

UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE CIÊNCIAS E TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

## Dissertação de Mestrado

# Diagnóstico de Falhas em Linhas de Transmissão Baseado em Redes Neurais Artificiais e Transformada Wavelet

Kleber Melo e Silva

Campina Grande - Paraíba - Brasil

© Kleber Melo e Silva, Março de 2005

---

Kleber Melo e Silva

**Diagnóstico de Falhas em Linhas de Transmissão Baseado  
em Redes Neurais Artificiais e Transformada Wavelet**

*Dissertação de mestrado apresentada à Coordenação do  
Programa de Pós-Graduação em Engenharia Elétrica da  
Universidade Federal de Campina Grande, em cumprimento  
às exigências para obtenção do Grau de Mestre em Ciências  
no Domínio da Engenharia Elétrica.*

---

Área de Concentração: Processamento da Energia

Benemar Alencar de Souza, D.Sc.

Orientador

Campina Grande - Paraíba - Brasil

Março de 2005



FICHA CATALOGRÁFICA PREPARADA PELA BIBLIOTECA CENTRAL DA UFCC.

Silva, Kleber Melo e  
S586d Diagnóstico de faltas em linhas de transmissão baseado em redes neurais artificiais e transformada wavelet / Kleber Melo e Silva - Campina Grande: UFCC, 2005.  
58f. : il.

Inclui Bibliografia.  
Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Campina Grande. Centro de Ciências e Tecnologia.  
Orientador: Benemar Alencar de Souza.

1 - Detecção e classificação de faltas 2 - Linhas de transmissão  
3 - Redes neurais artificiais 4 - Transformada wavelet 5 - Título


CDU 631.317.35


**DIAGNÓSTICO DE FALTAS EM LINHAS DE TRANSMISSÃO BASEADO EM REDES  
NEURAS ARTIFICIAIS E TRANSFORMADA WAVELET**

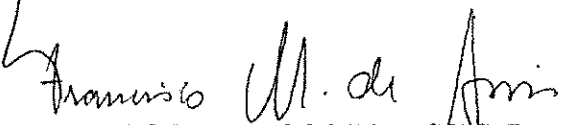
**KLEBER MELO E SILVA**

Dissertação Aprovada em 18.03.2005

  
**BENEMAR ALENCAR DE SOUZA, D.Sc., UFCG**  
Orientador

  
**JORGE DANTAS DE MELO, Dr., UFRN**  
Componente da Banca

  
**JOSÉ JÚLIO DE ALMEIDA LINS LEITÃO, Dr., CHESF**  
Componente da Banca

  
**FRANCISCO MARCOS DE ASSIS, Dr., UFCG**  
Componente da Banca

  
**WELLINGTON SANTOS MOTA, Ph.D., UFCG**  
Componente da Banca

CAMPINA GRANDE - PB  
Março - 2005

*À minha mãe Marlene e a meus irmãos Cristiano e  
Christianne pelo apoio, compreensão e incentivo em  
todos os momentos.*

## AGRADECIMENTOS

Alguns erros foram cometidos no decorrer desse trabalho, muitos dos quais corrigidos. No entanto, talvez cometa mais um não expressando meus agradecimentos a todos àqueles que realmente merecem, a quem peço antecipadamente minhas desculpas. Dessa forma, gostaria de agradecer:

À minha família, mãe e irmãos, pela paciência e pelos ensinamentos de grande valia passados a minha pessoa, que contribuíram na formação de meu caráter e no despertar para busca incansável pelo conhecimento científico e pessoal.

Aos professores Benemar Alencar e Washington Neves pela contribuição no desenvolvimento desse trabalho e pela participação valiosa em minha formação acadêmica e profissional.

A José Júlio Leitão e aos professores Jorge Dantas, Francisco Marcos e Wellington Mota pela participação na banca e pelas contribuições ao trabalho.

À minha namorada Djane pelo grande incentivo e compreensão nos momentos de ausência, se mostrando uma grande companheira.

Aos meus companheiros de trabalho Flávio, Alessandro, Karcius, Antônio Carlos e Ricardo, pela participação brilhante, essencial e incansável no desenvolvimento dessa pesquisa.

Aos amigos de todas as horas Jaidilson, Eisenhower, Max, José Antônio, Vagner, Nilo, Ademar, Tomás, Carlos Alberto, Luciano, Ronimack, Helon, George, Fábio Robério, Júlio, Thiago e Alex pelo grande incentivo passado a minha pessoa e pela amizade incondicional cultivada entre nós.

Aos engenheiros da Chesf Sergio Caupone, José Horácio e Milde Lira, pela grande contribuição na realização desse trabalho.

Em especial, à engenheira Sandra Sayonara e à professora Núbia Brito pela contribuição e os incansáveis esforços no desenvolvimento do projeto de P&D que originou essa dissertação.

*Kleber Melo e Silva*

## RESUMO

Um método baseado em redes neurais artificiais e transformadas wavelet para a detecção e classificação de faltas em linhas de transmissão é proposto. A análise é feita sobre os sinais de tensão e corrente capturados pelos registradores digitais de perturbação. A detecção da falta e a determinação de sua duração são realizadas por um conjunto de regras construídas a partir da análise dos sinais de corrente nos domínios do tempo e wavelet. Nessa fase, uma falta é diferenciada de distúrbios associados à qualidade da energia elétrica, tais como afundamentos de tensão e transitórios de chaveamento. No caso de falta, sua classificação é realizada por meio de uma rede neural, a partir do reconhecimento dos padrões das tensões e correntes no domínio do tempo. O método foi avaliado para situações de faltas simuladas e reais em linhas do sistema de transmissão da CHESF, apresentando bons resultados em ambos os casos.

Palavras-chave: Detecção e classificação de faltas; linhas de transmissão; transformadas wavelet; redes neurais artificiais.

## ABSTRACT

A method based on artificial neural networks and wavelet transforms for fault detection and classification in transmission lines is proposed. The analysis is accomplished in current and voltage waveforms obtained from digital fault recorders. The detection step and the fault interval are achieved by means of a set of rules obtained from the current waveform analysis in the time and wavelet domains. In this step, a fault is distinguished from power quality disturbances such as voltage sags and switching transients. In the case of fault, its classification is accomplished by a neural network, responsible for voltage and current waveforms pattern recognition in time domain. The method has been evaluated for real and simulated faults in transmission lines of CHESF's transmission system, good results were obtained in both cases.

**Keywords:** Fault detection and classification; transmission lines; wavelet transforms; artificial neural networks.



## SUMÁRIO

<b>Lista de Figuras</b>	xi
<b>Lista de Tabelas</b>	xiii
<b>Lista de Símbolos</b>	xiv
<b>Glossário</b>	xvi
<b>Capítulo 1– Introdução</b>	1
1.1 Motivação . . . . .	2
1.2 Revisão Bibliográfica . . . . .	3
1.3 Objetivos . . . . .	7
1.4 Estrutura da Dissertação . . . . .	7
<b>Capítulo 2– Fundamentação Teórica</b>	8
2.1 Falhas em Sistemas Elétricos de Potência . . . . .	8
2.2 Redes Neurais Artificiais . . . . .	11
2.2.1 Modelo do Neurônio . . . . .	11
2.2.2 Redes <i>Perceptron</i> de Múltiplas Camadas . . . . .	13
2.2.2.1 Algoritmo de Treinamento <i>Resilient Propagation</i> . . . . .	16
2.3 Transformada Wavelet . . . . .	20

<i>SUMÁRIO</i>	x
<b>Capítulo 3– Método Proposto</b>	<b>26</b>
3.1 Módulo de Detecção . . . . .	27
3.1.1 Regras para a Detecção da Falta . . . . .	27
3.1.2 Determinação do Intervalo de Falta . . . . .	30
3.2 Módulo de Classificação . . . . .	33
3.2.1 Normalização das Tensões e Correntes . . . . .	33
3.2.2 Reamostragem do Intervalo de Falta . . . . .	34
3.2.3 Janelamento das Tensões e Correntes . . . . .	35
3.2.4 Classificação da Falta . . . . .	36
<b>Capítulo 4– Concepção e Avaliação do Método Proposto</b>	<b>38</b>
4.1 Concepção do Método . . . . .	38
4.1.1 Regras de Detecção . . . . .	38
4.1.2 Aprendizado da RNA . . . . .	39
4.2 Avaliação do Método . . . . .	42
4.2.1 Registros Simulados no ATP . . . . .	42
4.2.2 Registros Simulados por um Sistema de Teste de Relés de Proteção . . . . .	42
4.2.3 Registros Reais do Sistema de Transmissão da CHESF . . . . .	46
<b>Capítulo 5– Conclusões</b>	<b>49</b>
<b>Referências Bibliográficas</b>	<b>50</b>
<b>Apêndice A– Padrão COMTRADE</b>	<b>55</b>
<b>Apêndice B– Publicações em Eventos</b>	<b>59</b>

## LISTA DE FIGURAS

1.1	Representação do processo de coleta automática de registros capturados pelos RDPs. . . . .	2
2.1	Influência da localização: (a) 10 km; (b) 100 km. . . . .	10
2.2	Influência do ângulo de incidência: (a) 10°; (b) 90°. . . . .	10
2.3	Influência de resistência de falta: (a) 0,1 $\Omega$ ; (b) 200 $\Omega$ . . . . .	10
2.4	Modelo de um neurônio artificial. . . . .	12
2.5	Tipos de função de ativação: (a) sigmóide; (b) tangente hiperbólica. . . . .	13
2.6	Arquitetura de uma rede MLP. . . . .	14
2.7	TWD direta: (a) bloco da TWD direta; (b) três estágios da TWD direta. . . . .	24
2.8	TWD inversa: (a) bloco da TWD inversa; (b) três estágios da TWD inversa. . . . .	24
2.9	Exemplo de aplicação da TWD direta. . . . .	25
2.10	Exemplo de aplicação da TWD inversa. . . . .	25
3.1	Diagrama de blocos do método proposto. . . . .	27
3.2	Falta monofásica na fase C: (a) correntes no domínio do tempo; (b) coeficientes wavelet. . . . .	28
3.3	Afundamento de tensão: (a) correntes no domínio do tempo; (b) coeficientes wavelet. . . . .	28
3.4	Transitório de chaveamento: (a) correntes no domínio do tempo; (b) coeficientes wavelet. . . . .	29

3.5	Energização de uma LT: (a) correntes no domínio do tempo; (b) coeficientes wavelet. . . . .	29
3.6	Desligamento de uma LT: (a) correntes no domínio do tempo; (b) coeficientes wavelet. . . . .	29
3.7	Registro real com a indicação das etapas de pré-falta, falta e pós-falta. . . . .	31
3.8	Sinal de corrente em uma falta e os respectivos coeficientes wavelet de detalhe da primeira escala de resolução, antes e depois da filtragem. . . . .	32
3.9	Coefficientes wavelet das correntes após a filtragem. . . . .	33
3.10	Exemplo de um sinal na frequência original do RDP (15360 Hz) e reamostrado (1200 Hz), utilizando-se um passo de reamostragem constante $\Delta_{Reamostragem} = 12,8 \approx 13$ . . . . .	35
3.11	Processo de janelamento dos sinais de tensão e corrente. . . . .	35
4.1	Diagrama unifilar simplificado do trecho do subsistema Leste de transmissão da CHESF, ao qual pertence a LT 04V4. . . . .	39
4.2	Erro médio quadrático para os conjuntos de treinamento e validação. . . . .	41
4.3	Representação da montagem do experimento. . . . .	43
4.4	Fotografia da montagem do experimento. . . . .	43
4.5	Janela do software de programação do equipamento. . . . .	44
4.6	Registro que apresenta anormalidade na componente de seqüência zero das correntes. . . . .	45

## LISTA DE TABELAS

1.1	Resumo da revisão bibliográfica . . . . .	6
2.1	Faltas ocorridas no sistema de transmissão da CHESF no período de 2003 a 2004. . . . .	9
3.1	Esquema de codificação das respostas desejadas da RNA. . . . .	37
4.1	Conjunto de variáveis utilizadas na simulação da LT 04V4. . . . .	40
4.2	Distribuição dos padrões nos conjuntos de treinamento, validação e teste. . . . .	40
4.3	Conjunto de variáveis utilizadas na simulação da LT 04V4. . . . .	42
4.4	Resultados para os registros simulados pelo sistema de teste de relés de proteção. . . . .	44
4.5	Resultados para faltas com vários valores de resistência. . . . .	46
4.6	Resultados para os registros reais na LT 04V4. . . . .	46
4.7	Resultados para outras LTs de 230 kV. . . . .	47
4.8	Resultados para outras LTs de 500 kV. . . . .	47
A.1	Tipos de arquivos do padrão COMTRADE. . . . .	55
A.2	Registros e campos dos arquivos de configuração. . . . .	57

## LISTA DE SÍMBOLOS

- $b_j^k$  - Polarização do neurônio  $j$  da camada  $k$ .
- $B$  - Número de neurônios da camada de saída.
- $c_k$  - Coeficiente wavelet.
- $C_{max}$  - Maior coeficiente wavelet em valor absoluto.
- $\Gamma$  - Condição de admissibilidade para funções wavelet mãe.
- $D^{k+1}$  - Conjunto de todos os neurônios da camada  $k + 1$ , imediatamente posterior a a camada  $k$ .
- $d_j$  - Sinal de saída desejado para o neurônio  $j$  da camada de saída.
- $\mathcal{E}(n)$  - Função energia de erro para as saídas da rede neural, referente ao  $n$ -ésimo padrão de entrada.
- $\mathcal{E}_{med}(m)$  - Função energia de erro média para as saídas da rede neural, referente à  $m$ -ésima época de treinamento.
- $I^k$  - Número total de entradas da camada  $k$ .
- $N$  - Número total de padrões do conjunto de treinamento.
- $o_j$  - Sinal de saída do neurônio  $j$  da camada de saída.
- $\Re$  - Conjunto dos números reais ( $\Re^*$  número reais, exceto o zero).
- $V_m$  - Subespaço de funções  $\in L^2(\Re)$ .
- $v_j^k$  - Potencial de ativação do neurônio  $j$  da camada  $k$ .
- $W_m$  - Complemento ortogonal do subespaço  $V_m$  em  $V_{m+1}$ .
- $w_{ji}^k$  - Peso da conexão sináptica da entrada  $i$  do neurônio  $j$  da camada  $k$ .
- $x_i^k$  - Sinal de entrada  $i$  da camada  $k$ .

