelo método de Johns são piores que os dos três métodos de ONL utilizados.

Tabela 8.5: Teste para a comparação entre os tipos de métodos - casos simulados.

Multiple Comparison of Means - Tukey HSD, FWER=0.05					
group1	group2	meandiff	lower	upper	reject
Elipsoidal	Genetico	0.0165	-0.0219	0.0549	False
Elipsoidal	Johns	0.0732	0.0348	0.1116	True
Elipsoidal	Quasi_Newton	-0.0046	-0.043	0.0338	False
Genetico	Johns	0.0567	0.0183	0.0951	True
Genetico	Quasi_Newton	-0.0211	-0.0594	0.0173	False
Johns	Quasi_Newton	-0.0778	-0.1162	-0.0394	True




Figura 8.14: Teste de Tukey para comparação entre os tipos de métodos - casos simulados.

8.3 Localização de Falta: Casos Reais

Os métodos de localização da falta e determinação da resistência de falta implementados nesta dissertação foram também aplicados a sete casos reais de faltas em linhas de transmissão, indicados na Tabela 8.6.

Tabela 8.6: Caracterização dos cenários reais de falta.

Linha	Tensão (kV)	Comprimento (km)	Tipo	Local de Falta (km)	Causa
1	345	74,40	AT	60,0	Descarga atmosférica
			BT	54,0	Descarga atmosférica
2	500	105,58	AT	30,0	Queimada
3	500	342,71	CT	317,0	Descarga atmosférica
			AT	76,0	Queimada
			CT	55,0	Queimada
4	500	248,44	ACT	91,0	Descarga atmosférica

Além da linha de transmissão de 74,4 km, utilizada inicialmente para o estudo dos resultados simulados e reais de localização fornecidos pelas RNAs e pelos métodos de ONL, também foram efetivadas técnicas para a localização de faltas em outras três linhas. Os resultados alcançados pelos métodos, para cada caso de falta, encontram-se registrados na Tabela 8.7.

Tabela 8.7: Resultados da localização: faltas reais.

Linha	Localização (km)							
	Real	RNA Média	RNA Mediana	Quasi Newton	Elipsoidal	AGRP Média	AGRP Mediana	Johns
1	60,0	55,6	59,0	65,4	65,4	65,4	65,4	64,4
	54,0	33,5	39,0	54,4	54,4	54,4	54,4	54,3
2	30,0	24,0	25,0	23,6	23,6	23,6	23,6	29,7
3	317,0	306,4	308,5	311,0	311,0	311,0	311,0	324,0
	76,0	103,0	104,3	78,4	78,4	78,4	78,4	82,7
	55,0	60,5	59,5	55,7	55,7	55,7	55,7	56,6
4	91,0	124,0	149,6	91,5	91,5	91,5	91,5	94,1

Convém destacar que, devido às características estocásticas do método, as RNAs e o AGRP passaram por 40 execuções para a obtenção da localização. Os resultados da média e da mediana obtidas pelas execuções encontram-se registrados na Tabela 8.7 e a estabilidade de cada método pode ser acompanhada pelas Figuras 8.15 e 8.16.




Figura 8.15: Indicação dos locais de falta em 40 execuções das RNAs - casos reais.




Figura 8.16: Indicação dos locais de falta em 40 execuções do AGRP - casos reais.

Assim como nas simulações, os erros de localização de falta, apresentados na Tabela 8.8, foram calculados em relação ao comprimento da linha onde ocorreu o curto-circuito. Para as RNAs e para o AGRP os erros foram indicados a partir do erro médio das 40 execuções dos métodos. Pelas Figuras 8.17 e 8.18, podem ser observadas as variações do erro em cada cenário real, para cada um desses métodos.

Tabela 8.8: Erros percentuais de localização: faltas reais.

Linha	Caso	RNA	Quasi Newton	Elipsoidal	AGRP	Johns
1	AT 60 km	12,4	7,2	7,2	7,2	5,9
	BT 54 km	31,4	0,5	0,5	0,5	0,4
2	AT 30 km	12,7	6,1	6,1	6,1	0,3
3	CT 317 km	3,3	1,8	1,8	1,8	2,0
	AT 76 km	8,9	0,7	0,7	0,7	2,0
	CT 55 km	4,9	0,2	0,2	0,2	0,5
4	ACT 91 km	34,2	0,2	0,2	0,2	1,1




Figura 8.17: Erros de localização em 40 execuções das RNAs - casos reais.




