

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**DESENVOLVIMENTO DE MODELO RNA PARA
LOCALIZAÇÃO DE FALTAS FASE-TERRA EM
REDES DE DISTRIBUIÇÃO DISPERSAS E DE
GRANDES EXTENSÕES**

por

VITOR RODRIGO ALVES EMERENCIANO

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da
Universidade Federal de Pernambuco como parte dos requisitos para a obtenção do grau de
Mestre em Engenharia Elétrica.

ORIENTADOR: JOSÉ MAURÍCIO DE BARROS BEZERRA, Doutor

Recife, Fevereiro de 2012.

© Vitor Rodrigo Alves Emerenciano, 2012

Catálogo na fonte
Bibliotecária: Rosineide Mesquita Gonçalves Luz / CRB4-1361 (BCTG)

- E53d Emerenciano, Vitor Rodrigo Alves.
Desenvolvimento de Modelo RNA para localização de Falhas Fase-Terra em redes de distribuição dispersas e de grandes extensões / Vitor Rodrigo Alves Emerenciano. – Recife: O Autor, 2012.
xvi, 129f., il., figs., gráfs., tabs.
- Orientador: Prof. Dr. José Maurício de Barros Bezerra.
- Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Elétrica, 2012.
Inclui Referências.
1. Engenharia Elétrica. 2. Redes Neurais Artificiais. 3. Transformada de Wavelets. 4. Reconhecimento de Padrões. 5. Localização de Falhas. 6. Teoria das Ondas Viajantes. I. Bezerra, José Maurício de Barros (Orientador). II. Título.



Universidade Federal de Pernambuco
Pós-Graduação em Engenharia Elétrica

PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE
DISSERTAÇÃO DO MESTRADO ACADÊMICO DE

VITOR RODRIGO ALVES EMERENCIANO

TÍTULO

**“DESENVOLVIMENTO DE MODELO RNA
PARA LOCALIZAÇÃO DE FALTAS FASE-TERRA EM REDES DE
DISTRIBUIÇÃO DISPERSAS E DE GRANDES EXTENSÕES”**

A comissão examinadora composta pelos professores: JOSÉ MAURÍCIO DE BARROS BEZERRA, DEE/UFPE, RONALDO RIBEIRO BARBOSA DE AQUINO, DEE/UFPE, ZANONI DUEIRE LINS, DEE/UFPE e BENEMAR ALENCAR DE SOUZA, DEE/UFCG sob a presidência do primeiro, consideram o candidato **VITOR RODRIGO ALVES EMERENCIANO APROVADO.**

Recife, 03 de fevereiro de 2012.

CECILIO JOSÉ LINS PIMENTEL
Vice-Coordenador do PPGEE

JOSÉ MAURÍCIO DE BARROS BEZERRA
Orientador e Membro Titular Interno

BENEMAR ALENCAR DE SOUZA
Membro Titular Externo

RONALDO RIBEIRO BARBOSA DE AQUINO
Membro Titular Interno

ZANONI DUEIRE LINS
Membro Titular Externo

Dedico este trabalho aos meus pais, Eugênio e Sílvia, que sempre me motivaram e me apoiaram incondicionalmente.

AGRADECIMENTOS

Agradeço ao meu pai, Eugênio, sempre presente nos momentos mais difíceis com seus sábios conselhos e incentivos me mostrando sempre racionalmente o caminho correto; à minha querida mãe Silvania, que com o seu imenso amor me forneceu um ombro amigo nos momentos de choro e muitos beijos nos momentos de alegria. Sou imensamente grato pelo porto seguro e pelo equilíbrio que meus pais representam em minha vida.

Agradeço a sábia orientação do professor José Maurício de Barros Bezerra, que acompanhou todo trabalho sempre entusiasmado, mesmo nos momentos nos quais dava tudo errado. Profissional exemplar que com muita paciência e atenção se dedicou a realização deste trabalho.

Agradeço aos professores que compuseram a banca examinadora por suas contribuições para o aprimoramento desta dissertação e sugestões instigantes.

Agradeço aos grandes amigos Alexsandro Aleixo e Maherbson Carvalho pela presença constante mesmo nos momentos azedumes da vida. O apoio incondicional de ambos viabilizou a construção desta dissertação. Gostaria de agradecer Suelen Holder pela participação fundamental e indispensável na construção do abstract desta dissertação.

Agradeço, finalmente, a todos aqueles não citados nominalmente mas que, de alguma forma, contribuíram para esta realização.

Resumo da Dissertação apresentada à UFPE como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica.

DESENVOLVIMENTO DE MODELO RNA PARA LOCALIZAÇÃO DE FALTAS FASE-TERRA EM REDES DE DISTRIBUIÇÃO DISPERSAS E DE GRANDES EXTENSÕES.

Vitor Rodrigo Alves Emerenciano

Fevereiro/2012

Orientador: José Maurício de Barros Bezerra, Doutor

Área de Concentração: Processamento de Energia.

Palavras-chave: Redes neurais artificiais, transformada de Wavelets, reconhecimento de padrões, localização de Faltas, teoria das ondas viajantes.

Número de Páginas: xiv+129.

RESUMO: A crescente demanda por energia elétrica vem impactando diretamente na regulação do setor elétrico, onde a falta de energia elétrica hoje disponibilizada passa a ser inaceitável e conseqüentemente impactando em penalização para as empresas concessionárias do setor. Diante deste cenário a possibilidade de contar com um sistema de monitoramento em tempo real que oriente ações corretivas das equipes de manutenção constitui uma ferramenta de fundamental importância na melhoria dos indicadores operacionais das empresas do setor. No sistema elétrico de potência, devido às suas características, cerca de 60% das ocorrências de falta de energia estão associadas a curtos-circuitos de origem monofásicas, o que apresentam ondas viajantes se propagando ao longo do alimentador, em ambas as direções, sofrendo reflexões e refrações relacionadas com as singularidades do percurso realizado. Assim, os sinais eletromagnéticos transitórios gerados pela incidência da falta manifestam peculiaridades associada ao caminho percorrido por essas ondas viajantes. Essas particularidades quando extraídas adequadamente podem ser empregadas, com grande eficácia, por sistemas inteligentes indicando a localidade da falta. Com base nesta premissa esta dissertação propõe uma abordagem utilizando redes neurais artificiais para localizar faltas fase-terra em sistemas elétricos de distribuição rurais fortemente dispersos e de grandes extensões. A modelagem proposta faz uso da transformada de wavelets e das técnicas multirresolução de sinais no intuito de melhorar a precisão na localização de faltas como também se ressalta o emprego de processos estatísticos, o qual visa extrair atributos representativos do trecho sob falta.

Abstract of Dissertation presented to UFPE as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering.

DEVELOPMENT OF AN ANN MODEL FOR LOCATING SINGLE PHASE FAULTS IN LARGE SCALE AND DISPERSED DISTRIBUTION SYSTEMS.

Vitor Rodrigo Alves Emerenciano

Fevereiro/2012

Supervisor(s): José Maurício de Barros Bezerra, Doutor

Area of Concentration: Energy Processing.

Keywords: Artificial neural networks, Wavelet transforms, pattern recognition, fault location, travelling wave theory.

Number of Pages: xiv+129.

ABSTRACT: The growing demand for electricity is having a direct impact on regulation in the electricity sector, where power outages have become unacceptable and are consequently penalizing utility companies in the industry. Within such a scenario, a real-time monitoring system that can guide maintenance teams in carrying out corrective actions is a vitally important tool for improving operational indicators. Due to the characteristics of the electrical power system, about 60% of power outages are associated with a single phase short-circuit source, in which traveling waves propagate along the feeder in both directions, subjected to reflections and refractions related to the singularities of the route undertaken. Thus, the transient electromagnetic signals generated by faults display peculiarities associated with the course taken by these traveling waves. When properly extracted, these particularities may be used to great effect by intelligent systems in order to indicate the location of the fault. Based on this premise, this dissertation proposes an approach using artificial neural networks to locate phase-to-ground faults in widely dispersed, large-scale rural distribution systems. The proposed model makes use of wavelet transform and multi-resolution signal techniques to improve the accuracy of locating faults, and emphasizes the use of statistical processes aimed at extracting attributes representing the section under fault.

Sumário

Lista de Figuras	x
Lista de Tabelas	xi
Lista de Simbologia	xii
1 Aspectos Gerais.....	1
1.1 Introdução	1
1.2 Organização do Texto	5
2 Revisão Bibliográfica.....	7
2.1 Introdução	7
2.2 Métodos Baseados nos Componentes de Frequência Fundamental	8
2.3 Métodos Baseados em Componentes de Alta Frequência e Ondas Viajantes	15
2.4 Métodos Knowledge-Based.....	19
2.5 Considerações Finais	24
3 Teoria das Ondas Viajantes.....	26
3.1 Introdução	26
3.2 Reflexões e Refrações de Ondas Viajantes.....	27
3.3 Diagramas Lattice	29
3.4 Atenuação e Distorção das Ondas Viajantes	30
3.5 Considerações Finais	31
4 Wavelets e a Representação Multirresolução de Sinais.....	32
4.1 Introdução	32
4.2 A Wavelet-mãe e as Wavelets Filhas	33
4.3 Transformada de Wavelets	36
4.3.1 Transformada de Wavelets Contínua	38
4.3.2 Transformada de Wavelet Discreta de Tempo Contínuo	39
4.3.3 Transformada de Wavelets Discreta de Tempo Discreto	40
4.4 Análise Multirresolução de Sinais.....	42
4.4.1 Aproximação Multirresolução	42
4.4.2 Representação Wavelet.....	44
4.4.3 Codificação por Sub-bandas.....	47
4.5 Considerações Finais	53
5 Reconhecimento de Padrões	55
5.1 Introdução	55
5.2 Redes Neurais Artificiais	58
5.2.1 Neurônios Biológicos	59
5.2.2 Modelo de um Neurônio Artificial	60
5.2.3 Funções de Ativação.....	62
5.2.4 Principais Arquiteturas de Rede	64
5.2.5 Aprendizagem.....	68
5.3 Considerações Finais	76
6 Processamento de Sinais	78
6.1 Introdução	78
6.2 Pré-processamento de Dados	78
6.3 Normalização	81
6.4 Extração de Atributos	82
6.4.1 Espectro Wavelet da Energia.....	82

6.4.2	Medidas de Entropia Wavelet.....	83
6.5	Considerações Finais	88
7	Estudo de Caso.....	90
7.1	Introdução	90
7.2	Modelagem do Sistema Elétrico	90
7.2.1	Subestação	91
7.2.2	Condutores.....	92
7.2.3	Estruturas	94
7.2.4	Implementação no ATP (Alternative Transients Program).....	94
7.3	Critérios de Implementação	98
7.3.1	Limitação do ATP	98
7.3.2	Subdivisão do Alimentador CPS-01L7	99
7.4	Classificador Baseado em Redes Neurais.....	101
7.4.1	Avaliação de Desempenho	102
7.4.2	Critérios de Parada dos Treinamentos	102
7.4.3	Codificação das Classes.....	103
7.4.4	Método de Validação Cruzada	105
7.4.5	Resultados do Treinamento das Redes	106
7.5	Considerações Finais	115
8	Conclusão.....	117
8.1	Considerações Gerais.....	117
8.2	Sugestões para Trabalhos Futuros	118
	Referências Bibliográficas.....	119

Lista de Figuras

Figura 2.1 – Metodologia para localização de faltas [17].	8
Figura 3.1 – Diagrama Lattice computando reflexões sucessivas [66].	29
Figura 4.1 – Exemplos de wavelets-mãe no domínio do tempo.	36
Figura 4.2 – Processo de representação do algoritmo de codificação por sub-bandas baseado em WMRA.	51
Figura 4.3 – Decomposição do sinal original em três escalas representado os coeficientes escala e wavelet em cada escala.	51
Figura 4.4 – Processo de reconstrução do algoritmo de codificação por sub-bandas baseado na WMRA para a escala j .	52
Figura 4.5 – Reconstrução do sinal $c_0(n)$ a partir de sua versão aproximada de terceira escala e de suas versões detalhadas em três escalas.	53
Figura 5.1 – Exemplo de regiões de decisão em um espaço bi-dimensional [85].	56
Figura 5.2 – Componentes do neurônio biológico [88].	60
Figura 5.3 – Modelo não linear de um neurônio [87].	61
Figura 5.4 – Funções de ativação.	64
Figura 5.5 – Rede alimentada adiante (feedforward) com uma única camada de neurônios.	65
Figura 5.6 – Rede alimentada adiante (feedforward) com uma camada oculta e uma camada de saída.	66
Figura 5.7 – Rede recorrente com neurônios ocultos [87].	67
Figura 5.8 – Fluxo de processamento do algoritmo back-propagation.	71
Figura 7.1 – Representação do alimentador CPS-01L7 da regional Caruaru.	91
Figura 7.2 – Sistema equivalente simplificado de uma rede elétrica.	92
Figura 7.3 – Algumas variações de estruturas encontradas no CPS-01L7.	95
Figura 7.4 – Cartão de entrada da rotina Line Constants para uma estrutura tipo L2-L3 utilizando cabos CAA 25 mm ² .	97
Figura 7.5 – Cartão de entrada do ATP para uma falta fase-terra no alimentador CPS-01L7.	97
Figura 7.6 – Subdivisão do alimentador CPS-01L7 em grupos identificados em diferentes cores.	100
Figura 7.7 – Classificação com um especialista.	104
Figura 7.8 – Classificação com três especialistas.	104

Lista de Tabelas

- Tabela 1.1** – Ocorrência dos Curtos-Circuitos [2].
- Tabela 7.1** – Parâmetros equivalentes do alimentador CPS-01L7.
- Tabela 7.2** – Listas dos principais tipos de condutores.
- Tabela 7.3** – Características básicas dos ramais do alimentador em análise.
- Tabela 7.4** – Variações no ângulo de incidência e impedância.
- Tabela 7.5** – Dimensão de entrada da RNA.
- Tabela 7.6** – Codificação da camada de saída da RNA.
- Tabela 7.7** – Variações das arquiteturas das redes neurais.
- Tabela 7.8** – Formação dos conjuntos de treinamento, validação e teste.
- Tabela 7.9** – Melhor arquitetura do modelo 1 para o vetor de entrada *ApEn*.
- Tabela 7.10** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.9**.
- Tabela 7.11** – Melhor arquitetura do modelo 1 para o vetor de entrada espectro wavelet de energia.
- Tabela 7.12** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.11**.
- Tabela 7.13** – Melhor arquitetura do modelo 1 para o vetor de entrada *WEE/WSE*.
- Tabela 7.14** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.13**.
- Tabela 7.15** – Melhor arquitetura do modelo 2 para o vetor de entrada *ApEn*.
- Tabela 7.16** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.15**.
- Tabela 7.17** – Melhor arquitetura do modelo 2 para o vetor de entrada espectro wavelet de energia.
- Tabela 7.18** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.17**.
- Tabela 7.19** – Melhor arquitetura do modelo 2 para o vetor de entrada *WEE/WSE*.
- Tabela 7.20** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.19**.
- Tabela 7.21** – Melhor arquitetura do modelo 3 para o vetor de entrada *ApEn*.
- Tabela 7.22** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.21**.
- Tabela 7.23** – Melhor arquitetura do modelo 3 para o vetor de entrada espectro wavelet de energia.
- Tabela 7.24** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.23**.
- Tabela 7.25** – Melhor arquitetura do modelo 3 para o vetor de entrada *WEE/WSE*.
- Tabela 7.26** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.25**.
- Tabela 7.27** – Melhor arquitetura do modelo 4 para o vetor de entrada *ApEn*.
- Tabela 7.28** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.27**.
- Tabela 7.29** – Melhor arquitetura do modelo 4 para o vetor de entrada espectro wavelet de energia.
- Tabela 7.30** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.29**.
- Tabela 7.31** – Melhor arquitetura do modelo 4 para o vetor de entrada *WEE/WSE*.
- Tabela 7.32** – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.31**.

Lista de Simbologia

<i>ApEn</i>	Entropia aproximada.
AMR	Análise multirresolução de sinais.
ANEEL	Agência nacional de energia elétrica.
ATP-EMTP	Alternative transients program – Electromagnetic transients program.
CA	Condutor de alumínio
CAA	Condutor de alumínio com alma de aço
CAL	Condutor de liga de alumínio
CALA	Condutor de alumínio com alma de liga de alumínio
CBGA	Algoritmo genético de Chu Beasley.
CELPE	Companhia energética de Pernambuco.
CTW	Coefficientes da transformada de wavelets.
CWT	Continuous wavelet transform.
DEC	Duração equivalente de interrupção por unidade consumidora.
DFT	Transformada discreta de Fourier.
DIC	Duração de interrupção individual por unidade consumidora.
DSP	Digital signal processing.
DWT	Discrete wavelet transform.
E.C.	Erro de classificação.
FEC	Frequência equivalente de interrupção por unidade consumidora.
FIC	Frequência de interrupção por unidade consumidora.
GD	Gradiente descendente.
GDM	Gradiente descendente com momento.
GPS	Global positioning system.
IED	Dispositivos eletrônicos inteligentes.
LM	Algoritmo Levenberg-Marquardt.
MLP	Perceptron de múltiplas camadas.
MRA	Análise multirresolução.
MSE	Erro médio quadrático.
MV	Média tensão.
QMF	Quadrature mirror filters.
RBF	Radial basis functions.

RGGA	Algoritmo genético refinado.
RNA	Rede neural artificial.
RPROP	Algoritmo resilient propagation.
SVD	Decomposição do valor singular.
SVM	Máquinas de vetor de suporte.
TP	Transformadores de potencial.
TW	Transformada de wavelet.
WEE	Entropia da energia wavelet.
WMRA	Representação wavelet baseada em multirresolução.
WSE	Wavelet singular entropy.
A	Limite superior da energia normalizada do produto interno dos coeficientes wavelet discreto de tempo contínuo.
B	Limite inferior da energia normalizada do produto interno dos coeficientes wavelet discreto de tempo contínuo.
b_k	Bias.
C	Capacitância por unidade de comprimento.
$c'_j(n)$	Sinal reconstruído pelo processo inverso de representação.
$c_{j,k}$	Coefficiente escala discreto.
$C_i^m(r)$	Medida quantitativa da regularidade.
C_ψ	Constante de admissibilidade.
$d_{j,k}$	Coefficiente wavelet discreto.
$CWT_f(s, \tau)$	Transformada de Wavelet contínua, numa escala s e deslocamento τ de uma função $f(t)$.
$DWT_{m,n}$	Coefficientes wavelet discretos.
d_i	Submatrizes da matriz $d_{m \times k}$.
$d_{m \times k}$	Matriz formada pela decomposição SVD.
$D_j(k)$	Representação wavelet de um sinal $f(t)$.
E	Potência total do sinal.
Er	Função do erro.
$E_{j,k}$	Espectro wavelet de energia.
E_j	Espectro wavelet de energia para uma determinada janela de tempo.
$f(t)$	Sinal dependente do tempo.

$f(k)$	Sinal discreto no tempo.
f_c	Frequência de corte.
f_s	Frequência de amostragem.
G	Condutância.
$g(k)$	Coefficiente do filtro wavelet.
$h(k)$	Coefficiente do filtro escala.
i	Corrente.
I'	Corrente modal.
j	Nível de resolução.
$J(x)$	Matriz Jacobiano
L	Indutância por unidade de comprimento.
L_{inf}	Limite inferior do intervalo de normalização.
L_{max}	Limite superior do intervalo de normalização.
$L^2(R)$	Espaço de Hilbert para funções de tempo contínuo.
ℓ^2	Espaço de Hilbert para funções de tempo discreto.
m	Parâmetro discreto da transformada de wavelet discreta de tempo contínuo.
P_j	Energia wavelet relativa.
Q	Número total de padrões utilizados no treinamento.
M	Número de camadas utilizada na rede neural.
N	Comprimento do filtro wavelet.
n	Parâmetro discreto da transformada de wavelet discreta de tempo contínuo.
$ns_0^m \tau_0$	Discretização do parâmetro de translação.
$Proj_{V_j}(f)$	Projeção ortogonal de $f(t)$ no subespaço V_j .
$Proj_{W_j}(f)$	Projeção ortogonal de $f(t)$ no subespaço W_j .
R	Resistência por unidade de comprimento.
R_j	Região de decisão particular.
s	Fator de escala.
s_0	Passo de dilatação discreto.
s_0^m	Discretização do parâmetro de dilatação.
T	Transformação modal.
T_e	Transformação modal da tensão.
T_i	Transformação modal da corrente.

U	Matriz decomposição da técnica SVD.
u	Vetor coluna da matriz U .
V'	Tensão modal.
\bar{V}	Altura média do condutor.
V_j	Subespaço escala.
V_{mid}	Altura do condutor ao solo onde define-se a flecha.
V_{svd}	Matriz ortogonal da decomposição SVD.
V_{tower}	Altura do condutor ao solo.
v	Velocidade de propagação da onda de tensão [m/s].
ϑ	Tensão.
Z_0	Impedância característica.
W_j	Subespaço wavelet.
$w_{k,n}$	Pesos sinápticos.
x_i	Vetor de atributos.
Y	Admitância.
y_{cij}	Saída calculada para cada neurônio.
y_{cmax}	Valor máximo da saída da rede neural.
y_{cmin}	Valor mínimo da saída da rede neural.
y_{dij}	Saída desejada para cada neurônio.
y_k	Saída do neurônio k .
Z	Matriz Impedância.
Z_m	Impedância mutua.
Z_{mi}	Impedâncias de surto modais
Z_s	Impedância própria.
α_i	Constante de atenuação.
β_i	Constante de fase.
β	Fator de punição.
$[\gamma]^2$	Constante de propagação.
Δ_{ij}	Valor de correção.
Δx	Correções aplicadas à função a ser minimizada no algoritmo LM.
η	Taxa de aprendizagem.
η^+	Fator multiplicador incremental.

η^-	Fator multiplicador decremental.
θ_i	Vetor coluna da matriz V_{svd} .
Λ	Matriz diagonal da decomposição SVD.
λ_i	Valores singulares.
λ'_e	Autovalor da matriz de transformação da tensão.
λ'_i	Autovalor da matriz de transformação da corrente.
μ	Parâmetro momento.
v_k	Saída do combinador linear.
$\Psi(w)$	Transformada de Fourier de $\psi(t)$.
$\psi(t)$	Wavelet-mãe.
$\psi^*(t)$	Conjugado complexo de $\psi(t)$.
$\psi_{s,\tau}(t)$	Wavelet filha.
$\psi_{m,n}(t)$	Wavelet filha discretizada.
$\psi_{m,n}(t)$	Wavelet filha discretizada no tempo discreto.
$\psi_{j,k}$	Base ortonormal do subespaço wavelet.
$\varphi(\cdot)$	Função de ativação.
$\Phi^m(r)$	Valor médio do logaritmo natural.
$\phi(t)$	Função escala.
$\phi_{j,k}(t)$	Base ortonormal do subespaço escala.
τ	Fator de translação.
τ_0	Passo de translação discreto.
Ω_x	Espaço de atributos.
\mathbb{Z}	Conjunto dos números inteiros.
$\nabla^2 V(x)$	Matriz Hessiana.
$\nabla V(x)$	Matriz gradiente.

1 ASPECTOS GERAIS

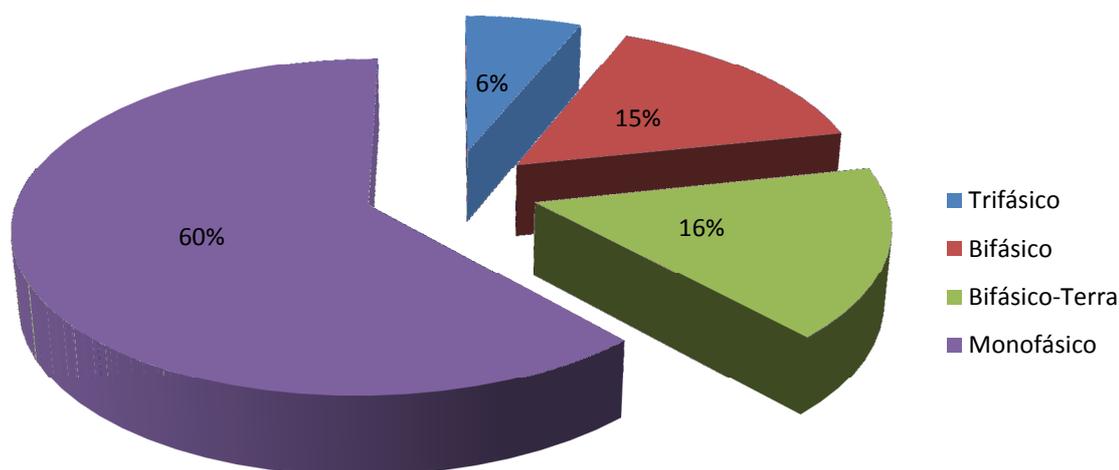
1.1 INTRODUÇÃO

A demanda crescente por energia elétrica vem sendo associada cada vez mais a uma cobrança por políticas rígidas de regulação do setor elétrico, pois qualquer interrupção do fornecimento de energia hoje se torna totalmente inaceitável. Portanto problemas como curtos-circuitos, descargas atmosféricas, rompimentos de cadeia de isoladores, incêndios, entre outros, precisam ser administrados pela empresa concessionária prontamente para restaurar o serviço aos seus clientes. A Aneel (Agência Nacional de Energia Elétrica) com o intuito de regular e fiscalizar as empresas concessionárias distribuidoras de energia elétrica estabeleceu indicadores de continuidade, tais como, DEC (duração equivalente de interrupção por unidade consumidora), DIC (duração de interrupção individual por unidade consumidora), FEC (frequência equivalente de interrupção por unidade consumidora) e FIC (frequência de interrupção por unidade consumidora) [1]. Esses indicadores medem a duração e frequência com que ocorre falta de energia e caso os valores apurados sejam maiores que o padrão estipulado à resolução nº 024 da Aneel [1] estabelece compensação às unidades consumidoras afetadas.

As condições impostas pela regulamentação levaram as permissionárias à procura de metodologias as quais permitissem uma melhoria na localização do problema causador de falta de energia para uma posterior restauração do serviço elétrico. Na vasta gama de fatores causadores de descontinuidade de serviço de fornecimento de energia um deles destaca-se pela grande quantidade de ocorrência experimentada pelas empresas do setor elétrico que é o curto-circuito, também conhecido como falta elétrica. Devido à natureza física dos tipos de curto-circuito, o trifásico é mais raro, em contrapartida o curto-circuito monofásico a terra é o mais corriqueiro, como exemplo pode-se citar as regiões fortemente arborizadas, onde a incidência de rompimento de fase em função da queda de galhos de

árvores é elevada. Esta dissertação leva em consideração apenas as faltas monofásicas, por serem as de maior ocorrência (Tabela 1.1 [2]).

Tabela 1.1 – Ocorrência dos Curtos-Circuitos [2].



A rápida restauração do fornecimento de energia para contingências do tipo curto-circuito têm sido perseguida por muitos pesquisadores principalmente quando relacionada ao nível de distribuição onde se enfrenta barreiras referentes à complexidade do sistema elétrico. Normalmente os sistemas de distribuição, principalmente os rurais, são de forma radial onde sua alimentação é realizada pela subestação conectada ao tronco principal com existência de varias ramificações de forma a atender aos mais diversos consumidores finais. Portanto a dispersão do alimentador de distribuição, a possibilidade de diversos tipos de condutores e a não transposição das fases (rotações feitas nos condutores da linha aérea de modo a minimizar o acoplamento indutivo entre as fases) caracteriza a grande complexidade de se implementar metodologias viáveis para solucionar o problema eficientemente, algo perseguido por diversas pesquisas discutidas posteriormente nas referências bibliográficas.

A indicação precisa do local da contingência ajuda sobremaneira a equipe de manutenção se dirigir diretamente ao local com problema, minimizando substancialmente o tempo de interrupção. Tal procedimento influencia diretamente na melhoria dos

indicadores de confiabilidade e de continuidade bastante perseguidos pelas empresas, diante da rígida regulamentação em vigor. Fica evidente que diante de um cenário com essas características a busca por sistemas de monitoramento em tempo real, que aponte o local da contingência constitui uma ferramenta importantíssima para orientar as ações corretivas das equipes de manutenção.

O desenvolvimento de técnicas para classificação ou detecção de situações de contingência no sistema possui um leque de abrangência muito grande e a escolha da metodologia mais adequada à solução do problema necessita de uma avaliação do sistema ao qual se deseja aplicar. Os vários métodos de localização de curtos-circuitos já propostos podem ser divididos em dois grandes grupos: i) métodos que utilizam a impedância aparente do sistema. ii) métodos que utilizam os conceitos de ondas viajantes, também conhecidas como ondas de surto eletromagnético. Contudo, a forte dispersão associadas aos sistemas de distribuição de grande porte limitam o emprego dos métodos, sendo normalmente utilizado o cálculo da impedância aparente. Já as metodologias que utilizam a teoria das ondas viajantes conseguem vencer tal problemática fazendo uso de sistemas dedicados e inteligentes.

As técnicas envolvendo ondas viajantes são reconhecidas como metodologias mais precisas em sistemas de transmissão, portanto seu uso será considerado neste trabalho. A técnica baseia-se no fato de, na ocorrência de uma falta, ondas de surto de alta frequência se propagam por toda extensão das linhas tanto de distribuição como de transmissão. De posse dos registros dessas perturbações provocadas no alimentador pode-se utilizar técnicas de reconhecimento de padrões para classificar e inferir a localização do ponto em contingência. Nesses sistemas, as grandezas corrente e tensão são monitoradas nas subestações terminais, procurando-se aferir distorções específicas dos sinais de corrente e tensão que possibilitem inferir a localização da falta. A grande limitação deste método reside na necessidade de se trabalhar com altas taxas de amostragem e de restrições quanto à aplicação dos Transformadores de Potencial (TP's) convencionais [3]. Contudo, visto o enorme desenvolvimento dos conversores A/D de alta velocidade e da tecnologia dos transdutores de corrente e tensão capazes de registrar os transitórios oriundos de uma falta com altas taxas de amostragem, a sua aplicação tem-se tornado viável, conforme refência [4] – [6].

Nos sistemas de distribuição as distorções percebidas nos sinais senoidais adquiridos incorporam grandes complexidades associadas à imensa quantidade de

ramificações, inerentes às características dos alimentadores principalmente os rurais, o que ocasiona diversas refrações e reflexões dos surtos originais propagados. As diversas refrações e reflexões dão origem a oscilações no sinal senoidal tanto da tensão como da corrente, devido tanto à peculiaridade da configuração do sistema como do local de ocorrência do curto-circuito. Portanto os sinais transitórios (fenômenos eletromagnéticos observados na variação do valor instantâneo da tensão/corrente nas condições de regime permanente, em altas frequências, e de curta duração) gerados pela falta tende a ser único corroborante para o uso de técnicas de análise de reconhecimento de padrões aqui empregadas. A análise desses sinais necessita de ferramentas matemáticas e estatísticas mais apuradas de forma a minimizar o custo computacional e as complexidades associados aos alimentadores em estudo, para tanto se utilizou neste trabalho as transformadas de Wavelets (TW) e ferramentas estatísticas tais como a entropia aproximada do sinal, a energia, entropia wavelet singular, entre outros que posteriormente serão detalhados mais afundo.

Nesta dissertação a transformada de Wavelets foi utilizada com o propósito de filtrar a componente fundamental (senoidal) do sinal sob análise e ressaltar as distorções associadas às ondas de surto presentes, por ocasião do curto-circuito. Como técnica de reconhecimento de padrões foi utilizada rede neural artificial (RNA). Entre as diversas propriedades das RNAs, aquelas referentes ao reconhecimento de padrões têm sido um dos grandes atrativos para sua utilização na engenharia elétrica. As RNAs estão presentes em diversas aplicações na engenharia elétrica na atualidade, sendo sua utilização em pesquisas envolvendo sistemas elétricos de potência cada vez mais presente em diversos problemas tais como: determinação do fluxo de carga, determinação da estabilidade, programa de geração de energia elétrica, etc. [7], [8]. Sua utilização em problemas envolvendo a proteção de sistemas elétricos de potência também tem avançado rapidamente [9] – [13]. Os excelentes resultados obtidos em diversos trabalhos que envolvem RNAs e engenharia elétrica estão causando o aumento dos estudos nesta área. Os resultados obtidos neste trabalho também encorajam maiores estudos referentes à utilização de RNAs na localização de faltas em linhas de distribuição [14].

Nas pesquisas aqui relatadas, foi utilizado como estudo de casos o sistema de distribuição rural da CELPE (Companhia Energética de Pernambuco) em Caruaru, o qual foi modelado levando-se em consideração a não transposição das fases, os diferentes tipos de condutores utilizado na rede e a presença de circuitos monofásicos e trifásicos. Com o

intuito de minimizar o custo computacional e conseqüentemente tornar a ferramenta final própria para uso em tempo real foi proposta a subdivisão do alimentador em grupos de ramais, de tal forma que a saída do algoritmo permitisse ao usuário final identificar de qual grupo se originou a falta e posteriormente organizar sua equipe de manutenção para corrigir o problema. Portanto um novo método de localização de curtos-circuitos é apresentada nesta dissertação a partir de simulações de monitorações em apenas um terminal da linha (subestação). O método proposto identifica os atributos característicos do caminho percorrido pelo curto-circuito e suas peculiaridades para inferir a localização da contingência.

1.2 ORGANIZAÇÃO DO TEXTO

No primeiro dos oito capítulos introduz-se o tema da pesquisa com apresentação dos objetivos e motivações.

No segundo capítulo é apresentada a evolução dos estudos na área de localização de faltas, desde as primeiras pesquisas realizadas por Roytman *et al* que datam de 1982 até as mais recentes com utilização de redes neurais, lógica nebulosa (*Fuzzy*). São abordados os diferentes métodos disponíveis de cálculo da distância da falta e as dificuldades de serem empregadas para redes de distribuição a propósito de justificar a escolha do método utilizado.

No terceiro capítulo a teórica das ondas viajantes é descrita, a qual representa a base do método aqui utilizado. Portanto os pontos principais são abordados com o intuito de caracterizar as informações que podem levar à inferência do local que originou os sinais de ondas viajantes.

No quarto capítulo é apresentado o equacionamento matemático inerente à transformada de wavelets, tanto para sua formulação contínua como para a discreta. Apresentam-se também os fundamentos básicos da técnica de Análise Multirresolução de Sinais (AMR), assim como exemplos das famílias wavelets. Por fim apresentam-se os benefícios da aplicação da TW em análise de sinais transitórios em sistemas de potência.

No quinto capítulo apresenta-se uma breve descrição das redes neurais artificiais, abordando seus conceitos principais, arquiteturas e algoritmos de aprendizagem. Portanto, mostra-se a RNA como um classificador de padrões empregado nas análises de localização da seção da falta.

No sexto capítulo são descritas as rotinas de processamento dos dados de entrada no sistema de reconhecimento de padrões utilizada neste trabalho, que são: desacoplamento de fases, normalização e o equacionamento matemático dos atributos estatísticos avaliados.

No sétimo capítulo apresenta-se estudo de caso aborda-se a modelagem do sistema elétrico no software ATP-EMTP, bem como os critérios de implementação do algoritmo proposto. Por fim se apresentam os resultados encontrados das simulações realizadas mostrando os impactos causados pela variação de alguns parâmetros, tais como a distância da falta, a resistência da falta e o ângulo de incidência.

O oitavo capítulo descreve-se as considerações finais. Nele se enfatizam os ganhos desta pesquisa para os sistemas de distribuição e apresentam-se propostas para trabalhos futuros na mesma linha dos que foram realizados para esta dissertação.