- $y_j^k$  - Sinal de saída do neurônio  $j$  da camada  $k$ .  
 $Z$  - Conjunto dos números inteiros.  
 $\delta_j^k$  - Gradiente local do neurônio  $j$  da camada  $k$ .  
 $\Delta b_j^k$  - Variação da polarização do neurônio  $j$  da camada  $k$ .  
 $\Delta w_{ji}^k$  - Variação do peso da conexão sináptica da entrada  $i$  do neurônio  $j$  da camada  $k$ .  
 $\Delta_{ji}^k$  - Taxa de variação do peso  $w_{ji}^k$  no algoritmo RPROP.  
 $\Theta_j^k$  - Taxa de variação da polarização  $b_j^k$  no algoritmo RPROP.  
 $\eta$  - Coeficiente de aprendizagem.  
 $L^2(\mathcal{R})$  - Espaço de Hilbert das funções quadrado integráveis.  
 $\varphi_j^k(\cdot)$  - Função de ativação do neurônio  $j$  da camada  $k$ .  
 $\varphi_j^{k'}(\cdot)$  - Derivada da função de ativação do neurônio  $j$  da camada  $k$ .  
 $\psi(t)$  - Função wavelet mãe.  
 $\Psi(\omega)$  - Transformada de Fourier de uma função wavelet mãe.  
 $\oplus$  - Soma direta entre dois subespaços.  
 $\langle f_1, f_2 \rangle$  - Produto interno entre duas funções  $f_1$  e  $f_2$ .

## GLOSSÁRIO

- AM - Análise multiresolução.
- ART - *Adaptive resonance theory.*
- ATP - *Alternative transient program.*
- CGD - Campina Grande II.
- CHESF - Companhia Hidro Elétrica do São Francisco.
- P&D - Pesquisa e desenvolvimento.
- LT - Linha de transmissão.
- MLP - *Multilayer perceptron.*
- NTD - Natal II.
- RDP - Registrador digital de perturbação.
- RPROP - *Resilient propagation.*
- RNA - Rede neural artificial.
- TW - Transformada wavelet.
- TWC - Transformada wavelet contínua.
- TWD - Transformada wavelet discreta.
- WAN - *Wide area network.*



# INTRODUÇÃO

As faltas em sistemas elétricos de potência são caracterizadas como desligamentos não programados de seus componentes e podem ser provocadas por problemas de natureza elétrica, mecânica ou térmica, originados das condições adversas às quais o sistema está sempre submetido. Seu diagnóstico (detecção, classificação e localização) deve ser rápido e preciso, para permitir sua extinção imediata e apropriada, desativando apenas a parte defeituosa do sistema.

Após a eliminação da falta, uma análise mais detalhada é de fundamental importância, para avaliar o desempenho do sistema de proteção e adotar estratégias para o reestabelecimento e a manutenção do sistema elétrico. Nesse momento, destaca-se a importância da *oscilopertubografia*, também denominada de *oscilografia*, que consiste do constante monitoramento das grandezas elétricas do sistema de potência e do estado de operação do sistema de proteção e dos equipamentos a ele relacionados.

O equipamento utilizado no monitoramento é denominado de *oscilopertubografo*, mas atualmente é empregado o termo *registrador digital de perturbação* (RDP), devido a tecnologia digital empregada em sua concepção. De um modo geral, um RDP possui recursos de armazenamento e transferência de dados através de comunicação remota via rede WAN (*wide area network*), possibilitando a formação de redes de monitoramento de grande porte, denominadas convenientemente de *redes oscilográficas*.

As redes oscilográficas são responsáveis pelo monitoramento de diversos pontos do sistema elétrico de uma empresa. No caso particular da Companhia Hidro Elétrica do São Francisco (CHESF), a rede é composta de cerca de 350 pontos de supervisão, cobrindo todo o sistema de 500 kV e de 230 kV, grande parte do sistema de 138 kV e alguns pontos do sistema de 69 kV.

Na maioria dos casos, o monitoramento é realizado sobre as linhas de transmissão (LTs), mas outros equipamentos como transformadores, banco de capacitores e compensadores estáticos também são constantemente supervisionados.

As redes oscilográficas possuem, de um modo geral, um sistema de verificação e coleta das informações registradas pelos RDPs. Essas informações são coletadas automaticamente e organizadas em registros padronizados (Apêndice A). Em seguida, são transferidas para o *servidor central da oscilografia*, onde são armazenadas e posteriormente, compartilhadas na rede corporativa da empresa por diferentes tipos de usuários (Figura 1.1).

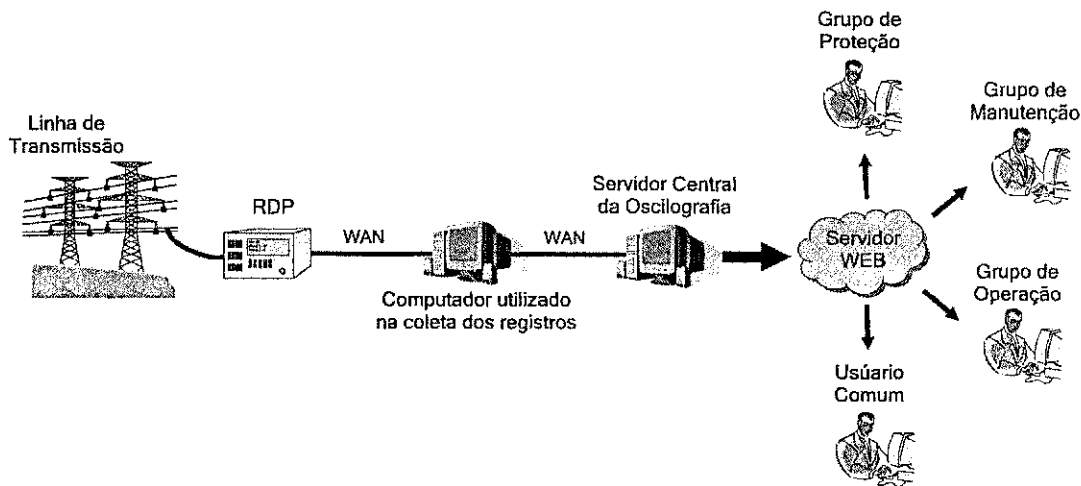


Figura 1.1. Representação do processo de coleta automática de registros capturados pelos RDPs.

A oscilografia foi concebida principalmente com o intuito de avaliar o desempenho dos sistemas de proteção e dos equipamentos a ele relacionados, quando da ocorrência de uma falta. No entanto, devido as estratégias de disparo empregadas nos RDPs, não é possível registrar apenas essas situações. De fato, na maioria das vezes são registrados distúrbios associados à qualidade da energia elétrica (QEE), tais como transitórios de chaveamento e afundamentos de tensão, e operações de manobra para manutenção do sistema, a exemplo de desligamentos e energizações programadas de LTs. Isso pode provocar problemas de caráter operacional associado a grande quantidade de registros que são capturados pelos RDPs, que são irrelevantes aos propósitos da oscilografia. Dessa forma, uma depuração prévia desses registros é de fundamental importância, a fim de compartilhar apenas informações relacionadas à faltas.

## 1.1 MOTIVAÇÃO

A principal motivação dessa dissertação está na importância prática do tema, uma vez que está sendo relacionada com um projeto de Pesquisa e Desenvolvimento (P&D) da CHESF, intitulado *Implantação de Técnicas de Inteligência Artificial para Identificação e Análise de*

*Ocorrências no Sistema Elétrico.* O projeto foi desenvolvido pelo Grupo de Sistemas Elétricos da Universidade Federal de Campina Grande, no período de Agosto de 2002 a Julho de 2004, e teve como resultado o software Neuranálise<sup>®</sup> de diagnóstico de registros oscilográficos. Ele foi concebido na tentativa de reduzir os problemas associados ao monitoramento do sistema elétrico da empresa, a partir da pré-análise e triagem automática dos registros capturados pelos RDPs. Atualmente, ele encontra-se integrado ao sistema de monitoramento de uma LT de 230 kV, situada entre as subestações Campina Grande II (CGD) e Natal II (NTD), pertencentes ao subsistema Leste de transmissão da CHESF (SOUZA et al., 2004a).

## 1.2 REVISÃO BIBLIOGRÁFICA

A maioria dos métodos tradicionalmente empregados na detecção e classificação de faltas são baseados na análise do comportamento das componentes simétricas das tensões e correntes em diversas situações de falta. Em alguns casos o desempenho desses métodos pode ser comprometido devido a fatores como as mudanças nas condições de operação do sistema e a grande diversidade de situações de falta às quais ele está sempre sujeito.

As técnicas de inteligência artificial em conjunto com os métodos de processamento digital de sinais vêm sendo largamente empregadas em aplicações de reconhecimento de padrões, configurando-se como uma alternativa para a detecção e a classificação de faltas.

Dausten & Kulieke (1995) utilizaram uma rede neural artificial (RNA) do tipo *perceptron* de múltiplas camadas, mais conhecida como rede MLP (*multilayer perceptron*), para realizar a classificação de faltas em LTs com circuito duplo. O algoritmo de treinamento utilizado é o algoritmo de retropropagação de erro, mais conhecido como *backpropagation*. O tempo de treinamento para alcançar um erro médio quadrático de 0,0399 para o conjunto de validação foi 24 horas. Os padrões de entrada apresentados à RNA são as amostras das tensões e correntes em situações de faltas simuladas, considerando-se uma frequência de amostragem de 1 kHz.

Um estudo comparativo entre cinco diferentes arquiteturas de RNAs empregadas para a classificação de faltas em LTs com compensação série foi realizado por Song et al. (1996). As redes do tipo *counter-propagation* e do tipo aprendizado LVQ (*learning quantization vector*) se sobressaíram em relação aos demais tipos avaliados.

Kezunovic & Rikalo (1996) utilizaram para a classificação uma RNA do tipo ART (*adaptive resonance theory*), que combina durante sua fase de aprendizado características inerentes aos treinamentos supervisionado e não-supervisionado. Os sinais utilizados para a geração da base de dados de aprendizado da RNA foram apenas os sinais de corrente nas fases do sistema, simulados em um programa do tipo EMTP. A frequência de amostragem utilizada é de 2 kHz. Os padrões de entrada da rede são organizados na forma de uma janela de amostras referentes a um ciclo da frequência fundamental de 60 Hz, contabilizando ao total 99 amostras por janela. Essa metodologia alcançou uma porcentagem de acerto de 95,93 % para os padrões de teste.

Da mesma forma que Kezunovic & Rikalo (1996), Giovanini & Coury (1999) utilizaram para a classificação da falta apenas as correntes como padrões de entrada para uma RNA. Contudo, é empregado um janelamento de apenas três amostras consecutivas relacionadas à falta, percorrendo os sinais ao passo de uma amostra. O instante de incidência da falta é determinado utilizando-se um algoritmo tradicional de proteção de sistemas de potência. Outra diferença é a utilização da componente de sequência zero das correntes como entrada. O sistema elétrico simulado consiste apenas de uma LT isolada com um equivalente de rede em cada um dos seus terminais. A RNA empregada foi do tipo MLP. O desempenho da rede é avaliado para cada janela de dados, chegando a 100 % após 5 ms do início da falta.

Oleskovicz et al. (2000) também utilizaram as redes MLP para realizar a classificação. Um processo de janelamento é empregado aos sinais de entrada da rede, que agora são as tensões e correntes. Cada janela possui 4 amostras, o equivalente a 1/4 do ciclo da componente fundamental de 60 Hz, considerando-se a frequência de amostragem empregada de 1 kHz. Diferentemente de Giovanini & Coury (1999), são utilizados apenas os sinais de tensão e corrente em grandeza de fase. O desempenho da RNA também é avaliado para cada janela de dados, alcançando 99,16 % após 9 ms do instante de início da falta. Novamente, o sistema simulado consiste apenas de uma LT isolada com um equivalente de rede em cada um dos seus terminais.