Figura 8.18: Erros de localização em 40 execuções do AGRP - casos reais.

Os Boxplots dos erros de localização pelos métodos aplicados em cenários reais são apresentado na Figura 8.19.




Figura 8.19: Erros de localização - casos reais.

Visando identificar a existência de diferenças nos resultados de localização ocorridas em função do caso de falta e/ou do método utilizado, foi proposto o modelo estatístico de experimento com dois fatores, seguindo distribuição normal com $\mu = 0$ e variância σ^2 . Verificadas as premissas de aleatoriedade, homocedasticidade e normalidade foi possível assumir que as observações são independentes, normalmente distribuídas e mantêm a mesma variância em cada tratamento. Os resultados do teste ANOVA2 são apresentados na Tabela 8.9.

Tabela 8.9: Teste ANOVA2 - casos reais.

	sum_sq	df	F	PR(>F)
C(Tipo_Falta)	266.130927	6.0	1.239680	0.321484
C(Tipo_Metodo)	944.311311	4.0	6.598127	0.000992
Residual	858.708488	24.0	NaN	NaN

Pelo teste, os erros ocorridos em razão do método utilizado foram estaticamente significativos, o mesmo não se verifica para os erros em função do caso de falta analisado. Referente ao método utilizado, o resultado do p-valor obtido é consideravelmente menor que a significância, $0.001 < 0.05$, indicando a rejeição da hipótese nula e a existência de diferença entre os métodos. Para os casos analisados, como $1.24 > 0.05$, a hipótese nula não foi rejeitada, ou seja, não houve evidências estatísticas de existência de diferenças entre os casos de falta. Visando identificar a diferença no tipo de método, sinalizada pelo teste ANOVA2, foi aplicado o teste de Tukey, com resultados indicados na Tabela 8.10 e na Figura 8.20.

Tabela 8.10: Teste para comparação entre os tipos de métodos - casos reais.

group1	group2	meandiff	lower	upper	reject
AGRP	Elipsoidal	-1.0258	-10.5193	8.4678	False
AGRP	Johns	-1.6714	-11.165	7.8221	False
AGRP	Quasi_Newton	-1.0259	-10.5195	8.4676	False
AGRP	RNA	11.9857	2.4922	21.4793	True
Elipsoidal	Johns	-0.6457	-10.1392	8.8479	False
Elipsoidal	Quasi_Newton	-0.0001	-9.4937	9.4934	False
Elipsoidal	RNA	13.0115	3.5179	22.505	True
Johns	Quasi_Newton	0.6455	-8.848	10.1391	False
Johns	RNA	13.6571	4.1636	23.1507	True
Quasi_Newton	RNA	13.0116	3.5181	22.5052	True




Figura 8.20: Teste de Tukey em casos reais de localização - comparação entre métodos.

A partir da realização do teste ANOVA2 e do teste de Tukey, não foram verificadas evidências estatísticas de diferença para a localização de faltas efetuadas entre os métodos de otimização e nem entre esses métodos e o método analítico de Johns e Jamali. Também foi possível identificar diferença na localização de faltas realizada pelas RNAs em relação aos demais métodos, com maiores erros de localização fornecidos por esse último método.

Em relação aos resultados obtidos em situações simuladas e reais, uma consideração a ser feita para as RNAs relaciona-se com a impedância das fontes. Na simulação, as RNAs utilizam impedâncias fixas na fonte (reatância e resistência) e em cenários reais estes valores variam no tempo. As impedâncias fornecidas pelas concessionárias e utilizadas no treinamento das redes referem-se a uma determinada carga do Sistema Elétrico de Potência, não sendo, necessariamente, as mesmas no momento de ocorrência da falta.

8.4 Resistência de Falta

Em relação à resistência de falta, o método de Johns não fornece esse valor e, embora existam pesquisas relacionadas com a obtenção destes valores a partir do resultado de Johns, o presente estudo não teve este objetivo. Assim, foram realizadas comparações entre os resultados fornecidos na validação das RNAs e nos métodos de otimização para os valores simulados.