2 REVISÃO BIBLIOGRÁFICA

2.1 INTRODUÇÃO

O desenvolvimento de métodos e técnicas para localização de faltas tanto em linhas de transmissão como em redes de distribuição vêm sendo bastante enfocado devido à necessidade de criar-se um sistema cada vez mais robusto, com indicadores de continuidade compatíveis com a grande quantidade de tecnologia hoje disponível no mercado. Essa questão vem crescendo o interesse dos pesquisadores em alavancar um sistema ou uma metodologia visando melhorar a precisão e a rapidez na localização de faltas em sistemas elétricos [15]. Das propostas apresentadas uma grande quantidade faz uso das técnicas de redes neurais, como também das ferramentas matemáticas da transformada de Fourier e wavelet que será bastante empregada neste trabalho.

Existe uma variedade de métodos para a detecção de falhas em sistemas de distribuição de energia. A maioria desses métodos de estimativa da distância da falta à aquisição de dados é realizada por dispositivos de proteção. O desempenho dessas técnicas depende de algumas características do sistema a que se aplicam, tais como o sistema desequilíbrio, não-homogeneidade dos condutores, grau de ramificação [16]. Neste capítulo revisam-se algumas técnicas de localização de faltas propostas para sistemas de distribuição. Em geral, estes métodos podem ser classificados em três grandes categorias, que são os métodos baseados em componentes de frequência fundamental, nos quais os fasores de tensão e corrente são calculados; os métodos baseados em ondas viajantes e o método *knowledgebased* (método baseado no conhecimento do operador). A Figura 2.1 é um esquema dos métodos de localização de falta identificados ao se fazer à revisão bibliográfica.

O método baseado nos fasores de tensão e corrente utiliza somente os registros destes sinais, que são obtidos a partir dos próprios equipamentos de proteção já instalados nos terminais da linha, como os relés de proteção. Este método pode considerar dados

fornechos tanto de apenas um terminal como de dois ou mais terminais [17]. O uso da segunda técnica precisa ser bem mais requintado com a utilização de medição nos extremos da linha o que dificulta bastante seu uso para linhas de distribuição esparsas.

A técnica relacionada com a propagação de componentes de alta frequência baseia-se no cálculo do tempo de propagação da onda partindo do ponto da falta para o terminal de monitoramento e na velocidade de propagação da onda viajante na linha em análise [17]. Esta técnica possui algumas adversidades proporcionadas pela necessidade do uso de oscilógrafos de alto grau de precisão instalados na subestação. Porém o uso deste método é justificado pelo grau de precisão superior ao fornecido pela técnica dos componentes fasoriais a frequência fundamental [18].

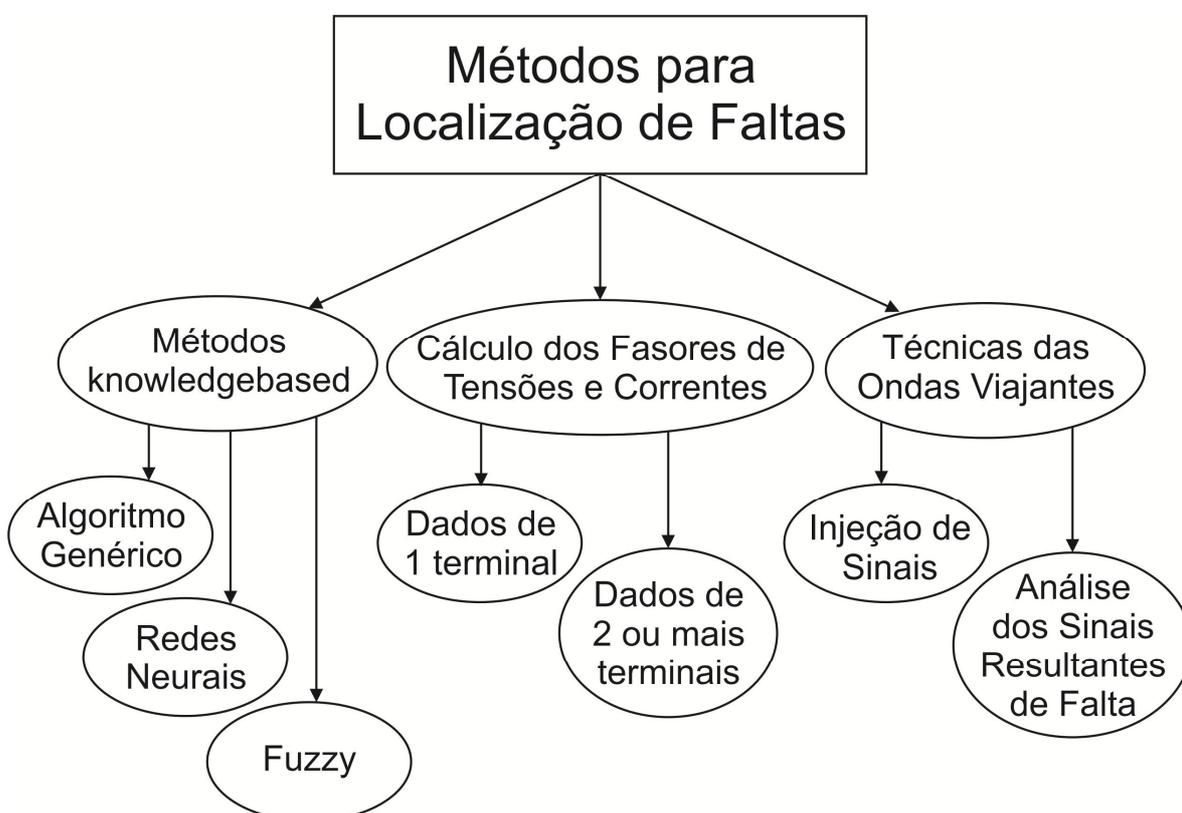


Figura 2.1 –Metodologia para localização de faltas [17].

2.2 MÉTODOS BASEADOS NOS COMPONENTES DE FREQUÊNCIA FUNDAMENTAL

Nesta família de métodos a distância de falha do barramento de distribuição primária para a localização da falta é calculada baseada na estimação da impedância

aparente da linha. Tensão e corrente medidos em uma extremidade ou em duas extremidades da linha são necessárias assim como equacionamentos matemáticos para estimar a localização do defeito. A maior parte dos métodos, desta família, é empregada apenas para os sistemas radiais e exige mais informações tais como, o status do disjuntor, a forma da corrente de falta e o indicador de status de falha do sistema [19], [20].

As primeiras técnicas de localização de faltas desenvolvidas datam de épocas anteriores 1950, pois os princípios baseado na impedância já eram utilizados de maneiras rudimentares, porém igualmente efetiva [21], [22]. As aplicações mais direcionadas para as linhas de distribuição datam do início de 1980 [23], [24]. Estas técnicas representam o início da história da localização de faltas específica para estes sistemas. A técnica proposta em [24] também já apresentava o estudo do local da falta através de técnicas de análise de circuitos na frequência fundamental, representando as técnicas fundamentadas na impedância através de medições de tensão e corrente em somente um terminal [25].

Uma técnica de localização de faltas para alimentadores rurais utilizando medições de tensão e corrente em apenas um único ponto foi apresentada por [26]. O algoritmo proposto leva em consideração as múltiplas ramificações, as condições desbalanceadas e a assimetria natural presentes nos alimentador de distribuição rural. Técnicas recursivas de estimação ótima foram utilizadas para se obter os fasores de tensão e corrente a frequência industrial. A localização da falta é então estimada utilizando o método baseado na impedância aparente e na atualização dos vetores de tensão e corrente. O algoritmo propõe localizar faltas nos ramais laterais e minimizar os erros advindos da resistência de falta, do desbalanceamento e da corrente de carga levando em consideração esses efeitos no algoritmo.

Um algoritmo para localização de faltas em um sistema de média tensão, levando em consideração as diferentes cargas conectadas ao longo do alimentador como também a não homogeneidade do mesmo foi apresentada por [27]. Dados de simulação no ATP-EMTP como também de uma empresa de distribuição do setor público foram utilizados na montagem do algoritmo. A distância da falta é calculada em dois passos segundo método proposto. Primeiramente a impedância da falta é calculada utilizando medições de tensão e corrente obtida antes e depois da falta. Posteriormente a impedância ao longo do alimentador é calculada assumindo a falta sucessiva em cada seção do alimentador. Comparando a impedância medida com a impedância calculada do alimentador uma

indicação da distância da falta pode ser obtida. As incertezas com respeito às condições pré-falta e o desbalanceamento do alimentador pode provocar erros na medição.

Em [28] propõe-se uma técnica para localização de faltas fase-terra para alimentadores rurais. O algoritmo faz uso apenas dos fasores de tensão e correntes fornecidos pela subestação como também pela impedância de sequência zero e positiva do alimentador primário. O método proposto baseia-se na técnica da impedância aparente do sistema onde a localização da falta é proposta resolvendo-se uma equação, sendo a distância da falta uma função da resistência de falta. O algoritmo proposto possui uma menor sensibilidade à resistência da falta.

Já em [29] uma técnica de localização de faltas para redes de distribuição rurais utilizando os fasores de tensão e corrente na frequência fundamental é descrita. A não homogeneidade das linhas (incluindo cabos e a combinação de diferentes geometrias de linhas aéreas), a presença de ramais laterais e bancos capacitores foram levando em consideração no algoritmo desenvolvido. A técnica se processa em seis passos:

- A. Seção em falta aparente – Estimação preliminar da localização da falta é realizada através das componentes de tensão e correntes pré e pós-falta detectados a partir da subestação. Os parâmetros da linha, o tipo da falta e os fasores de tensão e corrente são utilizados para esta estimativa.
- B. Sistema radial equivalente – Todos os ramais laterais e a localização aparente da falta são ignorados, sendo as cargas conectadas aos ramais laterais transportadas para o tronco principal.
- C. Modelagem da Carga – As cargas presentes em todos os nós são consideradas como dependentes da tensão e seus efeitos são compensados através de suas correntes. As constantes que determinam a relação entre tensão e admitância são estimadas a partir dos dados pré-falta de tensão e corrente [25]. Os modelos estáticos são utilizados para todas as cargas, incluindo também uma carga agregada ao terminal remoto.
- D. Tensão e corrente da falta e do terminal remoto – Os fasores de tensão e corrente de um nó são estimados assumindo que todas as cargas além desse nó sejam consolidadas como uma única impedância representando todo o equivalente do sistema após o nó estudado.

- E. Estimaco da distncia da falta – A distncia da falta  estimada atravs da relao tenso-corrente no ponto da falta e da natureza resistiva da impedncia da mesma. Para cada tipo de falta h uma equao diferente, obtida atravs de um equacionamento em componentes simtricas da impedncia no ponto da falta [25].
- F. Converso de mltiplas estimativas em apenas uma – A tcnica de localizao de falta proposta por [29] pode resultar em mltiplas estimativas caso a linha possua ramais laterais. O nmero de estimativas depende diretamente da configurao do sistema avaliado como tambm da distncia da falta. Para a minimizao das varias possibilidades o autor sugere a utilizao de equipamentos indicadores das faltas, com o propsito de sinalizar a passagem de corrente de falta no ponto instalado. A informao deste indicador  combinada com a sada do algoritmo proposto proporcionando um resultado nico do local em falta.

A metodologia apresentada por [29] apresenta-se bastante promissora, porm considera as linhas de distribuio como curtas e transpostas o que despreza o efeito capacitivo das mesmas. Tais hipteses simplificativas restringem a utilizao do algoritmo.

Uma alternativa para localizar faltas em sistemas de distribuio utilizando equacionamento direto da anlise de circuitos para curto-circuito fase-terra e fase-fase  proposta por [30] e [31]. No mtodo proposto o reclculo da tenso e corrente em cada n se faz necessrio para compensar as caractersticas nicas dos sistemas de distribuio. O mtodo se processa fazendo a equivalncia dos ramais laterais ao tronco principal como tambm das cargas, previamente conhecida,  jusante do ponto em falta. O equacionamento proposto pelo autor est em funo dos parmetros das linhas, da impedncia das cargas e das tenses e correntes medidas na subestao, generalizando o estudo para qualquer geometria da linha. Apesar da grande contribuio o algoritmo no leva em considerao a no transposio da linha, ou seja, o efeito capacitivo pode proporcionar erros significativos no mtodo [25].

O desenvolvimento e os resultados de simulaes e de testes prticos de um sistema automtico para localizao de faltas em redes de distribuio primrias  proposto por [20]. O sistema localizador de falta proposto baseia-se em bancos de dados, contendo informaes sobre a topologia da rede e os parmetros do alimentador, e em medies

provenientes de dispositivos eletrônicos inteligentes (IEDs) equipados com sistemas de oscilografia, instalados apenas na subestação do alimentador. Um módulo DSP (*Digital Signal Processing*) é utilizado para determinar o instante da ocorrência da falta, posteriormente faz uso de duas janelas de dados para estimar as quantidades dos fasores nas condições pré-falta e pós-falta utilizando a transformada discreta de Fourier (DFT). Apesar de a técnica proposta apresentar contribuições importantes ela limita-se a aplicações apenas para sistemas de distribuição balanceados o que restringe seu uso à minoria dos casos.

Um algoritmo de localização de faltas baseado em medições de corrente em ambas as extremidades da linha sem a necessidade dos parâmetros da mesma foi proposto por [32]. A grande contribuição do método foi à utilização de medições de tensão pré e pós-falta em ambas às extremidades da linha de modo sincronizado ou não sincronizado o que pode reduzir bastante os erros advindos da perda de sincronismo dos equipamentos das extremidades. Outra contribuição importante foi a incorporação de um método para estimar os parâmetros de sequência positiva da linha, utilizando as medições de tensão e corrente tomadas em momentos diferentes durante as operações normais. Uma vez estimado os parâmetros da linha todo sistema de proteção e controle pode ser beneficiado. Apesar de boas contribuições o algoritmo leva em consideração a transposição da linha, desprezando a possibilidade da consideração do efeito capacitivo para aplicação em linhas de distribuição. O autor também não incorpora em seu algoritmo a possibilidade de existência de ramais laterais o que pode inviabilizar o uso da técnica para aplicação em sistemas de distribuição.

Em [33] descreve-se um algoritmo baseado nas características de afundamento de tensão para localização de faltas em alimentadores aéreos de distribuição de energia elétrica. O algoritmo propõe-se a indicar o local ou a região da falta em um alimentador radial com vários ramais laterais sendo baseado na comparação de tensões esparsamente medidas com tensões simuladas para a condição de falta. Para a localização da falta o algoritmo utiliza os fasores de pré e durante a falta das tensões e correntes medidas no nó inicial do alimentador, as amplitudes das tensões durante a falta medidas em alguns nós do alimentador, bem como uma base de dados contendo parâmetros, tais como a topologia do alimentador, as impedâncias das seções da linha e a potência nominal dos transformadores conectados ao alimentador. Apesar da excelente contribuição dos autores o algoritmo necessita de sistemas de aquisição de dados na subestação e em pontos remotos do

alimentador o que pode provocar um aumento da demanda de manutenção nas linhas de distribuição.

Uma metodologia geral para calcular a distância da falta utilizando um algoritmo baseado na impedância aparente da linha é descrita por [34]. O método proposto utiliza os sinais locais de tensão e corrente como dado de entrada para o algoritmo e sua formatação leva em consideração os efeitos da variação da carga e os diferentes tipos de faltas. Para aplicação da técnica em sistemas de grande porte, uma análise baseado no fluxo de potência é executada a fim de determinar a possível localização da falta. O algoritmo proposto segue as etapas abaixo descritas:

- A. Roda o algoritmo de fluxo de potência trifásico considerando as condições pré-falta do sistema.
- B. Calcula a impedância equivalente em cada nó do sistema, utilizando a seguinte expressão:

$$Z_{eq_{p-q}} = \frac{V_p}{I_{p-q}} \quad (2.1)$$

sendo,

V_p – tensão pré-falta na barra p (em volts);

I_{p-q} – corrente pré-falta da barra p para a barra q (em amps).

- C. Determinar os possíveis números de trajetos de fluxos de potência junto ao tronco principal.
- D. Selecionar um trajeto de fluxo de potência e determinar o nós com ramais laterais conectados.
- E. Para cada nó com ramais laterais, determinar a carga equivalente respectiva, considerando apenas a impedância equivalente previamente calculada fora do trajeto analisado.
- F. Para cada nó com ramais laterais e cargas, realizar o paralelo entre a carga e o equivalente da carga determinado no passo E.
- G. Refazer o passo D até que todos os possíveis sistemas equivalentes sejam determinados.
- H. Executar o algoritmo de localização de falta para cada sistema equivalente.

- I. Determinar a correta localização da falta e o trajeto correto utilizando o algoritmo de determinação do ponto da falta.

A aplicação do algoritmo apresenta-se bastante robusto e geral para as possíveis configurações dos sistemas de distribuição, contudo a aplicação deste método deve tornar-se onerosa computacionalmente devido à grande quantidade de iterações necessárias para distinguir a possível localização da falta. Um possível exemplo desta problemática seria um sistema de distribuição rural de grande porte com vários ramais e sub-ramais laterais o que possivelmente inviabilizaria o uso desta técnica. Em uma metodologia viável a aplicação de monitoramento em tempo real do local da falta exige um algoritmo que possa dar respostas rápidas e precisa como resposta ao operador.

Também há algoritmo para localização de faltas em redes de distribuição subterrânea baseada na impedância aparente do sistema, proposto em [35] e centrada numa representação em sistemas de fase de forma a considerar os componentes mútuos da linha. A impedância aparente da linha é calculada utilizando apenas dados de tensão e corrente local. A técnica é iterativa de forma a compensar os componentes capacitivos típicos nas correntes em cabos subterrâneos. O algoritmo proposto pode ser utilizado tanto para linhas subterrâneas balanceadas como para as não balanceadas. O desempenho do método independe da resistência de falta e da distância da mesma, porém pode apresentar imprecisão quando da variação da topologia do sistema, com respeito a existência de ramais laterais.

Um estudo numérico dos efeitos causados pelo desbalanceamento e da impedância de falta em sistemas de potência quando submetido a uma situação de curto-circuito foi apresentado em [36]. Duas técnicas de análise de faltas foram consideradas tais como componentes simétricas e os componentes de fases e avaliada sobre um sistema padrão do IEEE de 13 barras. Os estudos de caso incluem os efeitos do desbalanceamento e os efeitos da impedância de falta nas tensões e correntes pós-falta. Os resultados encontrados apontam para a grande dependência dos métodos para os efeitos de desbalanceamento e impedância da falta.

A necessidade da rápida restauração do fornecimento tem estimulado inúmeras pesquisas em algoritmos de localização de faltas tanto por pesquisadores nacionais como em nível mundial, porém este tópico ainda permanece em discussão devido às diversas variações encontradas nos sistemas elétricos. Os métodos que levam em consideração a

localização da falta através da impedância aparente da linha tem se mostrado promissor, porém ainda encontra barreiras relacionadas à característica do problema encontrado em sistemas de distribuição principalmente em redes rurais onde encontramos alimentadores muito dispersos o que proporciona erros significativos nos algoritmos até aqui mencionados. Como principal dificuldade pode-se relacionar as múltiplas estimativas de prováveis locais de ocorrência da falta necessitando pulverizar equipamentos indicadores de curto-circuito nos diversos ramais do alimentador o que pode proporcionar um aumento no índice de manutenção desses equipamentos. No próximo tópico os algoritmos utilizando alta frequência serão descritos.

2.3 MÉTODOS BASEADOS EM COMPONENTES DE ALTA FREQUÊNCIA E ONDAS VIAJANTES

Esta família de métodos baseia-se na reflexão e refração das ondas viajantes propagadas pela incidência de uma falta na rede. Embora, com base nesse princípio, seja possível determinar o local de ocorrência da falha com uma exatidão elevada, a sua aplicação necessita de uma complexa análise do sistema, o que a torna pouco competitiva em relação aos métodos baseados na impedância aparente da rede. Além disso, ela necessita de equipamentos acrescentados à rede, tais como o sistema de GPS, detectores de transitórios de falhas e um software de diagnóstico. Além disso, a complexidade comum às configurações dos sistemas de distribuição dificulta a escolha do local de instalação dos detectores de falhas transitórias, limitando bastante o uso desta técnica nas aplicações para distribuição.

Um método para localização de falta utilizando medições tanto em apenas um terminal da linha como também em dois terminais foi proposto por [37] baseando-se na teoria de ondas viajantes. O esquema do método proposto atua visualizando as ondas viajantes incidentes da corrente transitória do ponto da falta medida na subestação do alimentador, sendo utilizada uma função de correlação cruzada para identificar as ondas viajantes transitórias. As tensões são estimadas utilizando os métodos de modelagem usual utilizado em linhas de transmissão, enquanto a distância da falta é computada fazendo uso das funções de correlações. As simulações realizadas pelo autor sugerem que o método utilizando dois terminais apresenta uma melhor precisão caso a falta ocorra no ramal onde o registrador de perturbações esteja instalado. O método proposto apresenta problemas quanto ao nível de descontinuidade proporcionada pelo alimentador, o que poderá levar a

erros significantes, como também não considera o desequilíbrio entre as fases frequente em alimentadores rurais de distribuição.

Uma nova técnica foi descrita por [38] para determinar a precisa localização da falta em linhas aéreas de distribuição e em sistemas de cabos. Tal metodologia desenvolvida depende quase que exclusivamente dos sinais de falta gerados de alta frequência o que evita os problemas de dantes enfrentados de identificar as múltiplas reflexões geradas pelas descontinuidades dos barramentos e do ponto da falta, o que restringia bastante o uso de outras técnicas de ondas viajantes. A técnica desenvolvida pelo autor é insensível ao tipo da falta, resistência da falta e as configurações das fontes. Outra problemática enfrentada pelos algoritmos antecessores eram os baixos ângulos de incidência da falta, superado na metodologia proposta, pois os sinais de alta frequência associados com o arco de falta não variam com o ponto da onda no qual a falta ocorre.

O esquema de funcionamento do algoritmo corresponde a um sistema de amostragem de alta velocidade para capturar os transitórios de alta frequência gerados pela falta. De forma a assegurar uma alta exatidão utilizou-se uma taxa amostragem de 20MHz. A precisão da localização da falta está diretamente relacionada com a taxa de amostragem utilizada nas medições.

Existe também um método para localização de faltas baseado na teoria das ondas viajantes proposto por [39] o qual utiliza como base para análise as medições dos sinais transitórios advindos do ponto da falta. Primeiramente os sinais registrados passam pelo processo de decomposição em seus componentes modais para posteriormente serem submetidos a transformada de wavelets (TW) e passem do domínio do tempo para o domínio do tempo-frequência. Esta informação relata o tempo de viagem dos sinais transitórios para localizar a falta. Finalmente a distância da falta é estimada fazendo uso das informações contidas nos coeficientes da transformada de wavelets (CTW). Os CTW do sinal de tensão do modo aérea 1 é utilizado para identificar o ramal lateral onde ocorreu a falta já os CTW do modo terra são utilizados para determinar a presença de conexão à terra e a metade da linha em que uma falta aterrada se encontra [39]. O método proposto independe da resistência de falta e mostra-se também adequado para aplicação em linhas onde existe a compensação série. O método pode ser usado também em situações onde existem medições provenientes de apenas um terminal como para dois terminais. A precisão do algoritmo é proporcional à taxa de amostragem utilizada para o registro dos sinais transitórios [15].

Em [40] apresenta-se uma técnica para localização de falta previamente proposta por [38], porém incrementando os estudos com o uso da transformada de wavelets (TW). O método proposto consiste em um dispositivo detector de transitórios, instalado no barramento, que funciona detectando sinais transitórios de tensão de alta frequência, portanto os sinais iniciais e subsequentes causados pela reflexão das ondas viajantes são gravados no dispositivo proposto. A transformada de wavelets é utilizada como um banco de filtro de forma a decompor o sinal em coeficientes de aproximação e detalhamento. Portanto o tempo de viagem dos transitórios e a localização da falta são conseqüentemente calculados utilizando esses coeficientes de decomposição. A exatidão do método está diretamente relacionada com taxa de amostragem dos sinais de alta frequência adquiridos.

Existe também uma aplicação da transformada de wavelets como uma técnica para localização de faltas em linhas de distribuição com cargas conectadas proposta por [41]. O tempo necessário para que o transitório gerado pela falta se propague e chegue ao terminal da subestação ou ao terminal da carga depende diretamente da distancia percorrida e da velocidade de propagação da onda o qual é medida pelo detector de transitórios de falta instalados tanto na subestação quanto no terminal da carga. Portanto, o tempo de propagação é medido nos dois barramentos e sincronizado com uso de um GPS (*“Global Positioning System”*), de posse também da estrutura topológica da rede estima-se a distância da falta.

Em [42] descreve-se um método para localização de faltas baseando-se no algoritmo proposto por [39]. A metodologia apresentada faz uso das características especiais da transformada de wavelets para diferenciar as faltas ocorridas ao longo dos diferentes ramais laterais ao tronco principal do alimentador com igual distância da subestação. Tal método faz uso da modelagem de linhas de José Marti, sendo especificado um intervalo ao invés de um número fixo para determinar os ramais laterais ao tronco principal da rede, o que depende da topologia. A generalização do método para linhas não transpostas fica a cargo das matrizes de decomposição modal. Para as linhas desbalanceadas o cálculo da matriz modal de decomposição utilizou a rotina *“line constante”* do ATP para o intervalo de frequência desejado. A precisão do método também está diretamente conectada a taxa de amostragem da aquisição dos sinais a serem avaliados.

Existe também uma metodologia desenvolvida por [43] baseada na transformada de wavelets continua (CWT) para análise dos transitórios de tensão devido a uma falta na

linha de um sistema de potência de distribuição. As análises desenvolvidas pelo autor ilustram a existência de uma correlação entre as frequências típicas dos sinais transformados pela CWT e o caminho específico na rede percorrido pelas ondas viajantes originadas no ponto da falta. O uso da CWT é justificado pelo autor devido sua performance mais detalhada e da possibilidade de análise contínua do espectro de energia do transitório da falta. Tal característica é utilizada para detectar frequências individuais que caracterizem os transitórios de tensão gerados pela falta. Posteriormente essas frequências individuais são utilizadas para inferir a distância da falta, sendo previamente conhecida a topometodologia da rede, a velocidade de propagação das ondas viajantes ao longo das linhas e o tipo da falta.

Há um procedimento para localização da falta em redes de distribuição que é baseado em análises utilizando transformada de wavelets das ondas viajantes geradas do local em curto-circuito [44]. Nesse método a transformada de wavelet contínua se aplica as formas de onda da tensão medidas durante a ocorrência da falta em uma determinada barra da rede. A wavelet mãe é contruída em conformidade com a onda dos sinais transitórios decorrentes da falta. O desempenho do algoritmo foi avaliado através de um estudo de caso em uma rede de distribuição de 34 barras do IEEE e seus resultados comparados com uma wavelet mãe mais tradicional (Morlet). A localização da falta ocorre pela determinação de frequências peculiares pertencentes a trajetos específicos percorridos pelas ondas viajantes injetada no momento do curto-circuito.

O uso de entropia aproximada ($ApEn$) para análise dos sinais de potência não estacionários foi proposto em [45] para uso combinado com a transformada de wavelet de forma a minimizar os ruídos. Segundo o autor o uso da $ApEn$ pode distinguir bem dois sinais transitórios de faltas diferentes mesmo em condições de séries temporais curtas. Sua pequena amplitude, obtida através da distribuição marginal de probabilidade, a torna insensível a ruídos e interferências. Seu emprego é bastante adequado para uso em análises de transitórios em sinais não estacionários com é o caso dos sinais gerados pela falta. Entre as características da $ApEn$ pode-se destacar algumas tais como:

- A. Eficaz não apenas para sequências determinísticas, mas também para sequências estocásticas;
- B. Necessita de uma sequência curta de dados para uma análise eficaz do sinal em estudo;

- C. Boa capacidade em resistir a perturbações e ruídos existentes na sequência de sinais;
- D. Pode ser afetada apenas pela complexidade, mas não pela amplitude dos sinais avaliados;
- E. Possui características bem superiores a média, variância, covariância entre outros parâmetros estatísticos.

ApEn possui uma grande vantagem, pois sua utilização em sistemas de potência apresenta insensibilidade à resistência da falta e necessita de poucos dados para caracterizar bem o local da falta, facilitando bastante seu uso para aplicativos que funcionem em tempo real.

A técnica para detecção e classificação de faltas em linhas de transmissão utilizando os sinais transitórios de tensão que foi apresentada em [46] faz uso da transformada de wavelets, da decomposição em valores singulares e da entropia de Shannon, o que, segundo os autores, torna o algoritmo imune a ruídos nos sinais transitórios da falta e as diferentes possíveis amplitudes do sinal transitório. A *WSE* (*Wavelet Singular Entropy*) é ser utilizada para expressar as características da falta intuitivamente e quantitativamente mesmo em situações tais que o transitório do sinal apresente muito ruído e baixa amplitude. O algoritmo proposto apresenta baixa sensibilidade ao tipo, ao ângulo de incidência, resistência e a localização da falta.

Um procedimento para localização de faltas em redes de distribuição baseado no uso da decomposição wavelet integrada do tempo-frequência dos transitórios de tensão associado com as ondas viajantes originadas pela falta foi apresentado em [47]. Medições de transitórios de tensão apenas no barramento MV (media tensão) da subestação do alimentador de distribuição é requerido e posteriormente faz o tratamento dos dados utilizando a decomposição wavelet em tempo-frequência associado aos padrões característicos da distância da falta. Vários testes foram realizados utilizando um modelo reduzido de um alimentador de forma a testar a performance do proposto algoritmo.

2.4 MÉTODOS KNOWLEDGE-BASED

Os métodos baseados em inteligência artificial vêm avançando bastante devido à capacidade crescente de processamento dos computadores. Algoritmos cada vez mais sofisticados e robustos que permitem reconhecimentos de padrões altamente satisfatórios

em sistemas de potência. O grande inconveniente dos métodos dessa classe seria a necessidade de registradores de perturbação com uma alta taxa de amostragem, algo que vêm sendo contornado pelo desenvolvimento de tecnologia, permitindo preços mais acessíveis. A aplicação destas técnicas normalmente baseia-se no reconhecimento de padrões dos sinais avaliados do local em falta para posterior classificação e localização do ponto em curto-circuito.

Um algoritmo para localização de faltas baseado na lógica nebulosa, [48]. Os dados da corrente de curto-circuito foram adquiridos de sensores de faltas instalados no alimentador. Assim, de forma a tratar o banco de dados disponível um conjunto de metodologias difusas foram propostas, vale ressaltar que a experiência do operador também foi levada em consideração. O algoritmo proposto não se limita a indicar apenas a seção do alimentador onde se encontra o curto-circuito.

Em [49] um modelo matemático e sistemático utilizando algoritmo genético refinado (RGA) foi proposto. A estimação da localização da falta é realizada através de seções, ou seja, defini-se uma região onde existe a probabilidade da falta estar localizada. Inicialmente uma matriz de causalidade probabilista é formulada levando em consideração a relação probabilística existente entre a seção de ocorrência da falta, a ação de ativação dos relés de proteção e dos disjuntores. Desta forma, a estrutura e a função de proteção do sistema de potência são codificadas na matriz proposta. Posteriormente, um conjunto de dados é desenvolvido utilizando a teoria parcimoniosa, da qual se obtém um modelo de programação inteira. Por fim, aplica-se um método baseado em RGA para estimar a seção da falta, onde apenas as informações sobre a operação dos relés de proteção e disjuntores são necessárias para indicar a seção em contingência. A metodologia proposta é versátil e pode lidar com a incerteza da estimação da seção da falta, tais como as falhas dos relés de proteção, as falhas dos disjuntores. Os resultados têm mostrado que a abordagem probabilística é viável e eficiente para pequenos sistemas, contudo, sua aplicação em sistemas de potência de grande porte é inviável.

Uma nova abordagem on-line para estimar o local de ocorrência da falta na subestação de distribuição foi proposta por [50]. O algoritmo também identifica o tipo de falha utilizando uma metodologia híbrida de lógica nebulosa e redes causa-efeito. Uma rede causa-efeito, a qual é adequada para processamento paralelo, representa as funções dos relés de proteção e dos disjuntores na seleção da seção em curto-circuito, assim, a velocidade de processamento pode ser melhorada significativamente. A fim de minimizar

as incertezas envolvidas no processo de localização da falta, o autor propõe uma regra baseada nas técnicas de lógica *fuzzy*. Segundo o autor, os resultados experimentais revelaram que o diagnóstico foi preciso mesmo em situações envolvendo múltiplas falhas. Contudo, vale ressaltar que o sistema de distribuição avaliado era de pequeno porte.

Há também uma metodologia, proposta por [51], a qual visa repartir eficiente um sistema de grande porte e classificar a seção em contingência. O trabalho propõe a partição de redes de energia de grande escala em um número desejado de sub-redes com feixe de condutores balanceados no intuito de minimizar os estudos de estimação da seção da falta. O número de elementos na fronteira de cada sub-rede também é minimizado no método. O método sugerido consiste em três etapas básicas: formar uma árvore ponderada por todo alimentador, posteriormente toda a rede é repartida em sub-redes conectados e balanceados. Por fim, os nós de fronteira da conexão entre sub-redes são minimizados em número no intuito de diminuir a quantidade de iterações de estimação da seção da falta nas regiões de conexão entre sub-redes.

O método foi implementado com a técnica de armazenamento esparsos e testado nos sistemas do IEEE 16 barras, 30 barras e 118 barras. Os resultados de simulação em computador do algoritmo desenvolvido são eficazes na localização da seção em contingência em sistemas de médio porte quando combinado com as técnicas de inteligência artificial distribuída.

Em [52] apresentou-se um método baseado no uso de técnicas de redes neurais artificiais como um algoritmo para economizar tempo na localização de faltas. Esta técnica é aplicada a uma rede de distribuição existente 13,8 kV, que atende a um campo de produção de petróleo espalhados por uma área de aproximadamente 60 km². A natureza deste sistema de distribuição, que consiste de uma configuração multi-anel, ou seja, dispersa, ilustra a complexidade da rede. Os resultados de simulação, segundo o autor, têm mostrado a viabilidade e a eficácia do método sugerido na localização de faltas em sistemas de pequeno porte.

Uma abordagem para localização de falhas em sistemas de distribuição utilizando o autovalor e um algoritmo baseado em redes neurais artificiais foi proposto por [53]. A rede neural é treinada para mapear a relação não linear existente entre a localização de faltas e as características intrínsecas dos autovalores. Segundo o autor, a abordagem é capaz de identificar, classificar e localizar diferentes tipos de falhas, tais como: faltas monofásicas, curtos-circuitos bifásicos e faltas trifásicas. Assim, o trabalho mostra que os autovalores

são capazes de carregar as características do local de ocorrência da falta e, portanto, localizar corretamente o ponto em contingência. Contudo o algoritmo proposto não leva em consideração o desequilíbrio entre as fases, causado pela não transposição das linhas de distribuição, como também todas as simulações foram realizadas em sistemas não dispersos, ou seja, com características completamente distintas das redes de distribuição brasileiras.

Em [54] apresentou-se um algoritmo inteligente para diagnóstico de curto-circuito, onde a localização da falta primeiramente é realizada utilizando um estimador iterativo da carga e da corrente de curto-circuito em cada seção da linha. Posteriormente, aplicam-se as regras de reconhecimento de padrões para as correntes de falta no intuito de identificar a seção em contingência. Caso necessário uma comparação entre a carga interrompida e a carga atual do sistema é realizada para um diagnóstico final. Os efeitos da variação da impedância e da carga foram investigados através de simulações com resultados satisfatórios, contudo, o algoritmo desenvolvido não leva em consideração a possibilidade de sistemas com um alto grau de dispersão, limitando-se apenas a redes de pequeno porte.