Alguns algoritmos de detecção e classificação de faltas que utilizam a transformada wavelet (TW) têm sido propostos (SOLANKI et al., 2001; YOUSSEF, 2001; KIM & AGGARWAL, 2001; PROBERT & SONG, 2002; SOLANKI & SONG, 2003; JIANG et al., 2003). Esses métodos baseiam-se, basicamente, na comparação dos coeficientes wavelet com valores padrões, estabelecidos pela análise da situação normal de operação do sistema e de diversas situações de falta.

Kim et al. (2002) propuseram um algoritmo de detecção de faltas baseado na aplicação da TW a uma janela de amostras referentes a um ciclo dos sinais de corrente, na frequência fundamental de 60 Hz. Essa janela é móvel e a cada passo é avaliado o somatório dos coeficientes wavelet de primeira escala de cada uma das correntes. A partir dessa avaliação e com base em limiares pré-estabelecidos é realizada a detecção da falta. No entanto, os autores ressaltam que esse método pode ser estendido para realizar a classificação do tipo de falta.

Outros métodos baseados na utilização de RNAs para o diagnóstico de faltas tem sido propostos, sempre na tentativa de melhorar o desempenho (velocidade, exatidão e segurança) de algoritmos já existentes (SILVA, 2002; KEZUNOVIC et al., 2002; OLESKOVICZ et al., 2003; MAHANTY & GUPTA, 2004; SOUZA et al., 2004c).

Uma alternativa para a etapa de classificação foi proposta por Kashyap & Shenoy (2003), a partir da combinação da TW com uma RNA probabilística. A primeira fase do método consiste da extração de características dos sinais de tensões utilizando-se a TW. Na segunda fase, a RNA é treinada recebendo como padrões de entrada os coeficientes wavelet de primeira escala dos sinais de tensão, referentes à faltas. A porcentagem de acerto alcançada na classificação dos padrões de teste foi de 100 %. Entretanto, o sistema elétrico considerado é bastante simples, uma LT com uma fonte em um terminal e uma carga no outro.

A lógica *fuzzy* tem sido empregada para o tratamento das incertezas na classificação de faltas a partir da análise dos coeficientes wavelets dos sinais de corrente (YOUSSEF, 2004; PRADHAN et al., 2004). Essa estratégia aumenta a capacidade de generalização dos algoritmos até então propostos, que utilizam apenas os coeficientes wavelet para realizar a classificação.

Outra abordagem utiliza lógica *fuzzy* juntamente com as RNAs (VASILIC & KEZUNOVIC, 2002; VASILIC & KEZUNOVIC, 2005). Nesse caso, o diagnóstico é realizado aplicando-se uma regra de decisão *fuzzy* às saídas de uma RNA do tipo ART. Essa estratégia aumenta a segurança no diagnóstico de casos de faltas reais que não foram contemplados na fase de treinamento.

Nessa dissertação serão abordadas apenas as etapas de detecção e classificação da falta. Na Tabela 1.2, um resumo do levantamento bibliográfico realizado é apresentado. Notadamente, a maioria dos trabalhos relacionados a classificação emprega RNA, mas há também aqueles que utilizam a TW. Em alguns casos, a lógica *fuzzy* é combinada com essas técnicas, afim de diminuir as incertezas quanto a classificação. Entretanto, em geral, esses algoritmos foram

propostos para faltas simuladas em uma LT em particular, não sendo avaliados para faltas reais e nem para simuladas em outras LTs. As RNAs e a TW também vêm sendo empregadas na etapa de detecção. Contudo, as faltas são diferenciadas apenas da situação normal de operação do sistema em regime permanente, não contemplando outros distúrbios associados à QEE e operações de manobra para manutenção, que também podem ser registrados pelos RDPs.

Referência	Técnica empregada		Sinais avaliados	
	Detecção	Classificação	Tensão	Corrente
Dausten & Kulieke (1995)	-	RNA	✓	✓
Song et al. (1996)	-	RNA	✓	✓
Kezunovic & Rikalo (1996)	RNA	RNA	-	✓
Giovanini & Coury (1999)	-	RNA	-	✓
Oleskovicz et al. (2000)	-	RNA	✓	✓
Solanki et al. (2001)	TW	-	-	✓
Youssef (2001)	-	TW	-	✓
Kim & Aggarwal (2001)	TW	-	-	✓
Silva (2002)	-	RNA	-	✓
Kim et al. (2002)	TW	-	-	✓
Probert & Song (2002)	TW	-	-	✓
Kezunovic et al. (2002)	-	RNA+fuzzy	-	✓
Vasilic & Kezunovic (2002)	-	RNA+fuzzy	-	✓
Solanki & Song (2003)	TW	-	-	✓
Jiang et al. (2003)	TW	-	-	✓
Kashyap & Shenoy (2003)	-	TW+RNA	✓	-
Oleskovicz et al. (2003)	RNA	RNA	✓	✓
Mahanty & Gupta (2004)	RNA	RNA	-	✓
Souza et al. (2004c)	-	RNA	-	✓
Youssef (2004)	-	TW+fuzzy	-	✓
Pradhan et al. (2004)	-	TW+fuzzy	-	✓
Vasilic & Kezunovic (2005)	-	RNA+fuzzy	-	✓

Tabela 1.1. Resumo da revisão bibliográfica

# FUNDAMENTAÇÃO TEÓRICA

As RNAs caracterizam-se como uma tentativa de emular o raciocínio do especialista através de algoritmos computacionais velozes e robustos. Esse método, combinado com outras técnicas de inteligência artificial e de processamento digital de sinais, pode substituir com vantagens os métodos tradicionais de diagnóstico de faltas.

Técnicas de processamento digital de sinais, baseadas na TW, se aplicam muito bem à análise de sinais não-estacionários, cujo espectro de frequências varia no tempo. Esse é o caso dos transitórios eletromagnéticos originados nas formas de onda de tensão e corrente do sistema quando da ocorrência de uma falta. Essa metodologia difere da teoria de Fourier, principalmente quanto a informação da relação tempo-frequência do conteúdo espectral do sinal. Notadamente, várias outras aplicações dessa técnica têm surgido no contexto de proteção e da QEE.

## 2.1 FALTAS EM SISTEMAS ELÉTRICOS DE POTÊNCIA

As faltas em sistemas de potência podem ser basicamente de dois tipos: simétricas, quando todas as fases estão envolvidas (faltas trifásicas); e assimétricas, quando apenas uma fase (monofásicas) ou duas (bifásicas) estão envolvidas. As faltas assimétricas são distintas conforme envolvam ou não a terra. De acordo com os dados da CHESF no período de 2003 a 2004 (Tabela 2.1), cerca de 68 % das faltas ocorridas no sistema são monofásicas e 25 % bifásicas, com a minoria sendo do tipo fase-fase-terra. As faltas trifásicas correspondem apenas a 7 % das ocorrências no período.

Cada tipo de falta possui características particulares quanto às tendências de crescimento e decréscimo das tensões e correntes e seus respectivos defasamentos. No entanto, de um modo geral, para as fases envolvidas na falta observa-se uma diminuição do valor máximo das tensões e um aumento para as correntes. Além disso, no caso de faltas que envolvem a

Tipo de falta	Ocorrências	Ocorrências(%)
Monofásicas	2260	67,71
Bifásicas	660	19,77
Bifásicas para a terra	177	5,30
Trifásica	241	7,22
	<b>3338</b>	<b>100,00</b>

**Tabela 2.1.** Faltas ocorridas no sistema de transmissão da CHESF no período de 2003 a 2004.

terra, as componentes de seqüência zero das tensões e correntes são maiores que nas faltas sem o envolvimento da terra. Há também as faltas evolutivas, que consistem basicamente da ocorrência de um tipo falta que evolui para outro, como por exemplo, uma falta monofásica na fase A que passa à uma falta bifásica com o envolvimento da terra entre as fases A e B.

A complexidade do problema de diagnóstico de faltas é evidenciado pela quantidade de parâmetros que influenciam nas características particulares de cada tipo de falta. Dentre eles, destacam-se o ângulo de incidência<sup>1</sup>, a localização e o valor da resistência de falta. As diversas possibilidades de combinação dessas variáveis originam diferentes cenários de falta.

A localização é medida com relação ao ponto de monitoramento. Ela está intimamente relacionada com a intensidade do transitório sobre as tensões e valores máximos das correntes na situação de falta, os quais são maiores à medida que se aproximam do ponto de monitoramento. O ângulo de incidência pode modificar as características das tensões de um tipo de falta nos primeiros instantes após sua ocorrência. Por outro lado, a resistência pode distorcer completamente as características referentes à uma falta.

A influência da localização, do ângulo de incidência e da resistência de falta nas características de uma falta monofásica na fase A são representadas nas Figuras 2.1, 2.2 e 2.3, respectivamente. Em cada caso, apenas o parâmetro que está sendo avaliado é modificado, os demais permanecem constantes.

<sup>1</sup>Ângulo relacionado ao instante de início da falta, geralmente medido tomando-se como referência a tensão na fase A do sistema.



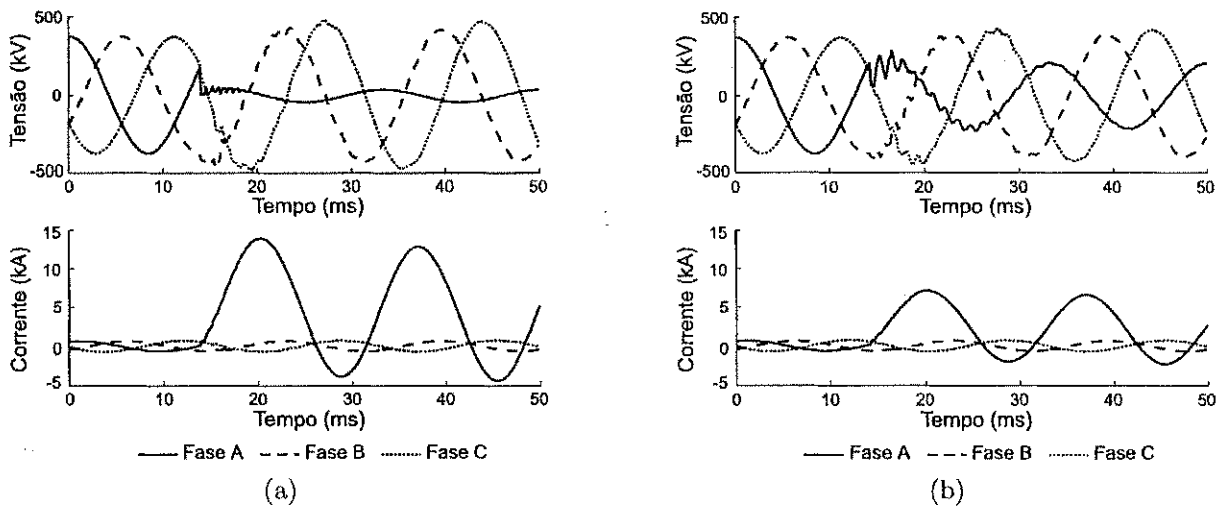


Figura 2.1. Influência da localização: (a) 10 km; (b) 100 km.

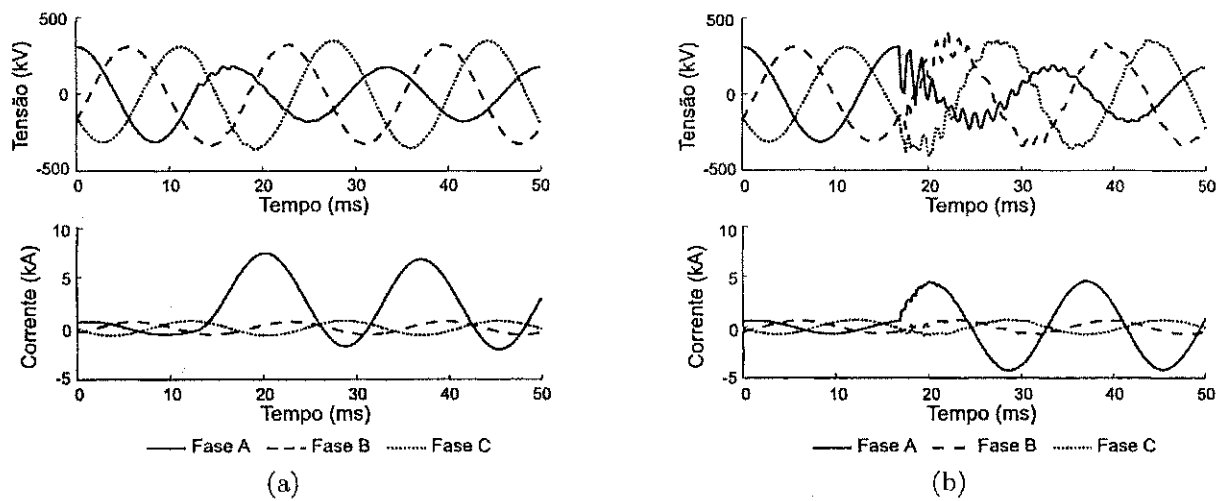


Figura 2.2. Influência do ângulo de incidência: (a)  $10^\circ$ ; (b)  $90^\circ$ .