Conforme a Tabela 7.2, os casos bifásicos e trifásicos de falta foram simulados com resistências de falta de $2,5 \Omega$ e $4,5 \Omega$. Em relação às faltas fase-terra e bifásico-terra, foram realizadas simulações com resistências de falta de 10Ω , 21Ω e 31Ω . Os resultados da validação da resistência de falta de casos simulados para as RNAs e para os métodos de ONL são representados nas Figuras 8.21, 8.22, 8.23, 8.24 e 8.25.

Na comparação entre as resistências simuladas e as obtidas nos casos de validação, pela condução do Teste T, com 5% de significância, não houve indícios estatísticos para rejeitar a hipótese nula de igualdade. Nesse sentido, para todos os tipos de falta e para todos os métodos aplicados, a resistência de falta obtida pelos métodos foi compatível com o resultado sinalizado no cenário simulado.




Figura 8.21: Validação para a resistência de falta de $2,5 \Omega$ - casos simulados.




Figura 8.22: Validação para a resistência de falta de $4,5 \Omega$ - casos simulados.




Figura 8.23: Validação para a resistência de falta de 10Ω - casos simulados.




Figura 8.24: Validação para a resistência de falta de 21 Ω - casos simulados.




Figura 8.25: Validação para a resistência de falta de 31 Ω - casos simulados.

Em relação aos casos reais, os valores de resistência de falta fornecidos pelas RNAs foram inconsistentes, fornecendo em algumas situações valores negativos. Para os métodos de Otimização foram obtidos os valores expressos na Tabela 8.11.

Tabela 8.11: Resistência de falta em casos reais.

Linha	Resistência de Falta (Ω)			
	Caso	QN	EL	AGRP
1	AT 60 km	4,3	4,3	4,3
	BT 54 km	4,9	4,9	4,9
2	AT 30 km	28,5	28,5	28,5
3	CT 317 km	3,0	3,0	3,0
	AT 76 km	2,4	2,4	2,4
	CT 55 km	38,0	38,0	38,0
4	ACT 91 km	3,8	3,8	3,8

Capítulo 9

Conclusões

Este trabalho teve como objetivo geral apresentar propostas para o estudo da aplicação de Redes Neurais Artificiais e de técnicas de Otimização Não Linear ao problema de localização de faltas em linhas de transmissão, utilizando dados de dois terminais. Em resposta às questões inerentes à temática e norteadoras desta dissertação, buscou-se compreender como ferramentas matemáticas e computacionais, relacionadas com técnicas de Otimização e RNAs têm sido utilizadas para a localização de faltas em linhas de transmissão e também quais benefícios, dificuldades e limites encontram-se associados à utilização de destas ferramentas. A partir do estudo de trabalhos relativos à temática, foram comparadas metodologias para classificar, localizar faltas e determinar resistência de faltas em linhas de transmissão.

Em relação ao aspecto prático da pesquisa, para a análise e testes dos modelos implementados, uma base de dados foi simulada no programa ATP a partir de uma linha de transmissão de 74,4 km existente no sistema elétrico brasileiro. Foram simulados 1672 cenários de faltas destinados ao treinamento das RNAs utilizadas e 182 cenários de falta destinados à comparação dos resultados obtidos para a indicação do tipo de falta, a determinação do local de falta e da resistência de falta pelas RNAs e pelos métodos de ONL e pelo método analítico de referência, o método de Johns. As técnicas desenvolvidas foram aplicadas a dois casos reais de curto-circuito. Utilizando-se procedimentos análogos, foram simuladas base de dados para outras 3 linhas de transmissão existentes e 5 casos reais de falta.

A partir dos resultados apresentados, as análises realizadas corroboraram para a confirmação das hipóteses de trabalho desta pesquisa. Para a classificação utilizou-se uma RNA por linha de transmissão acompanhada, com topologia definida após uma série de testes. Para cada evento, foram utilizados como dados de entrada os módulos dos fasores de tensão e corrente de um dos terminais da linha de transmissão, chegando-se à correta identificação do tipo de falta, mesmo com redes treinadas com arquivos de curto-circuito simulados no ATP.