Existe também uma abordagem, proposto por [55], com base nas redes ANFIS no intuito de localizar faltas. O algoritmo necessita das formas de onda da corrente medida na subestação e do conhecimento prévio das configurações dos dispositivos de proteção. A metodologia proposta consiste no treino do sistema ANFIS com um banco de dados de curtos-circuitos obtidos do sistema de distribuição, sendo o mesmo apresentado ao sistema inteligente em par entrada-saída. Como resultado, as redes ANFIS, segundo o autor, provaram a capacidade de localizar a falha em uma zona específica do sistema de distribuição de energia. O resultado mostra erros de validação inferior a 1% para localizar zonas de falha, porém sua aplicação limita-se a sistemas de pequeno porte.

Uma abordagem via Rede Neural Artificial (RNA) para a localização de falhas em sistemas de distribuição foi proposta por [56]. Diferente dos métodos tradicionais de estimação da seção em curto-circuito, a metodologia proposta utiliza apenas medições do sistema elétrico. As faltas são, portanto, localizadas de acordo com a impedância do caminho percorrido pelas correntes de curto-circuito até a subestação através de redes neurais *feed forward*. Situações corriqueiras nos sistemas de distribuição são levadas em consideração no treino das redes neurais, tais como: dispositivos de proteção existentes apenas nas subestações, medições limitadas do sistema em estudo, vários tipos de curto-circuito. O estudo foi realizado em um sistema de distribuição típico do IEEE com 34

barras, com cargas desequilibradas, existindo também ramificações monofásicas e trifásicas, sendo, portanto, um alimentador com 69 nós de teste com diferentes configurações. Os resultados, segundo o autor, apresentam resultados precisos, contudo aplicado para sistemas de distribuição pequenos.

Em [57] uma abordagem prática para identificar a localização de falhas em um sistema de distribuição foi proposta. A técnica utiliza como dado de entrada medições da potência nas subestações, pois sempre que uma falha ocorre no sistema de distribuição, tanto a direção como a amplitude da potência se modificam da condição de frequência industrial em cada fase. Baseado nesta informação, o máquinas de vetor de suporte (SVM) identifica a localização da falta com os dados captados da subestação. Após a identificação da localização da falta, os eventos ocorridos em cada fase são então classificados individualmente através de um classificador de dois estágios nebuloso. O sistema foi simulado utilizando o *Simulink* do Matlab e o PSCAD, apresentando resultados interessantes para sistemas de pequeno porte.

Em [58] uma solução alternativa para o problema da continuidade do serviço de energia associada à localização da falta foi apresentada. Uma metodologia de natureza estatística com base em misturas finitas é proposta, ou seja, um modelo estatístico é obtido da extração da amplitude do afundamento de tensão registrado durante um evento de falha, juntamente com os parâmetros de rede e topologia. O objetivo é oferecer uma alternativa econômica de fácil implementação para o desenvolvimento de estratégias orientadas para melhorar a confiabilidade da redução dos tempos de restauração em sistemas de distribuição de energia.

Em [59] uma técnica de regressão como as máquinas de vetor de suporte (SVM) configurado para utilizar a técnica de otimização de algoritmo genético de Chu Beasley (CBGA) no intuito de desenvolver uma metodologia para localizar faltas. A técnica proposta faz uso das medições de tensão e corrente em apenas um ponto do alimentador, subestação, como entrada do algoritmo de regressão clássico. A estratégia desenvolvida é, então, testada na seleção dos parâmetros de calibração de um SVM de fase única, obtendo, assim, um erro médio de aproximadamente 5,278%.

Há também um método para localização de faltas, proposto por [60], o qual utiliza como técnica de classificação a máquina de vetor de suporte (SVM) e uma busca inteligente baseado em técnicas de vizinhança variável para selecionar os parâmetros de configuração do SVM. Como resultado, propõe-se relacionar um conjunto de

características, obtidas a partir de medições em apenas um terminal de tensão e corrente, com o local de ocorrência da falta através de uma tarefa de classificação clássica. A abordagem proposta é testada utilizando os dados de calibração selecionados pelo SVM conseguindo, portanto, um erro de classificação da ordem de 3,7% considerando todos os tipos de faltas.

Um novo algoritmo para localização de faltas fase-terra em sistemas de distribuição de energia foi proposto por [61]. A incidência de uma falta injeta no sistema ondas viajantes que se propagam ao longo do alimentador de distribuição em todos os sentidos, sendo então, refletidas nas terminações da linha. Dependendo do caminho que as ondas injetadas se propagem frequências características distintas serão guardadas no sinal. Com base nesta peculiaridade, a tensão transitória é decomposta utilizando os filtros de wavelets, sendo, portanto, o espectro de energia do sinal, o qual possui alta densidade em torno das frequências características, decomposto em diferentes níveis. Assim uma rede neural é proposta, utilizando como entrada um vetor com diferentes níveis de decomposição do espectro de energia do sinal. Os processos de simulação e treinamento foram realizados utilizando o ATP-EMTP e o Matlab.

2.5 CONSIDERAÇÕES FINAIS

Neste capítulo se apresentou uma revisão das técnicas de localização de faltas em sistemas de distribuição das três classes: (i) baseada na impedância, (ii) nas ondas viajantes e (iii) no conhecimento do operador foram revisadas. A grande maioria das técnicas de localização de faltas discutidas apresentam limitações, tais como:

- Os algoritmos de localização de faltas iterativos apresentam, normalmente, um alto custo computacional, o que inevitavelmente impacta em tempo de processamento. Outro fator está relacionado com a possibilidade da não convergência da solução.
- Os procedimentos heurísticos, utilizado em lógica *fuzzy* e em outros algoritmos, necessitam de um número considerável de exemplos de curtos-circuitos do sistema de distribuição analisado de forma a identificar corretamente o local de falta.

- A maioria dos métodos necessita de medições de tensão e corrente em mais de um ponto e em diferentes locais do alimentador, impactando em custo de aquisição e manutenção para as empresas concessionárias.

De acordo com as vantagens e desvantagens descritas para cada método pode-se concluir que os métodos baseado no conhecimento do operador apresentam uma acurácia melhor, como também baixo custo na sua implementação operacional. Entre os métodos *Knowledge-Based* as redes neurais artificiais ganham destaque em função da sua alta capacidade de generalização em processos de reconhecimento de padrões.

3

TEORIA DAS ONDAS VIAJANTES

3.1 INTRODUÇÃO

O conceito de ondas viajantes ou ondas de surto aqui empregado pode ser analogamente comparado com os fenômenos encontrados na hidráulica, inclusive podem ser descritos matematicamente por equações diferenciais semelhantes. Uma simples comparação poderia ser realizada em função da abertura das compostas de um reservatório de uma hidrelétrica, onde se observa que a propagação de água dispersada irá preencher os dutos paulatinamente, ou seja, em alguns instantes parte do duto subsequente a frente de água corrente estará completamente seco, enquanto que os trechos previamente percorridos estarão plenamente tomados pela água. Analogamente ao processo hidráulico a energização das linhas de transmissão e distribuição irá apresentar comportamento gradual, quando da aplicação de tensão repentina em um de seus terminais. Assim a energia irá viajar ao longo da linha com uma velocidade se aproximando da velocidade da luz [62], [63].

As análises aqui empregadas referem-se à propagação de energia elétrica e magnética em uma linha de distribuição quando do surgimento de uma variação de tensão ou corrente ocorrida em qualquer ponto do seu comprimento ou no instante de energização da mesma. Neste contexto, ao se energizar uma linha duas ondas simultâneas, uma de tensão e outra de corrente, partem do elemento transmissor se deslocando até os elementos receptores. Essas duas ondas são denominadas *ondas diretas* ou *ondas incidentes*. Portanto o lado receptor de uma linha não tem conhecimento desta injeção de surto até que a onda tenha viajado completamente do emissor até a ponta receptora. Assim, observa-se que os sinais elétricos tendem a se propagar para frente e para trás, como ondas viajantes, normalmente dissipando energia em perdas no material por onde ele passa [64].

Com o exposto acima, temos que qualquer distúrbio em uma linha de transmissão (tal como os provocados por descargas atmosféricas, curtos-circuitos, ou uma alteração da condição de regime permanente) dá origem a ondas viajantes. Estas por sua vez, deslocam-se no sentido das extremidades da linha de acordo com a velocidade de propagação da linha, onde encontram descontinuidades físicas do sistema que provocam a sua reflexão ou refração, dependendo das características dessas descontinuidades. Este sucessivo processo continua até que as ondas sejam extintas devido às atenuações causadas por perdas na linha, alcançando o regime permanente do distúrbio [15].

3.2 REFLEXÕES E REFRAÇÕES DE ONDAS VIAJANTES

Quando uma onda eletromagnética se propaga ao longo de uma linha uma certa impedância característica (Z_0), dada pela equação, fica diretamente definida, ou seja, existe uma relação fixa entre as ondas de tensão e corrente ao qual não pode ser violada.

$$Z_0 = (L/C)^{1/2} \quad (3.1)$$

sendo, L representa a indutância da linha e C representa a capacitância da linha.

Resolvendo as equações diferenciais das linhas pode-se demonstrar a existência de proporcionalidade entre as ondas de corrente e as ondas de tensão, sendo o fator de proporcionalidade dado pela impedância característica (Z_0), conforme descrito pelas equações (3.2) - (3.7). Onde $v = (LC)^{-1/2}$ representa a velocidade de propagação da onda de tensão.

$$\frac{\partial I}{\partial t} = -\frac{1}{L} \frac{\partial V}{\partial x} \quad (3.2)$$

sendo, V representa a tensão, I a corrente, t representa o tempo e x o espaço.

Integrando a equação (3.2) em ambos os lados em relação ao tempo, temos a equação (3.3) e como resultado da integração a equação (3.4).

$$\int \frac{\partial I}{\partial t} dt = \int -\frac{1}{L} \frac{\partial V}{\partial x} dt \quad (3.3)$$

$$I = \frac{1}{L} V \frac{\partial t}{\partial x} \quad (3.4)$$

A variação no espaço em relação ao tempo pode ser definida como velocidade de propagação da onda de tensão, conforme equação (3.5).

$$I = \frac{1}{Lv} V \quad (3.5)$$

Rearrmando a equação (3.5) chega-se na equação (3.6), onde a $\sqrt{L/C}$ pode ser definido como a proporcionalidade entre a tensão e corrente, chamado de impedância característica, como demonstrado na equação (3.7).

$$I = \sqrt{\frac{C}{L}} V \quad (3.6)$$

$$I = \frac{V}{Z_0} \quad (3.7)$$

Vale ressaltar que quando essa onda de surto atinge uma descontinuidade na linha, onde existe uma mudança na impedância característica tais como um terminal aberto ou um curto-circuito, ou junção entre linhas distintas, pode-se causar uma incoerência na impedância característica previamente fixada, de forma a evitar tal problemática alguns ajustes necessitam ser feitos nas ondas de tensão e corrente. Estes ajustes se refletem no surgimento de duas novas ondas, onde na descontinuidade parte da energia é deixado passar (refratado) e se propaga pelos trechos subsequentes da linha e a parte restante de energia é refletida e se propaga retornando a fonte. A amplitude das ondas refletidas e refratadas é de forma tal que a proporcionalidade de tensão e corrente é preservada, como demandado pela impedância característica da linha pela qual os sinais elétricos estão se propagando. Portanto as tensões e correntes nas descontinuidades da linha são constantes, preservando os princípios de conservação de energia caso as perdas sejam desconsideradas nas análises [62], [65].

3.3 DIAGRAMAS LATTICE

Em redes extensas e muito dispersas fica evidente que a incidência de uma única onda viajante irá desencadear sucessivas reflexões e refrações se propagando por todo o sistema. Como este processo não pode ter uma quantidade de energia maior do que o surto inicial, essa energia é compartilhada com as demais ondas oriundas do processo de cisão frente a uma descontinuidade. No entanto é possível que a tensão seja acrescida de um percentual pela ação acumulada das diversas ondas viajantes projetada no sistema elétrico. A fim de estudar esses efeitos alguns métodos sistemáticos foram propostos por Bewley (1933) [66] utilizando esquemas de diagramas espaço-tempo, também conhecidos como diagrama *Lattice* [62]. Tal diagrama mostra a posição e direção de cada onda viajante (incidente, refletida e refratada) em cada instante de tempo. Além disso, o diagrama *Lattice* facilita o cálculo da forma de todas as ondas refletidas e refratadas. O diagrama *Lattice* também mostra uma visão ampla do histórico de cada onda. Conhecendo-se as funções de atenuação e distorção, tais efeitos podem ser incluídos no diagrama [15].

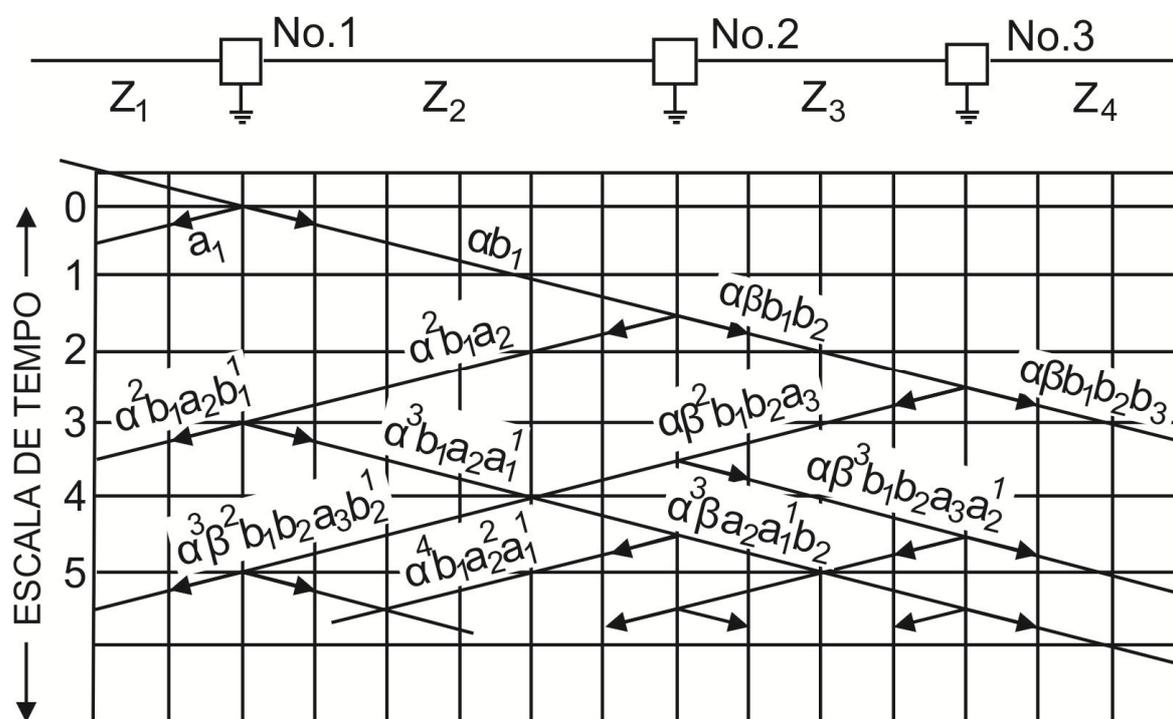


Figura 3.1 – Diagrama *Lattice* computando reflexões sucessivas [66].

A finalidade do diagrama *Lattice* é propiciar um meio gráfico simples que denote as relações tempo-espaço dos sinais sobre redes de transmissão/distribuição com múltiplas

descontinuidades. Por exemplo, no cálculo de surtos de descargas atmosféricas em linhas de transmissão com muitos pontos de aterramento, torna-se difícil o conhecimento de todas as ondas refletidas e refratadas ao longo da linha, especialmente após um intervalo de tempo relativamente longo. Isto se deve ao fato ao qual, à medida que cada onda atinge uma descontinuidade, uma nova onda refletida e refratada é gerada naquele ponto. A Figura 3.1 [66] ilustra um diagrama *Lattice* onde temos três junções de linhas com diferentes comprimentos [15].

3.4 ATENUAÇÃO E DISTORÇÃO DAS ONDAS VIAJANTES

Geralmente é justificável para o cálculo de ondas viajantes estabelecer a hipótese de ausência de perdas, e, em seguida, compensar a atenuação por um fator de decréscimo exponencial calculado experimentalmente. A atenuação e a distorção podem causar o nivelamento da crista da onda como também o alongamento da mesma, porém esses efeitos podem variar com o clima e suas condições. Portanto não existem efeitos definitivos de atenuação e distorção em uma linha, podendo variar com as diferentes mudanças das condições impostas à mesma [66].

O efeito das perdas da linha nas ondas viajantes pode causar três tipos de alterações diferentes: (i) a valor da crista da onda de tensão e corrente decresce em amplitude, ou seja, atenuado; (ii) a forma da onda é distorcida com relação ao tempo tornando-a mais alongada, sua irregularidade alisada e sua inclinação reduzida; (iii) o final da onda de tensão e corrente tornam-se similares, perdendo, portanto, seu fator de proporcionalidade conhecido como impedância característica. As duas últimas alterações ocorrem juntas e estão relacionadas às modificações de distorção [15], [66].

Existem vários fenômenos que contribuem para a atenuação e distorção dos quais podemos citar alguns, tais como, resistência serie dos condutores, efeito skin (pelicular) para altas frequências, correntes de fugas nas cadeias isoladoras, influência da resistência de aterramento, porém o mais potente deles é o efeito corona. O efeito corona ocorre quando o gradiente do campo elétrico excede um valor crítico, ionizando parcialmente o ar envolta dos condutores, fazendo-o perder suas propriedades isolantes. Uma grande quantidade de energia é necessária para ionizar o ar sendo essa energia suprida pelo sistema de potência.

3.5 CONSIDERAÇÕES FINAIS

Como as recentes melhorias nos sistemas de aquisição de dados e nos sistemas de comunicações o interesse pelas técnicas envolvendo a teoria das ondas viajantes vem crescendo vertiginosamente. Assim sua aplicação nos mais variados sistemas, tais como descargas atmosféricas, localização de faltas, identificação de faltas, entre outros, tem tomado espaço dentro das empresas concessionárias.

As metodologias utilizando as técnicas de ondas viajantes com medições em apenas um terminal apresentam uma performance mediana. Seu desempenho é suscetível a uma infinidade de erros, tais como a resistência da falta, o acoplamento mútuo na impedância de sequência zero causado por linhas paralelas, entre outros. Já as técnicas que utilizam medições em dois ou mais terminais corrigem a grande maioria dos erros, porém ainda sofrem com as faltas nas cercanias dos sistemas de medição como também da não transposição das fases [67].

As metodologias utilizando as técnicas de reconhecimento de padrões combinado com a teoria das ondas viajantes vêm alavancando a acurácia dos sistemas de localização de faltas. Assim, esta dissertação faz uso desta tecnologia aplicando a mesma para sistemas de distribuição de grande porte.

4

WAVELETS E A REPRESENTAÇÃO MULTIRRESOLUÇÃO DE SINAIS

4.1 INTRODUÇÃO

Um dos principais objetivos da análise de sinais é extrair informações relevantes sobre o processo ao qual o sinal está associado. Geralmente, a análise está ligada a uma transformação, a qual está fundamentada no método de representação e reconstrução de sinais. Uma representação permite que um sinal possa ser analisado em “outro domínio”, através de uma transformação, usualmente linear. Já a reconstrução está associada à transformação inversa, de modo que o sinal original possa ser obtido a partir de sua representação.

Em sistemas de potência, a teoria de Fourier é um dos métodos de representação e reconstrução de sinais mais utilizados, permitindo que um sinal no domínio do tempo seja representado no domínio da frequência, através de sua transformada. Alternativamente, permite que, partindo de uma representação no domínio da frequência, seja obtida a reconstrução do sinal através de sua transformada inversa [68]. Porém uma das grandes desvantagens da análise de Fourier provém do fato de apresentar apenas resolução na frequência e não no tempo. Isto significa que, embora capaz de determinar o conteúdo de frequência presentes em um sinal, não há noção em que intervalo de tempo elas ocorram [69]. Portanto, não é o método mais indicado para a análise de sinais transitórios, apesar de ser utilizado com sucesso em alguns casos.

A teoria de wavelets, que se constitui em um método alternativo para a representação e reconstrução de sinais, cobre as limitações da teoria de Fourier ao empregar “funções base”, denominadas wavelets, que são funções locais nos domínios do

tempo e da frequência. A transformada wavelet adapta-se bem a sinais de banda larga que não são periódicos e podem conter tanto componentes sinusoidal como também impulsos como é típico nos rápidos transitórios dos sistemas de potência. Em particular, a habilidade das wavelets para focar no intervalo de tempo curto para componentes de altas frequências e intervalos de tempo longos para componentes de baixa frequência beneficia as análises de sinais com impulsos e oscilações localizadas, especialmente na presença de harmônicos fundamentais e de baixa ordem [70]. Com isso, a transformada de wavelets permite que um sinal seja representado, simultaneamente, nos domínios do tempo e da frequência. Além disso, a reconstrução de um sinal através da teoria de wavelets permite que seja obtida a informação de localização no tempo de um sinal transitório, o que não ocorre quando do emprego da teoria de Fourier, onde esta informação estará invariavelmente perdida [71].

4.2 A WAVELET-MÃE E AS WAVELETS FILHAS

Na teoria de wavelet, as funções base que constituem os processos de representação e reconstrução são obtidas através de transladação e dilatação de uma única wavelet, conhecida como wavelet-mãe, sendo, portanto denominadas wavelet filhas [72], ou seja, o termo mãe e filha vêm do fato de funções com diferentes tamanhos serem usadas no processo da transformada e todas serem originadas de uma wavelet principal, a wavelet-mãe. Ela é um protótipo para a geração de outras funções janela, portanto todas as janelas a serem utilizadas são de fato versões dilatadas e comprimidas da mesma wavelet-mãe [69].

Um sinal, $\psi(t)$, de tempo contínuo ou discreto, define uma wavelet-mãe caso algumas características sejam encontradas no sinal sob análise. Uma delas está relacionada com o fato da possibilidade de reconstrução do sinal através da transformada wavelet. Esta propriedade envolve a conservação de energia no espaço da escala de tempo e a condição wavelet de admissibilidade. Primeiramente qualquer função de quadrado integrável a qual possua energia finita e satisfaça as condições de admissibilidade pode ser uma wavelet. A segunda propriedade básica está relacionada com o fato de que a transformada wavelet deve ser um operador local tanto no domínio tempo como no da frequência. A terceira propriedade está relacionada como o fato da transformada wavelet permitir análises multirresolução dos sinais [73].

- Condição pertencente ao espaço de sinais de energia finita:

$L^2(R) = \left\{ f: R \rightarrow R; \int_R |f(t)|^2 dt < \infty \right\}$, para os sinais contínuos, ou
 $\ell^2 = \left\{ (x_i)_{i \in \mathbb{Z}}; \sum_{i=-\infty}^{+\infty} |x_i|^2 < \infty \right\}$, para os sinais discretos;

- Condição de admissibilidade:

Observando a constante de admissibilidade dado por $C_\psi = \int_{-\infty}^{+\infty} \frac{|\Psi(w)|^2}{|w|} dw < \infty$, onde $\Psi(w)$ é a transformada de Fourier de $\psi(t)$, verifica-se que a transformada de Fourier de $\psi(t)$ deve anular-se à frequência zero de modo que C_ψ seja infinita. Além disso, sendo $\psi(t)$ um sinal de energia finita, sua transformada de Fourier também deve anular-se quando a frequência tende ao infinito, uma vez que o teorema de Parseval estabelece que um sinal de energia finita apresenta mesma energia em quaisquer dos domínios, tempo ou frequência. Impondo que a transformada de Fourier do sinal $\psi(t)$ seja dado pela equação (4.1).

$$|\Psi(w)|^2_{w=0} = 0 \text{ e } |\Psi(w)|^2_{w=\pm\infty} = 0, \quad (4.1)$$

No domínio do tempo, as condições expressas em (4.1) correspondem a afirmar que $\psi(t)$ deve ser um sinal oscilatório, ter rápido decaimento e valor médio nulo conforme equação (4.2) [71].

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0, \quad (4.2)$$

Esta é uma característica fundamental das wavelets, pois a área total sob as wavelets é nula, o que está associado diretamente ao comportamento típico ondulatório, ou seja, a wavelet deve oscilar de modo a cancelar as áreas positivas e negativas para anular a integral (área simétrica de $-\infty$ a $+\infty$) [74].

A wavelet-mãe, quando escalonada e transladada no tempo, dá origem às wavelets filhas de acordo com a equação (4.3).

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right), \quad (4.3)$$

sendo, as constantes s e τ ($s, \tau \in \mathbb{R}$, $s \neq 0$), respectivamente, os parâmetros fator de escala e fator de translação.

Normalmente é considerado apenas o fato de escala positivo ($s > 0$), portanto pode-se dizer que as wavelets filhas são dilatadas caso $s > 1$ e contraídas se $s < 1$. Todas as wavelets filhas ($\psi_{s,\tau}(t)$) geradas pela mesma wavelet básica possuem diferentes escalas " s " e localizações " τ ", porém todas possuem a mesma forma padrão da wavelet-mãe a qual as originaram [73].

A constante $s^{-1/2}$ na equação (4.3) está relacionada com a normalização da energia. Como a representação de uma função no domínio wavelet é realizada em escalas é conveniente que as wavelets filhas apresentem mesma energia que a wavelet-mãe. Desta forma é possível comparar a representação de sinais em quaisquer escalas. Como demonstrado pela equação (4.4).

$$\int |\psi_{s,\tau}(t)|^2 dt = \int |\psi(t)|^2 dt = 1, \quad (4.4)$$

Uma grande variedade de wavelets-mãe discreta e contínua foi desenvolvida por alguns pesquisadores que, em função da compacticidade e da suavidade em suas formas de onda, criaram famílias de wavelets [69]. Dentre as famílias mais usuais, podem-se citar as famílias de wavelets discretas de Haar, Daubechies, Coiflets e Symlets (todas ortogonais).

A Figura 4.1 mostra como exemplo, uma wavelet-mãe pertencente a cada uma das famílias citadas. No domínio do tempo, a abscissa dos gráficos é definida de acordo com o suporte da função para as wavelets discretas, dado por $N-1$, sendo N o comprimento do filtro wavelet. Já para as wavelets contínuas, como é o caso das wavelets Meyer, Mexican Hat, Gaussian e Morlet, a abscissa dos gráficos é definida no tempo contínuo, sendo dada em segundos.

Como as wavelets filhas são as funções base na teoria de wavelets, a wavelet-mãe deve sempre ser mencionada, pois a representação de um sinal no domínio wavelet é função da wavelet-mãe escolhida. Portanto, as considerações estabelecidas para uma representação podem ser totalmente inválidas para outra se as wavelets-mãe forem distintas [72].

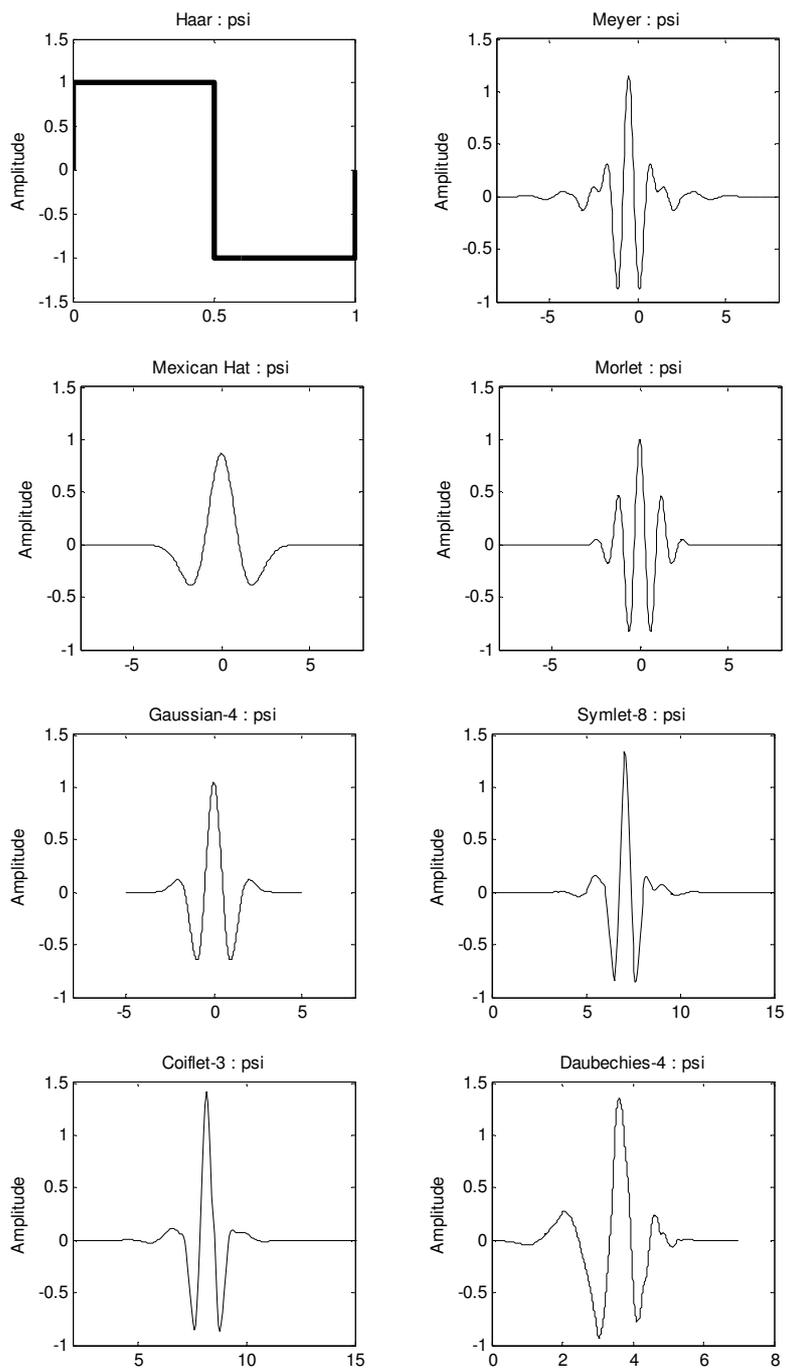


Figura 4.1 – Exemplos de wavelets-mãe no domínio do tempo.

4.3 TRANSFORMADA DE WAVELETS

A transformada de wavelets permite representar um sinal em diferentes escalas. Para cada escala é definido um parâmetro escala, s , e todas as translações possíveis no tempo para varrer o sinal em análise, os parâmetros translação, τ .

O parâmetro escala está relacionado ao processo de compressão e dilatação da wavelet-mãe, ou seja, à criação de uma wavelet filha, e o parâmetro translação ao deslocamento desta wavelet filha de modo a varrer cada trecho do sinal em análise [71].

Uma mudança no parâmetro escala permite criar uma nova wavelet filha e obter, em uma escala maior, uma visão mais global do sinal em análise, porém com menor precisão. Em uma escala menor pode-se observar os detalhes do sinal, mas perde-se em estudar o comportamento global [69].

Frequentemente, os parâmetros escala são definidos em uma sequência crescente de valores. Nas primeiras escalas, ou seja, nas escalas menores, a wavelet filha é mais localizada no tempo e oscila mais rapidamente dentro de um curto período de tempo. À medida que a wavelet-mãe é expandida para escalas maiores, as wavelets filhas tornam-se menos localizadas no tempo e oscilam lentamente, devido à dilatação do sinal. Como resultado da decomposição do sinal em escalas, os distúrbios curtos e rápidos presentes no sinal em análise podem ser detectados nas escalas menores, enquanto que os distúrbios lentos e longos serão detectados nas escalas maiores [75].

A transformada de wavelets tem como uma de suas principais vantagens à capacidade de representar localmente as características de um sinal, conjuntamente, nos domínios do tempo e da frequência. Esta forma de representação está relacionada ao fato de que a wavelet-mãe apresenta a maior parte de sua energia concentrada em um intervalo finito, seja no domínio do tempo ou da frequência. Devido a estas propriedades da wavelet-mãe diz-se que a transformada de wavelets é bem localizada no tempo e na frequência [76].

Existem, basicamente, dois tipos de transformadas de wavelets: transformada de wavelets contínua (CWT – *Continuous Wavelet Transform*), definida no tempo contínuo; e a transformada de wavelet discreta (DWT – *Discrete Wavelet Transform*), definida no tempo contínuo e no tempo discreto. O termo discreto, relativo à transformada, refere-se à discretização dos parâmetros das wavelets filhas e não a discretização do tempo. Dependendo da escolha destes parâmetros, tal transformada pode ser realizada através de bases de wavelets redundantes (frames) ou ortogonais [68].

4.3.1 Transformada de Wavelets Contínua

A transformada de wavelet contínua, a qualquer escala s e deslocamento τ , de uma função $f(t)$ com relação à wavelet-mãe $\psi(t)$ é definida como o produto interno entre ambos, ou seja, a projeção da função $f(t)$ sobre a wavelet $\psi(t)$, processo demonstrado pela equação (4.5).

$$CWT_f(s, \tau) = \langle f, \psi_{s,\tau} \rangle = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \psi^* \left(\frac{t - \tau}{s} \right) dt, \quad (4.5)$$

sendo $\psi^*(t)$ o conjugado complexo de $\psi(t)$, para s e $\tau \in R$ e $s \neq 0$.

A $CWT_f(s, \tau)$ expressa o quão próximo a função e a wavelet correlacionam-se com intervalo de tempo determinado pela wavelet de suporte. A transformada de wavelet mede a similaridade entre o conteúdo de frequência contida na função e a wavelet base $\psi_{s,\tau}(t)$ no domínio do tempo-frequência [77].

O conjunto de todas as $CWT_f(s, \tau)$, em diferentes escalas e localizações, além de constituir a representação do sinal $f(t)$ no domínio wavelet, permite que a reconstrução de $f(t)$ possa ser obtida como uma decomposição em wavelets. Porém, para que a reconstrução do sinal seja válida, é necessária a existência da transformada wavelet inversa, a qual é garantida caso a condição de admissibilidade da wavelet-mãe $\psi(t)$ seja validada, ou seja, $\psi(t)$ tenha energia finita. A equação (4.6) expressa a transformada de wavelet contínua inversa de (4.5) [70], [71].

$$f(t) = \frac{1}{C_\psi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} CWT_f(s, \tau) \psi_{s,\tau}(t) \frac{ds d\tau}{s^2}, \quad (4.6)$$

Portanto, caso $\psi(t) \in L^2(R)$ e satisfaça as condições de admissibilidade, logo $\psi(t)$ pode ser utilizada como uma wavelet-mãe e $f(t)$ pode ser reconstruída através das diversas decomposições em wavelets, ou seja, decomposições em diferentes escalas e translações, utilizando a transformada de wavelet contínua inversa.

A CWT não é de um maior uso prático, porque o sinal original $f(t)$, o qual no domínio do tempo possui apenas uma dimensão, é mapeado pela transformada wavelet em uma nova função no espaço bidimensional, em que várias correlações poderá ser

construídas e conseqüentemente uma vasta redundância na representação do sinal será formada [77], [78].

4.3.2 Transformada de Wavelet Discreta de Tempo Contínuo

Com o intuito de representar o sinal eficientemente com um número reduzido de parâmetros a transformada de wavelet discreta de tempo contínuo promove a discretização dos parâmetros de escala e translação das wavelets filhas, s e τ . O parâmetro de dilatação possui uma discretização natural do tipo $s = s_0^m$, com o passo de dilatação fixado em $a_0 > 1$ e $m \in \mathbb{Z}$. O fator de translação discreto pode ser dado por $\tau = ns_0^m \tau_0$, onde $n \in \mathbb{Z}$, e $b_0 \neq 0$. Portanto a discretização da wavelet filha se expressa do seguinte modo [79]:

$$\psi_{m,n}(t) = s_0^{-\frac{m}{2}} \psi\left(\frac{t - n\tau_0 s_0^m}{s_0^m}\right) = s_0^{-\frac{m}{2}} \psi(s_0^{-m}t - n\tau_0), \quad (4.7)$$

Conseqüentemente, a transformada wavelet discreta contínua no tempo, ou seja, os coeficientes wavelet discretos $DWT_{m,n}$ de um sinal $f(t)$ contínuo com relação a wavelet-mãe $\psi(t)$, passa a ser representada por:

$$DWT_f(m,n) = s_0^{-\frac{m}{2}} \int_{-\infty}^{\infty} f(t) \psi^*(s_0^{-m}t - n\tau_0) dt, \quad (4.8)$$

Devido à discretização da wavelet filha, por conseguinte a redução na redundância dos parâmetros, o processo de reconstrução do sinal $f(t)$ pode não convergir para uma representação coerente, sendo necessária, para uma reconstrução numericamente estável, a escolha adequada tanto da wavelet-mãe $\psi(t)$ como do processo de discretização a ser realizado [80].