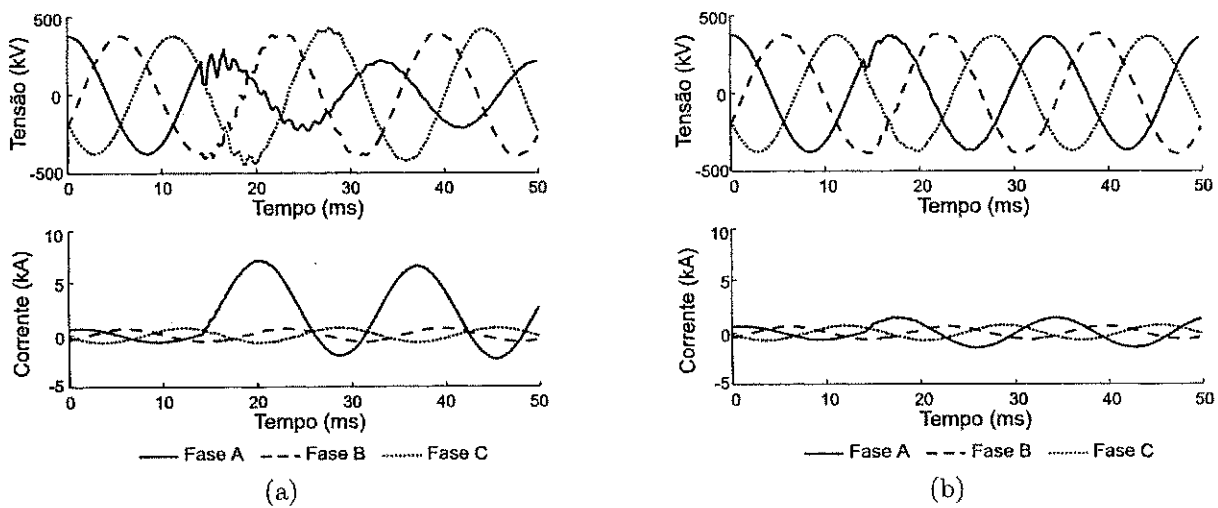


Figura 2.3. Influência de resistência de falta: (a)  $0,1 \Omega$ ; (b)  $200 \Omega$ .

## 2.2 REDES NEURAIS ARTIFICIAIS

As RNAs são modelos de processamento de informação inspirados na estrutura física natural do cérebro humano. Elas são conceitualmente sistemas paralelos, não lineares e distribuídos, compostos por unidades de processamento simples (*neurônios*). Essas, por sua vez, estão dispostas em estruturas interligadas por um grande número de conexões (*sinapses*).

Dentre as características inerentes as RNAs, a principal é a capacidade de se adaptar a novas situações. Tal capacidade é alcançada a partir de um estágio de aprendizado (treinamento), no qual o conhecimento sobre a aplicação é passado através de exemplos. Outra característica importante é a de generalização, quando se avalia com sucesso outros padrões similares, mas não necessariamente idênticos aos utilizados durante o aprendizado (HAYKIN, 2001). Além de uma fase de aprendizagem bem sucedida, para se alcançar a generalização é essencial a elaboração de um conjunto de exemplos que representem significativamente todas as situações às quais a rede possa ser submetida, denominado de *base de dados*.

Em geral, a base de dados é dividida em três subconjuntos disjuntos: de *treinamento*, de *validação* e de *teste*. O primeiro é responsável por passar efetivamente o conhecimento sobre a aplicação em questão. O conjunto de validação é utilizado para supervisionar o desenvolvimento da capacidade de generalização da RNA durante a fase de aprendizagem. Já o conjunto de teste só é aplicado ao final da etapa de aprendizagem, para verificar a qualidade do aprendizado da RNA.

Com base no tipo de aprendizado utilizado, define-se duas classes distintas de RNAs: *supervisionadas* e *não-supervisionadas*. As primeiras são redes que realizam seu treinamento a partir de um conjunto definido de entradas e saídas desejadas. Por outro lado, as não-supervisionadas realizam o agrupamento dos padrões em *clusters* a partir de suas semelhanças, não sendo necessária a indicação da saída desejada.

### 2.2.1 Modelo do Neurônio

O neurônio é a unidade de processamento fundamental da RNA. O modelo de um neurônio artificial é apresentado na Figura 2.4, no qual se identificam três elementos básicos:



sigmóides, que possuem a forma de um  $S$  e são definidas no intervalo  $[0,1]$  como sendo:

$$\varphi_j^k(v_j^k) = \frac{1}{1 + \exp(-av_j^k)}, \quad (2.2)$$

em que o parâmetro  $a$ , cujo valor é sempre maior que zero, representa a suavidade da função sigmóide (Figura 2.5(a)).

Outro tipo de função sigmoidal bastante utilizada é a função tangente hiperbólica (Figura 2.5(b)), que possui a forma de uma sigmóide com definição no intervalo contínuo  $[-1,1]$ :

$$\varphi_j^k(v_j^k) = \frac{1 - \exp(-av_j^k)}{1 + \exp(-av_j^k)}. \quad (2.3)$$




Figura 2.5. Tipos de função de ativação: (a) sigmóide; (b) tangente hiperbólica.

## 2.2.2 Redes *Perceptron* de Múltiplas Camadas

Dentre as diversas arquiteturas de RNA, destacam-se como as mais difundidas as redes MLP. Elas representam uma generalização da rede do tipo *perceptron* de camada única (HAYKIN, 2001).

Tipicamente uma rede MLP consiste de uma camada de entrada constituída de unidades sensoriais, uma ou mais camadas ocultas e uma de saída, todas conectadas (Figura 2.6). Com exceção da camada de entrada, que tem a única função de distribuir os sinais de entrada sem alterá-los, as demais são constituídas de neurônios, cujo modelo foi descrito na seção anterior (Figura 2.4). O sinal de entrada se propaga através da rede, camada a camada, a partir das equações (2.1a) e (2.1b), até que um sinal de saída seja computado.

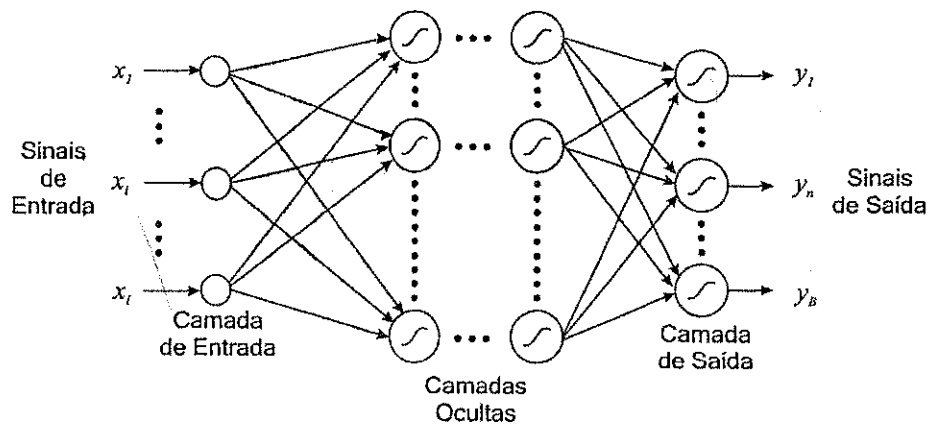


Figura 2.6. Arquitetura de uma rede MLP.

As redes MLP são classificadas como redes supervisionadas, pois possuem um processo de aprendizagem supervisionado.

O processo de aprendizagem de uma RNA pode ser entendido como um problema de otimização da configuração de pesos e polarizações que venha a minimizar uma função de custo. Essa função, denominada de *função energia de erro*, é definida como o erro médio quadrático entre a saída produzida pela rede e a desejada.

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j=1}^B [d_j(n) - o_j(n)]^2, \quad (2.4)$$

sendo  $B$  o número de neurônios da camada de saída;  $d_j(n)$  e  $o_j(n)$  a saída desejada e a calculada do neurônio de saída  $j$  da camada de saída para o padrão  $n$ -ésimo padrão do conjunto de treinamento.

O aprendizado pode ser dividido basicamente em duas etapas:

1. *Propagação*- os sinais de entrada são aplicados às unidades sensoriais da rede e seu efeito se propaga na rede, camada a camada, produzindo sinais de saída. Nessa etapa os pesos mantêm-se inalterados.
2. *Retropropagação* - as polarizações e os pesos sinápticos são reajustados de acordo com um algoritmo, denominado de *algoritmo de treinamento*, com o intuito de minimizar a função de energia de erro definida na equação 2.4.

Dentre os algoritmos de treinamento empregados às redes MLP, destaca-se o algoritmo de retropropagação de erro, mais conhecido como *backpropagation*. Ele é na verdade uma

adequação do método clássico do gradiente descendente ao problema do aprendizado de RNAs. A idéia fundamental do algoritmo *backpropagation* é retropropagar o sinal de erro entre as saídas desejadas e obtidas pela rede na camada de saída, pelas demais camadas.

De acordo com o método do gradiente descendente, o reajuste dos pesos e das polarizações dos neurônios em cada iteração é dada por:

$$\Delta w_{ji}^k(n) = -\eta \frac{\partial \mathcal{E}(n)}{\partial w_{ji}^k(n)} \quad (2.5a)$$

$$\Delta b_j^k(n) = -\eta \frac{\partial \mathcal{E}(n)}{\partial b_j^k(n)}, \quad (2.5b)$$

em que  $\eta$  é apenas um parâmetro de ponderação no reajuste, denominado de *coeficiente de aprendizagem*, que assume valores no intervalo  $(0, 1]$ ; e  $n$  indica a apresentação do padrão de entrada referente ao  $n$ -ésimo exemplo do conjunto de treinamento da rede.

Aplicando-se a regra da cadeia às derivadas das equações (2.5) (HAYKIN, 2001), obtêm-se as expressões para o reajuste dos pesos e polarizações:

$$\Delta w_{ji}^k(n) = \eta \delta_j^k(n) y_i^{k-1}(n) \quad (2.6a)$$

$$\Delta b_j^k(n) = \eta \delta_j^k(n), \quad (2.6b)$$

sendo  $y_i^{k-1}(n)$  a saída do neurônio  $i$  da camada  $k - 1$  para o  $n$ -ésimo padrão de treinamento e  $\delta_j^k$  o gradiente local do neurônio  $j$  da camada  $k$ , cujo valor depende do tipo de camada a qual o neurônio pertence.

$$\delta_j^k(n) = \begin{cases} \varphi_j^{k'}(v_j^k(n)) (d_j(n) - o_j(n)), & \text{sendo } k \text{ a camada de saída} \\ \varphi_j^{k'}(v_j^k(n)) \sum_{l \in D^{k+1}} \delta_l^{k+1}(n) w_{jl}^{k+1}(n), & \text{sendo } k \text{ uma camada oculta} \end{cases}, \quad (2.7)$$

sendo  $D^{k+1}$  o conjunto de neurônios da camada  $k + 1$ , posterior a camada oculta  $k$ .

No processo de aprendizagem, um aspecto relevante é a frequência de atualização dos pesos e polarizações da rede. As abordagens mais difundidas em aplicações de redes MLP são: atualização *seqüencial* e atualização por *lote*, do inglês *batch*.

No modo de atualização seqüencial, os pesos são reajustados após a apresentação de cada padrão de treinamento. Esta abordagem é estável se o coeficiente de aprendizagem for pequeno ( $\eta \ll 1$ ), entretanto o processo pode tornar-se muito lento. Se  $\eta \approx 1$ , o treinamento, torna-se

muito instável. Em geral, este modo de reajuste é mais rápido, sobretudo se o conjunto de treinamento for grande, mas nem sempre o aprendizado da rede é bem sucedido.

Na atualização no modo *batch*, os pesos são atualizados ao final da apresentação de todos os padrões do conjunto de treinamento, ou seja, após uma *época de treinamento*. O valor do reajuste dos pesos é calculado para todos os padrões. No entanto, os pesos são modificados apenas ao final da época, utilizando-se o valor médio dos reajustes acumulados.

A formulação matemática do algoritmo *backpropagation* apresentada até então é referente ao modo de atualização seqüencial. No modo *batch* a função de erro da equação (2.4) para a  $m$ -ésima época é expressa por:

$$\mathcal{E}_{med}(m) = \frac{1}{2N} \sum_{n=1}^N \sum_{j=1}^B [d_j(n) - o_j(n)]^2, \quad (2.8)$$

sendo  $\mathcal{E}_{med}(m)$  a *função energia de erro média* de uma época  $m$  e  $N$  o número de padrões do conjunto de treinamento.

As equações de reajuste dos pesos e polarizações, descritas nas equações (2.6a) e (2.6b), são modificadas no modo *batch* para:

$$\Delta w_{ji}^k(m) = \frac{\eta}{N} \sum_{n=1}^N \delta_j^k(n) y_i^{k-1}(n) \quad (2.9a)$$

$$\Delta b_j^k(m) = \frac{\eta}{N} \sum_{n=1}^N \delta_j^k(n). \quad (2.9b)$$

### 2.2.2.1 Algoritmo de Treinamento *Resilient Propagation*

Apesar do algoritmo *backpropagation* apresentar simplicidade na implementação, ele possui em geral uma convergência muito lenta (HAYKIN, 2001).