Em relação ao processo de localização de faltas em cenários simulados, os resultados dos métodos utilizados foram analisados tendo-se como referência as respostas fornecidas pelo método de Johns, reconhecido por suas aplicações em situações práticas de localização de

falta. Pela aplicação do teste ANOVA2, os erros percentuais obtidos pelas RNAs e pelos métodos de ONL, confrontados com os fornecidos pelo método de Johns, revelaram a existência de evidências estatísticas, com 5% de significância, que permitiram concluir que os efeitos principais do tipo de método utilizado afetam o erro percentual em relação ao valor de referência para o local da falta. Neste sentido, o teste de Tukey evidenciou menores erros percentuais com a utilização das RNAs e maiores erros com a utilização do algoritmo de Johns implementado nesta dissertação, ficando os métodos de ONL com erros intermediários.

Em cenários reais, a aplicação do teste ANOVA2 para os erros de localização de faltas revelou a existência de evidências estatísticas, com 5% de significância, que permitiram concluir que o tipo de método utilizado afeta o erro percentual em relação ao valor de referência para o local da falta. Nestes cenários, diferente da situação verificada em ambientes simulados, o teste de Tukey evidenciou maiores erros percentuais com a utilização das RNAs, sinalizando também a inexistência de evidências estatísticas para rejeitar a igualdade entre a localização de faltas efetuada pelo método de Johns e os métodos de ONL.

Em relação à discrepância os resultados apresentados pelas RNAs na localização de curto-circuito simulados e reais, destaca-se que a restrição de parâmetros de simulação como os valores das tensões nas fontes e suas respectivas impedâncias equivalentes no momento do curto-circuito, limitaram a capacidade de generalização das RNAs, comprometendo a metodologia proposta.

Em todas as situações simuladas, os resultados alcançados pelos algoritmos de otimização mostraram-se rápidos e estáveis, com erros inferiores a 0,40% do comprimento da linha. Os mesmos, quando aplicados em casos reais, forneceram erros estatisticamente semelhantes e próximos dos apresentados pelo algoritmo clássico de Johns, sinalizando a possibilidade de utilização conjunta desses métodos em situações práticas de problemas de localização de faltas em linhas de transmissão.

Entre os métodos de ONL utilizados não foram identificadas diferenças estatísticas para a localização da falta. Frente às características do problema de localização de faltas e diante da possibilidade de utilização prática dessas técnicas, o baixo custo computacional e a rápida resposta associada ao método Quasi-Newton colocaram-no como método em destaque, devendo-se ressaltar a necessidade de verificação da utilização de dados referentes a outras

faltas reais ocorridas nas linhas estudadas e também a ampliação do estudo para situações de curto-circuito ocorridas em outras linhas de transmissão.

Embora o valor da resistência de falta associada ao evento de curto-circuito não tenha se constituído como um objeto de estudo dissertação, destaca-se que em casos reais, os valores estimados de resistência de falta fornecem indícios da causa que originou o defeito. Nesse sentido, valores entre 0 e 10 Ω estão geralmente associados a descargas atmosféricas, valores entre 10 Ω e 70 Ω indicam a possibilidade de queimadas e valores superiores a 70 Ω podem estar associados à presença de árvores nas proximidades da linha de transmissão. Para uma resposta mais conclusiva entre o agente causador do curto-circuito e o valor da resistência de falta faz-se necessário a utilização de bancos de dados maiores que os utilizados nesse estudo.

9.1 Trabalhos Futuros

Diferentes situações de estudo emergiram a partir dos resultados oriundos dessa dissertação.

- i. Desenvolver um modelo de localização de faltas em linhas de transmissão utilizando RNA que não necessite dos valores das impedâncias das fontes para gerar o banco de dados de treinamento.
- ii. Um recurso cada vez mais utilizado para o aumento da capacidade de transporte de energia elétrica de uma linha de transmissão é a compensação série, feita a partir da inserção do capacitor na linha. Este dispositivo, embora possibilite vantagens ao sistema elétrico em que se insere, altera a impedância da linha e, se o método aplicado não prevê sua inserção, pode-se prejudicar sobremaneira a tarefa de proteção da linha e também a localização da falta. Em relação às linhas de transmissão compensadas, duas propostas relacionadas ao estudo apresentado nessa dissertação podem ser estudadas:

- O desenvolvimento de um modelo com RNA que não utilize as impedâncias das fontes para a localização de faltas em linhas de transmissão compensadas.
- A elaboração de uma função objetivo que contemple o comportamento não linear do varistor de proteção do capacitor, $f(x, R_F, C_{eq}, R_{eq})$, sendo x o local da falta, R_F a resistência de falta, C_{eq} e R_{eq} a capacitância e a resistência equivalente do conjunto capacitor e varistor, quando este está em condução.