Daubechies [79] provou que a condição necessária e suficiente para uma reconstrução estável da função $f(t)$ através de seus coeficientes $DWT_f(m,n)$ reside na restrição da energia dos coeficientes entre dois limites positivos (A e B , tal que $A > 0$, $B < \infty$ e A, B sejam independentes de $f(t)$), conforme equação (4.9).

$$A\|f\|^2 \leq \sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2 \leq B\|f\|^2, \quad (4.9)$$

Ao se dividir a equação (4.9) por $\|f\|^2$ fica evidente que A e B são limites da energia normalizada do produto interno, ou seja, dos coeficientes wavelet discreto de tempo contínuo [81]. A família de funções wavelets que obedecem as restrições de estabilidade recebe a denominação de frames, ou sistemas discretos redundantes, e as constantes A e B são chamadas de limite inferior e superior do *frame*, respectivamente [68].

Se a condição de estabilidade for satisfeita, ou seja, se as wavelets filhas $\psi_{m,n}(t)$ constituem um *frame*, então $f(t)$ pode ser reconstruído a partir de seus coeficientes wavelet discretos de forma estável através da transformada wavelets discreta inversa, a qual é dada por:

$$f(t) = \frac{2}{A+B} \sum_{m=0}^{\infty} \sum_{n=0}^{\infty} DWT_f(m,n) \psi_{m,n}(t), \quad (4.10)$$

A acurácia do processo de reconstrução é governada pelos limites do *frame*, A e B , os quais podem ser calculados pelo passo de dilatação s_0 , pelo passo de translação τ_0 e pela função base $\psi(t)$. Quanto mais próximo estão os limites A e B mais exata será a reconstrução do sinal [73].

4.3.3 Transformada de Wavelets Discreta de Tempo Discreto

Esta transformada apoia-se não só na discretização do plano “escala-translação”, mas também na discretização da variável independente do sinal, ou seja, quando $f(k)$ é um sinal discreto no tempo, $k \in \mathbb{Z}$, as wavelets filhas serão apenas definidas em argumentos inteiros e expressas por:

$$\psi_{m,n}(k) = s_0^{-\frac{m}{2}} \psi\left(\frac{k - n\tau_0 s_0^m}{s_0^m}\right) = s_0^{-\frac{m}{2}} \psi(s_0^{-m}k - n\tau_0), \quad (4.11)$$

sendo k, m, n, s_0 e $\tau_0 \in \mathbb{Z}$, $s_0 > 1$ e $\tau_0 \neq 0$.

Dessa forma, a transformada de wavelets discreta, ou coeficientes wavelet discretos $DWT_f(m, n)$, de um sinal $f(k)$ de tempo discreto passa a ser dado pela equação (4.12).

$$DWT_f(m, n) = s_0^{-\frac{m}{2}} \sum_{k=-\infty}^{\infty} f(k) \psi^*(s_0^{-m}k - n\tau_0), \quad (4.12)$$

sendo k, m, n, s_0 e $\tau_0 \in \mathbb{Z}$, $s_0 > 1$ e $\tau_0 \neq 0$.

E assim como para o caso anterior, fazendo todas as considerações de estabilidade do processo de reconstrução discorrida na seção 1.3.2, $f(k)$ pode ser reconstruído de forma exata pela equação (4.13).

$$f(k) = \sum_{m=0}^{\infty} \sum_{n=0}^{\infty} DWT_f(m, n) \psi_{m,n}(k), \quad (4.13)$$

quando $\psi(k)$ constitui-se em uma base de wavelets ortonormal [71], [69], [78].

A cuidadosa escolha dos parâmetros de processo de discretização, s_0 e τ_0 , e, por conseguinte, da wavelet-mãe $\psi(k)$ permite que a família de wavelets filhas geradas constituam uma base ortonormal no $L^2(R)$, caso as funções sejam de tempo contínuo, ou no ℓ^2 , se as funções sejam de tempo discreto.

Apesar da construção de bases ortonormais poder ser obtida através da escolha de qualquer número inteiro para s_0 , desde que $s_0 > 1$, a escolha de $s_0 = 2$ e $\tau_0 = 1$ permite que seja obtida a mais simples das construções. Neste caso, a transformada de wavelets discreta é referida com transformada de wavelets diádica ortonormal [78].

O uso da transformada de wavelets diádica implica em uma série de fatores, um deles está relacionado com a perda da redundância da informação na decomposição do sinal devido às propriedades da ortonormalidade. Outro fator está relacionado com a possibilidade da implementação computacional do algoritmo baseado na representação multirresolução de sinais que, assim como a transformada de wavelets, decompõe o sinal em escalas com diferentes resoluções no tempo e na frequência [75].

4.4 ANÁLISE MULTIRRESOLUÇÃO DE SINAIS

A análise multirresolução (MRA – *Multiresolution Analysis*) de sinais é um modelo matemático adequado para formalizar a representação de um sinal em bandas múltiplas de frequência, ou seja, uma representação em níveis ou escalas de sinais do universo físico [73], [82]. Dessa forma, a análise multirresolução de sinais permite decompor um sinal $f(t) \in L^2(R)$ em escalas, onde em cada escala j é possível obter uma aproximação do sinal original, a qual é obtida a uma frequência de amostragem dada por 2^j [68].

Existem duas metodologias de análise multirresolução, a pirâmide Laplaciana e o processo de codificação por sub-bandas, os quais foram desenvolvidos independentemente da transformada wavelet [73]. A estrutura da análise através do algoritmo pirâmide Laplaciana, como estudada por Burt e Crowley, sofre com a dificuldade dos dados obtidos de diferentes resoluções serem correlacionados, ou seja, existe uma grande dificuldade em identificar se a similaridade obtida do detalhamento da imagem em diferentes níveis corresponde às propriedades da imagem ou a redundância intrínseca da representação, por conseguinte esta técnica não prosperou como uma metodologia viável na análise multirresolução de sinais [83]. Portanto este texto discorre apresentando apenas a técnica de codificação por sub-bandas.

A análise multirresolução de sinais apoia-se na construção de bases wavelets ortonormais e na implementação de transformadas wavelets ortonormais. As bases ortonormais geradas pela decomposição MRA, de um sinal $f(t) \in L^2(R)$, a uma frequência de amostragem 2^j , estão fundamentadas em uma combinação da aproximação multirresolução e da representação wavelet, ou seja, filtros escala e wavelets, que constituem-se, respectivamente, em filtros passa-baixa e passa-faixa.

4.4.1 Aproximação Multirresolução

A aproximação multirresolução é um operador linear ao qual visa representar qualquer função $f(t) \in L^2(R)$, ou seja, que possua energia finita e seja mensurável, a uma frequência de amostragem dada por 2^j . Portanto uma técnica simples e efetiva consiste no emprego da projeção ortogonal de $f(t)$ em um espaço vetorial particular V_j , $V_j \subset L^2(R)$. O subespaço escala V_j gerado pode ser interpretado como o conjunto de todas as aproximações possíveis, amostradas a 2^j , das funções pertencentes ao $L^2(R)$ [83].

De forma a caracterizar este operador algumas propriedades intuitivas precisam ser observadas nos subespaços gerados pela projeção ortogonal, tais como [82]:

- $V_j \subset V_{j-1}$: os detalhes do sinal que aparecem na escala 2^j certamente precisam aparecer quando representado o sinal em uma escala menos grosseira 2^{j-1} ;
- $f(t) \in V_j$ se, e somente se, $f(2t) \in V_{j-1}$, $j \in \mathbb{Z}$: a escala da variável de f multiplicado por 2 reduz a amplitude de f por um fator de $1/2$. Portanto os detalhes de f irão para uma escala mais refinada;
- $\overline{\bigcup_{j \in \mathbb{Z}} V_j} = L^2(\mathbb{R})$: o $L^2(\mathbb{R})$ é composto por todas as escalas possíveis, ou seja, por todas as aproximações possíveis.
- $\overline{\bigcap_{j \in \mathbb{Z}} V_j} = \{0\}$: a função nula é a única função do $L^2(\mathbb{R})$ que pode ser bem representada em qualquer escala.
- Existe uma função $\phi(t) \in V_0$, chamada função escala, tal que o conjunto de todas as translações discretas da função escala, a cada nível de resolução j , constitui uma base ortonormal, $\phi_{j,k}(t) = 2^{-j/2} \phi(2^{-j}t - k)$, para o subespaço V_j .

O espaço vetorial V_0 é chamado de subespaço referência, desde que $V_0 \subset V_{-1}$, qualquer função em V_0 pode ser escrita como uma combinação linear das funções base de V_{-1} , $\phi_{-1,k}(t)$. Como $\phi(t) \in V_0$ tem-se então que:

$$\phi(t) = \sum_k h(k) \overbrace{\sqrt{2} \phi(2t - k)}^{\phi_{-1,k}(t)}, \quad (4.14)$$

sendo $h(k)$ os coeficientes da função escala $\phi(t)$, definidos por $h(k) = \langle \phi(t), \phi_{-1,k}(t) \rangle$, $\{h(k)\} \in \ell^2$, $k \in \mathbb{Z}$.

Assim como na teoria de wavelets, as funções base $\phi_{j,k}(t)$ do subespaço escala V_j em uma MRA são obtidas através do escalonamento e translação de uma única função, a função escala $\phi(t)$. Como os subespaços V_j podem ser obtidos através do uso de filtros passa-baixa, a função escala $\phi(t)$ também é conhecida como filtro escala [71].

A aproximação multirresolução de um sinal $f(t)$ pode ser representada, portanto, pela projeção ortogonal de $f(t)$ no subespaço V_j gerado pela base ortonormal $\phi_{j,k}(t)$, como mostrado na equação (4.15).

$$Proj_{V_j}(f) = \sum_k \langle f, \phi_{j,k} \rangle \phi_{j,k}, \quad (4.15)$$

Fazendo uma analogia com a transformada de wavelet discreta de tempo contínuo, a aproximação multirresolução, que corresponde à obtenção dos coeficientes escala discretos, $c_{j,k}$, de um sinal $f(t)$ contínuo no tempo, com relação à função escala $\phi(t)$, pode ser representada como segue:

$$Proj_{V_j}(f) = \sum_k c_{j,k} \phi_{j,k}, \quad (4.16)$$

sendo $c_{j,k} = \langle f, \phi_{j,k} \rangle = \int_{-\infty}^{+\infty} f(t) 2^{-j/2} \phi(2^{-j}t - k) dt$, j e $k \in \mathbb{Z}$.

A função escala desempenha o papel de suavizar a função na análise multirresolução. A projeção de um sinal, $f(t)$, no subespaço V_j resulta em uma aproximação turva do sinal original, $f(t)$.

A implementação computacional da MRA pode ser obtida ao fazer uso de um algoritmo baseado na multirresolução de sinais associado à teoria de wavelets, permitindo decompor o sinal em análise em escalas com diferentes resoluções no tempo e na frequência [68].

4.4.2 Representação Wavelet

Segundo Stéphane Mallat [83] a diferença na informação entre as aproximações de um sinal às escalas 2^j e 2^{j-1} poderia ser extraída através da decomposição deste “sinal diferença” em uma base de wavelets ortonormal do $L^2(\mathbb{R})$. Por conseguinte, Mallat, define esta decomposição como uma representação multirresolução completa e ortogonal, sendo denominada “representação wavelet”.

A teoria de wavelets e a teoria de análise multirresolução de sinais se combinam, permitindo que qualquer sinal do $L^2(\mathbb{R})$, ou do ℓ^2 , possa ser decomposto em suas versões

aproximadas e detalhadas, através do uso de filtro escala e wavelet, que constituem-se, respectivamente, em filtros passa-baixa e passa-faixa [68]. Existe, porém, uma relação biunívoca entre a função escala e wavelet, pois se definindo uma base do subespaço escala, V_j , defini-se também uma base do subespaço wavelet, W_j , ou seja, as diferenças entre as escalas 2^j e 2^{j-1} constituem o subespaço wavelet, definido como o complemento ortogonal de V_j em V_{j-1} , como demonstrado na equação (4.17).

$$V_{j-1} = V_j \oplus W_j, \quad (4.17)$$

sendo o símbolo \oplus a soma ortogonal.

Das propriedades da representação multirresolução no $L^2(R)$, sabe-se que os subespaços V_j são constituídos por aproximações de funções do $L^2(R)$ amostrados à 2^j . Conseqüentemente, pode-se afirmar que os subespaços W_j são constituídos pelos detalhes perdidos destas funções, quando da realização de sua amostragem a esta freqüência, ou seja, a representação de uma função em uma escala mais refinada, V_{j-1} , é obtida pela representação desta função em um espaço escala mais grosseiro, V_j , adicionando-se os detalhes, W_j , caracterizado pelo complemento ortogonal de V_j [73].

Logo, assim como os subespaços V_j podem ser obtidos através do uso de filtros passa-baixa, quando da amostragem do sinal à 2^j , os subespaços W_j podem ser obtidos através do uso de filtros passa-faixa, quando da amostragem do mesmo sinal [68].

Os subespaços wavelet, W_j , herdam as propriedades de escalonamento dos subespaços escalas, V_j , previamente relacionados, por esta razão é suficiente dizer que existe também uma função wavelet, $\psi(t) \in W_0$, tal que o conjunto translações na função wavelet gera uma base ortonormal de W_0 . Portanto tem-se que o conjunto dado pela equação (4.18) forma uma base ortonormal de W_j .

$$\psi_{j,k} = 2^{-j/2} \psi(2^{-j}t - k), \quad (4.18)$$

Como $W_0 \subset V_{-1}$, a função wavelet, $\psi(t)$, pode ser escrita como uma combinação linear das funções bases de V_{-1} , $\phi_{-1,k}(t)$, de modo que:

$$\psi(t) = \sum_k g(k) \overbrace{\sqrt{2}\phi(2t-k)}^{\phi_{-1,k}(t)}, \quad (4.19)$$

sendo $g(k)$ os coeficientes de $\psi(t)$, definidos por $g(k) = \langle \psi(t), \phi_{-1,k}(t) \rangle$, $\{g(k)\} \in \ell^2$, $k \in \mathbb{Z}$.

Devido à relação biunívoca entre a função escala, $\phi(t)$, e a função wavelet, $\psi(t)$, ou seja, a wavelet-mãe $\psi(t)$ pode ser obtida através de uma versão escalonada e transladada da função escala $\phi(t)$, porém algumas condições devem ser impostas aos filtros escala e wavelet de modo a manter a ortonormalidade entre os subespaços escala, V_j , e o subespaço wavelet, W_j . As condições são relacionadas abaixo [68]:

- Condição de normalidade para as funções escala:

$$\int_{-\infty}^{+\infty} \phi(t) dt = 1 \text{ ou } \sum_{k \in \mathbb{Z}} h(k) = \sqrt{2}, \quad (4.20)$$

- Condição de normalidade para as funções wavelet:

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \text{ ou } \sum_{k \in \mathbb{Z}} g(k) = 0, \quad (4.21)$$

- Condição de ortogonalidade entre os filtros escala:

$$\sum_{k \in \mathbb{Z}} h(k)h(k+2m) = \delta_{0,m}, \quad (4.22)$$

- Condição de ortogonalidade entre os filtros escala e wavelet:

$$g(k) = (-1)^k h(1-k), \quad (4.23)$$

Em decorrência da dependência existente dos coeficientes do filtro wavelet, $\psi(t)$, com o filtro escala, $\phi(t)$, em alguns casos $\psi(t)$ é chamado de filtro espelho de $\phi(t)$

diretamente relacionada pela condição de ortogonalidade. Caso o sinal a ser analisado, $f(t)$, possua duração finita, os filtros $\phi(t)$ e $\psi(t)$ são chamados de par de filtros espelhados em quadratura (QMF – *Quadrature Mirror Filters*) e, portanto, uma implementação computacional bastante eficiente da transformada de wavelets diádica ortonormal pode ser obtida através do uso de filtros passa-baixa e passa-faixa [68].

De forma análoga a aproximação multirresolução, a representação wavelet de um sinal $f(t)$ pode ser representada pela projeção ortogonal de $f(t)$ no subespaço W_j gerado pela base ortonormal $\psi_{j,k}(t)$, conforme equação (4.24) [82].

$$Proj_{W_j}(f) = \sum_k \langle f, \psi_{j,k} \rangle \psi_{j,k}, \quad (4.24)$$

4.4.3 Codificação por Sub-bandas

O algoritmo de codificação por sub-bandas é uma abordagem utilizando a técnica multirresolução de sinais ao qual o princípio básico está fundamentado na divisão do espectro do sinal em sub-bandas independentes através do uso de um banco de filtros [68], [73]. Este princípio aplicado no cálculo da Transformada Discreta de Wavelet consiste em projetar filtros passa-alta (*HPF – High pass filters*) e passa-baixa (*LPF – Low pass filters*) de tal modo que “particione” o espectro do sinal exatamente ao meio [69].

Os algoritmos baseados na codificação por sub-bandas têm sido dos mais utilizados para a implementação computacional dos processos de representação e reconstrução de sinais através da teoria de wavelets diádica ortonormal. Esses algoritmos são constituídos por dois processos: o processo de representação, do qual obtém-se, especialmente, os coeficientes wavelet do sinal analisado, sendo, portanto, equivalente à implementação da transformada de wavelets e o processo de reconstrução, do qual obtém-se, o sinal original sendo portanto equivalente à implementação de wavelets inversa.

Ambos os processos estão fundamentados nas expressões que geram bases ortonormais dos subespaços referência escala, V_0 , e wavelet, W_0 , ou seja, estão fundamentados nas expressões dos filtros escalas $\phi(t)$ e wavelet $\psi(t)$ dados, respectivamente, por:

$$\phi(t) = \sum_k h(k)\sqrt{2}\phi(2t - k), \quad (4.25)$$

e

$$\psi(t) = \sum_k (-1)^k h(1 - k)\phi(2t - k), \quad (4.26)$$

Estas expressões definem as bases dos subespaços escala, V_j , $\phi_{j,k}(t)$, e wavelet, W_j , $\psi_{j,k}(t)$, para qualquer escala j , as quais são representadas, respectivamente, por:

$$\phi_{j,k}(t) = 2^{-\frac{j}{2}}\phi(2^{-j}t - k), \quad (4.27)$$

e

$$\psi_{j,k}(t) = 2^{-\frac{j}{2}}\psi(2^{-j}t - k). \quad (4.28)$$

4.4.3.1 Processo de Representação

O conjunto de todos os subespaços formados por $\phi_{j,k}(t)$ e $\psi_{j,k}(t)$ pode gerar toda função do $L^2(R)$, ou seja, qualquer função, $f(t)$, pode ser escrita como uma expansão em série em termos da função escala e wavelets. Com isso a decomposição do sinal original será obtida através de versões aproximadas ou de baixa resolução, pertencente ao subespaço escala, e detalhada ou de alta resolução, pertencentes ao subespaço wavelet, analogamente a série de Fourier onde os termos de alta frequência possuem os detalhes do sinal como demonstrado pela equação (4.29) [81].

$$f(t) = \sum_k c_{j+1}(k)\phi_{j+1,k}(t) + \sum_k d_{j+1}(k)\psi_{j+1,k}(t), \quad (4.29)$$

sendo $c_{j+1}(k)$ e $d_{j+1}(k)$ os coeficientes escala e wavelet, respectivamente, referentes à representação de $f(t)$ no subespaços V_{j+1} e W_{j+1} .

Devido à propriedade da expansão em série de $\phi_{j,k}(t)$ e $\psi_{j,k}(t)$ formar bases ortonormais, os coeficientes escala e wavelet podem ser calculados, respectivamente, utilizando o produto interno como demonstrado abaixo.

$$c_{j+1}(k) = \langle f(t), \phi_{j+1,k}(t) \rangle = \int f(t) \phi_{j+1,k}(t) dt, \quad (4.30)$$

e

$$d_{j+1}(k) = \langle f(t), \psi_{j+1,k}(t) \rangle = \int f(t) \psi_{j+1,k}(t) dt, \quad (4.31)$$

Descreve-se abaixo a relação entre os coeficientes da expansão em série da equação (4.29), exemplificando apenas os coeficientes escala e de forma análoga ilustrando os coeficientes wavelet, tem-se portanto que:

$$c_{j+1}(k) = \int_{-\infty}^{\infty} f(t) \left[2^{-\frac{j+1}{2}} \phi(2^{-(j+1)}t - k) \right] dt, \quad (4.32)$$

computando-se:

$$\phi(2^{-(j+1)}t - k) = \sum_m h(m) \sqrt{2} \phi(2^{-j}t - 2k - m), \quad (4.33)$$

realizando mudança de variável, $n = 2k + m$, obtendo-se:

$$\phi(2^{-(j+1)}t - k) = \sum_n h(n - 2k) \sqrt{2} \phi(2^{-j}t - n), \quad (4.34)$$

resultando em:

$$c_{j+1}(k) = \sum_n h(n - 2k) \int_{-\infty}^{\infty} f(t) 2^{-\frac{j}{2}} \phi(2^{-j}t - n) dt, \quad (4.35)$$

e desde que:

$$c_j(n) = \int_{-\infty}^{\infty} f(t) 2^{-\frac{j}{2}} \phi(2^{-j}t - n) dt, \quad (4.36)$$

os coeficientes escala são obtidos por:

$$c_{j+1}(k) = \sum_n h(n - 2k) c_j(n). \quad (4.37)$$

Seguindo de forma análoga o desenvolvimento exposto acima pode-se obter os coeficientes wavelet, a partir da equação (4.31), obtém-se:

$$d_{j+1}(k) = \sum_n g(n - 2k) c_j(n). \quad (4.38)$$

A expressão (4.37) descreve a correlação existente entre $c_j(n)$ e $h(n)$, representando um filtro passa-baixa de forma a obter apenas os componentes de baixa frequência, seguida por um processo de subamostragem por 2, também chamado de dizimação, de forma a eliminar a redundância projetada na saída do filtro. O deslocamento por 2 em $c_j(n)$ resulta em um deslocamento por 1 em $c_{j+1}(k)$, logo o intervalo de amostragem na escala $j + 1$ é o dobro que na escala anterior, j . Portanto, o comprimento da seqüência $c_{j+1}(k)$ será metade de $c_j(n)$, de forma análoga o mesmo procedimento ocorre para a expressão (4.38). A Figura 4.2 ilustra o processo de codificação por sub-bandas baseado em WMRA.

A frequência de corte, f_c , de ambos os filtros, em cada escala, é definida por:

$$f_c = \frac{f_s}{2^{(j+1)}}, \quad (4.39)$$

sendo f_s a frequência de amostragem que foi utilizada para amostrar o sinal original. Deste modo, o espectro de frequências do sinal proveniente do filtro escala, $c_{j+1}(k)$, compreende

a faixa de frequências de 0 a f_c Hz, e o espectro do sinal proveniente do filtro wavelet, $d_{j+1}(k)$, a faixa de frequência de f_c a $2f_c$ Hz.

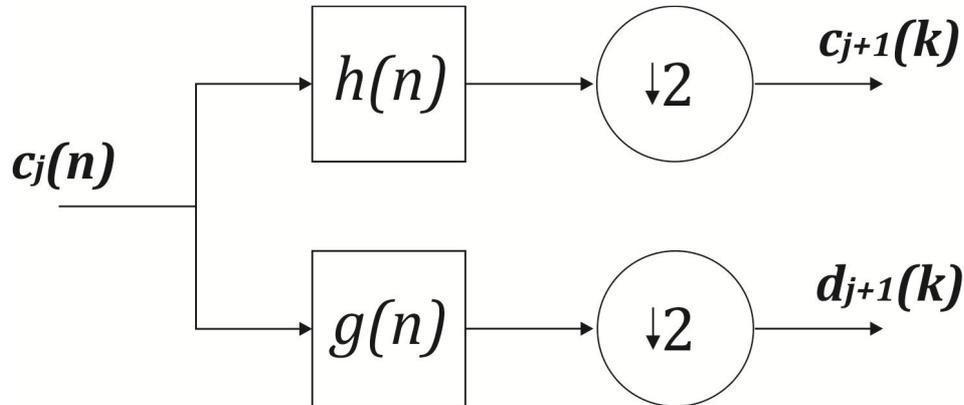


Figura 4.2 – Processo de representação do algoritmo de codificação por sub-bandas baseado em WMRA.

O número de escalas possíveis, j_{max} , para promover a representação do sinal original depende de seu número máximo de amostras, N , e pode ser obtido por $N = 2^{j_{max}}$. Dessa forma, as frequências de corte utilizadas em todo o processo de representação são obtidas ao se fazer $j = 1, 2, \dots, j_{max}$.

A Figura 4.3 mostra o processo de representação do algoritmo de codificação por sub-bandas baseado na WMRA, considerando três escalas de decomposição.

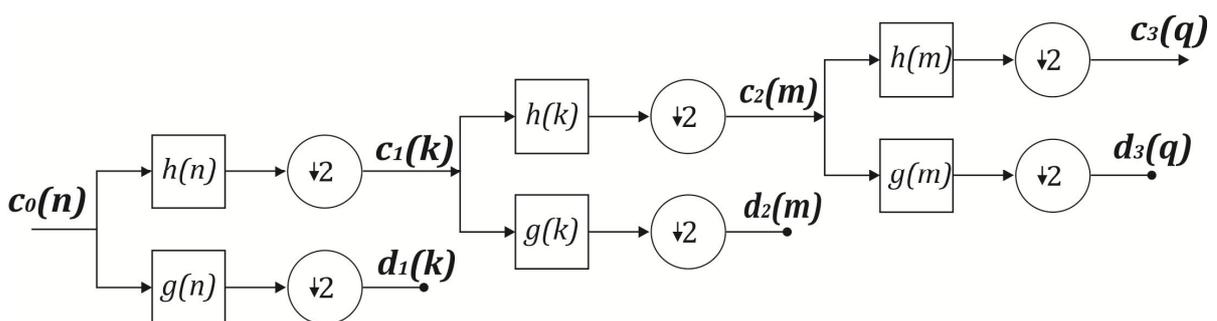


Figura 4.3 – Decomposição do sinal original em três escalas representando os coeficientes escala e wavelet em cada escala.

O processo de representação do algoritmo se baseia, portanto, em operação de convolução e decimação em cada escala, cujo objetivo é decompor a versão aproximada do sinal, à escala j , em suas versões aproximada e detalhada, à escala $j + 1$ [68].

4.4.3.2 Processo de Reconstrução

A recuperação do sinal a partir de seus coeficientes é feita pelo processo reverso similar ao processo de representação. A expressão para a reconstrução do sinal em função dos coeficientes escala e wavelet é dada por:

$$c'_j(n) = \sum_k h(n - 2k)c_{j+1}(k) + \sum_k g(n - 2k)d_{j+1}(k), \quad (4.40)$$

Neste processo, primeiramente realiza-se uma operação de sobreamostragem expandindo o sinal original a duas vezes o seu comprimento de origem. A operação de sobreamostragem é realizada inserindo-se zeros entre cada amostra dos coeficientes escala, $c_{j+1}(n)$, e wavelet, $d_{j+1}(n)$. Posteriormente realiza-se o processo de convolução das seqüências sobreamostradas utilizando os filtros passa-baixa, $h(n)$, e passa-alta, $g(n)$. Dessa forma, a expressão (4.40) permite representar a escala j do processo de reconstrução do algoritmo de codificação por sub-bandas baseado na WMRA conforme Figura 4.4.

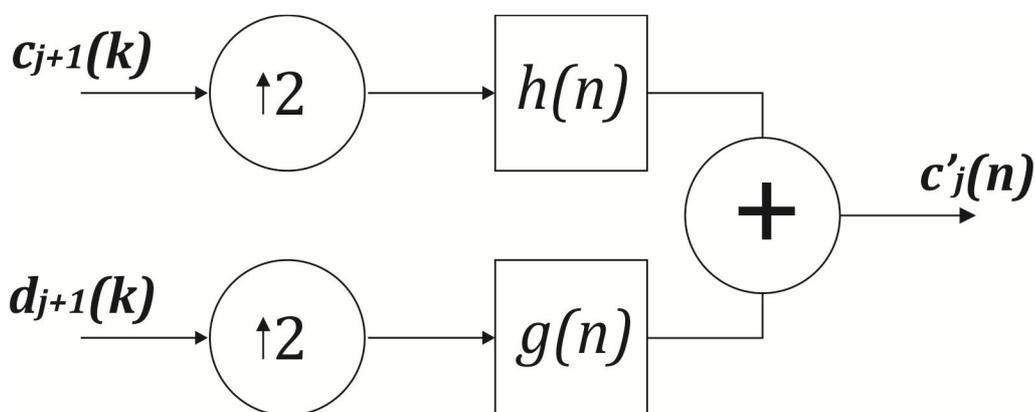


Figura 4.4 – Processo de reconstrução do algoritmo de codificação por sub-bandas baseado na WMRA para a escala j .

A Figura 4.5 ilustra o processo de reconstrução do algoritmo de codificação por sub-bandas baseado na WMRA, considerando três escalas de decomposição. Neste processo, o sinal reconstruído, $c'_0(n)$, será idêntico ao sinal original $c_0(n)$ se os filtros de reconstrução são iguais aos filtros empregados durante o processo de representação do sinal [68]. Portanto para uma reconstrução perfeita do sinal original o banco de filtros deve ser inverso ao utilizado no processo de representação, no caso de transformações

ortogonais os bancos de filtros também serão ortogonais, e a relação de invertibilidade estará diretamente definida situação semelhante ocorre para os conjuntos de filtros QMF e biortogonais [84].

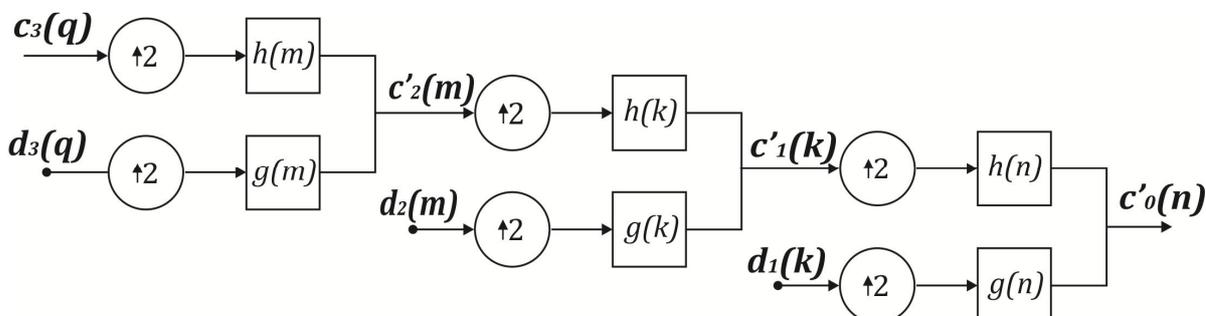


Figura 4.5 – Reconstrução do sinal $c_0(n)$ a partir de sua versão aproximada de terceira escala e de suas versões detalhadas em três escalas.

O processo de reconstrução do algoritmo se baseia, portanto, em operações de superamostragem e convolução em cada escala, cujo objetivo é recompor a versão aproximada do sinal, à escala $j + 1$, a partir de suas versões aproximadas e detalhadas, à escala j .

4.5 CONSIDERAÇÕES FINAIS

Neste capítulo foi apresentada uma introdução à teoria de wavelets e à análise multirresolução de sinais. Uma representação wavelet baseada em multirresolução (WMRA) foi apresentada e com ela os fundamentos para o desenvolvimento de algoritmos eficientes baseados no processo de codificação por sub-bandas, um dos algoritmos mais utilizados para a representação e reconstrução de sinais através da teoria de wavelets.

Algumas wavelet-mãe e funções escala foram apresentadas. No caso contínuo, destaca-se a existência de apenas uma função wavelet-mãe contínua com amplitude plana em alguma parte de sua resposta em frequência: a wavelet-mãe de Meyer. No caso discreto, destacam-se os bancos de filtros ortogonais de Daubechies, que são os bancos de filtros mais utilizados na análise de sinais, mesmo naquelas aplicações onde a característica de ortogonalidade não é estritamente necessária.

Pesquisas, tais como [70], comprovam que a teoria de wavelets, associada ou não a MRA, pode ser considerada como o método mais indicado para a análise de sinais transitórios em sistemas de potência. Nas diversas aplicações, ressalta-se o uso da wavelet-

mãe contínuas complexas, no caso contínuo, e de bancos de filtros ortogonais, no caso discreto.

No próximo capítulo serão apresentadas as técnicas de reconhecimento de padrões dando ênfase para os algoritmos de redes neurais artificiais.

5

RECONHECIMENTO DE PADRÕES

5.1 INTRODUÇÃO

A classificação de padrões é um processo de informação e transformação. Isto é, um classificador transforma um conjunto relativamente grande de dados nebulosos em um pequeno conjunto de dados úteis. Não é surpresa, portanto, que máquinas, assim como seres vivos, possuam a capacidade de detectar e classificar padrões. Exemplos de tais máquinas que foram construídas e usadas efetivamente são: classificador de células do sangue, analisador de cromossomos, analisador de fotografias aéreas, analisador de vozes, leitor de zona postal, analisador de impressões digitais e analisador de radiografia [85]. Cada vez mais estão sendo pesquisadas e introduzidas novas aplicações face à agilidade e automação de tarefas que muitas vezes não podem ser desenvolvidas pelo ser humano a exemplo de atividades em meios insalubres, como já citado, e/ou monitorações em tempo real com a necessidade de respostas imediatas, fruto de processamentos exaustivos.

Um classificador é um dispositivo que agrupa dados em categorias. Os dados são frequentemente estruturados em vetores no espaço de atributos. Todo ponto neste espaço é chamado de vetor de atributos. Cada componente x_i do vetor x é usualmente uma característica ou propriedade de um objeto sob análise [85].

O vetor de atributos em uma dada classe ocupa uma região no espaço de atributos chamada região de classe. É frequentemente considerado que toda região de classe é demarcada. Outra consideração é que as regiões de classe não se sobrepõem (entretanto em muitos casos práticos, existem algumas sobreposições). Quando as regiões de classe não se sobrepõem, as classes são ditas separáveis. Se, para toda região de classe, um hiperplano pode ser colocado de tal forma que separe uma região de todas as outras regiões de classe, as classes são ditas linearmente separáveis. Muitos dos trabalhos recentes que utilizam a

teoria de classificação de padrões se concentram em classes linearmente separáveis. Ao mesmo tempo, um número significativo de trabalhos tem focado classes não separáveis e classes que não são linearmente separáveis.

O classificador relaciona todo vetor de atributos com uma região de decisão particular, R_j , no espaço de atributos, Ω_x , através de um conjunto de hiper-superfícies de decisão. Cada um de tais relacionamentos pode ou não corresponder a uma classificação desejável. Um classificador treinável é um classificador que conduz a um número pequeno de classificações incorretas através do ajuste do conjunto de regiões de decisão, $\{R_j\}$, em resposta a observações em uma seqüência de vetores de atributos, $\{x_i\}$. Essa seqüência de observações ocorre durante uma fase de aprendizado ou treinamento. Na Figura 5.1 podem ser observadas as hiper-superfícies (linhas no espaço de atributos Ω_x , bi-dimensional) que representam fronteiras entre as regiões de decisão. Não foram consideradas possíveis sobreposições de regiões.