A maioria dos algoritmos propostos baseia-se em uma adaptação dinâmica de seus parâmetros durante o aprendizado da rede. Em geral, as estratégias de adaptação podem ser classificadas como globais, que modificam os parâmetros do algoritmo de forma global, ou locais, que utilizam informações específicas dos pesos para ajustar parâmetros de cada um deles individualmente. No entanto, as estratégias locais são mais intimamente relacionadas ao conceito de aprendizado neural, mostrando-se superior em relação às globais em diversas aplicações.

O que torna muitas estratégias de treinamento algumas vezes ineficazes, é que a atualização

dos pesos não depende somente dos parâmetros de treinamento, mas também do valor do gradiente da função energia de erro em função dos pesos. Assim, o efeito de uma adaptação desses parâmetros pode ser drasticamente distorcido pela variação do comportamento do gradiente.

Riedmiller & Braun (1993) propuseram um algoritmo de treinamento chamado de RPROP, *resilient propagation*, que é derivado do algoritmo *backpropagation* tradicional. A diferença entre eles é que no RPROP a atualização dos pesos é feita de modo direto, fazendo-se uso apenas do sinal do gradiente da função energia de erro em relação aos pesos e polarizações da rede e não de seu valor, como no caso do *backpropagation*. Isso evita uma adaptação descontrolada e faz com que a convergência torne-se mais rápida. Os pesos e polarizações são alterados apenas após uma época de treinamento, ou seja, o aprendizado é realizado em modo *batch*, e a estratégia de reajuste é local, o que resulta em cada peso  $w_{ji}^k$  e polarização  $b_j^k$  possuírem suas próprias taxas de variação  $\Delta_{ji}^k$  e  $\Theta_j^k$ , respectivamente:

$$\Delta_{ji}^k(m) = \begin{cases} \eta^+ \cdot \Delta_{ji}^k(m-1), & \text{se } \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) > 0 \\ \eta^- \cdot \Delta_{ji}^k(m-1), & \text{se } \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) < 0 \\ \Delta_{ji}^k(m-1), & \text{caso contrário} \end{cases} \quad (2.10)$$

e

$$\Theta_j^k(m) = \begin{cases} \eta^+ \cdot \Theta_j^k(m-1), & \text{se } \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m) > 0 \\ \eta^- \cdot \Theta_j^k(m-1), & \text{se } \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m) < 0 \\ \Theta_j^k(m-1), & \text{caso contrário} \end{cases}, \quad (2.11)$$

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

Os gradientes locais  $\frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m)$  e  $\frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m)$  avaliados para uma época de treinamento são expressos como:

$$\frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) = \frac{1}{N} \sum_{n=1}^N \frac{\partial \mathcal{E}}{\partial w_{ji}^k}(n) \quad (2.12a)$$

$$\frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m) = \frac{1}{N} \sum_{n=1}^N \frac{\partial \mathcal{E}}{\partial b_j^k}(n). \quad (2.12b)$$

A partir das equações 2.5, 2.6 e 2.7, as equações 2.12 podem ser escritas como:

$$\frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) = -\frac{1}{N} \sum_{n=1}^N \delta_j^k(n) y_i^{k-1}(n) \quad (2.13a)$$

$$\frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m) = -\frac{1}{N} \sum_{n=1}^N \delta_j^k(n). \quad (2.13b)$$



Dessa forma, as mesmas expressões obtidas no *backpropagation* para o cálculo do gradiente local para cada padrão do conjunto de treinamento podem ser utilizadas nas equações 2.13.

Durante o processo de aprendizagem, uma mudança no sinal dos gradientes  $\frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m)$  de uma iteração para outra, indica que a última adaptação dos pesos foi suficiente para que a rede saltasse sobre um ponto extremo da função  $\mathcal{E}_{med}(m)$ . Uma interpretação semelhante pode ser dada no caso das polarizações. Nessa situação, a configuração de pesos e polarizações anterior a última adaptação é retomada e os valores de reajuste são calculados, respectivamente, como  $\eta^- \Delta_{ji}^k(m-1)$  e  $\eta^- \Theta_j^k(m-1)$ . Isso torna a busca pelo ponto extremo identificado mais refinada. Em seguida, o valor do ponto extremo é avaliado pelos critérios de parada impostos na implementação do algoritmo, caso algum destes seja atingido o aprendizado é encerrado e a última configuração de pesos e polarizações é preservada, caso contrário o algoritmo continua a busca por outros pontos extremos. Já no caso em que não houve modificação do sinal dos gradientes de uma iteração para outra, identifica-se uma situação em que o reajuste está sendo feito em uma mesma direção, o que implica num aumento nas taxas de variação, dado por  $\eta^+ \Delta_{ji}^k(m-1)$  e  $\eta^+ \Theta_j^k(m-1)$ , acelerando a busca por pontos extremos.

De maneira geral, os valores de reajuste dos pesos e das polarizações da RNA são calculados do seguinte modo:

$$\Delta w_{ji}^k(m) = \begin{cases} -\Delta_{ji}^k(m), & \text{se } \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) > 0 \\ +\Delta_{ji}^k(m), & \text{se } \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (2.14)$$

e

$$\Delta b_j^k(m) = \begin{cases} -\Theta_j^k(m), & \text{se } \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m) > 0 \\ +\Theta_j^k(m), & \text{se } \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m) < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (2.15)$$

No entanto, há uma exceção. No caso em que  $\frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) < 0$  ou  $\frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m) < 0$ , a configuração anterior ao último reajuste deve ser retomada. Nesse caso, o reajuste dos pesos e das polarizações é calculado como sendo:

$$\Delta w_{ji}^k(m) = -\Delta w_{ji}^k(m-1) \quad (2.16a)$$

$$\Delta b_j^k(m) = -\Delta b_j^k(m-1). \quad (2.16b)$$

Os pesos e as polarizações são reajustados a cada época da seguinte forma:

$$w_{ji}^k(m+1) = w_{ji}^k(m) + \Delta w_{ji}^k(m) \quad (2.17a)$$

$$b_j^k(m+1) = b_j^k(m) + \Delta b_j^k(m). \quad (2.17b)$$

A mudança nos pesos e polarizações da rede depende apenas do sinal dos respectivos gradientes e não do seu valor absoluto. Se a derivada for positiva, o peso é decrementado por  $\Delta_{ji}^k(m)$  e a polarização por  $\Theta_j^k(m)$ ; se a derivada for negativa, eles serão incrementados por esses mesmos valores. Esse artifício permite que o algoritmo seja eficiente mesmo em situações onde o gradiente é muito pequeno, que é o caso no qual a superfície de erro tem forma plana.

De forma simplificada, o núcleo do algoritmo RPROP é representado a seguir. Onde  $\Delta_{min}$ ,  $\Theta_{min}$ ,  $\Delta_{max}$  e  $\Theta_{max}$  são os valores mínimo e máximo admissíveis na prática. Em geral são considerados como  $10^{-6}$  e 50, respectivamente. O valor inicial das taxas de variação dos reajustes dos pesos e das polarizações  $\Delta_0$  e  $\Theta_0$  são considerados geralmente como 0,1. Geralmente,  $\eta^-$  e  $\eta^+$  são escolhidos como 0,5 e 1,2, respectivamente. Os operadores **min** e **max** retornam, respectivamente, o menor e o maior valor entre dois números. O operador **sign** retorna +1 se o argumento for positivo, -1 se for negativo e 0 caso contrário (RIEDMILLER & BRAUN, 1993).

### Algoritmo RPROP

Para todos os pesos:

se  $\left( \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) > 0 \right)$  então

$$\Delta_{ji}^k(m) = \min(\Delta_{ji}^k(m-1) \cdot \eta^+, \Delta_{max})$$

$$\Delta w_{ji}^k(m) = -\text{sign}\left(\frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m)\right) \cdot \Delta_{ji}^k(m)$$

$$w_{ji}^k(m+1) = w_{ji}^k(m) + \Delta w_{ji}^k(m)$$

caso contrário

se  $\left( \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) < 0 \right)$  então

$$\Delta_{ji}^k(m) = \max(\Delta_{ji}^k(m-1) \cdot \eta^-, \Delta_{min})$$

$$w_{ji}^k(m+1) = w_{ji}^k(m) - \Delta w_{ji}^k(m-1)$$

$$\frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) = 0$$

caso contrário

se  $\left( \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m) = 0 \right)$  então

$$\Delta w_{ji}^k(m) = -\text{sign}\left(\frac{\partial \mathcal{E}_{med}}{\partial w_{ji}^k}(m)\right) \cdot \Delta_{ji}^k(m)$$

$$w_{ji}^k(m+1) = w_{ji}^k(m) + \Delta w_{ji}^k(m)$$

Para todas as polarizações:

se  $\left( \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m) > 0 \right)$  então

$$\Theta_j^k(m) = \min(\Theta_j^k(m-1) \cdot \eta^+, \Theta_{\max})$$

$$\Delta b_j^k(m) = -\text{sign}\left(\frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m)\right) \cdot \Theta_j^k(m)$$

$$b_j^k(m+1) = b_j^k(m) + \Delta b_j^k(m)$$

caso contrário

se  $\left( \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m) < 0 \right)$  então

$$\Theta_j^k(m) = \max(\Theta_j^k(m-1) \cdot \eta^-, \Theta_{\min})$$

$$b_j^k(m+1) = b_j^k(m) - \Delta b_j^k(m-1)$$

$$\frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m) = 0$$

caso contrário

se  $\left( \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m-1) \cdot \frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m) = 0 \right)$  então

$$\Delta b_j^k(m) = -\text{sign}\left(\frac{\partial \mathcal{E}_{med}}{\partial b_j^k}(m)\right) \cdot \Theta_{ji}^k(m)$$

$$b_j^k(m+1) = b_j^k(m) + \Delta b_j^k(m)$$

### 2.3 TRANSFORMADA WAVELET

A TW efetua uma transformação de sinais do domínio do tempo para o domínio wavelet, a partir da decomposição do sinal em vários outros com diferentes níveis de resolução. Ela é uma poderosa ferramenta matemática para análise de sinais, com aplicações em diversas áreas, como física, medicina e engenharia. Ao contrário da transformada de Fourier, ela é extremamente adequada à análise de sinais com conteúdo espectral variante no tempo (POULARIKAS, 1996; DAUBECHIES, 1992).

Dado um sinal ou uma função  $f(t)$ , a transformada wavelet contínua (TWC) é definida como:

$$W_f(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt, \quad (2.18)$$

sendo:  $(a, b) \in (\mathbb{R}^+, \mathbb{R})$  e  $f(t) \in L^2(\mathbb{R})$ ;  $a$  e  $b$ , respectivamente, os fatores escala e translação;  $W_f(a, b)$  os coeficientes wavelet contínuos da função  $f(t)$  e  $\psi(t)$  a função wavelet mãe.

A equação 2.18 é a equação fundamental da teoria das wavelets e matematicamente corresponde a um produto interno entre as funções  $f(t)$  e  $\psi\left(\frac{t-b}{a}\right)$ .

A função wavelet mãe deve satisfazer algumas propriedades básicas, sendo a mais importante a condição de admissibilidade:

$$\Gamma = \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < +\infty, \quad (2.19)$$

em que  $\Psi(\omega)$  é a transformada de Fourier da wavelet mãe.

Como implicação direta, as wavelets são funções oscilatórias de valor médio zero, ou seja:

$$|\Psi(\omega)|_{\omega=0}^2 = 0 \iff \int_{-\infty}^{\infty} \psi(t) dt = 0. \quad (2.20)$$

Outra característica necessária a uma wavelet mãe é que ela deve pertencer ao espaço de funções  $L^2(\mathbb{R})$ , o que implica em que ela possua energia finita:

$$\int_{-\infty}^{\infty} \psi^2(t) dt < +\infty. \quad (2.21)$$

As operações de escalonamento e translação da wavelet mãe originam novas funções, denominadas de wavelets filhas. Tais funções também são oscilatórias, de valor médio zero e possuem a mesma energia da mãe.

No caso contínuo, o cálculo de todos os coeficientes é impraticável computacionalmente. Uma alternativa é a utilização de parâmetros de escalonamento e translação discretos, originando a transformada wavelet discreta (TWD), considerando-se  $a = a_0^{-m}$  e  $b = na_0^{-m}b_0$ , com:  $a_0 > 1$ ,  $b_0 > 0$  e  $m, n \in \mathbb{Z}$  (RIOUL & VETTERLI, 1991).

Ao contrário da TWC, em que a reconstrução é convergente se  $\psi(t)$  satisfizer à condição de admissibilidade, no caso discreto isso nem sempre acontece. De fato, a convergência depende da escolha do tipo da wavelet mãe e do processo de discretização realizado. Essas restrições são estabelecidas a partir da teoria de *frames* (DAUBECHIES, 1990).