Referências

Agência Nacional de Energia Elétrica / Superintendência de Fiscalização dos Serviços de Eletricidade. (2017). **Relatório de Análise Desempenho da Operação nas Instalações de Transmissão**. ANEEL/SFE. Disponível em: www.aneel.gov.br. Acesso em: 07 Agosto 2019.

AMORIM, H. P.; HUAIS, L. (2004). **Faults Location in Transmission Lines Through Neural Networks**. IEEE/PES Transmission e Distribution Conference e Exposition: Latin America. [S.l.]: [s.n.].

BLAND, R.G.; GOLDFARB, D.; TODD, M. J. (1981). **Feature Article - The Ellipsoid Method: A Survey**. Operations Research, [s.l.], v. 29, n. 6, p.1039 - 1091. Institute for Operations Research and the Management Sciences (INFORMS).

BORTOLOSSI, H. J. (2002). **Cálculo Diferencial a Várias Variáveis: Uma Introdução à Teoria de Otimização**. Editora PUC-Rio. Edições Loyola - Coleção Matmídia. Rio de Janeiro.

BRAGA, A. P.; CARVALHO, A. C.; LUDERMIR, T. B. (2007). **Redes Neurais Artificiais: Teoria e Aplicações**. 2ª ed. São Carlos, LTC.

CHEN, Z.; MAUN, J.C. (2000). **Artificial Neural Network Approach to Single-Ended Fault Locator for Transmission Lines**. IEEE Transactions on Power Systems, v. 15.

CUNHA, A. G.; TAKAHASHI, R. H. C.; ANTUNES, C. H. (2013). **Manual de Computação Evolutiva e Metaheurística**, Imprensa da Universidade de Coimbra/Editora da Universidade Federal de Minas Gerais.

DASH, P. K; PRADHAN, A. K.; PANDA, G. (2000). **A Novel Fuzzy Neural Network Based Distance Relaying Scheme**. IEEE Transaction on Power Delivery, v. 15, n. 3, p. 902 - 907.

DEMUTH, H.; BEALE, M. (2015). **Neural Network Toolbox User'S Guide**. The Math Work. [S.l.]: [s.n.].

FENG, C-X. J.; YU, Z-G.; KING, U.; BAIG, M. P. (2005). **Threefold vs. Fivefold Cross Validation in One-Hidden-Layer and Two-Hidden-Layer Predictive Neural Network Modeling of Machining Surface Roughness Data**. Journal of Manufacturing Systems, v. 24 (02), 93 - 107.

GAYATHRI, K.; KUMARAPPAN, N. (2008). **Comparative Study of Fault Identification and Classification on EHV Lines Using Discrete Wavelet Transform and Fourier Transform Based ANN**. International Journal of Electrical, Computer, and Systems Engineering, vol. 2, n. 2, p. 125 - 136.

GIRGIS, A. et al. (1992). **A New Fault Location Technique for Two and Three Terminal Lines**. IEEE Trans. Power Delivery, v. 7.

GOLDBERG, D. E. (1989). **Genetic Algorithms in Search, Optimization and Machine Learning**. Addison-Wesley, 1989.

GOPALAKRISHNAN A.; KEZUNOVIC, M. (2000). **Fault Location Using the Distributed Parameter Transmission Line Model**. IEEE Trans. Power Delivery, v. 15.

GRACIA, J.; MAZÓN, A. J.; ZAMORA, I. (2005). **Best ANN Structures for Fault Location in Single and Double-Circuit Transmission Lines**. IEEE Transactions on Power System, v. 20, n. 4.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. H. (1996). **Neural Network Design**. BOSTON: [s.n.], Cap. 11 - 12.

HAYKIN, Simon. (2001). **Redes Neurais: Princípios e Prática**. 2ª ed. Porto Alegre: Bookman. 2001. 900 p. Tradução de: Neural Networks: a Comprehensive Foundation.

HECHT-NIELSEN, R. (1989). **Theory of the Backpropagation Neural Network**. Neural Networks. IJCNN, International Joint Conference on: IEEE, 1989:593-605.