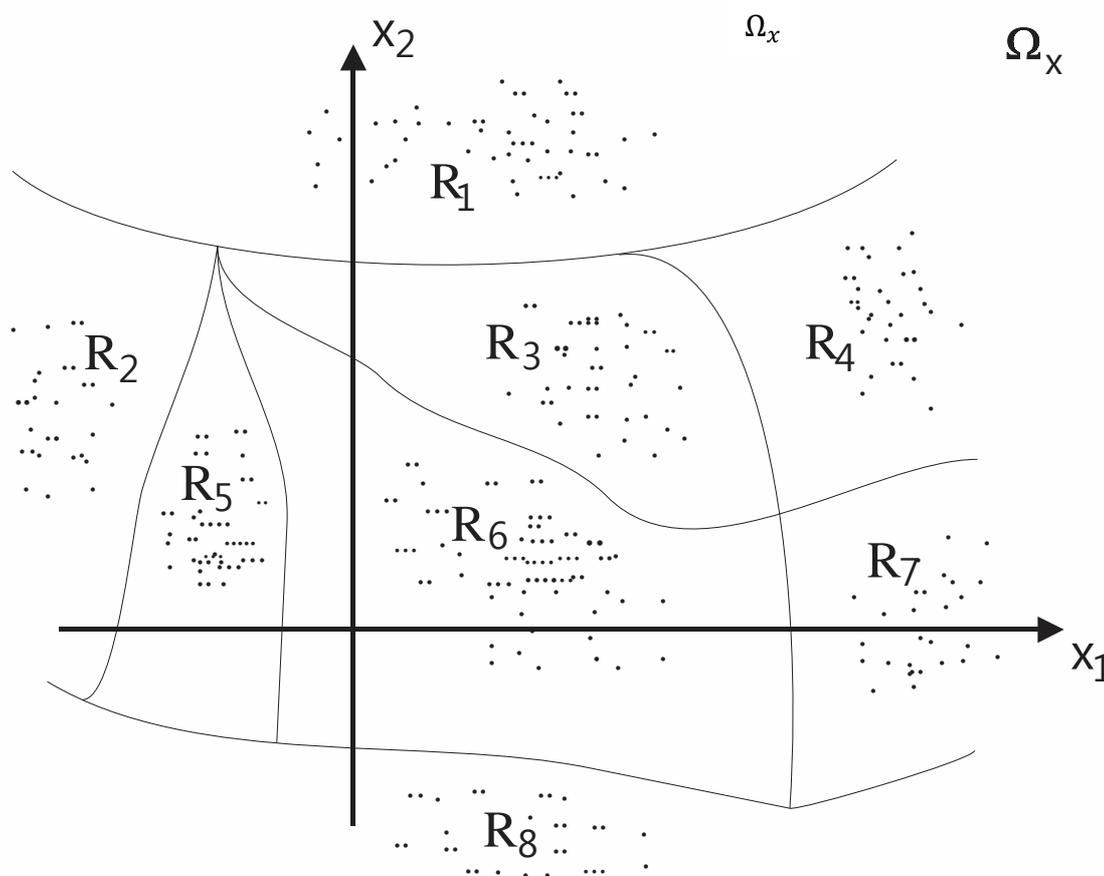


Figura 5.1 – Exemplo de regiões de decisão em um espaço bi-dimensional [85].

Devido às características dos problemas aqui tratados serem complexos e não lineares as técnicas de projeto de classificadores restringe o uso de superfícies de decisão lineares (hiperplanos). Em diversas situações práticas, tais hiperplanos não permitem a separação desejada de tal forma que uma superfície de decisão não linear se torna necessária.

A utilização de redes neurais para solucionar os tipos de problema não lineares tem se tornado mais usual ultimamente. Esta técnica busca a implementação de um novo tipo de classificador através da construção de múltiplas camadas do modelo básico de um neurônio. A implementação de uma rede de múltiplas camadas conduz a que as saídas dos neurônios de uma camada passem a representar entradas para novos neurônios em outra camada, discutido mais profundamente em seções seguintes.

Por outro lado, durante a montagem dos vetores de atributos, as observações devem incluir informações que conduzam a classificar corretamente os vetores de atributos. Se as observações incluem dados para uma correta classificação, o treinamento é dito supervisionado ou com um professor. Esses dados para classificação correta são algumas vezes referenciados como reforços. Se nenhum reforço é incluído, o treinamento é chamado sem supervisão ou sem professor.

O procedimento ou algoritmo através do qual os membros do conjunto de regiões de decisão, $\{R_j\}$, são ajustados em resposta aos vetores de atributos observados é chamado procedimento de treinamento. Cada ajuste do conjunto de regiões de decisão, $\{R_j\}$, ocorre em resposta a um ou mais vetores de atributos. Cada um de tais ajustes, juntamente com as observações associadas e reforços é chamado experimento. O número de experimentos é um indicador da extensão do treinamento.

Depois que o classificador é treinado, ele é usualmente submetido a dados de entrada de classificação desconhecida. Este modo de operação do classificador é referenciado como fase de trabalho aqui também denominada de etapa de validação e fase operacional, enquanto que o modo durante o qual ocorre o treinamento é conhecido como fase de treinamento. O conjunto de vetores de atributos ou observações utilizado como entrada durante a fase de treinamento é referenciado como conjunto de treinamento. Em alguns casos a fase de treinamento e a fase de trabalho podem coincidir ou se sobreporem. Esse é usualmente o caso no qual o treinamento é não supervisionado [85]. Esses tópicos serão destrinchados formalmente nas seções subseqüentes.

5.2 REDES NEURAIS ARTIFICIAIS

A grande capacidade de processamento de informações do cérebro humano tem motivado pesquisas no sentido de encontrar modelos que reproduzam suas características computacionais, que são totalmente diferentes do computador digital convencional, possibilitando, dessa forma, que se realizem certas tarefas de uma maneira semelhante ao cérebro humano [86].

O cérebro é um sistema de processamento de informações altamente complexo, cuja capacidade de organizar seus constituintes estruturais, conhecidos como neurônios, permite elevado índice de processamento de informações [87]. A estrutura individual desses neurônios, a topologia de suas conexões e o comportamento conjunto desses elementos de processamento naturais formam a base para o estudo das redes neurais artificiais (RNA). O cérebro humano é responsável por funções cognitivas básicas, assim como pela execução de funções sensoriomotoras e autônomas. Além disso, sua rede de neurônios tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento por experiência como também de interpretar observações [88].

As RNAs tentam reproduzir as funções das redes biológicas, buscando implementar seu conhecimento funcional e sua dinâmica. Elas fazem uma representação distribuída da informação, na forma de conexão entre um grande número de elementos simples (neurônios artificiais), se comunicando através de conexões sinápticas. Na maioria dos casos desenvolvidos estas conexões estão associadas a pesos, os quais armazenam o conhecimento, servindo para ponderar a entrada recebida por cada neurônio da rede [89]. Assim as redes neurais artificiais são modelos matemáticos dos neurônios biológicos e suas interconexões em redes.

A grande vantagem no uso de RNAs para solução de problemas complexos provém de algumas propriedades e capacidades úteis, descritas a seguir [87].

- Aprendizagem – Habilidade da RNA de aprender acerca de seu ambiente através de um processo iterativo de ajustes dos pesos sinápticos.
- Generalização – Corresponde ao fato da rede neural produzir saídas adequadas para entradas não presentes no processo de aprendizagem.
- Não-Linearidade – Uma rede neural, constituída por conexões de neurônios não lineares é ela mesma não linear. Característica de muita importância

devido à grande maioria dos sistemas físicos modelados serem intrinsecamente não lineares.

- Adaptabilidade – Capacidade inerente de adaptar os pesos sinápticos em função das variações ocorridas no meio ambiente, ou seja, uma rede neural treinada para operar em um ambiente específico pode ser re-treinada para lidar com pequenas modificações no ambiente.

Estas características dotam as redes neurais artificiais de capacidade de resolver problemas complexos que não podem ser resolvidos de forma tradicional [87]. É o caso da tarefa de classificação de padrões, na qual se deseja atribuir uma entre várias classes pré-definidas para um determinado sinal de entrada (representando um objeto físico ou evento) do qual não se conhece seu modelo estatístico [86].

5.2.1 Neurônios Biológicos

Os neurônios biológicos são divididos, de maneira simplificada, em três seções: o corpo celular, os dendritos e o axônio, cada um com funções específicas, porém complementares. O corpo celular mede apenas alguns milésimos de milímetros, e os dendritos apresentam poucos milímetros de comprimento, já o axônio pode ser mais longo e, em geral, tem calibre uniforme.

Os dendritos têm por função receber as informações, ou impulsos nervosos, oriundas de outros neurônios e conduzi-las até o corpo celular, também conhecido como soma. Aqui, a informação é processada e novos impulsos são gerados. Esses impulsos são transmitidos a outros neurônios, passando através do axônio até os dendritos dos neurônios seguintes. O ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro é chamado de sinapse. É pelas sinapses que os neurônios se unem funcionalmente, formando as redes neurais biológicas.

A Figura 5.2 ilustra, de forma simplificada, os componentes do neurônio biológico. Os sinais oriundos dos neurônios pré-sinápticos são transmitidos para o corpo do neurônio pós-sináptico, no qual são comparados com os outros sinais recebidos pelo mesmo. Se o percentual de excitação do neurônio é suficientemente alto, a célula dispara, produzindo um impulso que é transmitido para as células seguintes (neurônios pós-sinápticos). A capacidade de realizar funções complexas surge com a operação em paralelo de todos os neurônios do nosso sistema nervoso.

Em resumo, um neurônio biológico pode ser visualizado do ponto de vista funcional da seguinte forma: as suas múltiplas entradas recebem ativações excitatórias ou inibitórias dos neurônios anteriores, e caso essa soma de excitação e inibição ultrapasse um determinado limite, o neurônio emite um impulso nervoso. Com base nesse comportamento funcional um modelo computacional simplificado foi desenvolvido de forma a simular um neurônio biológico [88].

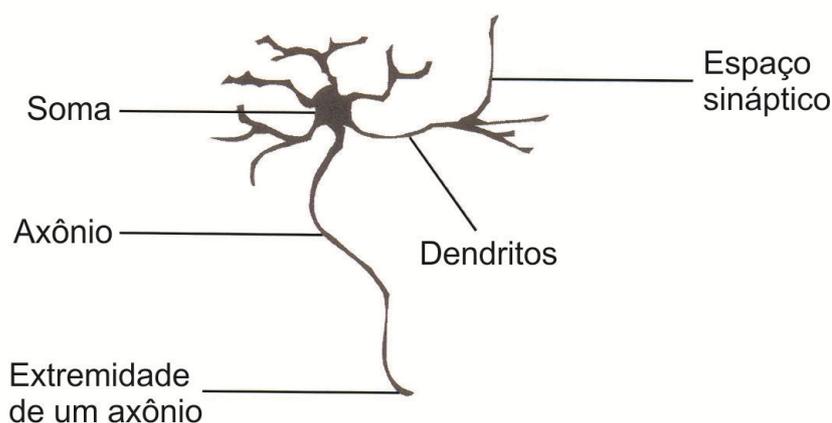


Figura 5.2 – Componentes do neurônio biológico [88].

5.2.2 Modelo de um Neurônio Artificial

O modelo de neurônio artificial é uma simplificação dos conhecimentos adquiridos do funcionamento de um neurônio biológico. Sua descrição matemática resultou em um modelo com n terminais de entradas (dendritos) que recebem os sinais de entrada x_1, x_2, \dots, x_n , representado as ativações de neurônios anteriores, e apenas um terminal de saída y , representado o axônio. Para ilustrar o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados, $w_{k,1}, w_{k,2}, \dots, w_{k,n}$, cujos valores podem ser positivos ou negativos, dependendo de as sinapses correspondentes serem inibitórias ou excitatórias. Os pesos determinam em que grau o neurônio deve considerar sinais de disparo que ocorrem naquela conexão. A Figura 5.3 exemplifica o modelo não linear de um neurônio.

Um neurônio biológico dispara quando a soma dos impulsos que ele recebe ultrapassa o seu limite de excitação (*threshold*). Esse comportamento do neurônio biológico, por sua vez, é representado no modelo artificial por um mecanismo simples, que

faz a soma dos valores $x_i w_i$ recebido pelo neurônio (soma ponderada) e decide se o neurônio deve ou não disparar (saída igual a 1 ou a 0), comparando a soma obtida ao limiar ou *threshold* do neurônio. No modelo apresentado, a ativação do neurônio é obtida através da aplicação de uma “função de ativação”, que ativa ou não a saída, dependendo do valor da soma ponderada das suas entradas [88].

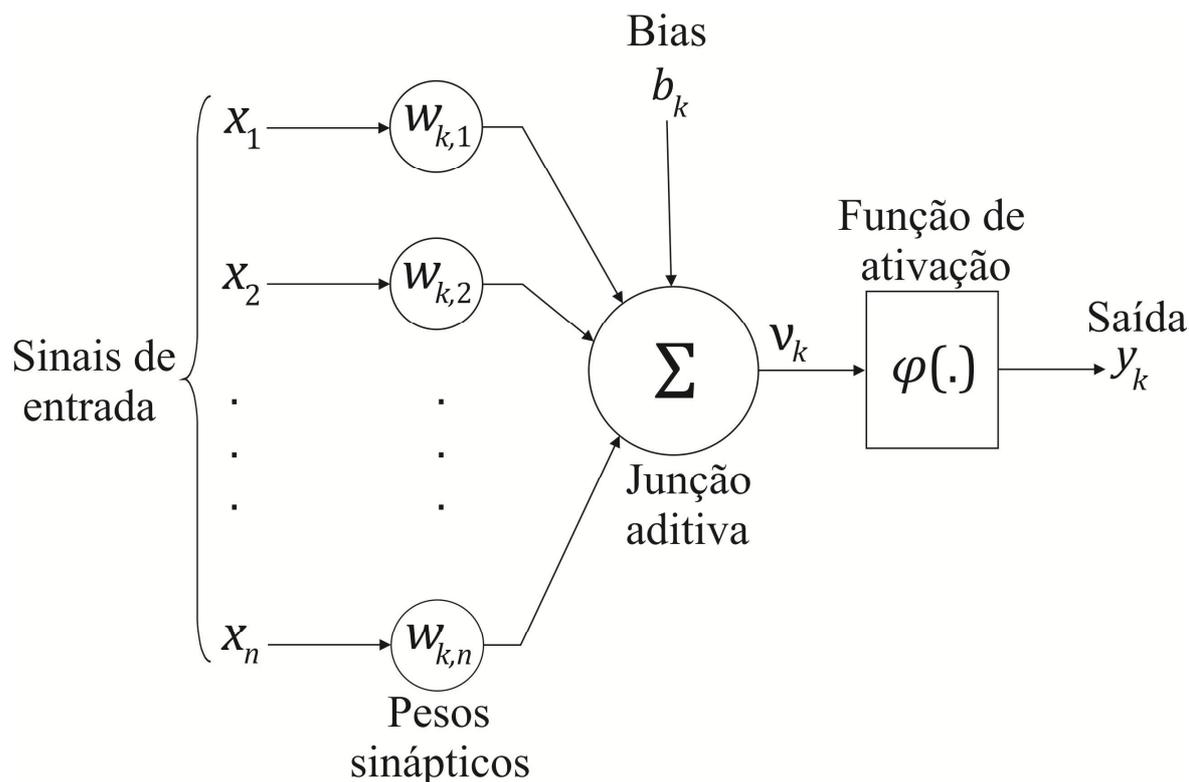


Figura 5.3 – Modelo não linear de um neurônio [87].

O modelo neuronal apresentado na Figura 5.3 inclui também um bias aplicado externamente, representado por b_k . O bias, b_k , tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente [87]. Em termos matemáticos, pode-se descrever um neurônio k incluindo o parâmetro externo bias como sendo um peso sináptico associado a uma entrada de valor constante unitário, conforme formulação descrita pelas equações (4.2) e (5.2) [86].

$$v_k = \sum_{i=0}^n x_i w_{k,i}, \quad (5.1)$$

$$y_k = \varphi(v_k), \quad (5.2)$$

sendo j o índice das n entradas do neurônio, v_k a saída do combinador linear. Quando $x_0=1$, $w_{k,0} = b_k$ representado o bias aplicado ao neurônio k . x_1, x_2, \dots, x_n são os sinais de entrada do neurônio, $w_{k,1}, w_{k,2}, \dots, w_{k,n}$ são os pesos sinápticos do neurônio k , $\varphi(\cdot)$ representa a função de ativação do neurônio k e y_k representa a saída do neurônio k .

A saída do neurônio k pode ser obtida, utilizando a notação matricial, pelo produto interno do vetor de pesos sinápticos (incluindo o bias) com o vetor dos sinais de entrada transposto e aplicando este resultado à função de ativação, $\varphi(\cdot)$.

5.2.3 Funções de Ativação

A função de ativação é responsável por gerar a saída y_k do neurônio a partir dos valores dos vetores peso, $w_{k,i}$, e do vetor entrada, x_i , podendo apresentar varias formas, das quais algumas mais frequentemente usadas estão apresentadas na Figura 5.4.

A função de ativação tipo limiar, apresentada na Figura 5.4(a), foi utilizada fortemente para definir os primeiros modelos neuronais, como proposto por McCulloch-Pitts [90]. Em seu modelo a função degrau deslocada em θ , em relação à origem, pode caracterizar o limiar de ativação do neurônio, ou seja, a saída y_k será igual a 1 para $\sum_{i=1}^n x_i w_{k,i} \geq \theta$ e 0 para $\sum_{i=1}^n x_i w_{k,i} < \theta$. A equação (5.3) expressa o processo de ativação da função limiar.

$$\varphi(v_k) = \begin{cases} 1, & \text{se } \sum_{i=1}^n x_i w_{k,i} \geq \theta \\ 0, & \text{se } \sum_{i=1}^n x_i w_{k,i} < \theta \end{cases}, \quad (5.3)$$

A função de ativação linear por partes, (Figura 5.4(b)), pode ser representada matematicamente pela equação (5.4). Esta forma de função de ativação pode ser vista como uma aproximação de um amplificador não linear, onde assume-se que o fator de amplificação dentro da região linear de operação é a unidade.

$$\varphi(v_k) = \begin{cases} 1, & v_k \geq +\frac{1}{2} \\ v_k, & +\frac{1}{2} > v_k > -\frac{1}{2} \\ 0, & v_k \leq -\frac{1}{2} \end{cases} \quad (5.4)$$

A função de ativação sigmoideal se apresenta como uma aproximação contínua da função degrau. Devido sua característica estritamente crescente exibe um balanceamento adequado entre o comportamento linear e não linear, tornando-a a função de ativação mais utilizada na construção de redes neurais artificiais. Um exemplo de função sigmóide é a da Figura 5.4(c) denominada de função logística e definida por:

$$\varphi(v_k) = \frac{1}{1 + e^{(-av_k)}}, \quad (5.5)$$

sendo a o parâmetro de inclinação da função sigmóide. Variando-se o parâmetro a , obtém-se funções sigmóides com diferentes inclinações, conforme Figura 5.4(c) [87].

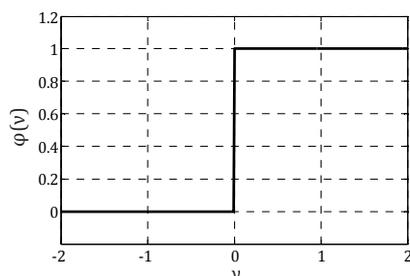
As funções de ativação acima descritas apresentam resultado no intervalo $[0,1]$. No entanto, dependendo da aplicação, deseja-se que a saída da rede neural artificial apresente também valores negativos, no intervalo $[-1,+1]$, por exemplo. Neste caso, devido a sua formulação antissimétrica em relação à origem, a função de ativação utilizada deverá ser ímpar, o que pode ser alcançado utilizando uma função tangente hiperbólica [86]. A Figura 5.4(d) pode ser obtida através da equação (5.6).

$$\varphi(v_k) = \tanh(av_k) = \frac{e^{(av_k)} - e^{(-av_k)}}{e^{(av_k)} + e^{(-av_k)}} \quad (5.6)$$

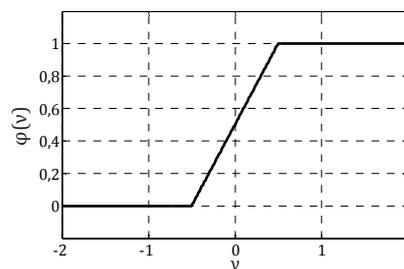
As RNAs do tipo RBF (*Radial Basis Functions*) utilizam neurônios com funções de ativação radiais, como a função gaussiana apresentada na Figura 5.4(e) e na equação (5.7) [88].

$$\varphi(v_k) = e^{-\frac{(v_k - \mu)^2}{r^2}}, \quad (5.7)$$

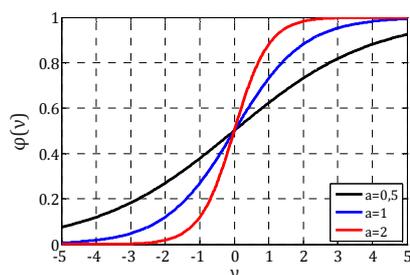
sendo μ o centro (ponto médio) e r o raio de abertura da função.



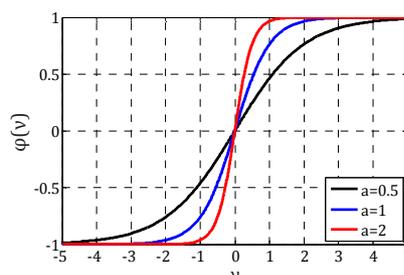
a) Função de ativação limiar ou degrau.



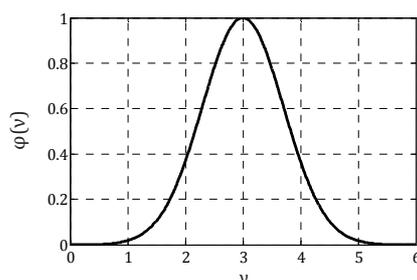
b) Função de ativação linear por partes.



c) Função de ativação sigmoideal unipolar.



d) Função de ativação sigmoideal bipolar.



e) Função de ativação gaussiana

Figura 5.4 – Funções de ativação.

5.2.4 Principais Arquiteturas de Rede

Neurônios individuais possuem capacidade computacional limitada, no entanto um conjunto de neurônios artificiais interconectados na forma de uma rede (neural) é capaz de resolver problemas de grande complexidade [88]. Por conseguinte, dependendo da característica do problema, a que se propõe a solução, faz-se necessário a escolha adequada do arranjo de neurônios de forma a obter melhores resultados [91]. Portanto define-se arquitetura de uma rede pela forma como os neurônios estão estruturados [86]. Em geral, podem-se identificar três classes de arquiteturas de rede fundamentalmente diferentes, descritos adiante [87].

5.2.4.1 Redes Alimentadas Adiante com Camada Única

São redes neurais constituídas por apenas um agrupamento de neurônios, conhecido como camada de saída, que recebem informação simultaneamente dos nós de fonte. Em outras palavras, esta rede possui a entrada se comunicando estritamente com a camada de saída caracterizando uma alimentação adiante (*feedforward*), ou seja, sem realimentação. O termo camada única se refere ao fato de existir apenas uma camada de nós computacionais (camada de saída) [87]. A Figura 5.5 ilustra a referida rede neural para o caso de quatro nós tanto na camada de entrada como na de saída.

Utiliza-se normalmente este tipo de rede em telecomunicação, onde modems de alta velocidade de transmissão fazem uso de equalizadores adaptativos de linha e canceladores adaptativos de eco, sendo cada um desses sistemas adaptativos composto de uma rede neural [92].

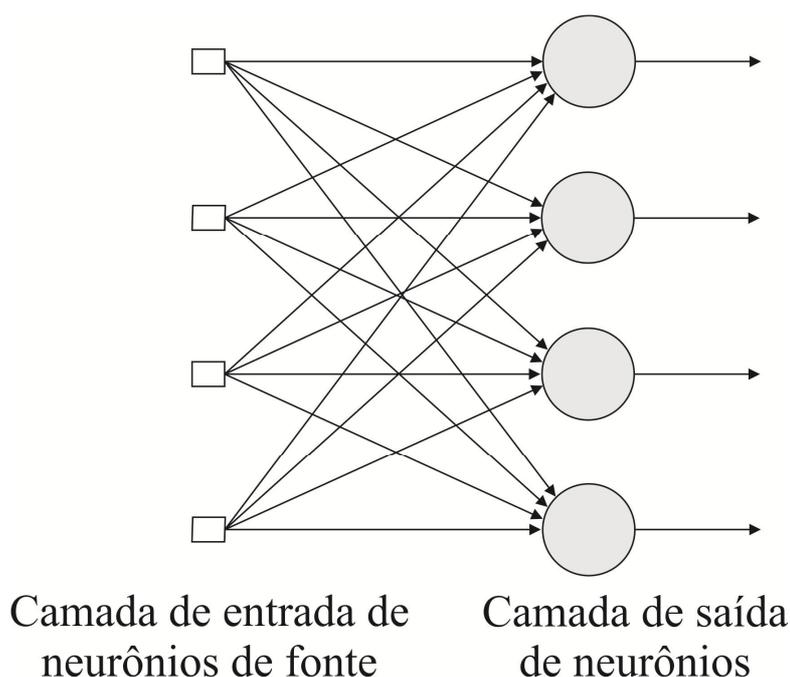


Figura 5.5 – Rede alimentada adiante (*feedforward*) com uma única camada de neurônios.

5.2.4.2 Redes Alimentadas Adiante com Múltiplas Camadas

São redes que, assim como as redes de única camada, possuem fluxo de informação unidirecional, porém neste caso, há presença de camadas ocultas, cujos nós computacionais

são chamados de neurônios ocultos. A função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede de uma maneira útil, o que devido ao conjunto extra de conexões sinápticas e da riqueza de interações neurais, as camadas ocultas são capazes de extrair características complexas do ambiente em que atuam.

Nas redes de múltiplas camadas, conforme Figura 5.6, cada camada tem uma função específica. A camada de saída recebe estímulos da camada intermediária e constrói a resposta global para o padrão de ativação fornecido pelos nós de fonte da camada de entrada. As camadas intermediárias funcionam como extratoras de características dos padrões de entrada, as quais são codificadas através dos pesos sinápticos, permitindo a rede criar representações próprias do problema sem perder a riqueza e a complexidade da informação inicial [91].

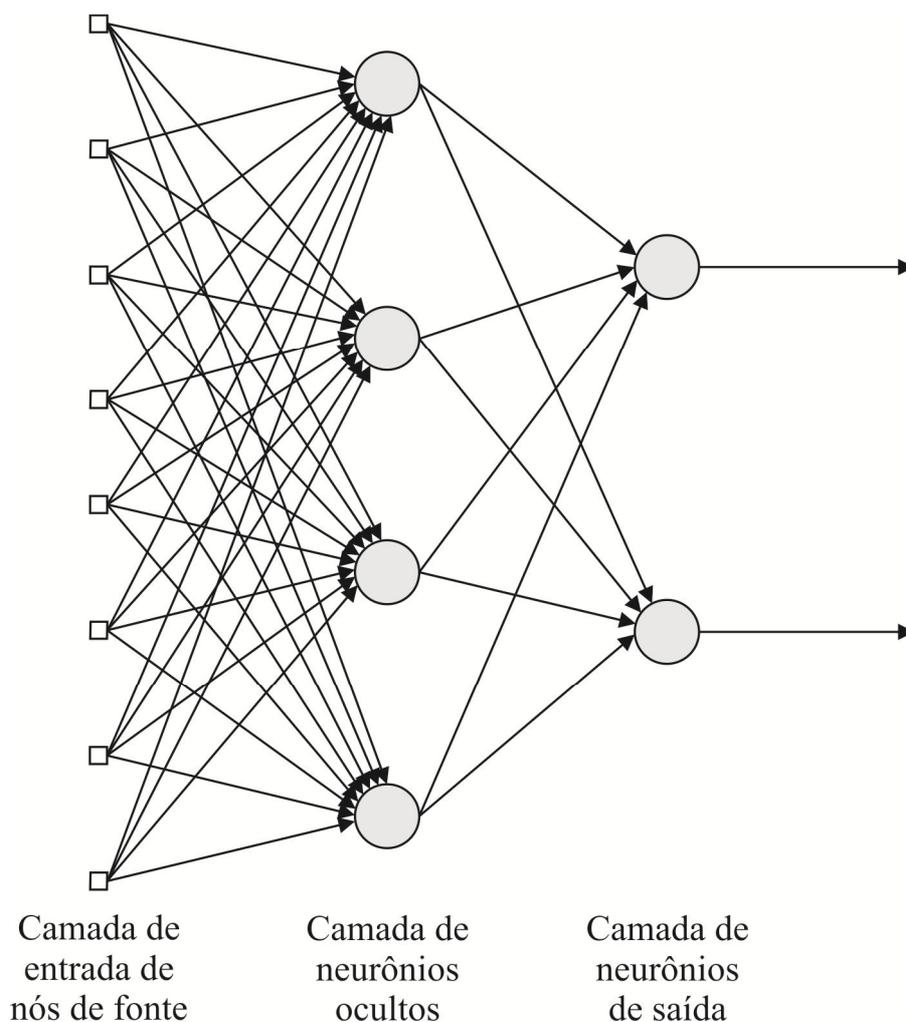


Figura 5.6 – Rede alimentada adiante (feedforward) com uma camada oculta e uma camada de saída.

Aplicações de redes de múltiplas camadas podem ser citadas na área de reconhecimento de caracteres. Por exemplo, redes neurais que reconhecem caracteres da língua japonesa [91]. Outra aplicação é em controle de qualidade, onde existem aplicações na área de detecção de nível de contaminação, com também em localização e detecção de faltas em redes de distribuição/transmissão.

5.2.4.3 Redes Recorrentes

Uma rede neural recorrente se distingue de uma rede neural alimentada adiante por ter pelo menos um laço de realimentação. A realimentação, em sua característica, tem o sinal de uma saída sendo enviado de volta para a entrada, influenciando no novo resultado de saída. A presença de laços de realimentação tem um impacto profundo na capacidade de aprendizagem da rede e no seu desempenho. Além disso, os laços de realimentação envolvem o uso de ramos particulares compostos de elementos de atraso unitário (representados por z^{-1}), o que resulta em um comportamento dinâmico não linear, quando admitindo a presença de unidades não lineares na rede neural [87]. A Figura 5.7 exemplifica uma classe de redes recorrentes com a existência de neurônios ocultos.

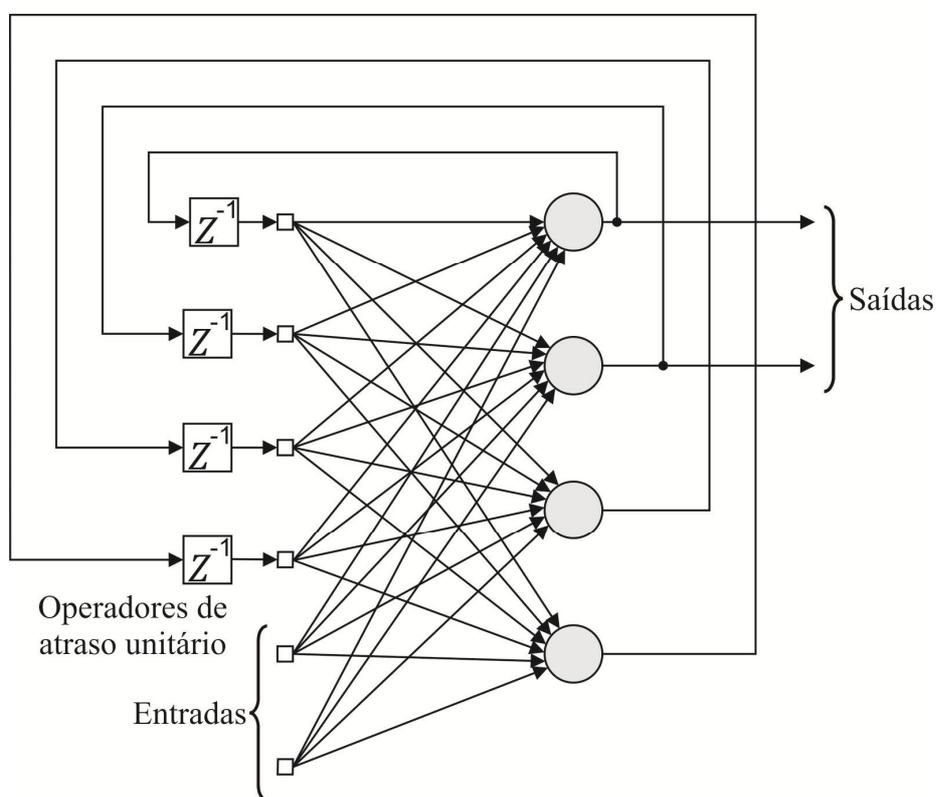


Figura 5.7 – Rede recorrente com neurônios ocultos [87].

5.2.5 Aprendizagem

Uma das características mais importantes das RNAs é a sua habilidade de aprender acerca do ambiente a qual está inserida e com isso melhorar seu desempenho [86]. Isto pode ser alcançado através de um processo iterativo, onde os pesos das conexões entre os neurônios são ajustados, e assim, a rede vai criando sua representação própria do problema, através da extração de informações relevantes de padrões que são apresentados a ela [93]. Portanto, o objetivo da aprendizagem é determinar a intensidade das conexões entre os neurônios em uma rede neural.

O conjunto de procedimentos definido para adaptar os parâmetros de uma rede, de modo a fazer com que ela aprenda uma determinada função, recebe o nome de algoritmo de aprendizagem. Diversos métodos para treinamento (aprendizagem) de redes foram desenvolvidos, cada qual com suas vantagens, podendo ser agrupados em duas principais categorias: aprendizagem supervisionada e aprendizagem não supervisionada.

5.2.5.1 Aprendizagem Supervisionada

Este algoritmo de aprendizagem possui a presença do professor, conhecedor do ambiente ao qual a rede neural está inserida, o que através de exemplos de entradas-saídas tenta treinar a RNA em questão.

O processo de aprendizagem é realizado através do contínuo ajuste dos pesos sinápticos em função do sinal de erro gerado pela discrepância entre a saída ótima, fornecida pelo conhecimento prévio do professor, e a saída calculada pela RNA em treino. A cada par entrada-saída errônea fornecida pela rede, um sinal de erro é gerado e os pesos sinápticos são reajustados no intuito de minimizar o erro na saída da rede neural.

Um dos parâmetros normalmente utilizado para aferição do desempenho de uma RNA é a soma dos erros quadráticos das saídas da rede para todo universo de amostras. O erro médio quadrático é também utilizado como função objetivo a ser minimizado pelo algoritmo de treinamento, o que será detalhado em seções seguintes [91].

5.2.5.2 Aprendizagem não Supervisionada

Esta metodologia de aprendizagem não há um professor responsável pelo fornecimento da resposta desejada, ou seja, não há exemplos do ambiente ao qual a rede está inserida para ser aprendido.

Para treinamento da rede não supervisionada, são utilizados apenas os valores de entrada, onde os neurônios são utilizados como classificadores e as entradas como elementos a serem classificados [86]. O processo de competição e cooperação pode ser utilizado entre os neurônios da rede, de forma que a competitividade pela oportunidade de responder as características contidas nos dados de entrada garanta um aumento da força sináptica dos neurônios bem sucedidos e conseqüentemente o enfraquecimento sináptico dos não tão bem sucedidos [87].

De uma forma mais simples, o aprendizado não supervisionado pode ser descrito da seguinte forma: o sinal é aplicado à entrada da RNA, onde somente o neurônio vencedor (aquele que possui o maior valor do campo local induzido) terá a oportunidade de se tornar ativo conseqüentemente os demais permanecerão inativos. Os pesos sinápticos deste neurônio são então ajustados, de acordo com a regra de aprendizagem definida, para um valor próximo do sinal de entrada ao final do processo. Dessa forma, sinais de entrada com características semelhantes serão identificados pela ativação do mesmo neurônio. Portanto cada neurônio ou conjunto de neurônios da rede será responsável por uma única classe de padrões de entrada, que deve ser mapeada após a finalização do treinamento [86].