No caso discreto, há diversos tipos de wavelets: redundantes, bi-ortonormais, semi-ortonormais e ortonormais, sendo o último tipo mais utilizado devido a garantia e a simplicidade da reconstrução do sinal (DAUBECHIES, 1992). Para esse tipo de wavelet, tipicamente adota-se  $a_0 = 2$  e  $b_0 = 1$ . No entanto, essas constantes podem assumir qualquer outro valor inteiro.

A construção de bases ortonormais e a implementação da TWD para esse tipo de wavelet é baseada em uma técnica oriunda da área de processamento de sinais, denominada de *análise multiresolucional* (AM). Assim como a TW, a AM possibilita a decomposição de um sinal em escalas com diferentes resoluções no tempo e na frequência.

Matematicamente, a AM pode ser entendida como uma seqüência de subespaços  $V_m$ , sendo  $m \in \mathbb{Z}$ , com as seguintes propriedades (BURRUS et al., 1998):

1.  $V_m \subset V_{m+1}$ .
2.  $V_\infty = L^2(\mathfrak{R})$ .
3.  $V_{-\infty} = 0$ .
4.  $f(t) \in V_m \iff f(2t) \in V_{m+1}$ .
5.  $f(t) \in V_0 \implies f(t - n) \in V_0$ .
6. Existe uma função  $\phi \in V_0$ , denominada de função escalonamento, tal que o conjunto  $\{\phi_{0,n} = \phi(t - n)\}$  é uma base ortonormal para  $V_0$  e por conseguinte,  $\{\phi_{m,n} = 2^{\frac{m}{2}} \phi(2^m t - n)\}$  constitui-se numa base ortonormal para  $V_m$ .

A construção da base de wavelets é feita a partir dos subespaços  $W_m$  (complementos ortogonais de  $V_m$  em  $V_{m+1}$ ), os quais apresentam as seguintes características:

$$V_{m+1} = V_m \oplus W_m \text{ e } W_m \perp W_{m'}, \text{ m} \neq \text{m}'.$$

Essas características juntas com as propriedades da AM resultam nas seguintes propriedades para os espaços  $W_m$ :

1.  $L^2(\mathfrak{R}) = \bigoplus_m W_m$ .
2.  $W_m \cap W_{m'} = \{0\}$  (diferencial fundamental entre os subespaços  $V_m$  e  $W_m$ ).
3.  $f(t) \in V_m \iff f(2t) \in V_{m+1}$ .
4. Existe uma função  $\psi \in W_0$ , tal que o conjunto  $\{\psi_{0,n} = \psi(t - n)\}$  é uma base ortonormal para  $W_0$  e por conseguinte,  $\{\psi_{m,n} = 2^{\frac{m}{2}} \psi(2^m t - n)\}$  constitui-se numa base ortonormal para  $L^2(\mathfrak{R})$ .

Portanto, qualquer função  $f(t) \in L^2(\mathfrak{R})$  pode ser expressa como:

$$f(t) = \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} d_{m,n} \psi_{m,n}(t), \quad (2.22)$$

com  $d_{m,n} = \langle f, \psi_{m,n} \rangle$ .

A AM resulta na equação fundamental para a representação de funções com as wavelets, denominada de equação de dilatação:

$$\phi(t) = \sum_k h(k)\phi(2t - k), \quad (2.23)$$

com  $k \in Z$  e  $\sum_k h(k) = 2$ .

A partir da equação (2.23) toda a base wavelet é formada, inclusive a equação da wavelet:

$$\psi(t) = \sum_k g(k)\phi(2t - k), \quad (2.24)$$

com  $g(k) = (-1)^k h(1 - k)$ .

Na construção das bases de wavelets, a forma de  $\phi(t)$  é uma função da aplicação, entretanto, algumas condições devem ser satisfeitas:

1. Norma unitária:  $\|\phi\| = \left( \int_{-\infty}^{\infty} |\phi(x)|^2 dx \right)^{\frac{1}{2}}$ .
2. Área unitária:  $\int_{-\infty}^{\infty} \phi(x) dx = 1$ .

Mallat (1989) baseado na estrutura da AM propôs um algoritmo rápido e eficiente de cálculo da TWD, utilizando wavelets ortonormais. Dessa forma, a TWD pode ser interpretada como um banco de filtros, representado na Figura 2.7(b) para o caso da transformada direta. Assim, em um estágio (escala)  $m$ , um sinal discreto  $c_m(n)$  é decomposto em duas componentes,  $c_{m+1}(n)$  e  $d_{m+1}(n)$ , que representam respectivamente a saída de um filtro passa-baixa  $h(n)$  e de outro passa-alta  $g(n)$  (Figura 2.7(a)). De fato, a saída do filtro  $h(n)$  pode ser interpretada como uma aproximação do sinal  $c_m(n)$ , contendo componentes de baixa frequência, enquanto que a saída de  $g(n)$  representa os detalhes do sinal  $c_m(n)$ , contendo componentes da alta frequência. Na próxima escala, o sinal  $c_{m+1}(n)$  é decomposto em mais uma aproximação  $c_{m+2}(n)$  e nos detalhes  $d_{m+2}(n)$ . Matematicamente,  $c_{m+1}(n)$  e  $d_{m+1}(n)$  são representados por:

$$c_{m+1}(n) = \sum_l h(l - 2n)c_m(l) \quad (2.25a)$$

$$d_{m+1}(n) = \sum_l g(l - 2n)c_m(l), \quad (2.25b)$$

com  $l = 2n + k$  e  $k \in Z$ .

Quando aplicadas recursivamente, essas equações definem a transformada wavelet rápida. As equações (2.25) representam a TWD direta.

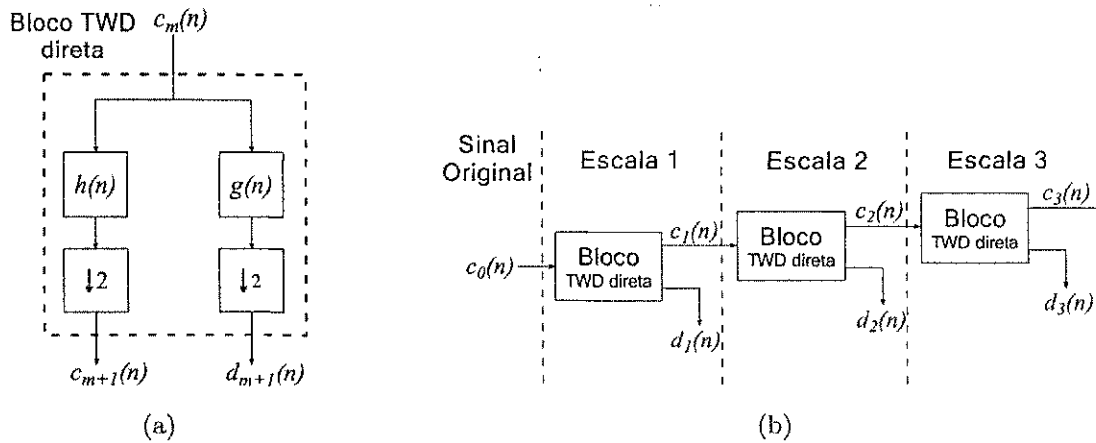


Figura 2.7. TWD direta: (a) bloco da TWD direta; (b) três estágios da TWD direta.

Ao final do processo de decomposição, devido ao processo de subamostragem ( $\downarrow 2$ ), obtém-se um vetor de coeficientes wavelet de comprimento igual ao número de amostras do sinal original.

A reconstrução do sinal realizada através da TWD inversa é também calculada a partir da estrutura de banco de filtros, de forma semelhante a decomposição, mas agora na ordem reversa (Figura 2.8(b)) a partir de um processo de sobreamostragem ( $\uparrow 2$ ). Matematicamente ela é representada por:

$$c_{m+1}(n) = \sum_l [h(l - 2n)c_m(l) + g(l - 2n)d_m(l)], \quad (2.26)$$

com  $l = 2n + k$  e  $k \in Z$ .

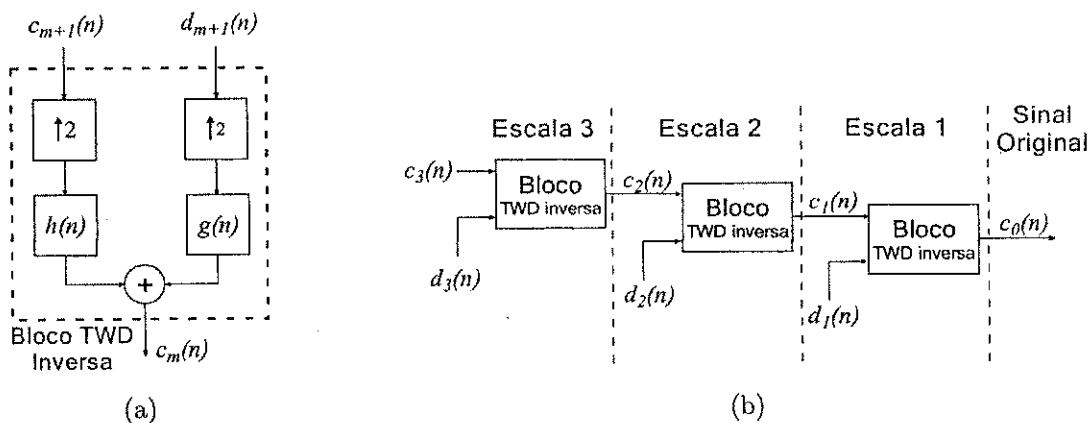


Figura 2.8. TWD inversa: (a) bloco da TWD inversa; (b) três estágios da TWD inversa.

Levando-se em consideração o processo de subamostragem ( $\downarrow 2$ ) utilizado na TWD direta e o de sobreamostragem ( $\uparrow 2$ ) na TWD inversa, a relação entre o índice do coeficiente wavelet e a amostra do sinal original a qual ele está relacionado é  $2^n$ , com  $n$  sendo o número da escala de resolução. Por exemplo, a vigésima amostra de um sinal está relacionada ao décimo coeficiente wavelet de detalhe da primeira escala de resolução e ao quinto da segunda escala.

Exemplos de aplicação da TWD, na forma direta e inversa, são apresentados respectivamente nas Figuras 2.9 e 2.10. Em cada caso, são apresentados os sinais referentes as saídas dos filtros passa-baixa e passa-alta para as duas primeiras escalas.

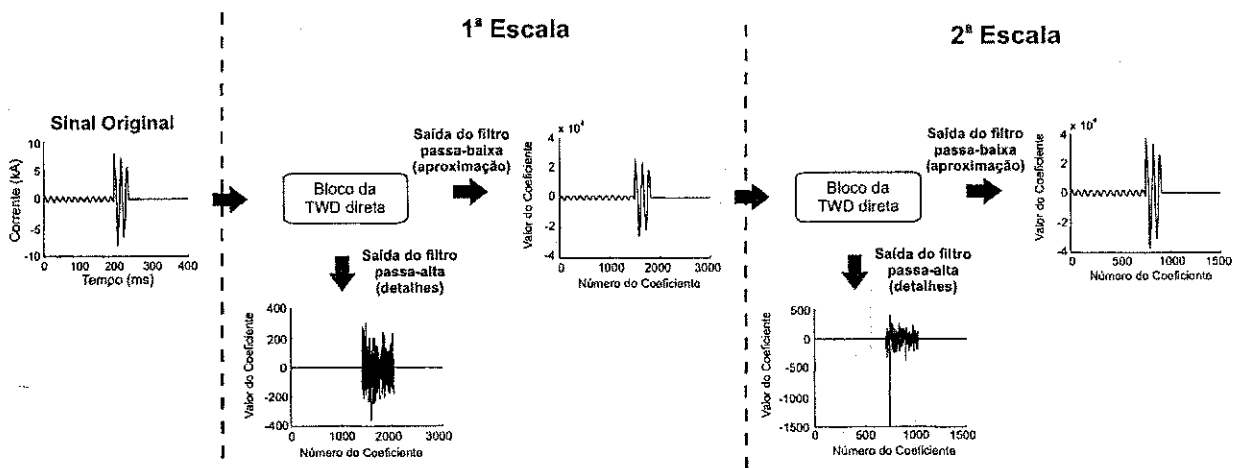


Figura 2.9. Exemplo de aplicação da TWD direta.




Figura 2.10. Exemplo de aplicação da TWD inversa.



# MÉTODO PROPOSTO

A descrição do método proposto para a detecção e classificação de faltas em LTs é apresentada nesse capítulo. O algoritmo deve ser implementado nos computadores utilizados na coleta dos registros capturados pelos RDPs. Dessa forma, podem ser realizadas a pré-análise e a triagem daqueles registros que não correspondem a uma falta, evitando que os mesmos sejam transferidos até o servidor central da oscilografia.

O método proposto é avaliado para todos os registros capturados pelos RDPs. Ele é dividido basicamente em dois módulos: *detecção* e *classificação*.