HOLLAND, J. H. (1975). **Adaptation in Natural and Artificial Systems**. University of Michigan Press.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. (1989). **Multilayer Feedforward Networks are Universal Approximators**. Neural Networks, 2(5): 359 - 366.

IEEE Commom Format for Transient Data Exchange (COMTRADE) for Power Systems Relay Committee of the IEEE Power Engineering Society. New York, USA, IEEE Standard C37.111 - 1999.

JIANG, J. et al. (2000). **An Adaptive PMU Based Fault Detection/Location Technique for Transmission Lines Part I: Theory and Algorithms**, IEEE Trans. Power Delivery, v. 15.

JOHNS, A. T.; JAMALI, S. (1990). **Accurate Fault Location Technique for Power Transmission Line**. IEE Proceedings, v. 137, p. 395 - 402.

LIPPMANN, R. (1987). **An Introduction to Computing with Neural Nets**. IEEE, v. 4, n. 2, p. 4 - 22.

LOUT, K.; AGGARWAL, R. K. (2012). **A Feedforward Artificial Neural Network Approach to Fault Classification and Location on a 132 kV Transmission Line Using Current Signals Only**. IEEE, Universities Power Engineering Conference (UPEC). [S.l.]: [s.n.].

LUENBERGER, D.G.; YE, Y. (2008). **Linear and Nonlinear Programming**. New York, NY: Springer.

MAIER, H. R.; DANDY, G. C. (2000). **Neural Networks for the Prediction and Forecasting of Water Resources Variables: A Review of Modelling Issues and Applications**. Environmental Modelling & Software, v. 15 (1), 101 - 124.

MARTÍN, F.; AGUADO, J. A. (2003). **Wavelet-Based ANN Approach for Transmission Line Protection**. IEEE Transactions on Power Delivery, v. 18, n. 4, October.

MENEZES, M. P. (2008). **Classificação e Localização de Faltas em Linha de Transmissão Usando Diferentes Arquiteturas de Redes Neurais Artificiais**. Dissertação de Mestrado submetida à Escola Politécnica da Universidade de São Paulo. São Paulo.

Ministério de Minas e Energia / Secretaria de Energia Elétrica / Departamento de Monitoramento do Sistema Elétrico. (2019). **Boletim Mensal de Monitoramento do Sistema Elétrico Brasileiro**.: MME/SEE/EPE, Fevereiro. Disponível em: www.epe.gov.br. Acesso em: 07 agosto 2019.

Ministério de Minas e Energia / Empresa de Pesquisa Energética. (2017). **Plano Decenal de Expansão de Energia 2027**.: MME/EPE. Disponível em: www.epe.gov.br. Acesso em: 19 agosto 2019.

MONTGOMERY, D. C. (2005). **Design and Analysis of Experiments**. John Wiley & Sons, 6ª ed.

MONTGOMERY, D.C.; RUNGER, G.C. (2016). **Estatística Aplicada e Probabilidade para Engenheiros**. 6ª ed., LTC Livros Técnicos e Científicos.

MORAIS, J. et al. (2010). **A Framework for Evaluating Automatic Classification of Underlying Causes of Disturbances and its Application to Short-Circuit Faults**. IEEE Transactions on Power Delivery, v. 25, n. 4, p. 2083 - 2094, October. ISSN 0885-8977.