5.2.5.3 Algoritmos de Aprendizagem

De acordo com as características do problema a ser abordado é possível selecionar o tipo de algoritmo de aprendizagem que melhor se adapte. A forma mais simples, Perceptron e Adaline, apresentam características que restringem sua utilização basicamente à solução de problemas linearmente separáveis. Contudo a não linearidade pertinentes à maioria das situações e problemas reais obriga, portanto, a utilização de estruturas com características não lineares para resolução de problemas de maior complexidade, como é o caso das redes Perceptron de Múltiplas Camadas (MLP – *multilayer perceptron*).

5.2.5.3.1 Perceptron de Múltiplas Camadas

As redes MLP apresentam uma camada de entrada, ou nós de fonte, pelo menos uma camada oculta ou intermediária constituída de nós computacionais e a camada de saída. Em termos de funcionalidade a camada de entrada está responsável por receber os padrões de entrada à rede, contudo não realiza nenhum processamento. Já as camadas intermediárias funcionam como extratores de características, onde a propagação do erro se

traduz no ajuste dos pesos sinápticos. Por fim a camada de saída tem por função construir os padrões de resposta da rede [91].

As não linearidades são incorporadas a este modelo neural através das funções de ativação (não lineares) de cada neurônio da rede e da composição da sua estrutura em camadas sucessivas. Assim, a resposta da camada mais externa da rede corresponde à composição das respostas dos neurônios das camadas anteriores [88], ou seja, o processamento da informação ocorre no sentido progressivo, também conhecido como *feedforward*, como esquematizado na Figura 5.6.

A capacidade da rede é função do número de camadas ocultas, ou seja, uma rede MLP com uma camada intermediária pode aproximar qualquer função contínua, enquanto que a utilização de duas camadas intermediárias permite a aproximação de qualquer função [88].

A grande popularidade das redes MLP para resolver problemas complexos está fundamentada no treinamento supervisionado utilizando o algoritmo de retropropagação do erro (*error back-propagation*). Este algoritmo é baseado na regra de aprendizagem por correção do erro, a qual consiste de dois passos através das diferentes camadas da rede: um passo para frente, a propagação (*forward*), e um passo para trás, a retropropagação (*backward*). No passo para frente, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede e seu efeito se propaga através da rede, camada por camada. Finalmente, um conjunto de saída é produzido como a resposta real da rede e comparado com a resposta desejada para produzir um sinal de erro, o qual será propagado no sentido contrário das conexões sinápticas, já caracterizando o passo de retropropagação. O sinal de erro propagado *backward* servirá para ajustar os pesos sinápticos no intuito de mover a resposta real da rede para mais perto da resposta desejada [87], o processo pode ser visualizado pela Figura 5.8. Portanto o problema de treinamento de uma rede MLP consiste basicamente em um problema de otimização, que a cada iteração se deseja minimizar uma função custo: a soma instantânea dos erros quadráticos. Com base nesta temática algumas variações do *back-propagation* foram propostas, tais como: Back-propagation com momento [94], Resilient Propagation [95], Levenberg-Marquardt [96], [97], entre outras [98], [99].

$$\frac{\partial Er(n)}{\partial w_{ij}(n)} = \frac{\partial Er(n)}{\partial y_i(n)} \frac{\partial y_i(n)}{\partial v_i(n)} \frac{\partial v_i(n)}{\partial w_{ij}(n)}, \quad (5.8)$$

sendo Er a função erro dada por saída desejada menos a saída real da rede, w_{ij} o peso sináptico do neurônio j para o neurônio i na iteração n , y_i a saída do neurônio i na iteração n e v_i a soma ponderada das entradas do neurônio i na iteração n , dado por $v_i = \sum_{i=1}^m w_{ij}(n)y_i(n)$. m é o número total de entradas.

Uma vez conhecida às derivadas parciais de todos os pesos sinápticos, o objetivo principal se torna agora minimizar a função erro através do algoritmo do gradiente descendente com momento, para efeito de determinar os ajustes nos pesos:

$$\Delta w_{ij}(n) = -\eta \frac{\partial Er}{\partial w_{ij}}(n) + \mu \Delta w_{ij}(n-1), \quad (5.9)$$

Na expressão (5.9) o parâmetro momento, μ , dimensiona a influência do passo anterior no atual. O termo do momento pode ser caracterizado de estabilizador do procedimento de aprendizado, como também, de acelerador da convergência nas proximidades da solução. No entanto, aplicações práticas têm mostrado, que a escolha ótima do valor do parâmetro momento, μ , assim como da taxa de aprendizagem, η , é igualmente dependente do problema sob questão, ou seja, torna-se novamente um problema de otimização sua escolha adequada [100]. Portanto suas aplicações são bastante reduzidas em função da existência de algoritmos mais eficientes.

5.2.5.3.2.1 Algoritmo Resilient Propagation (RPROP)

O algoritmo *Resilient Propagation* tem como proposta uma técnica de aprendizagem mais eficiente, tentando vencer as dificuldades enfrentadas pelo algoritmo de treinamento GDM. Em seu esquema de aprendizagem apresenta como característica marcante a adaptação direta dos pesos sinápticos baseada na informação do gradiente local. A diferença crucial para o método analisado na seção anterior está associada ao fato das adaptações propostas no algoritmo RPROP não sofrer com o comportamento dinâmico da amplitude do gradiente.

O problema da amplitude do peso pode ser solucionado fazendo com que cada peso sináptico possua seu próprio valor de correção, Δ_{ij} , implicando em uma atualização individual de cada peso sináptico. Este ajuste adaptativo, do valor de correção, evolui durante o processo de aprendizagem levando em consideração apenas uma aplicação local da função erro, Er , conforme equação (5.10) [100].

$$\Delta_{ij}(n) = \begin{cases} \eta^+ * \Delta_{ij}(n-1), & \text{se } \frac{\partial Er}{\partial w_{ij}}(n-1) * \frac{\partial Er}{\partial w_{ij}}(n) > 0 \\ \eta^- * \Delta_{ij}(n-1), & \text{se } \frac{\partial Er}{\partial w_{ij}}(n-1) * \frac{\partial Er}{\partial w_{ij}}(n) < 0, \\ \Delta_{ij}(n-1), & \text{se } \frac{\partial Er}{\partial w_{ij}}(n-1) * \frac{\partial Er}{\partial w_{ij}}(n) = 0 \end{cases} \quad (5.10)$$

onde $0 < \eta^- < 1 < \eta^+$.

No algoritmo RPROP o que importa é a mudança de sinal da derivada parcial de cada peso sináptico, w_{ij} , conforme se percebe em (5.10). Cada variação de sinal observada, na derivada parcial, indica que a última atualização realizada foi demasiada, conseqüentemente ultrapassando o limite mínimo local, sendo necessário, portanto, um decréscimo no valor incremental, Δ_{ij} , de um fator multiplicador, η^- . Caso a derivada mantenha seu sinal inalterado o valor incremental, Δ_{ij} , será ligeiramente acrescido de um fator multiplicador, η^+ , de forma a acelerar o processo de convergência na proximidade da solução.

Uma vez que todos os valores incrementais para cada peso estejam atualizados pelo processo anterior, deve-se seguir uma nova regra para a devida atualização dos pesos sinápticos, como segue: Se a derivada é positiva (aumentado o erro), o peso é diminuído do seu valor incremental, caso contrário, o valor será adicionado, conforme equação (5.11) [100].

$$\Delta w_{ij}(n) = \begin{cases} -\Delta_{ij}, & \text{se } \frac{\partial Er}{\partial w_{ij}}(n) > 0 \\ +\Delta_{ij}, & \text{se } \frac{\partial Er}{\partial w_{ij}}(n) < 0' \\ 0, & \text{caso contrário} \end{cases} \quad (5.11)$$

O valor atualizado de cada peso sináptico será dado por:

$$w_{ij}(n + 1) = w_{ij}(n) + \Delta w_{ij}(n), \quad (5.12)$$

Entretanto, existe uma exceção: caso a derivada parcial mude de sinal, ou seja, o passo anterior foi demasiado e, portanto, o mínimo local foi ultrapassado, deve-se então reverter à atualização dos pesos sinápticos, ou seja,

$$\Delta w_{ij}(n) = -\Delta w_{ij}(n - 1), \text{ se } \frac{\partial Er}{\partial w_{ij}}(n - 1) * \frac{\partial Er}{\partial w_{ij}}(n) < 0, \quad (5.13)$$

Consequentemente, é de se esperar que no próximo passo essa derivada mude novamente seu sinal. Para que não haja uma segunda “punição” nos valores incrementais, deve-se, portanto, adotar nenhuma medida de correção de valores no passo seguinte. Na prática este feito pode ser alcançado fazendo com que $\frac{\partial Er}{\partial w_{ij}}(n - 1) = 0$ na regra do valor incremental, Δ_{ij} [100], [101].

Uma das principais vantagens do algoritmo RPROP está ligada ao fato de que para a maioria dos problemas não é necessário fazer uma boa escolha dos parâmetros iniciais a fim de garantir convergência [101], sendo seu emprego bastante difundido para aplicações em reconhecimento de padrões [91].

5.2.5.3.2.2 Algoritmo Levenberg-Marquardt (LM)

O algoritmo de Levenberg-Marquardt se baseia no método de otimização de Gauss-Newton, ou seja, é uma técnica iterativa a qual propõe a localização do mínimo de uma função multivariável. Dentre as diversas variações do algoritmo *Back-propagation*, esta é a técnica mais rápida de treinamento de redes com múltiplas camadas, desde que a rede possua uma quantidade moderada de pesos sinápticos a fim de tornar o problema solúvel.

A técnica desenvolvida por Levenberg e Marquardt, assim como os métodos de Newton, faz uso das derivadas de segunda ordem, com uma ligeira modificação no cálculo da matriz Hessiana (matriz de derivadas segundas), de forma a vencer a possibilidade da inexistência de sua inversa. A alteração proposta pelo método LM, está basicamente

associada à soma de uma parcela, μI , à matriz Hessiana, calculada pelo método de Gauss-Newton, como explicado adiante.

Inicialmente deseja-se minimizar, com respeito ao vetor de parâmetros x , uma função dada por [102]:

$$V(x) = \frac{1}{2} * \sum_{i=1}^{Ns} Er_i^2(x), \quad (5.14)$$

O índice superior do somatório em (5.14) é $Ns = Q * M$, sendo Q o número total de padrões que serão utilizados no treinamento e M o número de camadas da rede neural.

Para que a função dada pela equação (5.14) seja minimizada pelo método de Newton as correções a serem aplicada à variável independente x se expressam do seguinte modo:

$$\Delta x = -[\nabla^2 V(x)]^{-1} * \nabla V(x), \quad (5.15)$$

sendo $\nabla^2 V(x)$ a Hessiana e $\nabla V(x)$ o gradiente, cujas expressões são , respectivamente:

$$\nabla^2 V(x) = J^T(x)J(x) + S(x), \quad (5.16)$$

$$\nabla V(x) = J^T(x)Er(x), \quad (5.17)$$

As expressões da matriz Jacobiano, $J(x)$, e $S(x)$ que aparecem em (5.16) e (5.17) são as seguintes:

$$J(x) = \begin{bmatrix} \frac{\partial Er_1(x)}{\partial x_1} & \frac{\partial Er_1(x)}{\partial x_2} & \dots & \frac{\partial Er_1(x)}{\partial x_n} \\ \frac{\partial Er_2(x)}{\partial x_1} & \frac{\partial Er_2(x)}{\partial x_2} & \dots & \frac{\partial Er_2(x)}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial Er_N(x)}{\partial x_1} & \frac{\partial Er_N(x)}{\partial x_2} & \dots & \frac{\partial Er_N(x)}{\partial x_n} \end{bmatrix}, \quad (5.18)$$

$$S(x) = \sum_{i=1}^N Er_i(x) \nabla^2 Er_i(x), \quad (5.19)$$

Para o método de Gauss-Newton a contribuição de $S(x)$ tende para 0, portanto, as correções aplicadas são da seguinte forma:

$$\Delta x = -[J^T(x)J(x)]^{-1} * J^T(x)Er(x), \quad (5.20)$$

O algoritmo LM é o próprio de Newton-Gauss modificado pela inclusão do termo, μI , no intuito de contornar as dificuldades relativas à inversão matriz Hessiana inversa. Portanto a expressão da correção é:

$$\Delta x = -[J^T(x)J(x) + \mu I]^{-1} * J^T(x)Er(x). \quad (5.21)$$

O parâmetro μ é multiplicado por um fator β toda vez que um passo resultar em um aumento da função erro, a qual se deseja minimizar. Quando um passo resultar na diminuição da função custo, $V(x)$, μ será dividido pelo fator β . Isto significa dizer que, caso haja convergência para o mínimo da função, μ se tornará muito pequeno no processo, consequentemente o algoritmo assume as características do método de Newton. Caso contrário o algoritmo será semelhante ao método do gradiente descendente [102]. Portanto, o parâmetro μ funciona como um fator estabilizador do treinamento, ajustando as atualizações garantindo, quando possível, a rápida convergência do método de Newton evitando passos demasiados que possam levar a erros de convergência [93].

5.3 CONSIDERAÇÕES FINAIS

Neste capítulo foi apresentada uma introdução à teoria das técnicas de reconhecimento de padrões com enfoque nas redes neurais artificiais, mediante uma breve descrição de suas características foi percorrida. As aplicações de reconhecimento de padrões aproveitam a capacidade de aprendizado e a grande capacidade de processamento das redes neurais a fim de obter identificações de padrões dentro de categorias previamente estabelecidas mais rapidamente.

O projeto de sistemas de reconhecimento de padrões, como descrito no capítulo, tem três fundamentos principais: aquisição de dados e seu pré-processamento, representação dos dados e tomada da decisão. Assim, geralmente o desafio encontra-se na escolha de técnicas para melhor efetuar essas etapas.

Em geral, problemas de reconhecimento de padrões bem definidos e restritos permitem uma representação compacta dos padrões e conseqüentemente uma estratégia de decisão simples. Contudo, nem sempre os padrões a serem reconhecidos possuem essas características, daí reside à vasta importância de algoritmos de extração e seleção de atributos.

No próximo capítulo será descrito o processo de formação, treinamento e separação dos dados, a metodologia adotada para escolha das melhores arquiteturas, bem como os resultados de treinamento e desempenho das redes propostas.

6

PROCESSAMENTO DE SINAIS

6.1 INTRODUÇÃO

A elaboração de uma base de dados consistente requer inicialmente um tratamento dos dados, ou seja, um pré-processamento do sinal oriundo de simulações. No caso específico de análise de faltas este tratamento tem como propósito minimizar ou mesmo eliminar os efeitos indesejáveis presentes no funcionamento natural das linhas como um todo. Portanto o processamento de sinais consiste na análise ou modificação de sinais de forma a extrair informações peculiares das características intrínsecas dos sinais avaliados e, assim, torná-los mais apropriados para as aplicações de técnicas de reconhecimento de padrões [103].

Nesta seção são introduzidos os passos de pré-processamento do sinal original obtido em simulações, posteriormente normalização dos dados e por fim a extração de atributos, onde as técnicas de extração de características aqui discutidas servirão para compor vetores de atributos dos padrões analisados. Esta etapa foi programada em Matlab[®].

6.2 PRÉ-PROCESSAMENTO DE DADOS

Linhas trifásicas possuem um significativo acoplamento eletromagnético entre os condutores. Por meio da decomposição modal, as tensões e correntes acopladas são decompostas em um novo conjunto modal de tensão e corrente, os quais podem ser tratados independentemente de uma maneira similar às linhas monofásicas. Em 1963, Wedepohl estabeleceu os fundamentos básicos dos métodos matriciais para resolver sistemas polifásicos fazendo uso das técnicas da teoria modal [104]. A transformação modal se caracteriza essencialmente pela capacidade de decompor um determinado grupo

de equações acopladas em desacopladas, excluindo assim as partes mutuas entre estas equações. O objetivo desta seção é ressaltar, portanto, as características básicas da teoria modal [105].

A transformação modal, T , pode ser normalmente aplicada às matrizes de impedância cheias (relativas a linhas com condutores acoplados) para transformá-las em matrizes diagonais.

$$\begin{bmatrix} Z_s & Z_m & Z_m \\ Z_m & Z_s & Z_m \\ Z_m & Z_m & Z_s \end{bmatrix} \xrightarrow{T} \begin{bmatrix} Z_{m0} & 0 & 0 \\ 0 & Z_{m1} & 0 \\ 0 & 0 & Z_{m2} \end{bmatrix}, \quad (6.1)$$

sendo Z_s a impedância própria, Z_m a impedância mutua e Z_{mi} as impedâncias de surto modais, com um modo terra e dois modos aéreos ($i = 0, 1, 2$).

Dependendo da geometria da torre, componentes modais irão viajar em velocidades diferentes ao longo da linha em falha. Assim, os transitórios advindos de uma contingência registrada em uma extremidade da linha vão ter atrasos de tempo entre seus componentes modais. Estes atrasos não poderão ser facilmente reconhecidos a menos que os sinais registrados passem por um processo de transformação modal.

O processo da transformação modal tem o propósito de tornar diagonal e desacoplada a matriz resultante da transformação. Inicialmente, considerando as equações de propagação das ondas eletromagnéticas tanto da tensão como da corrente para um sistema multicondutor, tem-se [106]:

$$\begin{aligned} -\frac{\partial[\vartheta]}{\partial x} &= [L] \frac{\partial[i]}{\partial t} + [R][i] \\ -\frac{\partial[i]}{\partial x} &= [C] \frac{\partial[\vartheta]}{\partial t} + [G][v], \end{aligned} \quad (6.2)$$

sendo $[\vartheta]$ e $[i]$ as matrizes colunas da tensão e da corrente e $[L]$, $[R]$, $[C]$ e $[G]$ as matrizes quadradas da indutância, resistência, capacitância e condutância respectivamente.

A equação (6.2) quando transformada por Fourier se apresenta em função da frequência do seguinte modo:

$$\begin{aligned} -\frac{d[V]}{dx} &= [Z(w)][I] \\ -\frac{d[I]}{dx} &= [Y(w)][V], \end{aligned} \quad (6.3)$$

A matriz impedância $[Z(w)] = [R(w)] + jw[L(w)]$ e a matriz admitância $[Y(w)] = [G(w)] + jw[C(w)]$.

Admitindo que a transformação modal exista e tenha $[T_e]$ como matriz quadrada de transformação das tensões modais, $[V']$, para as tensões de fase, $[V]$, e $[T_i]$ como matriz de transformação das correntes modais, $[I']$, para as correntes de fase, $[I]$, então os termos modais estão relacionadas com os termos de fase por:

$$\begin{aligned} [T_e][V'] &= [V] \\ [T_i][I'] &= [I] \end{aligned} \quad (6.4)$$

Combinando a equação (6.4) com a equação (6.3) e resolvendo obtém-se as duas equações independentes, seguintes:

$$\begin{aligned} \frac{d^2[V']}{dx^2} &= [T_e]^{-1}\{[Z(w)][Y(w)]\}[T_e][V'] \\ \frac{d^2[I']}{dx^2} &= [T_i]^{-1}\{[Y(w)][Z(w)]\}[T_i][I'] \end{aligned} \quad (6.5)$$

A solução da equação (6.5) pode ser obtida assumindo o comprimento da linha infinito, ou seja,

$$\begin{aligned} [V'] &= \epsilon^{-[\lambda'_e]x}[A'] \\ [I'] &= \epsilon^{-[\lambda'_i]x}[B'] \end{aligned} \quad (6.6)$$

A solução modal deve ser escolhida de tal forma que não exista nenhum acoplamento entre os modos quando um sinal de frequência constante for aplicado à linha. O resultado desejado pode ser alcançado quando $[\lambda'_e]$ e $[\lambda'_i]$ forem matrizes diagonais. Substituindo (6.6) em (6.5), tem-se:

$$\begin{aligned} [\lambda'_e]^2 &= [T_e]^{-1}\{[Z(w)][Y(w)]\}[T_e] \\ [\lambda'_i]^2 &= [T_i]^{-1}\{[Y(w)][Z(w)]\}[T_i] \end{aligned} \quad (6.7)$$

As matrizes diagonais $[\lambda'_e]^2$ e $[\lambda'_i]^2$ podem ser interpretadas como os autovalores da matriz quadrada da constante de propagação, $[\gamma]^2$ onde $\gamma_i = (\alpha_i + j\beta_i)$, sendo que α_i representa a constante de atenuação e β_i representa a constante de fase do modo i . Portanto as colunas das matrizes transformação $[T_e]$ e $[T_i]$ são formadas pelos autovetores linearmente independentes da matriz quadrada da constante de propagação, $[\gamma]^2$.

6.3 NORMALIZAÇÃO

O processo de normalização visa estabelecer prescrições destinadas à utilização comum com vistas à obtenção do grau ótimo de ordem em um dado contexto [103]. Portanto seu procedimento objetiva assegurar que a amplitude de determinados atributos estejam compreendidos entre valores previamente estabelecidos evitando, assim, o funcionamento dos neurônios na região de saturação, definida pelas funções transferências utilizadas. Os valores de entrada da rede neural podem ser problemáticos quando pertencentes a quantidades muito díspares, ou seja, valores de entrada da rede com amplitudes diferentes podem favorecer para o empobrecimento do aprendizado como também valores de saída próximo ao limite inferior ou superior das funções transferência, provocando saturação da resposta.

A equação (6.8) ilustra o processo de normalização utilizado.

$$x_{nij} = \frac{L_{inf}(\max(x_j) - x_{ij}) - L_{sup}(\min(x_j) - x_{ij})}{\max(x_j) - \min(x_j)} \quad (6.8)$$

sendo $\max(x_j)$ e $\min(x_j)$ os valores máximos e mínimos do vetor atributo avaliado e os termos L_{inf} e L_{sup} aos limites inferiores e superiores do intervalo de normalização, respectivamente.

Devido às características do problema de localização de faltas apresentar dados de entrada da rede com amplitudes muito diferentes utilizou-se um redimensionamento do espaço entrada em um intervalo compreendido entre 0,1 e 0,9. Portanto os valores de L_{inf} e L_{sup} foram assumidos iguais a 0,1 e 0,9, respectivamente.

6.4 EXTRAÇÃO DE ATRIBUTOS

O conceito de classificação envolve o aprendizado de semelhanças e diferenças de padrões, ou seja, é o processo de agrupamento de objetos em classes de acordo com suas similaridades [107]. Portanto o processo de classificação está diretamente relacionado com a escolha dos atributos que irão representar uma classe de padrões, assim, a escolha ideal das características representativas pode tornar o trabalho de um classificador trivial.

O propósito da extração ou seleção de atributos é identificar quais características são mais representativas quando se deseja discriminar classes, possibilitando que padrões da mesma classe sejam reconhecidos como tal. Assim, o objetivo principal baseia-se na escolha de um conjunto de propriedades ótimo no processo de classificação, contudo de menor dimensão possível de forma a minimizar os custos computacionais empregados. Portanto a obtenção de uma técnica coerente de extração de características relevantes de um padrão não constitui uma atividade das mais triviais.

Diversos métodos de extração de características foram desenvolvidos [85], porém as metodologias utilizando as transformadas matemáticas em conjunto com as poderosas técnicas estatísticas têm alavancado os estudos em processamento e análise de sinais no âmbito da localização de faltas [43], [61], [108] e [109]. Uma das justificativas para o sucesso do seu emprego reside no fato da informação mais relevante do sinal poder ser comprimida, constituindo uma forma viável de representação e descrição para sistemas de classificação e reconhecimento de padrões.

Para o caso de localização digital de faltas, devido às características não estacionárias dos sinais obtidos, é de se esperar que funções básicas localizadas no tempo representem melhor suas propriedades, como as transformadas de wavelets, conforme discutido em seção anterior. As seções seguintes descrevem as aplicações da transformada de wavelets em conjunto com as técnicas estatísticas como processos de extração de atributos.

6.4.1 Espectro Wavelet da Energia

Os sinais transitórios presenciados nos sistemas elétricos de potência apresentam uma característica tipicamente não estacionária, a qual manifestam rápidas mudanças em um curto intervalo de tempo. A transformada de wavelets em conjunto com a técnica multirresolução, conforme discutido em seção anterior, aplica várias decomposições no

signal original utilizando bases wavelet ortogonais. A aplicação repetida de decomposições permite determinar os coeficientes wavelet em diferentes escalas, os quais refletem importantes contribuições na distribuição de energia do sinal, tanto no domínio do tempo como no da frequência.

O espectro wavelet de energia é dado por [110]:

$$E_{j,k} = |D_j(k)|^2, \quad (6.9)$$

sendo $D_j(k)$ a representação wavelet de um sinal $f(t)$, ou seja, a projeção ortogonal de $f(t)$ no subespaço W_j gerado pela base ortonormal $\psi_{j,k}(t)$, conforme equação (4.28) e $E_{j,k}$ o espectro de wavelet de energia na escala j . Portanto o espectro wavelet de energia para uma determinada janela de tempo na escala j , pode ser calculado conforme a equação (6.10).

$$E_j = \sum_k E_{j,k}, \quad (6.10)$$

Podem ser observados que dependendo da topologia do sistema de distribuição e do local de ocorrência da falta o espectro wavelet de energia será maior em uma determinada escala j , favorecendo o processo inteligente de reconhecimento de padrões [61].

6.4.2 Medidas de Entropia Wavelet

A incidência de uma falta no sistema elétrico irá propiciar variações tanto na amplitude como na frequência, assim, quando as técnicas wavelets combinadas com a entropia são empregadas na análise do sinal torna-se possível extrair atributos localizados tanto no domínio do tempo como no domínio da frequência. A seguir definem-se algumas medidas de entropia wavelet.

6.4.2.1 Entropia da Energia Wavelet (*WEE*)

Assumindo que E_j representa o espectro wavelet de energia para uma determinada janela de tempo, na escala j , tem-se que de acordo com as propriedades ortogonais da transformada de wavelet a potência total do sinal, E , pode ser calculada pela soma de todos

os componentes do espectro wavelet de energia, ou seja, o somatório de todas as decomposições j realizadas, conforme equação (6.11).

$$E = \sum_j E_j, \quad (6.11)$$

A energia wavelet relativa é

$$P_j = \frac{E_j}{E}, \quad (6.12)$$

sendo P_j a distribuição de energia do sinal. Vale ressaltar que $\sum_j P_j = 1$. Assim se estabelece o conceito de entropia da energia wavelet (WEE) como:

$$WEE = - \sum_j P_j * \ln(P_j). \quad (6.13)$$

A WEE pode expressar a correlação entre o sinal e a sua frequência, significando que as perturbações no sinal podem representar variações correspondentes na WEE . Esta definição é de fundamental importância no processo de classificação, uma vez que se deseja caracterizar as contribuições das componentes de altas frequências e, assim, minimizar o número de atributos, garantindo a desempenho do classificador [111].

6.4.2.2 Entropia Singular Wavelet (WSE)

A entropia singular wavelet pode ser representada por uma combinação de técnicas, tais como a transformada de wavelets, a decomposição do valor singular (SVD) e a teoria da entropia de informação, incluindo, portanto, os seus benefícios no processamento de sinais. A transformada de wavelets permite análises tanto no tempo como na frequência, já a decomposição do valor singular, poderosa e efetiva técnica da álgebra linear, propicia uma ótima ferramenta para mineração de dados, ou seja, detecção de relacionamentos sistemáticos consistentes entre variáveis.

O processo propõe inicialmente a decomposição em uma série de singularidades, as quais conseguem transluzir as peculiaridades primordiais da matriz de coeficientes da

transformada de wavelets. Por conseguinte, as propriedades estatísticas da entropia do sinal são utilizadas no intuito de averiguar o nível de incerteza do conjunto de singularidade extraído e com isso determinar uma quantidade do grau de complexidade do sinal originalmente avaliado.

Supondo que o resultado da transformada de wavelet discreta de um sinal $f(t)$ na escala j , onde $j = [1, \dots, m]$, seja dado por $d_j(k)$, assim a dimensão da matriz formada será de $m \times k$ e de acordo com a teoria SVD qualquer matriz $m \times k$ pode ser decomposta conforme equação (6.14) [112].

$$d_{m \times k} = U \Lambda V_{svd}^T, \quad (6.14)$$

sendo U uma matrizes de ordem $m \times m$ e V_{svd} uma matriz ortogonal de ordem $k \times k$. Λ representa uma matriz diagonal de mesma dimensão de d . Os elementos que compõem a diagonal principal são todos não negativos e organizados de forma descendente, conforme equação (6.15).

$$\Lambda_{m \times k} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p), \quad (6.15)$$

sendo p igual ao mínimo entre m e k e λ_i representando os valores singulares da matriz d , ordenados da seguintes forma: $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$.

Admitindo que u_i e θ_i sejam as colunas de U e V_{svd} , respectivamente, a equação (6.14) pode ser rescrita na equação (6.16).

$$d_{m \times k} = U \Lambda V_{svd}^T = \sum_{i=1}^p u_i \lambda_i \theta_i^T = \sum_{i=1}^p \lambda_i d_i, \quad (6.16)$$

sendo p o rank da matriz $d_{m \times k}$ e d_i as submatrizes da matriz $d_{m \times k}$ com rank igual a 1.

A equação (6.16) evidencia que a matriz $d_{m \times k}$ pode ser decomposta em series de submatrizes d_i , ou seja, em vários subespaços ortogonais, portanto, todas as submatrizes formadas são distintas possuindo cada uma delas informações únicas. Assim os coeficientes da transformação de wavelets do sinal de falta podem ser transformados pela

técnica SVD, podendo vir a contribuir significativamente na localização do curto-circuito [113].

A *WSE* pode então ser definida como a quantidade da distribuição característica dos componentes de frequência, conforme equação (6.17).

$$WSE(p) = \sum_{i=1}^p \Delta h_i, \quad (6.17)$$

sendo Δh_i definido por:

$$\Delta h_i = - \left\{ \frac{\lambda_i}{\sum_{j=1}^p \lambda_j} \right\} \ln \left\{ \frac{\lambda_i}{\sum_{j=1}^p \lambda_j} \right\}, \quad (6.18)$$

A *WSE* reflete a incerteza do sinal no espectro singular como também incorpora a complexidade da distribuição de energia no domínio do tempo e da frequência, permitindo caracterizar os sinais quantitativamente em função de suas nuances dinâmicas.

6.4.2.3 Entropia Aproximada do Sinal (*ApEn*)

A entropia aproximada pode ser definida como uma família de parâmetros estatísticos, introduzidos por Pincus [114], no intuito de quantificar a regularidade nos dados sem qualquer conhecimento prévio sobre o sistema avaliado [115]. A técnica proposta visa, portanto, distinguir sinais curtos e ruidosos sob uma perspectiva de complexidade, onde seu grande motivador está baseado na característica distinta da distribuição de probabilidade marginal quando as medidas de probabilidade conjuntas, para reconstruções dinâmicas, são diferentes para cada sinal [116].

A *ApEn* é invariante nas oscilações da escala e independe do modelo, conseguindo avaliar com precisão os padrões dominantes e subdominantes em um conjunto de dados o que permite discriminar séries de atributos em ambientes onde a prospecção de dados é “hostil”. Assim, o algoritmo consegue distinguir mudanças subjacentes de um sinal transitório dificilmente refletido nas ocorrências de pico ou de amplitude [115].

A entropia aproximada apresenta dependência de dois parâmetros especificados pelo usuário, um é o comprimento de execução, m , o outro é a janela de tolerância, r .

Assim, a técnica *ApEn*, onde a comparação, entre análises de sinais, necessita ser realizada com os mesmos valores de m e r , pode ser definida, para uma sequência $\langle x(n) \rangle = \{x(1), x(2), \dots, x(n)\}$, conforme equações (6.19) – (6.24).

Inicialmente forma-se um vetor respeitando o comprimento de execução, m , fornecida pelo usuário, conforme equação (6.19)[115].

$$X(i) = [x(i), x(i + 1), \dots, x(i + m - 1)], \quad (6.19)$$

onde $X(i)$ representa um vetor com m valores consecutivos de x iniciando do ponto i , sendo $i = [1, 2, \dots, n - m + 1]$.

O segundo passo está relacionado com o cálculo da distância entre $X(i)$ e $X(j)$, ou seja, a máxima distância absoluta entre os respectivos componentes escalares de X , conforme equação (6.20).

$$d[X(i), X(j)] = \max_{k=1,2,\dots,m} (|x(i + k - 1) - x(j + k - 1)|), \quad (6.20)$$

Para uma dada janela de tolerância, r , maior do que zero, define-se $C_i^m(r)$ como uma medida quantitativa da regularidade (frequência) de padrões semelhantes para um determinado comprimento de execução, r , conforme equação (6.21) [116].

$$C_i^m(r) = \frac{1}{n - m + 1} * \{d[X(i), X(j)] \leq r\}, \quad (6.21)$$

No quarto passo define-se $\Phi^m(r)$ como o valor médio do logaritmo natural de $C_i^m(r)$, conforme equação (6.22).

$$\Phi^m(r) = \frac{1}{n - m + 1} * \sum_{r=1}^{n-m+1} \ln C_i^m(r), \quad (6.22)$$

$\Phi^m(r)$ representa a frequência média de todos os padrões, dos m pontos selecionados, que permanecem próximos uns dos outros na sequência em análise.

Por fim incrementa-se a dimensão da análise, fazendo $m = m + 1$, e repete-se os procedimentos anteriores. Por conseguinte definindo-se, teoricamente, a $ApEn$ em conformidade com a equação (6.23).

$$ApEn(m, r) = \lim_{n \rightarrow \infty} [\Phi^m(r) - \Phi^{m+1}(r)], \quad (6.23)$$

Na prática, o número de dados dos sinais avaliados é finito, portanto a equação (6.23) pode ser transformada na equação (6.24).

$$ApEn(m, r) = \Phi^m(r) - \Phi^{m+1}(r), \quad (6.24)$$

Existe, portanto, duas formas de avaliar a $ApEn$, uma delas está relacionada com a estatística métrica, ou seja, a média logarítmica de uma probabilidade condicional, a qual a torna viável para aplicações tanto em processos determinísticos quanto estocásticos. Um outro ponto de vista está relacionado com a taxa de geração de novos padrões e, portanto, diretamente associado com o conceito de entropia da informação o que permite boa aplicabilidade para os casos de reconhecimento de padrões [115].

6.5 CONSIDERAÇÕES FINAIS

Neste capítulo foi apresentada uma etapa importante do pré-processamento de sinais. Inicialmente foi demonstrada a aplicação da técnica de transformação modal, a qual permite analisar as linhas trifásicas de uma forma totalmente independente semelhante às linhas monofásicas, ou seja, eliminando a presença dos acoplamentos mútuos nos sinais avaliados.

Outro processo de fundamental importância para garantir um conjunto de dados adimensionais é a normalização. A aplicação desta técnica permite que toda base de dados estejam enquadrada em uma determinada faixa de valores evitando saturação no banco de dados e conseqüentemente o empobrecimento do processo de reconhecimento de padrões.

O processo de extração de atributos também foi contemplado neste capítulo, dando ênfase às técnicas estatísticas combinadas com a aplicação da transformada de wavelet e as análises de representação multirresolução de sinais. Esta etapa de extração de características permite maximizar os processos de reconhecimento de padrões, garantindo

uma excelente representatividade do sinal desejado com um grupo de dados de dimensão reduzida, favorecendo a otimização do processo.

Diante da base conceitual devidamente consolidada, no capítulo que segue se discute a aplicação dessas técnicas em caso de localização de faltas do sistema de distribuição da CELPE.