Inicialmente, no módulo de detecção, os campos do registro correspondentes aos canais analógicos do RDP são lidos. Em seguida, aplica-se a TWD apenas às correntes, obtendo-se os coeficientes wavelet de detalhe da primeira escala de resolução. Avalia-se então um conjunto de regras sobre esses coeficientes para identificar se o registro corresponde a uma falta. Caso nenhuma falta seja detectada, o algoritmo é finalizado e a transferência do registro até o servidor central não é realizada. Entretanto, se uma falta for detectada, seus instantes inicial e final são identificados, a partir da avaliação de um segundo conjunto de regras.

No módulo de classificação, todas as amostras de tensão e corrente referentes ao intervalo de falta, delimitado na fase de detecção, são normalizadas pelos seus respectivos valores máximos no registro. Em seguida, realiza-se a reamostragem desses sinais convertendo-os da frequência de amostragem original do RDP para uma frequência padrão de 1200 Hz. Um processo de janelamento é empregado ao intervalo de falta já reamostrado e cada janela de amostras obtida é apresentada a uma RNA, que indicará qual é o tipo de falta associado àquelas amostras. O tipo de falta mais identificado pela RNA após a avaliação de todas as janelas de amostras é o que prevalece e o que constará no relatório de saída.

A Figura 4.6 é uma representação do método proposto. Considera-se que o processo de verificação e coleta automática dos registros dos RDPs já esteja implementado.

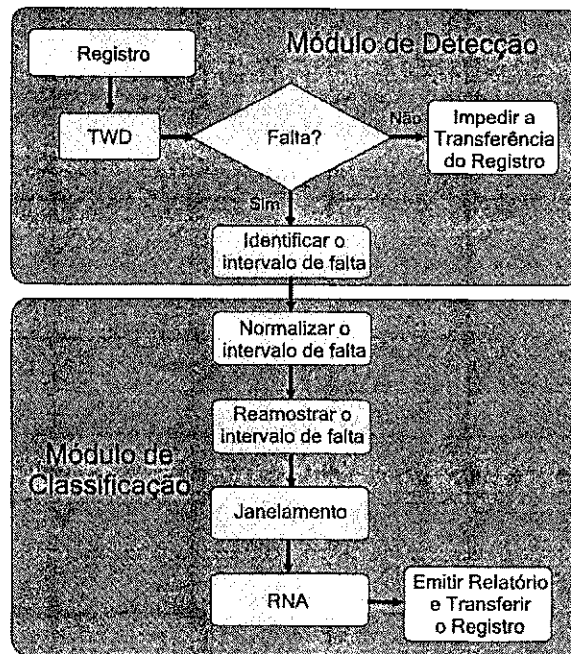


Figura 3.1. Diagrama de blocos do método proposto.

### 3.1 MÓDULO DE DETECÇÃO

As regras para a detecção da falta e de seu intervalo de duração são criadas a partir da observação das correntes em diversas situações reais de operação do sistema para diversas LTs. Isso porque as correntes, em geral, representam melhor uma falta (BRITO, 1996).

#### 3.1.1 Regras para a Detecção da Falta

Diversas ocorrências além das faltas são consideradas para estabelecer as regras de detecção, tais como: afundamentos de tensão, transitórios de chaveamento, energizações e desligamentos de LTs. De fato, qualquer registro no qual não seja identificada uma falta é classificado como sem falta e sua transferência até o servidor central não deve ser permitida.

Em transmissão, a maioria dos afundamentos de tensão verificados em uma LT são ocasionados por faltas em outras LTs. Em alguns casos, a incidência de componentes de alta frequência nos sinais de tensão e corrente é forte e aumenta à medida que a LT na qual ocorreu a falta esteja mais próxima. Dessa forma, além da análise dos coeficientes wavelet, para diferenciar uma falta de um afundamento de tensão é necessária análise das correntes no domínio do tempo.

No caso de energizações, os coeficientes wavelet das correntes associados às altas frequências são, em alguns casos, da mesma ordem de grandeza que os de uma falta. Esse comportamento depende das condições nas quais a linha é energizada.

Para transitórios de chaveamento e desligamentos de LTs, os coeficientes wavelet das correntes associados às altas frequências são, de um modo geral, muito inferiores aos de uma falta. Isso permite que esses distúrbios sejam facilmente diferenciados de uma falta apenas analisando os coeficientes wavelet de detalhe das correntes.

Nas Figuras de 3.2 a 3.6 são apresentadas as correntes no domínio do tempo e seus respectivos coeficientes wavelet de detalhe para alguns tipos de registros.




Figura 3.2. Falta monofásica na fase C: (a) correntes no domínio do tempo; (b) coeficientes wavelet.




Figura 3.3. Afundamento de tensão: (a) correntes no domínio do tempo; (b) coeficientes wavelet.




Figura 3.4. Transitório de chaveamento: (a) correntes no domínio do tempo; (b) coeficientes wavelet.




Figura 3.5. Energização de uma LT: (a) correntes no domínio do tempo; (b) coeficientes wavelet.




Figura 3.6. Desligamento de uma LT: (a) correntes no domínio do tempo; (b) coeficientes wavelet.

As regras utilizadas na etapa de detecção da falta são as seguintes:

1. Se  $C_{max} < C^*$  então o registro não corresponde a uma falta.
2. Se  $C_{max} \geq C^*$ ,  $I_{pre} \approx 0$  e  $I_{pos} > I_m$  então o registro não corresponde a uma falta.
3. Se  $C_{max} \geq C^*$  e  $|I_{pre} - I_{pos}| < 0,2I_{pre}$  então o registro não corresponde a uma falta.
4. Se  $C_{max} \geq C^*$  e se as demais regras não foram satisfeitas então o registro corresponde a uma falta.

Sendo  $C_{max}$  o máximo valor absoluto dentre os coeficientes wavelet de primeira escala das correntes;  $C^*$  um valor pré-estabelecido empiricamente, a partir da observação dos coeficientes wavelet das correntes em diversas situações de operação real do sistema;  $I_{pre}$  e  $I_{pos}$ , respectivamente, os valores de pico das correntes nas fases no primeiro e no último ciclos registrados, considerando a frequência fundamental de 60 Hz;  $I_m$  um valor padrão estabelecido, que é associado a corrente normal de operação do sistema numa situação de carga leve.

A regra 1 é relacionada aos desligamentos de LTs, transitórios de chaveamento e a outros distúrbios que podem ser registrados, mas que não apresentam uma forte incidência de componentes de alta frequência nos sinais de tensão e corrente. Por outro lado, as regras 2 e 3 estão relacionadas, respectivamente, a registros de energizações de linhas e a afundamentos de tensão.

### 3.1.2 Determinação do Intervalo de Falta

Analisando-se um registro real que corresponda a uma falta, em geral, observam-se três situações nas quais os sinais de tensão e corrente se comportam de modos distintos: as etapas de *pré-falta*, *falta* e *pós-falta* (Figura 3.7) (RODRIGUES et al., 2003).

A etapa de pré-falta consiste nas amostras do registro referentes ao intervalo de tempo no qual o sistema está em operação normal em regime permanente. A segunda etapa consiste no intervalo no qual o sistema encontra-se em situação de falta. A etapa de pós-falta refere-se a parte do registro que indica o comportamento do sistema após a atuação da proteção. A




Figura 3.7. Registro real com a indicação das etapas de pré-falta, falta e pós-falta.

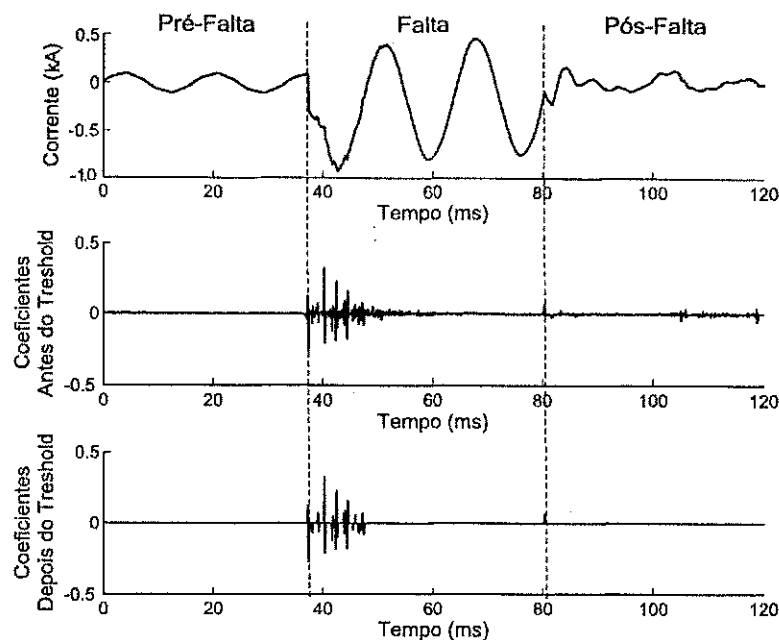
tarifa fácil, principalmente o instante final, quando pode ocorrer a incidência de componentes de alta frequência que são amortecidos lentamente.

A determinação da duração da etapa de falta é feita a partir da análise dos coeficientes wavelets de detalhe das correntes na primeira escala de resolução da TWD. Nesse momento, é importante a análise da componente de seqüência zero, já que esse sinal pode indicar de forma clara o envolvimento da terra na falta.

Para aumentar a precisão na determinação da duração da falta, os coeficientes wavelet são filtrados empregando-se a técnica de *hard wavelet threshold*, considerando-se um limiar de 10 % do maior coeficiente em valor absoluto para cada uma das correntes (Figura 3.8) (BRITO, 2001).

$$c_k = \begin{cases} c_k, & \text{se } |c_k| \geq (1 - u)C_{max} \\ 0, & \text{se } |c_k| < (1 - u)C_{max} \end{cases} \quad (3.1)$$

sendo  $u$  uma constante que pode variar no intervalo  $[0, 1]$  e define o ponto de aplicação do *threshold*;  $c_k$  o  $k$ -ésimo coeficiente wavelet e  $C_{max}$  o maior coeficiente wavelet em valor absoluto.



**Figura 3.8.** Sinal de corrente em uma falta e os respectivos coeficientes wavelet de detalhe da primeira escala de resolução, antes e depois da filtragem.

Para determinar as amostras inicial e final do distúrbio foi elaborado o seguinte algoritmo:

1. Identificar o índice do primeiro coeficiente diferente de zero para cada uma das correntes de fase e de seqüência zero.
2. O índice do coeficiente inicial da falta é definido como sendo aquele associado ao maior índice dentre os determinados no passo 1.
3. Identificar o índice do último coeficiente diferente de zero para cada uma das correntes de fase.
4. O índice do coeficiente final da falta é definido como sendo aquele associado ao maior índice dentre os determinados no passo 3.
5. Identificar o índice do último coeficiente diferente de zero para a componente de seqüência zero das correntes.
6. Se o índice obtido pela regra 4 for maior que o obtido na regra 5, então o índice do coeficiente final da falta passa a ser o determinado na regra 5.
7. As amostras inicial e final da falta são determinadas, respectivamente, como o dobro do índice dos coeficientes inicial e final da falta (processo de sobreamostragem).

Na Figura 3.9 são apresentados os coeficientes wavelet de detalhe das correntes após a filtragem. Nesse caso, os índices dos coeficientes inicial e final são, respectivamente, 230 e 653. Isto significa que as amostras inicial e final são, respectivamente, 460 e 1306. A frequência de amostragem do RDP é de 15360 Hz, o que implica que os instantes inicial e final da falta são, respectivamente, 30 ms e 85 ms.

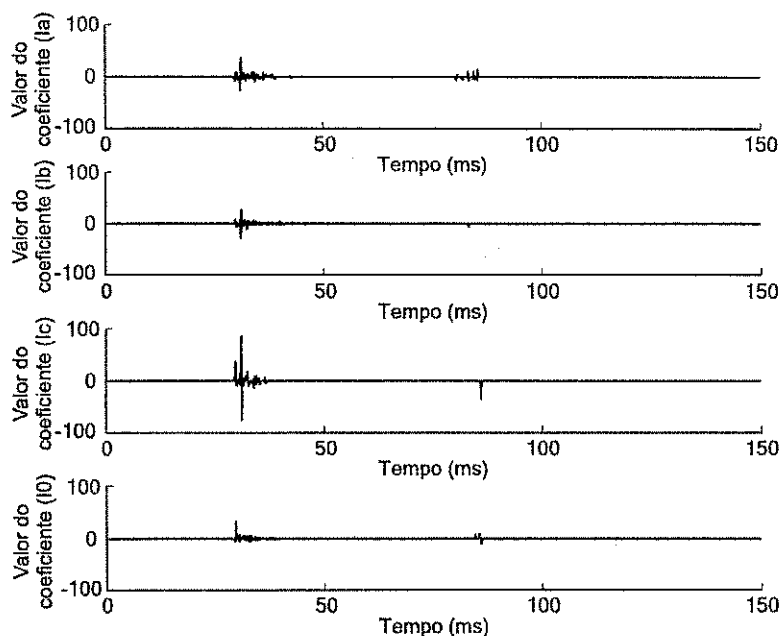


Figura 3.9. Coeficientes wavelet das correntes após a filtragem.