- NGAOPITAKKUL, A.; POTHISARN, C. (2009). **Discrete Wavelet Transform and Backpropagation Neural Network Algorithm for Fault Location on Single-Circuit Transmission Line**. Proceedings of the 2008 IEEE Internacional Conference on Robotics and Biomimetics Bangkok, Thailand: [s.n.]. February.
- NOVOSEL, D. et al. (1996). **Unsynchronized Two-Terminal Fault Location Estimation**, IEEE Trans. Power Delivery, v. 11.
- PANIGRAHI, B. K.; MAHESHWARI, R. P. (2011). **Transmission Line Fault Detection and Classification**. IEEE, Proceedings of Ictect. [S.l.]: [s.n.].
- PEREIRA, C.; CRUZ, F. C. (1999). **Análise do Comportamento Estático e Dinâmico dos Filtros Digitais de Mínimos Quadrados na Proteção de Linhas de Transmissão**. In: XV SNPTEE, 1999, Foz do Iguaçu. Anais.
- PHADKE, A. G.; THORP, J. S. (1998). **Computer Relaying for Power Systems**. New York: John Wiley&Sons Inc, 289 p.
- PRADHAN, A. K.; MOHANTY, S. R.; ROUTRAY., A. (2006). **Neural Fault Classifier for Transmission Line Protection - A Modular Approach**. IEEE, Department of Electrical Engineering. Kharagpur, Indian: [s.n.].
- ROSENBLATT, F. (1957). **The Perceptron: A Perceiving and Pecognizing Automaton**. Report 85-460-1, Project PARA, Cornell Aeronautical Lab. Ithaca, New York.
- SACHDEV M. S.; BARIBEAU, M. A. (1979). **A New Algorithm for Digital Impedance Relays**. IEEE Trans. PAS-98, p. 2232 - 2240.
- SANTOS, H. S. (2017). **Metodologia para Planejamento da Expansão do Setor Elétrico Brasileiro Considerando Critérios Ambientais e a Interação Oferta-Demanda**. Tese (Doutorado em Engenharia), COPPE-UFRJ, Rio de Janeiro.
- SILVA, K. M.; SOUSA, B. A.; BRITO, N. S. D. (2006). **Fault Detection and Classification in Transmission Lines Based on Wavelet Transform and ANN**. IEEE, Transactions on Power Delivery, v. 21, October.
- SILVEIRA, E. G. (2007). **Localização de Faltas em Linhas de Transmissão: Desenvolvimento de novos Algoritmos e Implementação de Sistema Computacional para Aplicações Práticas**. Tese de Doutorado, Universidade Federal de Minas Gerais. [S.l.].

SILVEIRA, E. G.; PAULA, H. R.; RIBEIRO, L. F.; ROCHA, S. A. (2017a). **Redes Neurais Artificiais para Classificação, Localização e Determinação de Resistência de Falhas em Linhas de Transmissão Compensadas**. the 12th Latin-American Congress on Electricity Generation and Transmission - CLAGTEE 2017, November.

SILVEIRA, E. G., PAULA, H. R., ROCHA, S.A. e PEREIRA, C. S. (2017b). **Hybrid Fault Diagnosis Algorithms for Transmission Lines**. Electrical Engineering, [s.l.], v. 100, n. 3, p.1689 - 1699.

SOUZA, S. M. D.; SILVA, A. P. A. D.; A.C.S.LIMA. (2007). **Voltage and Current Patterns for Fault Location in Transmission Lines**. IEEE, Proceedings of International Joint Conference on Neural Networks. Orlando, Florida, USA: [s.n.]. August.

SU, S.; X.DUAN; ZENG., X. (2008). **ATP-Based Automated Fault Simulation**. IEEE Transactions on Power Delivery, v. 23, n. 3.

TAKAHASHI, R.H.C., VASCONCELOS, J.A., RAMIREZ, J.A. e KRAHENBUHL, L.(2003). **A Multiobjective Methodology for Evaluating Genetic Operators**. IEEE Transactions On Magnetics, [s.l.], v. 39, n. 3, p.1321 - 1324.

TAKAHASHI, R.H.C., MARTINS, F.V.C.(2003). **Avaliação e Interpretação do Operador mAG**. Transactions On Magnetics, XXXVI Simpósio Brasileiro de Pesquisa operacional, UFSJ.

TEKLIC, L.; FILIPOVIC-GRICIC, B.; I.PAVICIC. (2013). **Artificial Neural Network Approach for Locating Faults in Power Transmission System**. IEEE, EuroCon. [S.l.]: [s.n.]. july.

TETKO, I. V.; LIVINGSTON, D.J.; LUIK, A. I. (1995). **Neural Network Studies**. 1. Comparison of Overfitting and Overtraining J. Chem. Inf. Comput. Sci., 35 (5), P. 826 - 833.

THOMAS, A. J.; PETRIDIS, M.; WALTERS, S. D., GHEYTASSI, S. M.; MORGAN, R. E.(2015). **On Predicting the Optimal Number of Hidden Nodes**, In: Proceedings International Conference on Computational Science and Computational Intelligence, P. 565 - 570.

WANG, H. S.; KEERTHIPALA, W. W. L. (1998). **Fuzzy-Neuro Approach to Fault Classification for Transmission Line Protection**. IEEE Transaction on Power Delivery, vol. 13, n. 4, p. 1093 - 1104.