7 ESTUDO DE CASO

7.1 INTRODUÇÃO

A rápida identificação de falhas nos sistemas elétricos permite a concessionária restabelecer os serviços no mínimo de tempo possível evitando, assim, o desconforto, da indisponibilidade da energia, para os consumidores em geral. O estudo de procedimentos inteligentes para suprir esta necessidade é de fundamental importância, então, propõe-se nesta dissertação um algoritmo localizador de faltas para um sistema de distribuição rural, da rede CELPE, balizado nas revisões teóricas previamente discutidas.

Inicialmente descreve-se o problema avaliado, identificando todo sistema CELPE de distribuição do trecho de Caruaru, contemplando a característica da subestação, os variados condutores empregados, as diversas estruturas utilizadas no alimentador rural como também a implementação computacional dessas informações no *software* ATP (*Alternative Transients Program*).

Limitação computacional imposta pelos softwares utilizados obrigou a necessidade da adoção de alguns princípios de implantação da técnica proposta, os quais foram devidamente relatados na seção de critérios de implementação. Posteriormente um classificador de padrões é proposto utilizando redes neurais artificiais, sendo relatados os princípios fundamentais a sua aplicação, tais como separação do banco de dados, escolha da arquitetura, avaliação do desempenho, critérios de parada e números de épocas.

7.2 MODELAGEM DO SISTEMA ELÉTRICO

O alimentador proposto para estudo, de nome CPS-01L7, está situado em Caruaru, região do Agreste do estado de Pernambuco. Este município apresenta aproximadamente 314.951 habitantes e uma área territorial de mais ou menos 921 quilômetros quadrados [117].

A Figura 7.1 é o esquema do sistema elétrico que abastece Caruaru. A rede mantém características intrínsecas a uma zona rural, mesmo depois de ter se expandido ao longo do tempo para atender ao crescimento populacional. Assim a crescente demanda por energia elétrica impacta necessariamente na expansão direta dos ativos das empresas concessionárias, ou seja, novos ramais são anexados ao conjunto original, os quais não obrigatoriamente apresentam as mesmas tecnologias.



Figura 7.1 – Representação do alimentador CPS-01L7 da regional Caruaru.

Incorporar ramais de diferentes tecnologias e geometrias fatalmente impacta em distintas velocidades de propagação das ondas transitórias e conseqüentemente mudanças nos registros oscilográficos das ondas de tensão. Portanto, de forma a caracterizar o sistema elétrico analisado foi realizado um levantamento dos diversos tipos de estruturas e condutores encontrados, denotando suas principais características, bem como a resistividade do solo considerada.

7.2.1 Subestação

Uma subestação é uma instalação elétrica, a qual funciona como ponto de controle e transferência unindo os sistemas de transmissão e distribuição elétrica. A subestação tem

como função direcionar e controlar o fluxo energético, transformando os níveis de tensão, para os pontos de entrega.

Representar uma subestação de distribuição significa recolher todas as informações que estão localizadas a sua montante eletricamente e, assim, compor um equivalente do sistema elétrico. A Figura 7.2 é do modelo simplificado de uma rede elétrica, cujas matrizes são normalmente fornecidas em termos das potências de curto-circuito trifásicas e monofásicas ou das impedâncias de sequência positiva e zero.



Figura 7.2 – Sistema equivalente simplificado de uma rede elétrica.

Os dados de curto-circuito, medidos na subestação, para o alimentador CPS-01L7, foram todos fornecidos pela CELPE e listados na Tabela 7.1. A subestação pode ser identificada visualmente na Figura 7.1 através de um quadrado totalmente preenchido em preto.

Tabela 7.1 – Parâmetros equivalentes do alimentador CPS-01L7.

Corrente de curto-circuito trifásica (A)	6438
Corrente de curto-circuito bifásica (A)	5575
Corrente de curto-circuito monofásica (A)	7578
Impedância sequência positiva (Ω/km)	$0,1467 + j1,2287$
Impedância sequência zero (Ω/km)	$j0,6827$

7.2.2 Condutores

Constituem os elementos ativos propriamente ditos das linhas de transmissão e distribuição, possuindo, portanto, características intrínsecas especiais. A sua escolha adequada representa um problema de fundamental importância no dimensionamento das

linhas, pois não só depende dela o bom desempenho da linha, como também tem importantes implicações de natureza econômica [63].

A seleção e o projeto de condutores para linhas de transmissão tornou-se uma ciência, onde a escolha do tipo e dimensão ótima do condutor para determinada linha de transmissão e distribuição requer um completo conhecimento de todas as características dos diversos condutores disponíveis. Esta compreensão deve incluir mais do que apenas a capacidade de transporte de corrente ou desempenho térmico do condutor. Assim, escolha adequada de condutores deve incluir uma abordagem sistemática: Estabilidade da linha versus corrente que ela transporta; operação econômica versus carregamento térmico; fluência (deformação permanente do condutor devido a ação da tração e da acomodação geométrica entre os fios do condutor) e flecha (maior distância vertical entre a catenária de um vão e a reta que liga seus apoios) resultante sob alta temperatura e carregamento mecânico adverso; resistência do condutor conforme determinada pelo desempenho tensão-alongamento dos componentes metálicos e características de fadiga do metal são apenas alguns dos parâmetros do projeto do sistema a serem avaliados [118].

Não há uma única técnica pela qual todas as linhas de distribuição e transmissão são projetadas. É evidente, porém, que os componentes de maior custo no projeto de uma linha dependem dos parâmetros elétricos e mecânicos dos condutores. Há quatro principais tipos de condutores utilizados em linhas aéreas de transmissão e distribuição, cada um com suas, respectivas, características elétricas conforme mostrado na Tabela 7.2.

Tabela 7.2 – Listas dos principais tipos de condutores.

Designação	Descrição
CA/AAC	Condutor de alumínio/All Aluminum Conductor
CAL/AAAC	Condutor de liga de alumínio/All Aluminum Alloy Conductor
CAA/ACSR	Condutor de alumínio com alma de aço/Aluminum Conductor Steel Reinforced
CALA/ACAR	Condutor de alumínio com alma de liga de alumínio/Aluminum Conductor Aluminum-Alloy Reinforced

Os condutores utilizados no alimentador CPS-01L7, com suas características básicas, estão descritos na Tabela 7.3. A resistividade do solo foi admitida igual a $100 \Omega\text{m}$ [43].

Tabela 7.3 – Características básicas dos ramais do alimentador em análise.

Condutor	Resistência CA	Diâmetro Nominal	Reatância
25mm ² CAA	1.7119 Ω/km	6.35 mm	0.4537 Ω/km
35mm ² Spacer	0.5916 Ω/km	9.75 mm	0.4200 Ω/km
50mm ² CA	0.8867 Ω/km	9.00 mm	0.4274 Ω/km
25mm ² Multiplex	1.0439 Ω/km	7.42 mm	0.4462 Ω/km
25mm ² CA	1.3166 Ω/km	6.61 mm	0.4550 Ω/km

7.2.3 Estruturas

As estruturas constituem os elementos de sustentação dos cabos das linhas de transmissão e distribuição, as quais terão tantos pontos de sustentação quantos forem os cabos condutores e cabos para-raios a serem suportados. Suas dimensões e formas dependem, portanto, de diversos fatores, onde se destaca: a disposição dos condutores, impactando em diferentes geometrias; distância entre condutores; fecho dos condutores, entre outros.

Portanto, o desempenho elétrico de uma linha aérea de transmissão e distribuição depende quase que exclusivamente de sua geometria, ou seja, de suas características físicas. Estas não só ditam o seu comportamento em regime normal de operação, definindo seus parâmetros elétricos, como também sob os efeitos indesejáveis dos transitórios elétricos que se propagam por todo o comprimento da linha [63].

A Figura 7.3 ilustra 4, em um total de 38, tipos distintos de estruturas encontradas no sistema de distribuição da CELPE em Caruaru. Todos os desenhos das estruturas, aqui demonstrados, foram fornecidos pela CELPE e foram cotados em milímetros.

7.2.4 Implementação no ATP (Alternative Transients Program)

Dentro do planejamento da construção de linhas de transmissão e distribuição, o cálculo dos parâmetros longitudinais e transversais é parte integrante de fundamental importância não só para o projeto adequado de futuras linhas, mas também para a correta avaliação no caso de expansão das redes. De fato o cálculo dos parâmetros assume nível de

importância semelhante à etapa de desenvolvimento de novos modelos para as linhas de distribuição [119].

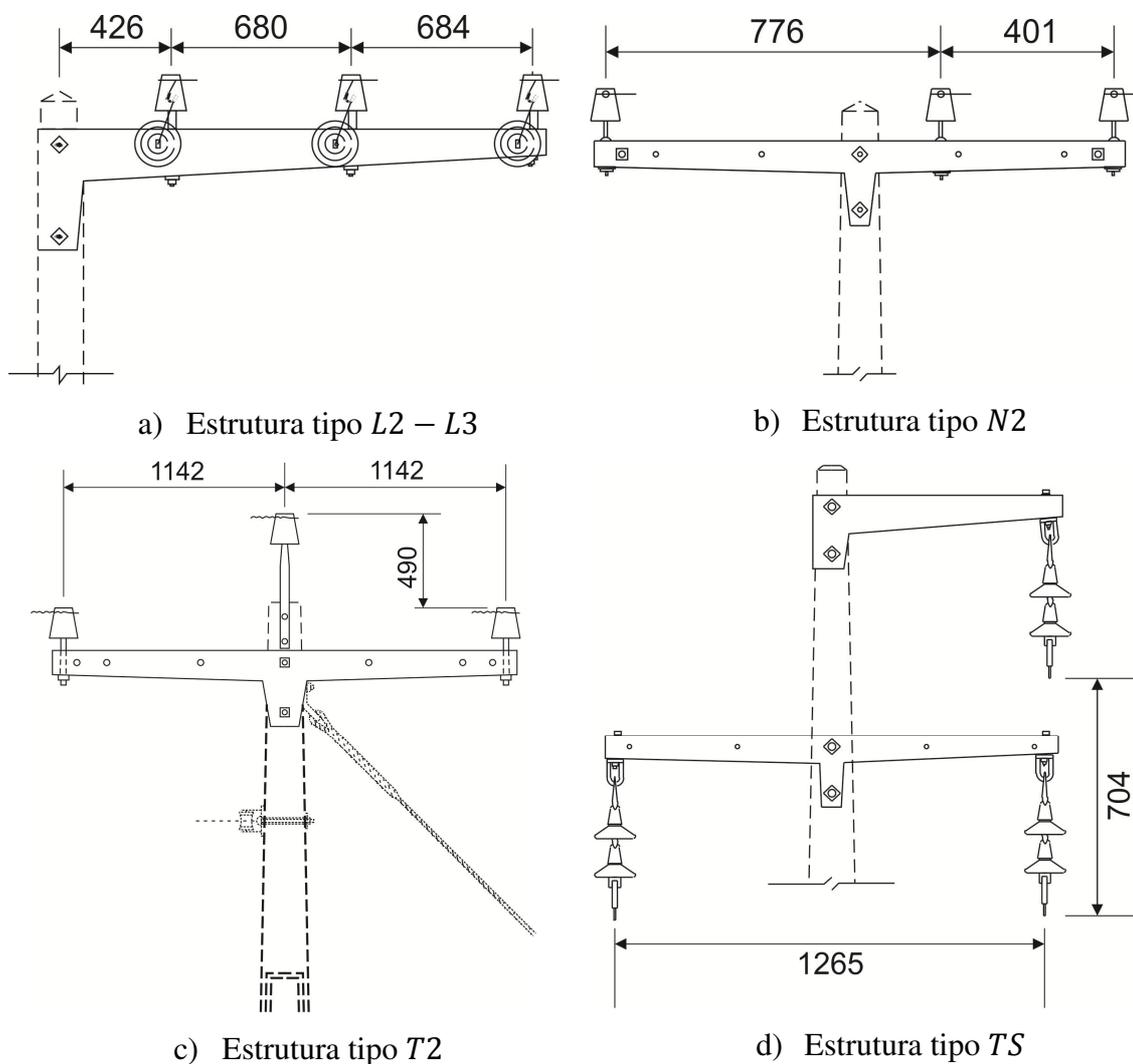


Figura 7.3 – Algumas variações de estruturas encontradas no CPS-01L7

A correta modelagem dos parâmetros elétricos impõe um rigor elevado, já que imprecisões em sua representação poderão produzir desvios significativos entre os resultados dos estudos de planejamento e os resultados verificados na operação diária do sistema. Tais desvios assumem uma gravidade ainda maior quando se leva em conta que os modelos que regem as redes elétricas subsidiam decisões cruciais para um funcionamento confiável do sistema [120].

Dessa forma os parâmetros unitários das linhas de distribuição e transmissão, tais como a resistência por unidade de comprimento (R), indutância por unidade de comprimento (L) e a capacitância por unidade de comprimento (C), não podem, em geral,

ser considerados como parâmetros concentrados, mas sim uniformemente distribuído por todo o comprimento do alimentador [119]. O principal atributo na representação por parâmetros distribuídos está na precisão dos resultados obtidos. Essa modelagem demonstra com grande acurácia os transitórios simulados para uma ampla faixa de frequência, pois são calculados diretamente em função da propagação da linha [121]. Computacionalmente esta técnica pode ser aplicada utilizando a sub-rotina *Line Constants* do software ATP-EMTP (*Alternative Transients Program – Electromagnetic Transients Program*) a qual será detalhada na seção seguinte.

7.2.4.1 Line Constants

A sub-rotina *Line Constants* é possivelmente a mais antiga do EMTP, tendo sido elaborada basicamente em conjunto com as primeiras versões do programa. É uma extensão do trabalho desenvolvido por Hesse [122] e utiliza a fórmula de Carson para terra homogênea. A fórmula de Carson se baseia em condutores perfeitamente horizontais acima da terra, onde a altura média, \bar{V} , do condutor é utilizada para os cálculos, sendo \bar{V} definido segundo a equação (6.8).

$$\bar{V} = \frac{1}{3}V_{tower} + \frac{2}{3}V_{mid} \quad (7.1)$$

sendo V_{tower} a altura do condutor ao solo em seu suporte e V_{mid} a altura do condutor ao solo onde define-se a flecha. Caso no arquivo de entrada de dados do ATP-EMTP um destes valores não seja especificado, o programa toma como altura média o valor especificado diferente de zero.

Esta rotina calcula as matrizes de capacitância e impedância tanto no domínio de fase quando no domínio de sequência (para o caso da linha não transposta). Portanto, o arquivo de entrada de uma estrutura tipo $L2 - L3$, conforme Figura 7.3 a), utilizando condutor do tipo CAA 25 mm² é exemplificado na Figura 7.4.

Foi criado um banco de dados com 1989 rotinas *Line Constants*, as quais redundaram das diversas variações de estruturas, condutores e comprimentos dos vãos. O conjunto de dados formado serviu como entrada para montar todo o sistema CPS-01L7 em uma rotina do ATP permitindo, assim, simular situações de faltas por todo o alimentador. A Figura 7.5 ilustra parte do cartão gerado simulado no ATP para uma falta fase-terra com impedância de 40Ω e um ângulo de incidência, instante de ocorrência da falta, de 120°.

De forma a montar um conjunto de dados de curtos-circuitos nas mais diversas conjunturas possíveis foi desenvolvido um algoritmo em *Java*, linguagem de programação orientada a objeto. O banco de dados montado levou em consideração variações na impedância e no ângulo de incidência, conforme demonstrado na Tabela 7.4, totalizando 4200 simulações de condições faltosas.

Tabela 7.4 – Variações no ângulo de incidência e impedância.

Ângulo de incidência	Impedância
0°	0Ω, 20Ω, 40Ω
60°	0Ω, 20Ω, 40Ω
90°	0Ω, 20Ω, 40Ω
120°	0Ω, 20Ω, 40Ω

7.3 CRITÉRIOS DE IMPLEMENTAÇÃO

Diante de um sistema de distribuição com aproximadamente 400 km de comprimento enfrenta-se sempre a possibilidade, quando de sua montagem computacional, de limitações impostas pelo software utilizado. Assim, vencer tais limitações necessita, inevitavelmente, impor alguns critérios no processo de implementação de forma a tornar o problema exequível.

Outra consideração está relacionada com a forma de equacionar o problema de reconhecimento de padrões. As características presentes no sistema de distribuição avaliado impõe uma avaliação estruturada do problema, assim se propõe um critério, descrito mais adiante, para aplicação das técnicas estudadas.

7.3.1 Limitação do ATP

O *software* ATP apresenta limitações quanto ao número de nós, ramos, fontes e etc. da rede elétrica, pode-se alterar tais valores atualizando a lista “*LISTSIZE.DAT*”. Contudo existe um limite para o qual o ATP não permite crescer tais valores. Um importante limitador, visualizado diante das simulações, foi o número de nós, que para o caso estudado estava estimado em aproximadamente 3472, porém o ATP limita em 2000 nós

monofásicos. Foram introduzidas algumas considerações de forma a tornar viáveis as simulações de curto-circuito. Abaixo são descritas as adequações realizadas.

- Trechos com as estruturas de mesmas dimensões utilizando o mesmo tipo de condutor foram adicionados a trechos de características elétricas semelhantes.
- Trechos com distâncias entre estruturas menores do que 0,09 km foram subtraídos, sendo seus comprimentos acrescidos ao trecho imediatamente adjacente.

As considerações implementadas não afetaram significativamente a modelagem pretendida, pois tais agrupamentos de trechos levaram em consideração a impedância do trecho subtraído. Essas adequações limitou o número de nós em 1989 monofásicos o que tornou viável realizar as simulações de curto-circuito para toda a extensão do alimentador CPS-01L7.

7.3.2 Subdivisão do Alimentador CPS-01L7

O crescimento vertiginoso da região de Caruaru impactou na expansão das linhas de distribuição e como consequência diversas ramificações foram projetadas no sistema no intuito de abastecer toda a demanda, porém tornando a rede elétrica, como um todo, demasiadamente dispersa.

Identificar faltas em função da distância de sua ocorrência até a subestação em alimentadores dispersos apresenta efeito invariavelmente não representativo, devido às inúmeras possibilidades de alocação, com mesma distância, do ponto em contingência. Assim o operador estaria sempre tratando com informações dúbias a respeito da localização da falta. Portanto, no intuito de minimizar esta problemática propõe-se nesta dissertação a subdivisão do alimentador em 14 setores, indicados na Figura 7.6, por cores distintas.



Figura 7.6 – Subdivisão do alimentador CPS-01L7 em grupos identificados em diferentes cores.

7.4 CLASSIFICADOR BASEADO EM REDES NEURAIIS

As redes neurais artificiais aplicadas nesta dissertação foram projetadas para garantir a generalização do conhecimento adquirido durante todo o processo de treinamento, que se deu empregando aprendizado supervisionado. Para tanto a base de dados foi dividida nos seguintes conjuntos: 60% dos dados compuseram, aleatoriamente, o conjunto de treinamento, 20% o conjunto de validação e o restante o conjunto de teste. Assim, a matriz formada para o conjunto de treinamento possui dimensão $n \times 2520$, já o conjunto de validação e teste possui dimensão $n \times 840$. n representa a dimensão do vetor entrada da rede diretamente relacionada com os atributos utilizados, conforme Tabela 7.5.

Tabela 7.5 – Dimensão de entrada da RNA.

Atributos	Dimensão (n)
<i>ApEn</i>	9
<i>WSE/WEE</i>	6
Espectro Wavelet de Energia	9

Vale ressaltar que o conjunto de treinamento deve ser constituído pela maior parte dos dados, pois é a partir deste conjunto que os pesos sinápticos serão devidamente ajustados durante o processo de treinamento cumprindo seu objetivo principal de repassar o conhecimento para as redes.

Já o conjunto de validação é utilizado paralelamente ao conjunto de treinamento, onde verifica-se constantemente a capacidade de generalização da rede neural durante o processo de treinamento. Portanto, este conjunto não é utilizado para ajuste dos pesos, mas sim como critério de parada no treinamento evitando, assim, que a rede memorize os resultados.

O conjunto de teste tem como função estimar o desempenho final das RNA, quando as mesmas estiverem em operação, apresentando como entrada conjunto de dados totalmente desconhecidos pela rede neural.

7.4.1 Avaliação de Desempenho

O processo de treinamento das redes neurais pode ser avaliado quanto a sua efetividade e habilidade de predição utilizando o erro médio quadrático (MSE), o qual foi aplicado tanto para o conjunto de treinamento como para o conjunto de validação. O MSE se expressa do seguinte modo [93]:

$$MSE = 100 \cdot \frac{y_{c_{max}} - y_{c_{min}}}{M \cdot N} \sum_{i=1}^N \sum_{j=1}^M (y_{c_{ij}} - y_{d_{ij}})^2 \quad (7.2)$$

sendo $y_{c_{max}}$ e $y_{c_{min}}$ os valores máximos e mínimos da saída da rede neural, N o número de neurônios da camada de saída, M o número de padrões da base de dados considerada. $y_{c_{ij}}$ e $y_{d_{ij}}$ são, respectivamente, a saída calculada e a saída desejada para cada neurônio.

7.4.2 Critérios de Parada dos Treinamentos

De uma forma geral, não existem meios de demonstrar a convergência do algoritmo de treinamento, logo, os critérios de parada não são bem definidos. No entanto, existem métodos particulares, os quais podem ser utilizados eficazmente como indicador de parada dos treinamentos das redes neurais. Vale ressaltar que todos os critérios têm como principal objetivo evitar o “*overfitting*” dos pesos, ou seja, evita a memorização dos padrões de treinamento, o que iria prejudicar a capacidade de generalização das redes. As seções seguintes descrevem os critérios adotados.

7.4.2.1 Números de Épocas

Define-se número de época como sendo a quantidade de vezes que ocorre uma apresentação completa do conjunto de treinamento inteiro a uma rede neural. Assim pode-se estipular um número máximo de épocas como critério de parada do processo de treinamento, evitando, assim, a possibilidade de “*overfitting*”. Nesta dissertação foram utilizadas 10000 épocas como número máximo, sendo o mesmo escolhido de forma arbitrária.

7.4.2.2 Early Stop

O critério “*Early Stop*”, parada prematura do treinamento, tem como objetivo aumentar a capacidade de generalização das redes neurais através da verificação periódica do erro MSE no conjunto de validação. Este erro, geralmente diminui durante a fase inicial do treinamento, porém quando a rede neural começa a memorizar ele aumenta. Portanto, quando o erro do conjunto de validação aumenta em um determinado número de épocas o processo de treinamento é interrompido, sendo os pesos e o bias atualizados para os valores onde ocorreu o menor erro MSE do conjunto de validação.

7.4.2.3 Erro de Treinamento

Este critério de parada avalia se o decréscimo do erro MSE sobre o conjunto de treinamento é significativo entre uma época e outra, como também, avalia se o objetivo de minimizar a função desejada foi alcançado.

O desempenho mínimo de treinamento define o limiar do erro durante o processo de treinamento, foi adotado o erro médio quadrado igual à zero. O valor escolhido permitiu o máximo de treinamento possível, porém sem infringir os outros critérios preestabelecidos.

Vale ressaltar que os critérios definidos foram utilizados simultaneamente durante o processo de treinamento, sendo o mesmo encerrado caso qualquer um dos critérios seja atendido.

7.4.3 Codificação das Classes

Com o intuito de selecionar a rede com a melhor representação de saída, foram realizados testes para a saída com 1 neurônio e com 14 neurônios. A codificação para cada classe é mostrada na Tabela 7.6.

A classificação da saída das redes com apenas um neurônio foi definido pelo valor das classes, ou seja, o valor de saída que mais se aproxime em modulo das quantidades designadas na Tabela 7.6 irá pertencer à respectiva classe. Já as redes com 14 neurônios na camada de saída faz uso da técnica o vencedor leva tudo (“*winner takes all*”). Portanto a saída da rede que obtiver o maior valor será a classe a qual o exemplo analisado pertence.

Foram propostos 4 modelos distintos de redes, descritos abaixo, sendo os modelos 1 e 2 mostrado na Figura 7.7 e os modelos 3 e 4 mostrados na Figura 7.8.

- Modelo 1 – Composto por apenas 1 neurônio na camada de saída da RNA.
- Modelo 2 – Composto por 14 neurônios na camada de saída da RNA.
- Modelo 3 – Formado por 3 especialistas do modelo 1.
- Modelo 4 – Formado por 3 especialistas do modelo 2.

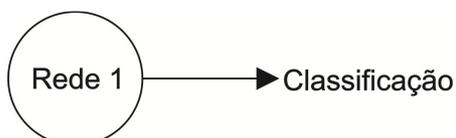


Figura 7.7 – Classificação com um especialista.

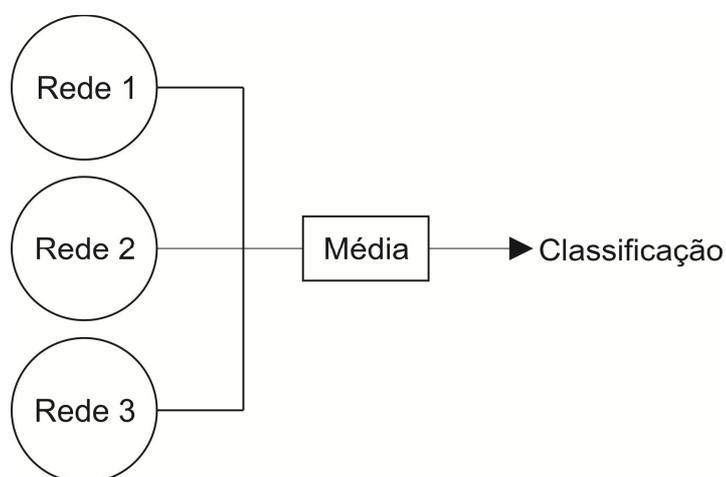


Figura 7.8 – Classificação com três especialistas.

Tabela 7.6 – Codificação da camada de saída da RNA.

Classes	Codificação	
	14 neurônios	1 neurônio
A	0,9 0 0 0 0 0 0 0 0 0 0 0 0 0	0,10
B	0 0,9 0 0 0 0 0 0 0 0 0 0 0 0	0,16
C	0 0 0,9 0 0 0 0 0 0 0 0 0 0 0	0,22
D	0 0 0 0,9 0 0 0 0 0 0 0 0 0 0	0,28
E	0 0 0 0 0,9 0 0 0 0 0 0 0 0 0	0,34
F	0 0 0 0 0 0,9 0 0 0 0 0 0 0 0	0,40
G	0 0 0 0 0 0 0,9 0 0 0 0 0 0 0	0,46
H	0 0 0 0 0 0 0 0,9 0 0 0 0 0 0	0,52
I	0 0 0 0 0 0 0 0 0,9 0 0 0 0 0	0,58
J	0 0 0 0 0 0 0 0 0 0,9 0 0 0 0	0,64
L	0 0 0 0 0 0 0 0 0 0 0,9 0 0 0	0,70
M	0 0 0 0 0 0 0 0 0 0 0 0,9 0 0	0,76
N	0 0 0 0 0 0 0 0 0 0 0 0 0,9 0	0,82
O	0 0 0 0 0 0 0 0 0 0 0 0 0 0,9	0,88

7.4.3.1 Escolha da Arquitetura

No projeto das redes neurais artificiais destaca-se a dependência existente entre o bom processo de aprendizagem dos neurônios e o número de padrões utilizados no conjunto de treinamento, a dificuldade do problema tratado, como também o número de parâmetros livres (pesos e bias). Contudo, não existe nenhuma regra determinística que relacione estas variáveis de uma forma ótima, assim a escolha adequada da arquitetura tem caráter experimental. Na prática o processo de seleção da arquitetura deve ser aplicado com o intuito de testar os vários métodos de aprendizado e as diferentes configurações que uma rede possa ter para a resolução do problema em questão.

O critério adotado leva em consideração a variação do número de neurônios nas camadas ocultas, como também variação da quantidade de camadas ocultas e da função de transferência. Sendo treinadas várias redes neurais e selecionada a melhor arquitetura em função do menor erro médio quadrático durante os treinamentos sobre o conjunto de validação. A Tabela 7.7 mostra as variações realizadas.

Assim como a arquitetura, a inicialização dos pesos sinápticos, realizada aleatoriamente, pode influenciar a desempenho dos treinamentos. Portanto, para cada arquitetura testada os pesos são inicializados 10 vezes, no intuito de garantir que a seleção da melhor arquitetura não tenha sido ocasionada por uma inicialização ótima dos pesos.

Tabela 7.7 – Variações das arquiteturas das redes neurais.

Número de camadas ocultas	Número de neurônios	Função de ativação
1	5 a 15	<i>tansig e logsig</i>
2	5 a 15	<i>tansig – tansig, tansig – logsig, logsig – logsig</i>

7.4.4 Método de Validação Cruzada

O método de validação cruzada, também conhecido como *k-fold cross-validation*, consiste em dividir o banco de dados em *k* repartições aleatórias, mutuamente exclusivas, de forma a treinar, validar e testar o sistema. Em cada iteração, uma partição diferente é

utilizada para testar e as outras $k - 1$ partições são utilizadas para validar e treinar. Nesta dissertação utilizou-se sempre $k = 10$, ou seja, $10 - fold$.

Foram realizados 10 experimentos, onde, para cada experimento, duas partições diferentes são utilizadas para testar o sistema e das oito restantes, duas são escolhidas para formar o conjunto de validação e as demais para formar o conjunto de treinamento. Para cada experimento criaram-se 30 redes, das quais se escolheu a rede de menor erro de classificação médio das 10 inicializações.

No intuito de assegurar uma boa generalização da rede foi utilizada a técnica de validação cruzada ($k - fold$), onde a Tabela 7.8 mostra os 10 experimentos dos diferentes subconjuntos de treinamento, validação e teste utilizados no presente trabalho.

7.4.5 Resultados do Treinamento das Redes

Nesta seção são apresentadas as arquiteturas das 3 melhores redes neurais obtidas, assim como os erros de classificação percentuais (E.C.) obtidos nas simulações de faltas utilizando o banco de dados de teste, seguindo, para tanto, o processo descrito previamente para os modelos 1, 2, 3 e 4.

Tabela 7.8 – Formação dos conjuntos de treinamento, validação e teste.

Experimentos	Rede	Conjuntos de treinamento	Conjuntos de validação	Conjuntos de teste
1	1 a 30	4, 5, 6, 7, 8, 9	2, 3	1, 10
2	31 a 60	5, 6, 7, 8, 9, 10	3, 4	2, 1
3	61 a 90	6, 7, 8, 9, 10, 1	4, 5	3, 2
4	91 a 120	7, 8, 9, 10, 1, 2	5, 6	4, 3
5	121 a 150	8, 9, 10, 1, 2, 3	6, 7	5, 4
6	151 a 180	9, 10, 1, 2, 3, 4	7, 8	6, 5
7	181 a 210	10, 1, 2, 3, 4, 5	8, 9	7, 6
8	211 a 240	1, 2, 3, 4, 5, 6	9, 10	8, 7
9	241 a 270	2, 3, 4, 5, 6, 7	10, 1	9, 8
10	271 a 300	3, 4, 5, 6, 7, 8	1, 2	10, 9

7.4.5.1 Resultados do Treinamento do Modelo 1

Na Tabela 7.9 apresenta-se a arquitetura da primeira rede pertencente ao modelo 1 utilizando como vetor de entrada a *ApEn*.

Tabela 7.9 – Melhor arquitetura do modelo 1 para o vetor de entrada *ApEn*.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
16	9 – 6 – 1	logsig – logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.10, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.10 – Erros de classificação percentuais da arquitetura proposta na Tabela 7.9.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	5,8571 %	8,7143 %	4,0714 %
60°	9,4286 %	3,0000 %	3,1429 %
90°	5,5000 %	6,9286 %	3,3571 %
120°	5,1429 %	8,0000 %	5,1429 %

Na Tabela 7.11 apresenta-se a arquitetura da segunda rede pertencente ao modelo 1 utilizando como vetor de entrada o espectro wavelet de energia.

Tabela 7.11 – Melhor arquitetura do modelo 1 para o vetor de entrada espectro wavelet de energia.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
17	9 – 7 – 1	tansig – logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.12, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.12 – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.11**.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	7,2857 %	6,9286 %	7,6429 %
60°	8,7143 %	11,2143 %	11,2143 %
90°	7,2857 %	9,7857 %	10,8571 %
120°	8,0000 %	9,4286 %	12,2857 %

Na Tabela 7.13 apresenta-se a arquitetura da segunda rede pertencente ao modelo 1 utilizando como vetor de entrada a *WEE/WSE*.

Tabela 7.13 – Melhor arquitetura do modelo 1 para o vetor de entrada *WEE/WSE*.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
17	6 – 10 – 1	tansig – logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.14, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.14 – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.13**.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	15,5000 %	16,9286 %	13,7143 %
60°	19,4286 %	18,0000 %	21,9286 %
90°	17,6429 %	19,0714 %	16,5714 %
120°	24,4286 %	22,2857 %	15,1429 %

7.4.5.2 Resultados do Treinamento do Modelo 2

Na Tabela 7.15 apresenta-se a arquitetura da primeira rede pertencente ao modelo 2 utilizando como vetor de entrada a *ApEn*.

Tabela 7.15 – Melhor arquitetura do modelo 2 para o vetor de entrada *ApEn*.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
36	9 – 8 – 5 – 14	tansig – logsig – logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.16, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.16 – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.15**.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	30,5000 %	22,6429 %	18,3571 %
60°	28,7143 %	26,5714 %	23,0000 %
90°	23,7143 %	23,3571 %	21,2143 %
120°	24,7857 %	28,0000 %	29,4286 %

Na Tabela 7.17 apresenta-se a arquitetura da segunda rede pertencente ao modelo 2 utilizando como vetor de entrada o espectro wavelet de energia.

Tabela 7.17 – Melhor arquitetura do modelo 2 para o vetor de entrada espectro wavelet de energia.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
34	9 – 5 – 6 – 14	tansig – tansig – logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.18, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.18 – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.17**.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	32,2857 %	34,7857 %	34,0714 %
60°	34,4286 %	35,5000 %	33,7143 %
90°	32,6429 %	33,0000 %	36,5714 %
120°	36,2143 %	36,9286 %	31,2143 %

Na Tabela 7.19 apresenta-se a arquitetura da terceira rede pertencente ao modelo 2 utilizando como vetor de entrada a *WEE/WSE*.

Tabela 7.19 – Melhor arquitetura do modelo 2 para o vetor de entrada *WEE/WSE*.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
30	6 – 10 – 14	logsig – logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.20, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.20 – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.19**.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	39,0714 %	38,0000 %	37,6429 %
60°	39,7857 %	36,2143 %	40,5000 %
90°	38,7143 %	35,5000 %	33,0000 %
120°	39,4286 %	41,2143 %	36,9286 %

7.4.5.3 Resultados do Treinamento do Modelo 3

Na Tabela 7.21 apresenta-se a arquitetura da primeira rede pertencente ao modelo 3 utilizando como vetor de entrada a $ApEn$.

Tabela 7.21 – Melhor arquitetura do modelo 3 para o vetor de entrada $ApEn$.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
16	9 – 6 – 1	logsig – logsig
15	9 – 5 – 1	logsig – logsig
20	9 – 10 – 1	logsig – logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.22, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.22 – Erros de classificação percentuais da arquitetura proposta na Tabela 7.21.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	1,5714 %	0,5000 %	1,9286 %
60°	0,8571 %	0,1429 %	2,2857 %
90°	1,2143 %	1,7857 %	1,0714 %
120°	2,6429 %	1,7143 %	1,4286 %

Na Tabela 7.23 apresenta-se a arquitetura da segunda rede pertencente ao modelo 3 utilizando como vetor de entrada o espectro wavelet de energia.

Tabela 7.23 – Melhor arquitetura do modelo 3 para o vetor de entrada espectro wavelet de energia.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
17	9 – 7 – 1	tansig – logsig
21	9 – 11 – 1	tansig – logsig
16	9 – 6 – 1	tansig – logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.24, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.24 – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.23**.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	2,8571 %	5,4236 %	3,7143 %
60°	3,0000 %	2,2143 %	2,6429 %
90°	2,0714 %	6,2143 %	2,5000 %
120°	1,4286 %	3,1429 %	4,7857 %

Na Tabela 7.25 apresenta-se a arquitetura da terceira rede pertencente ao modelo 3 utilizando como vetor de entrada a *WEE/WSE*.

Tabela 7.25 – Melhor arquitetura do modelo 3 para o vetor de entrada *WEE/WSE*.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
17	6 – 10 – 1	tansig – logsig
12	6 – 5 – 1	logsig - logsig
20	6 – 13 – 1	tansig-logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.26, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.26 – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.25**.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	9,7857 %	8,8571 %	8,0000 %
60°	7,2857 %	9,4286 %	8,3571 %
90°	8,7143 %	7,2857 %	7,6429 %
120°	9,9286 %	6,9286 %	9,0714 %

Resultados do Treinamento do Modelo 4

Na Tabela 7.27 apresenta-se a arquitetura da primeira rede pertencente ao modelo 4 utilizando como vetor de entrada a *ApEn*.

Tabela 7.27 – Melhor arquitetura do modelo 4 para o vetor de entrada *ApEn*.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
36	9 – 8 – 5 – 14	tansig – logsig – logsig
39	9 – 8 – 8 – 14	logsig – logsig – logsig
35	9 – 7 – 5 – 14	logsig – logsig – logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.28, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.28 – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.27**.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	22,2857 %	20,1429 %	18,0714 %
60°	18,7143 %	17,6429 %	20,8571 %
90°	21,5714 %	20,8571 %	21,2143 %
120°	18,3571 %	18,5321 %	19,2314 %

Na Tabela 7.29 apresenta-se a arquitetura da segunda rede pertencente ao modelo 4 utilizando como vetor de entrada o espectro wavelet de energia.

Tabela 7.29 – Melhor arquitetura do modelo 4 para o vetor de entrada espectro wavelet de energia.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
34	9 – 5 – 6 – 14	tansig – tansig – logsig
39	9 – 7 – 9 – 14	logsig – logsig – logsig
36	9 – 5 – 8 – 14	tansig – tansig – logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.30, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.30 – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.29**.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	24,0714 %	28,3571 %	27,6429 %
60°	26,2143 %	22,2857 %	29,7857 %
90°	31,2143 %	29,7857 %	25,1429 %
120°	26,5714 %	24,4286 %	23,3571 %

Na Tabela 7.31 apresenta-se a arquitetura da terceira rede pertencente ao modelo 4 utilizando como vetor de entrada a *WEE/WSE*.

Tabela 7.31 – Melhor arquitetura do modelo 4 para o vetor de entrada *WEE/WSE*.

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
30	6 – 10 – 14	logsig – logsig
27	6 – 7 – 14	logsig – logsig
32	6 – 12 – 14	logsig – logsig

Os resultados dos erros percentuais de classificação da simulação da referida rede são apresentados na Tabela 7.32, variando-se o ângulo de incidência da falta e a impedância da falta.

Tabela 7.32 – Erros de classificação percentuais da arquitetura proposta na **Tabela 7.31**.

Ângulo de Incidência	Impedância da falta		
	0 Ω	20 Ω	40 Ω
0°	25,8571 %	28,7143 %	29,7857 %
60°	24,4286 %	20,5234 %	23,3571 %
90°	24,7857 %	27,6429 %	20,1429 %
120°	21,9286 %	27,6429 %	25,1429 %

7.5 CONSIDERAÇÕES FINAIS

Diante dos resultados encontrados se observa que o algoritmo desenvolvido a partir das técnicas de redes neurais apresentou desempenho satisfatório, assim, a transformada de wavelets quando combinada com processos estatísticos, tais como: a entropia aproximada do sinal e o espectro de energia, constituem peculiaridades imprescindíveis ao processo de localização de faltas.

A Tabela 7.33 faz um resumo dos métodos propostos utilizando o erro médio percentual como comparação. A metodologia que mostrou melhor desempenho foi à combinação da transformada de wavelets e a entropia aproximada do sinal para o modelo

3, ou seja, a combinação das três melhores inicializações. O espectro wavelet de energia apresentou bom resultado também para o modelo 3 conforme destacado na Tabela 7.33 em amarelo. Portanto, a técnica aplicada mostrou insensibilidade à variação da impedância e do ângulo de incidência com erros aproximados de 2%, o que representa robustez para aplicação em sistemas de distribuição de grande porte e fortemente dispersos.

Tabela 7.33 – Erro médio percentual dos métodos propostos.

	<i>ApEn</i>	Espectro Wavelet de Energia	<i>WEE/WSE</i>
Modelo 1	5,6904833 %	9,2202417 %	18,3869167 %
Modelo 2	25,0238083 %	34,2797667 %	38,0000083 %
Modelo 3	1,428575 %	3,332925 %	8,440475 %
Modelo 4	19,7898083 %	26,571425 %	24,9960083 %

8 CONCLUSÃO

8.1 CONSIDERAÇÕES GERAIS

As problemáticas sociais vivenciadas em decorrência da falta de energia emanadas pelos curtos-circuitos, em especial nas linhas de distribuição, tem evidenciado a importância do desenvolvimento de metodologias de diagnóstico de faltas eficiente. Dentro desse escopo propôs-se nesta dissertação uma metodologia para localizar falta em redes de distribuição de grande extensão e demasiadamente dispersa baseada em técnicas de análise de sinais e inteligência artificial.

O processo de localização de faltas é realizado através da análise das formas de onda das tensões medidas apenas na saída da subestação. Assim o desencadeamento do algoritmo aplica as análises apenas nos períodos transitórios dos sinais adquiridos de simulações de faltas em um modelo do alimentador real do sistema de distribuição de Caruaru. Por conseguinte o vetor de características é composto mediante aplicação das ferramentas matemáticas previamente discutidas fomentando a criação de um extenso banco de dados o qual serviu como entrada para a técnica de reconhecimento de padrões. Assim, para o modelo de alimentador de distribuição utilizado, várias arquiteturas de sistemas de localização de faltas foram implementadas e testadas. Verificou-se que as diferentes combinações de parâmetros resultaram em sistemas com desempenhos satisfatórios. Todo processo de aferição do desempenho do algoritmo proposto foi verificado através de análises utilizando o banco de dados de validação, o qual não compôs a etapa de treinamento das redes neurais.

Vale ressaltar que devido à indisponibilidade de dados de faltas do sistema real em quantidade suficiente para treinamento das redes neurais, todo processo de treinamento das RNA's foram realizados mediante simulações computacionais no software ATP-EMTP. Contudo, verificou-se que devido à capacidade de generalização das redes, apenas uma pequena quantidade de faltas são realmente necessárias para assegurar o treinamento e

consequentemente desempenho satisfatório do classificador, onde no estudo de caso avaliado erros de aproximadamente 2% foram obtidos corroborando para o sucesso dos estudos aqui deflagrados. Portanto, pode-se supor que a utilização conjunta de dados simulados e dados obtidos por oscilografia digital constituiria um bom caminho para formação do banco de dados de treinamento das redes.

Em comparação com as metodologias encontradas na literatura, o algoritmo aplicado utiliza somente informações obtidas a partir dos sinais de tensão simulados na saída do alimentador para detectar corretamente a seção na qual a falta se localiza. Este fato representa uma vantagem em relação aos métodos convencionais propostos, que exigem informações sobre os vários parâmetros da rede.

A abordagem proposta combinando as técnicas de análise de sinais e inteligência artificial se mostrou uma alternativa promissora, principalmente dada a sua capacidade de identificação e aprendizado das características das faltas, com uma eficiência satisfatória quando aplicada a sistemas de distribuição de grande porte e altamente dispersos.

8.2 SUGESTÕES PARA TRABALHOS FUTUROS

No intuito de aperfeiçoar o trabalho desenvolvido algumas sugestões para trabalhos futuros são apresentadas abaixo:

- validação da metodologia proposta a partir de estudos de casos baseados em dados obtidos em redes de distribuição reais;
- estudo de outros modelos de redes neurais como também neuro-fuzzy e outros tipos de algoritmos de treinamento que possibilitem melhoria dos resultados obtidos;
- verificar a robustez do algoritmo proposto mediante presença de cargas dinâmicas no sistema de distribuição;
- busca de procedimentos padrões para localizar faltas em redes de distribuição dispersas.
- incorporar a técnica proposta para análise de outros tipos de faltas, tais como os curtos-circuitos bifásicos fase-fase, bifásicos fase-fase-terra e os trifásicos.

Referências Bibliográficas

- [1] Resolução Aneel nº 024, de 27 de janeiro de 2000. Disponível em: <http://www.aneel.gov.br/cedoc/res2000024.pdf>. Acesso em 25/05/2011.
- [2] KINDERMANN, G. *Curto-circuito*. Santa Catarina: Editora Afiliada. 1997.
- [3] BO, Z. Q.; JIANG, Z. C.; CHEN, Z. X. et al. Transients based protection for power transmission systems. *IEEE – Power Engineering Society Winter Meeting*, v. 3, p. 1832-1837, Jan. 2000.
- [4] BO, Z. Q.; JOHNS, A. T.; AGGARWAL, R. K. A novel fault locator based on the detection of fault generated high frequency transients. *IEE – Development in Power System Protection, Conference Publication*, n. 434, p. 197-200, Mar. 1997.
- [5] MAGNAGO, F. H.; ABUR, A. Fault location using Wavelets. *IEEE Transactions on Power Delivery*, v. 13, n. 4, p. 1475-1479, Out. 1998.
- [6] GALE, P. F.; TAYLOR, P. V.; NAIDOO, P. et al. Traveling wave fault locator experience on Eskom's transmission network. *IEE – Development in Power System Protection, Conference Publication*, n. 479, p. 327-330, 2001.
- [7] LU, C. N.; WU, H.T.; VERMURI, S. Neural Network Based Short Term Load Forecasting. *IEEE Transactions on Power Systems*, v.8, n. 1, p. 336- 342, Fev. 1993.
- [8] EL-SHARKAWI, M. A.; MARKS, R. J.; WEERASOORIYA, S. Neural Networks and Their Application to Power Engineering. *Control and Dynamics Systems*, v. 41, p.359-401, 1991.
- [9] JORGE, D. C.; COURRY, D. V. Artificial Neural Network Approach to Distance Protection of Transmission Lines. *IEEE Transactions on Power Delivery*, v. 13, n. 1, p.102-108, Jan. 1998.
- [10] KANO, H.; KANETA, M.; KANEMARU, K. Fault Location for Transmission Lines Using Inference Model Neural Network. *Electrical Engineering in Japan*, v. 111, n. 7, pp.84-92, 1991.
- [11] KHAPARDE, S. A.; KALE, P. B.; AGARWAL, S.H. Application of Artificial Neural Network in Protective Relaying of Transmission Lines. *First International Forum on Applications of Neural Networks to Power Systems*, Seattle, p. 139-143 Jul. 1991.

- [12] SIDHU, T.S.; SINGH, H.; SACHDEV, M.S. Design, Implementation and Testing of An Artificial Neural Network Based Fault Direction Discriminator for Protecting Transmission Lines. *IEEE Transactions on Power Delivery*, v.10, n. 2, pp. 647-706, Abr. 1995.
- [13] DALSTEIN, T.; KULICKE, B. Neural Network Approach to Fault Classification for High Speed Protective Relaying. *IEEE Trans. on Power Delivery*, v. 10, n. 2, p.1002-1011, Abr. 1995.
- [14] JORGE, D. C.; COURY, D. V.; CARVALHO, A. Localização de Faltas em Linhas de Transmissão de Energia Elétrica Utilizando Reconhecimento de Padrões. *Proceedings of the IV Brazilian Conference on Neural Networks*, São José dos Campos, SP, Brazil. p. 61-66, Jul. 1999.
- [15] SILVA, M. *Localização de faltas em linhas de transmissão utilizando a teoria de ondas viajantes e transformada wavelet*. São Carlos, 2003. Dissertação (mestrado) – Escola de Engenharia de São Carlos.
- [16] ZIOLKOWSKI, V.; SILVA, I.N.; FLAUZIN, R.A. Automatic Identification of Faults in Power Systems Using Neural Network Technique. *16th IEEE International Conference on Control Applications : Part of IEEE Multi-conference on Systems and Control*, Singapore, 2007.
- [17] MENEZES, M. P. *Classificação e localização de faltas em linhas de transmissão usando diferentes arquiteturas de redes neurais artificiais*. São Paulo, 2008. Dissertação (mestrado). Universidade de São Paulo. Escola Politécnica.
- [18] JUNIOR, M. G. *Sistema para localização de faltas em linhas de transmissão com subestações conectadas em derivação*. São Paulo, 2006. Dissertação (mestrado). Universidade de São Paulo. Escola Politécnica.
- [19] ZHU, J.; LUBKERMANN, D.L.; GIRGIS, A.A. Automated Fault Location and Diagnosis On Electric Power Distribution Feeders. *IEEE Trans on Power Delivery*, pp. 801-809, 1997.
- [20] SENGER, E.C.; MANASSERO, G.; GOLDEMBERG, C.; PELLINI, E.L. Automated fault location system for primary distribution networks. *IEEE Transactions on Power Delivery*, v..20, n.2, p. 1332- 1340, Abr. 2005.
- [21] AIEE COMMITTEE REPORT. Bibliography and Summary of Fault Location Methods. *Transactions of the American Institute of Electrical Engineers Part III, Power Apparatus and Systems*, New York, NY, v.74, n.3, p.1423-1428, Fev. 1955.

- [22] STRINGFIELD, T. W.; MARIHART, D. J.; STEVENS, R. F. Fault Location Methods for Overhead Lines. *Transactions of the American Institute of Electrical Engineers Part III, Power Apparatus and Systems*, New York, NY, v.76, n.3, p.518-529, Abr. 1957.
- [23] CASTRO, C.; BUNCH, J.; TOPKA, T. Generalized Algorithms for Distribution Feeder Deployment and Sectionalizing. *IEEE Transaction on Power Apparatus and Systems*, Piscataway, NJ, v.PAS-99, n.2, p.549-557, 1980.
- [24] ROYTMAN, L.; THOMAS, B.; TRUTT, F.; SWAMY, M. Direct Fault Location in Electrical Power Systems. *IEEE Transaction on Power Apparatus and Systems*, Piscataway, NJ, v.PASS-101, n.10, p.4049-4054, 1982.
- [25] S, R. H. *Novos Desenvolvimentos na Localização de Falhas em Sistemas de Distribuição de Energia Elétrica Fundamentada na Impedância*. Rio Grande do Sul, 2008. Dissertação (mestrado) - Universidade Federal do Rio Grande do Sul. Escola de Engenharia.
- [26] GIRGIS, A.A.; FALLON, C.M.; LUBKEMAN, D.L. A fault location technique for rural distribution feeders. *IEEE Transactions on Industry Applications*, v. 29, n.6, p.1170-1175, Nov/Dez 1993.
- [27] SAHA, M.M.; PROVOOST, F.; ROSOLOWSKI, E. Fault location method for MV cable network. *Developments in Power System Protection, Seventh International Conference on (IEE)*, p.323-326, 2001.
- [28] SANTOSO, S.; DUGAN, R.C.; LAMOREE, J. et al. Distance estimation technique for single line-to-ground faults in a radial distribution system. *Power Engineering Society Winter Meeting, IEEE*, v.4, p.2551-2555, 2000.
- [29] DAS, R.; SACHDEV, M.S.; SIDHU, T.S. A fault locator for radial subtransmission and distribution lines. *Power Engineering Society Summer Meeting, IEEE*, v.1, p.443-448, 2000.
- [30] CHOI, M. S.; LEE, S. J.; LEE, D. S. et al. A new fault location algorithm using direct circuit analysis for distribution systems. *IEEE Transactions on Power Delivery*, v.19, n.1, p. 35- 41, Jan. 2004.
- [31] CHOI, M. S.; LEE, S. J.; LIM, S. I.; et al. A Direct Three-Phase Circuit Analysis-Based Fault Location for Line-to-Line Fault. *IEEE Transactions on Power Delivery*, v.22, ed.4, p. 2541, 2007.

- [32] LIAO Y. Algorithms for Power System Fault Location and Line Parameter Estimation. *SSST '07. Thirty-Ninth Southeastern Symposium on System Theory*, p.189-193, Mar. 2007.
- [33] PEREIRA, R. A. F.; SILVA, L. G. W. ; MANTOVANI, J. R. S. Algoritmo baseado em fundamentos de tensão para localização de faltas em alimentadores de distribuição de energia elétrica. *Sba Controle & Automação*. v. 19, n.3, p. 337-349, 2008, ISSN 0103-1759.
- [34] SALIM, R.H.; RESENER, M.; FILOMENA, A.D.; et al. Extended Fault-Location Formulation for Power Distribution Systems. *IEEE Transactions on Power Delivery*, v. 24, n.2, p. 508-516, Abr. 2009.
- [35] FILOMENA, A. D.; RESENER M.; SALIM , R. H.; et al. Fault location for underground distribution feeders: An extended impedance-based formulation with capacitive current compensation. *International Journal of Electrical Power & Energy Systems*, v. 31, ed. 9, p. 489-496, Out. 2009.
- [36] PAZ, M. C. R.; FERRAZ, R. G.; BRETAS, A. S.; LEBORGNE, R. C. System Unbalance and Fault Impedance Effect on Faulted Distribution Networks. *Computer & Mathematics with Applications*, v. 60, ed. 4, p. 1105-1114, Ago. 2010.
- [37] THOMAS, D.W.P.; CARVALHO, R.J.O.; PEREIRA, E.T. Fault location in distribution systems based on traveling waves. *Power Tech Conference Proceedings*, IEEE, Bologna, v.2, p. 23-26, Jun. 2003.
- [38] BO, Z.Q.; WELLER, G.; REDFERN, M.A. Accurate fault location technique for distribution system using fault-generated high-frequency transient voltage signals. *Generation, Transmission and Distribution, IEE Proceedings*, v.146, no.1, p.73-79, Jan. 1999.
- [39] MAGNAGO, F.H.; ABUR, A. A new fault location technique for radial distribution systems based on high frequency signals. *Power Engineering Society Summer Meeting*, IEEE, vol.1, pp.426-431, Jul. 1999.
- [40] CHEN, Z.; BO, Z.Q.; JIANG, F.; et al. Wavelet transform based accurate fault location and protection technique for cable circuits. *Advances in Power System Control, Operation and Management*, 2000.
- [41] NOURI, H.; Chun WANG; DAVIES, T. An accurate fault location technique for distribution lines with tapped loads using wavelet transform. *Power Tech Proceedings*, IEEE, Porto , v.3, p.4, 2001.

- [42] DAVOOD, J.; NIKI, M. Fault location for radial distribution systems using fault generated high-frequency transients and wavelet analysis. *18th International Conference and Exhibition on Electricity Distribution, CIRED*, pp.1-4, Jun. 2005.
- [43] BORGHETTI, A.; CORSI, S.; NUCCI, C.A. et al. On the use of continuous-wavelet transform for fault location in distribution power systems. *International Journal of Electrical Power & Energy Systems, Selection of Papers from 15th Power Systems Computation Conference*, v. 28, ed 9, p. 608-617, Nov. 2006.
- [44] BORGHETTI, A.; BOSETTI, M.; Di SILVESTRO, M.; et al. Continuous-Wavelet Transform for Fault Location in Distribution Power Networks: Definition of Mother Wavelets Inferred From Fault Originated Transients. *IEEE Transactions on Power Systems*, v.23, n.2, p.380-388, Mai. 2008.
- [45] FU, L.; HE, Z.Y.; MAI, R.K. et al. Approximate entropy and its application to fault detection and identification in power swing. *Power & Energy Society General Meeting*, IEEE , p.1-8, Jul. 2009.
- [46] HE, Z.; FU, L. ; LIN, S.; BO, Z. Fault Detection and Classification in EHV Transmission Line Based on Wavelet Singular Entropy. *IEEE Transactions on Power Delivery*, v. 25, n.4, p. 2156-2163, Out. 2010.
- [47] BORGHETTI, A.; BOSETTI, M.; NUCCI, C.A.; et al. Integrated Use of Time-Frequency Wavelet Decompositions for Fault Location in Distribution Networks: Theory and Experimental Validation. *IEEE Transactions on Power Delivery*, v. 25, n. 4, p. 3139-3146, Out. 2010.
- [48] ZHONG, W.; LIU, W. Application of a fuzzy set method in distribution system fault location. *IEEE International Symposium on Circuits and Systems, Connecting the World*, v.1, p.617-620, Mai. 1996.
- [49] WEN, F.S.; CHANG, C.S. Probabilistic approach for fault-section estimation in power systems based on a refined genetic algorithm. *IEE Proceedings Generation, Transmission and Distribution*, v.144, n.2, p. 160-168, Mar 1997.
- [50] CHEN, W. H.; LIU, C. W.; TSAI, M. S. On-line fault diagnosis of distribution substations using hybrid cause-effect network and fuzzy rule-based method. *IEEE Transactions on Power Delivery*, v.15, n.2, p.710-717, Abr 2000.
- [51] BI, T.; NI, Y.; SHEN, C.M.; WU, F.F. Efficient multiway graph partitioning method for fault section estimation in large-scale power networks. *IEE Proceedings Generation, Transmission and Distribution*, v.149, n.3, p.289-294, Mai. 2002.

- [52] SHAHER, M. A. A., SABRY, M. M.; SALEH, A. S. Fault location in multi-ring distribution network using artificial neural network. *Electric Power Systems Research*, v. 64, ed. 2, p. 87-92, Fev. 2003.
- [53] MARTINS, L.S.; MARTINS, J.F.; ALEGRIA, C.M. A network distribution power system fault location based on neural eigenvalue algorithm. *Power Tech Conference Proceedings*, IEEE, Bologna, v. 2, p. 6, Jun. 2003.
- [54] LEE, S. J.; CHOI, M. S.; KANG, S. H.; et al. An intelligent and efficient fault location and diagnosis scheme for radial distribution systems. *IEEE Transactions on Power Delivery*. v.19, n.2, p. 524- 532, Abr. 2004.
- [55] MORA, J.J.; CARRILLO, G.; PEREZ, L. Fault Location in Power Distribution Systems using ANFIS Nets and Current Patterns. *Transmission & Distribution Conference and Exposition: Latin America*, IEEE, pp.1-6, Aug. 2006.
- [56] THUKARAM, D.; SHENOY, U.J.; ASHAGEETHA, H. Neural network approach for fault location in unbalanced distribution networks with limited measurements. *Power India Conference*, IEEE, pp.8, 2006.
- [57] SHAKYA, D.; SINGH, S.N. SVM based fault location and classification using fuzzy classifier for PQ monitoring. *Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century*, IEEE, p.1-8, July 2008.
- [58] FLÓREZ, J. M.; ANGARITA, J. C.; PLATA, G. O. k-means algorithm and mixture distributions for locating faults in power systems. *Electric Power Systems Research*, v. 79, ed. 5, , p 714-721, Mai. 2009.
- [59] TAPASCO, E. C.; LONDONO, S. P.; FLOREZ, J.M. Setting strategy of a SVM regressor for locating single phase faults in power distribution systems. *Transmission and Distribution Conference and Exposition: Latin America (T&D-LA)*, IEEE/PES, p.798-802, Nov. 2010.
- [60] GALLEGO, J. G.; LONDOÑO, S. P.; FLOREZ, J. M. Efficient adjust of a learning based fault locator for power distribution systems. *Transmission and Distribution Conference and Exposition: Latin America (T&D-LA)*, IEEE/PES , p.774-779, Nov. 2010.
- [61] NAKHLI, M. P.; SAFAVI, A.A. Path Characteristic Frequency-Based Fault Locating in Radial Distribution Systems Using Wavelets and Neural Networks. *IEEE Transactions on Power Delivery*, v.26, n.2, p.772-781, Abr. 2011.

- [62] GREENWOOD, A. *Electrical Transients in Power Systems*. New York: Wiley-Interscience. 1971.
- [63] FUCHS, R. D. *Transmissão de energia elétrica linhas aéreas, teoria das linhas em regime permanente*. 2.ed. Rio de Janeiro: LTC. 1979.
- [64] HEDMAN, D. E. *Teoria das Linhas de Transmissão II*. Santa Maria: UFMS. 1978.
- [65] SLUIS, L. V. D. *Transients in Power Systems*. New York: John Wiley & Sons.
- [66] BEWLEY, L. V. *Traveling waves on electric power systems*. New York :John Wiley & Sons.
- [67] IEEE Guide for Determining Fault Location on AC Transmission and Distribution Lines, *IEEE Std C37.114-2004*. p. 1-36. 2005.
- [68] SOARES, L. R. *Projeto de novos sistemas-wavelet com aplicações na análise de sinais do sistema elétrico*. Recife, 2006. 223 folhas Tese (doutorado) - Universidade Federal de Pernambuco. CTG. Engenharia Elétrica.
- [69] OLIVEIRA, H. M. *Análise de sinais para engenheiros: uma abordagem via Wavelets*. Rio de Janeiro: Brasport,. Sociedade Brasileira de Telecomunicações SBrT-Brasport, 2007. ISBN 9788574522835 (broch.).
- [70] KIM, C. H.; AGGARWAL, R. Wavelet transforms in power systems. I. General introduction to the wavelet transforms. *Power Engineering Journal*, v. 14, n. 2, p.81-87, Abr 2000.
- [71] SOARES, L. R.; CARVALHO JÚNIOR, M. A. *Wavelets na identificação e localização de faltas em linhas de transmissão*. Recife, 2001. Dissertação (Mestrado). Universidade Federal de Pernambuco. Centro de Tecnologia e Geociências. Departamento de Engenharia Elétrica.
- [72] BRITO, N. S. D. *Teoria Wavelet e sua Aplicação em Sistemas de Energia Elétrica*. Campinas, SP. Novembro 1996. 130p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de Campinas.
- [73] POULARIKAS, A. D. *The transforms and Applications Handbook. The Electrical Engineering Handbook Series. IEEE Press. Chapter 10: Wavelet Transform by Yunlong Sheng*. Boca Raton, FLA: CRC Press, Inc pp. 747-827. 1996
- [74] LIRA, M. M. S. *Wavelets na compactação e processamento de sinais de distúrbios em sistemas de potência para classificação via redes neurais artificiais*. Recife, 2004. Tese (doutorado) - Universidade Federal de Pernambuco. CTG. Engenharia Elétrica.

- [75] SANTOSO, S.; POWERS, E.J.; GRADY, W.M.; et al. Power quality assessment via wavelet transform analysis. *IEEE Transactions on Power Delivery*, v.11, n.2, p.924-930, Abr. 1996.
- [76] SWELDENS, W. Wavelets: What next? *Proceedings of the IEEE* , v.84, n.4, p. 680-685, Abr 1996.
- [77] RADUNOVIC, D. P. *Wavelets from Math to Practice*. Springer, Inc., 2009.
- [78] DAUBECHIES, I. *Ten Lectures on Wavelets*. Philadelphia, PA, SIAM: Society for Industrial and Applied Mathematics, Inc., 1992
- [79] DAUBECHIES, I. The wavelet transform, time-frequency localization and signal analysis. *IEEE Transactions on Information Theory*, v.36, n.5, p.961-1005, Set 1990.
- [80] RIOUL, O.; VETTERLI, M. Wavelet and Signal Processing. *IEEE Transaction on Signal Processing Magazine*.
- [81] BURRUS, C. S.; GOPINATH, R. A.; GUO, H. *Introduction to wavelets and wavelet transforms: a primer*. Upper Saddle River, N. Jersey: Prentice-Hall, c1998.
- [82] GOMES, J.; VELHO, L. *From Fourier Analysis to Wavelets*. Instituto de Matemática Pura e Aplicada, IMPA. Rio de Janeiro, Brasil. SIGGRAPH 99.
- [83] MALLAT, S.G. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v.11, n.7, p.674-693, Jul 1989.
- [84] LOUREIRO, F. P. *Modelagem Acústica no Domínio da Transformada Wavelet*. Rio de Janeiro, 2004. Dissertação (mestrado) – Pontifícia Universidade Católica do Rio de Janeiro. Engenharia Elétrica, 2004.
- [85] SLANSKY, J.; WASSEL, G. N. *Pattern Classifier and Trainable Machines*. New York: Spring. 1981.
- [86] MORETO, M. *Localização de Faltas de Alta Impedância em Sistemas de Distribuição de Energia: Uma metodologia Baseada em Redes Neurais Artificiais*. Rio Grande do Sul, 2005. Dissertação (mestrado) – Universidade Federal do Rio Grande do Sul.
- [87] HAYKIN, S.S.; *Redes Neurais - Princípios E Prática*. Bookman Companhia. 2001.
- [88] BRAGA, A. P. ; CARVALHO, A. C. P. L. ; LUDERMIR, T. B. . *Redes Neurais Artificiais: teoria e aplicações*. 2a. ed. Rio de Janeiro: LTC - Livros Técnicos e Científicos, 2007.

- [89] SANTOS, G. S. M. *Aplicação de redes neurais para diagnósticos de poluição em isoladores de alta tensão*. Recife, 2008. Dissertação (mestrado) - Universidade Federal de Pernambuco. CTG. Engenharia Elétrica, 2008.
- [90] MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, p.115-133. 1943.
- [91] OLIVEIRA, A. R. *Redes Neurais Artificiais Aplicadas na Detecção, Classificação e Localização de Defeitos em Linhas de Transmissão*. Juiz de Fora, Minas Gerais,. Dissertação (mestrado) – Universidade Federal de Juiz de Fora. Engenharia Elétrica. 2005.
- [92] WIDROW, B.; RUMELHART, D.E.; LEHR, M.A. Neural Networks: Applications in Industry, Business and Science. *Communications of ACM*, v.37, n.3, Mar. 1994.
- [93] SANTOS, A. F. *Aplicação de redes neurais artificiais no controle eficiente do motor de indução trifásico*. Recife, 2008. Dissertação (mestrado) - Universidade Federal de Pernambuco. CTG. Engenharia Elétrica, 2008.
- [94] RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by backpropagating erros. *Nature*, v. 323, p. 533–536, 1986.
- [95] RIEDMILLER, M. *Rprop - description and implementation details*. University of Karlsruhe, Tech. Rep., 1994.
- [96] LEVENBERG, K. *A method for the solution of certain problems in least squares*. *Quart. Appl. Math.*, v. 2, p. 164–168, 1944.
- [97] MARQUARDT, D. *An algorithm for least-squares estimation of nonlinear parameters*. *J. Appl. Math. SIAM*, v. 11, p. 431–441, 1963.
- [98] FAIRHURST, M. *Fundamentals of neural networks. architectures, algorithms and applications*. Prentice/Hall International, Tech. Rep., 1988.
- [99] PARMA, G. G. *Treinamento de redes neurais artificiais baseado em sistemas de estrutura variável com aplicações em acionamentos elétricos*. Ph.D. dissertation, Universidade Federal de Minas Gerais, junho 2000.
- [100] RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: the RPROP algorithm. *International Conference on Neural Networks*, IEEE, p.586-591, v.1, 1993.
- [101] CORDEIRO, L. F. A. *Eficiência energética no controle inteligente de sistemas de bombeamento*. Recife, 2008. Dissertação (mestrado) - Universidade Federal de Pernambuco. CTG. Engenharia Elétrica, 2008.

- [102] HAGAN, M.T.; MENHAJ, M.B. Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, v.5, n.6, p.989-993, Nov 1994.
- [103] Processamento de Sinal. Disponível em : http://pt.wikipedia.org/wiki/Processamento_de_sinal. Acesso em:07 Dez. 2011.
- [104] WEDEPOHL, L.M. Application of matrix methods to the solution of travelling-wave phenomena in polyphase systems. *Proceedings of the Institution of Electrical Engineers*, v.110, n.12, p. 2200-2212, Dez. 1963.
- [105] CLARKE, E. *Circuit Analysis of AC Power Systems*. New York: Wiley, vol. 1. 1943
- [106] HEDMAN, D. E. Propagation on Overhead Transmission Lines I-Theory of Modal Analysis. *IEEE Transactions on Power Apparatus and Systems*, v.84, n.3, p.200-205, Mar. 1965.
- [107] MENEZES. M. P. *Classificação e localização de faltas em linhas de transmissão usando diferentes arquiteturas de redes neurais artificiais*. São Paulo, 2008. Dissertação (mestrado) – Escola Politécnica da Universidade de São Paulo, Engenharia Elétrica, 2008.
- [108] XIAOLI, Z.; XIANGJUN, Z.; LI, L. et al. Fault location using wavelet energy spectrum analysis of traveling waves. *International Power Engineering Conference, IPEC*, p.1126-1130, Dez. 2007.
- [109] HE, Z.; WU, X.; QIAN, Q. Automatic fault detection for power system using wavelet singular entropy. *International Conference on Intelligent Mechatronics and Automation*, pp. 433- 437, Ago, 2004.
- [110] YANG, M. Y.; YANG, Y. K. A study of transient-based protection using wavelet energy entropy for power system EHV transmission line. *International Conference on Wavelet Analysis and Pattern Recognition, ICWAPR*, p.283-288, Jul. 2010.
- [111] YOU H. Z.; XIAOQING, C.; BIN, Z. Wavelet Entropy Measure Definition and Its Application for Transmission Line Fault Detection and Identification;(Part III: Transmission line faults transients identification). *International Conference on Power System Technology, PowerCon*, p.1-5, Out. 2006.
- [112] QING, L. ; ZENGZING, W. Study on non-unit transient protection principle for EHV transmission lines based on wavelet singular entropy. *Power & Energy Society General Meeting, IEEE*, pp.1-6, Jul. 2009.

- [113] ZHU, Z.; SUN, Y. Transmission line fault classification based on wavelet singular entropy and artificial immune recognition system algorithm. *2nd International Conference on Power Electronics and Intelligent Transportation System*, PEITS, v.1, p.154-157, Dez. 2009.
- [114] PINCUS, S. *Approximate entropy as a measure of system complexity*. Proc. Nat. Acad. Sci. USA, v. 88, p. 2297–2301, 1991.
- [115] HORNERO, R.; ABOY, M.; ABASOLO, D.; MCNAMES, J.; GOLDSTEIN, B. Interpretation of approximate entropy: analysis of intracranial pressure approximate entropy during acute intracranial hypertension, *IEEE Transactions on Biomedical Engineering*, v.52, n.10, p.1671-1680, Out. 2005.
- [116] PINCUS, S. *Assessing serial irregularity and its implications for health*. Ann. New York: Acad. Sci., vol. 954, pp. 245–267, 2001.
- [117] Caruaru. Disponível: <http://pt.wikipedia.org/wiki/Caruaru>. Acesso em: 12 Dez. 2011.
- [118] SILVA, A. A. P. *Modelagem para repotencialização de linhas de transmissão através da aplicação de condutores especiais*. Recife, 2009. Dissertação (mestrado) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências. Programa de Pós-graduação em Engenharia Elétrica.
- [119] LIMA, A. C. S.; PEREIRA, M. P.; HEVIA, O. *Cálculo de Parâmetros de Linha de Transmissão*. Brasil: Departamento de Planejamento da Transmissão, Furnas Centrais Elétricas. 2001.
- [120] LUSTOSA, L. S. *Cálculo dos parâmetros de linhas de transmissão trifásicas através das tensões e correntes em seus terminais*. Campinas, 2009. Dissertação (mestrado) – Faculdade de Engenharia Elétrica e de Computação da UNICAMP. Programa de Pós-graduação em Engenharia Elétrica.
- [121] COSTA, E. C. M. ; KUROKAWA, S. ; PISSOLATO FILHO, J. et al. Parâmetros Discretos e Distribuídos para o Estudo de Transitórios Eletromagnéticos. *Congresso Brasileiro de Automática*, CBA, Bonito – MS, 2010. v. único, ed. 18, p. 3911-3916. 2010
- [122] HESSE, M. H. Electromagnetic and electrostatic transmission-line parameters by digital computer. *IEEE Trans. on PAS*, v. 82, p. 282–290, Jan. 1963.