## 3.2 MÓDULO DE CLASSIFICAÇÃO

O módulo de classificação é dividido basicamente em quatro etapas: normalização das tensões e correntes; reamostragem das tensões e correntes; janelamento das amostras; e de classificação da falta. A descrição de cada uma dessas etapas é apresentada nessa seção.

### 3.2.1 Normalização das Tensões e Correntes

Para classificar um tipo de falta, o especialista observa a forma dos sinais, suas tendências de crescimento e decrescimento e as relações entre eles. A priori, ele não leva em consideração os valores extremos das tensões e correntes no sistema, informações de relevância para a localização da falta. Além do mais, a principal diferença entre uma falta que ocorra no início da linha e outra no final da linha, é a amplitude das correntes. Desse modo, a partir da normalização dos



sinais de tensão e corrente em relação aos seus valores máximos em um registro, faltas ocorridas em locais distintos da linha podem ser analisadas indistintamente.

O módulo de normalização tem, basicamente, a função de uniformizar os critérios empregados aos casos simulados, necessários para a construção da base de dados de treinamento da RNA, e aos registros capturados pelos RDPs. Com isso, a diferença na amplitude dos transitórios entre as situações reais e simuladas torna-se irrelevante.

Outra vantagem desse tipo de normalização é que registros provenientes de diferentes linhas de transmissão, até mesmo de classes de tensão diferentes, que a princípio possuem níveis de curto-circuito diferentes, poderão ser avaliados indistintamente.

### 3.2.2 Reamostragem do Intervalo de Falta

As características relevantes ao problema de classificação de faltas, estão presentes principalmente nas componentes de baixa frequência dos sinais de tensão e corrente. As componentes de alta frequência têm pouca importância no diagnóstico (NEVES et al., 2004). No entanto, a maioria dos RDPs empregados atualmente possuem taxas de amostragem típicas que variam de 20 amostras/ciclo à 256 amostras/ciclo. Nesse momento, é proposta uma etapa de reamostragem dos sinais provenientes dos RDPs. Com isso, espera-se que a classificação da falta por parte da RNA seja facilitada, já que serão apresentadas amostras em menor número, mas suficientes para que ela consiga distinguir as características de cada tipo de falta.

O processo de reamostragem é aplicado aos sinais de tensão e corrente, referentes apenas ao intervalo de falta delimitado. Ele consiste da conversão da amostragem do sinal na sua frequência original (frequência do RDP) para uma frequência padrão de 1200 Hz, que é a menor frequência de amostragem dos RDPs disponíveis na CHESF. Esse processo é realizado considerando-se um passo constante  $\Delta_{Reamostragem}$  (Figura 3.10) determinado como:

$$\Delta_{Reamostragem} = \frac{f_{RDP}}{1200}, \quad (3.2)$$

sendo  $f_{RDP}$  a frequência original do RDP em Hz.




Figura 3.10. Exemplo de um sinal na frequência original do RDP (15360 Hz) e reamostrado (1200 Hz), utilizando-se um passo de reamostragem constante  $\Delta_{Reamostragem} = 12,8 \approx 13$ .

### 3.2.3 Janelamento das Tensões e Correntes

O processo de janelamento consiste em agrupar 5 amostras consecutivas das tensões e correntes, em grandeza de fase e de seqüência zero, em um único padrão de entrada para a RNA. A janela de dados é tida como móvel, já que percorre as amostras dos sinais referentes ao intervalo de falta delimitado, deslocando-se ao passo de uma amostra (Figura 3.11).

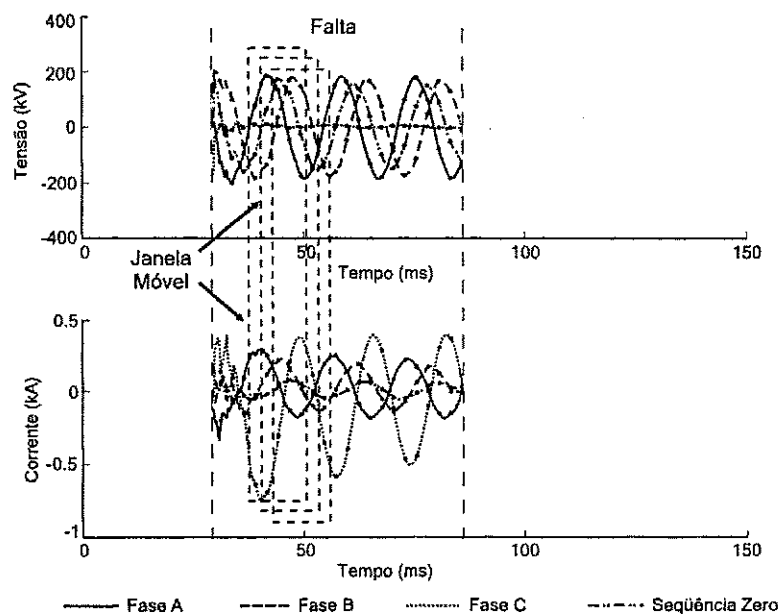


Figura 3.11. Processo de janelamento dos sinais de tensão e corrente.

A idéia de apresentar a RNA uma seqüência de amostras consecutivas dos sinais de tensão e corrente, em grandeza de fase e de seqüência zero, é fazer com que a rede consiga assimilar as características de cada tipo de falta. Assim como um especialista, ela deve ser capaz de identificar as tendências de crescimento e decrescimento das tensões e correntes de cada tipo de falta.

### 3.2.4 Classificação da Falta

Nessa etapa, cada uma das janelas obtidas no processo de janelamento é apresentada a uma RNA do tipo MLP. Essa por sua vez, deve identificar o tipo de falta à qual a janela de dados se refere.

O critério para a classificação da falta registrada pelo RDP consiste basicamente em identificar o tipo que possui o maior número de indicações pela RNA, ao avaliar todos os padrões de entrada originados no processo de janelamento. Essa estratégia garante que, mesmo que a RNA cometa erro, na grande maioria das vezes o diagnóstico do registro seja correto.

Para treinar a RNA, é necessária a criação de um conjunto de exemplos que representem significativamente a aplicação em questão, ou seja, um conjunto de sinais de tensão e corrente que contemple uma grande variedade de situações de falta às quais um sistema pode estar sujeito. Como essa diversidade não é encontrada em registros reais, casos de faltas simulados são utilizados.

As variáveis de simulação consideradas são a localização da falta, o ângulo de incidência e a resistência de falta. A combinação dessas variáveis origina os cenários de falta. Em todos os cenários simulados, a frequência de amostragem utilizada é 1200 Hz. Além disso, o tempo de simulação da falta é de 3 ciclos. Essa escolha é baseada no tempo esperado de atuação da proteção, que tipicamente varia de 3 a 8 ciclos (PHADKE & THORP, 1990). Na verdade, em cada cenário foram simuladas apenas as etapas de pré-falta e de falta.

Além dos casos simulados, também devem ser selecionados registros reais de faltas em diversas LTs para serem incorporados a base de dados da RNA. Essa estratégia tenta fazer com que a RNA adquira a capacidade de generalização na fase de aprendizado e consiga classificar corretamente as situações simuladas e as reais.

Em ambos os casos, simulados e reais, o intervalo de falta deve ser precisamente determinado e as etapas de normalização, reamostragem e janelamento devem ser executadas. Para a indicação da saída desejada da RNA para cada padrão de entrada dos conjuntos de treinamento, validação e teste é utilizado um esquema de codificação binário conforme apresentado na Tabela 3.1, com o termo *normal* tendo a conotação de operação normal do sistema.

Tipo de Falta	Fase A Saida 1	Fase B Saida 2	Fase C Saida 3	Terra Saida 4
AT	1	0	0	1
BT	0	1	0	1
CT	0	0	1	1
AB	1	1	0	0
AC	1	0	1	0
BC	0	1	1	0
ABT	1	1	0	1
ACT	1	0	1	1
BCT	0	1	1	1
ABC	1	1	1	0
Normal	0	0	0	0

**Tabela 3.1.** Esquema de codificação das respostas desejadas da RNA.

# CONCEPÇÃO E AVALIAÇÃO DO MÉTODO PROPOSTO

Na concepção do método proposto, além da fase de aprendizado da RNA, é necessária a determinação das constantes que compõe as regras de detecção, a partir da análise de diversos registros oscilográficos reais obtidos do banco de dados de oscilografia da CHESF.

O método foi implementado utilizando-se a linguagem de programação C++ e foi avaliado em três situações distintas:

- Com registros simulados no software ATP.
- Com os registros simulados por um sistema de teste de relés de proteção<sup>1</sup>.
- Com registros reais em linhas do sistema de transmissão da CHESF.

Dois critérios de avaliação são considerados: o diagnóstico do registro e a identificação do intervalo de falta. Alguns resultados obtidos são reportados nesse capítulo.

## 4.1 CONCEPÇÃO DO MÉTODO

### 4.1.1 Regras de Detecção

Para a determinação das constantes empregadas nas regras de detecção foram considerados diversos registros oscilográficos referentes a LTI de 230 kV. Após a análise das correntes nos domínios do tempo e wavelet, o valor da constante  $C^*$  foi estabelecido como 70, por ser um valor que distingue a maioria dos registros de faltas daqueles associados a distúrbios de QEE e a operações de rotina na manutenção do sistema (desligamentos e energizações programadas

---

<sup>1</sup> Equipamento empregado para calibração de relés de proteção, a partir da geração de tensões e correntes em níveis secundários de TP e TC.

de LTs). Por outro lado, a constante  $I_m$  foi escolhida como 150 A, por ser um valor associado a corrente de pico em regime de carga leve na maioria das LTs de 230 kV analisadas.

A wavelet mãe utilizada foi a Daubechies 4, por ser bastante difundida em aplicações de análise de fenômenos transitórios elétricos.

#### 4.1.2 Aprendizado da RNA

Para a simulação das faltas que compõem a base de dados de aprendizado da RNA escolheu-se a LT 04V4 de 230 kV e 188 km, localizada entre as subestações CGD e NTD, pertencentes ao subsistema Leste de transmissão da CHESF (Figura 4.1). O sistema foi modelado e simulado utilizando-se o software ATP (LEUVEN EMTP CENTER, 1987). Nesse modelo são considerados os parâmetros distribuídos e independentes da frequência e o nível de carga do sistema como sendo o máximo (BRITO et al., 2004). O ponto de monitoramento é considerado na subestação CGD.

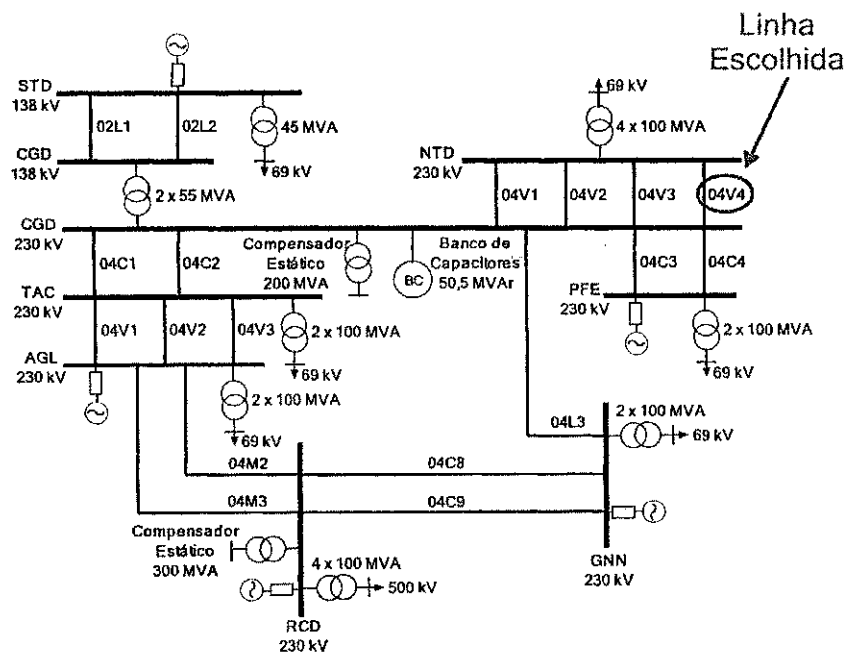


Figura 4.1. Diagrama unifilar simplificado do trecho do subsistema Leste de transmissão da CHESF, ao qual pertence a LT 04V4.

Na formação da base de dados são consideradas diversas combinações das variáveis de simulação (localização da falta, ângulo de incidência e resistência de falta), conforme apresentado na Tabela 4.1. Ao total, são simulados 360 cenários de falta (*18 localizações x 1 ângulo de*

incidência  $\times$  [4 tipos de falta entre fases  $\times$  2 resistências para faltas entre fases + 6 tipos de falta entre fases e a terra  $\times$  2 resistências para faltas entre fases e a terra]). Como na geração de cada cenário são simulados 3 ciclos de falta (3  $\times$  16,667 ms) e a frequência de amostragem empregada é de 1200 Hz (20 amostras/ciclo), há 60 amostras de falta em cada cenário. Devido ao janelamento de 5 amostras consecutivas adotado, cada cenário origina 56 janelas ou padrões de entrada para a RNA, perfazendo o total de 20160 padrões simulados, que são distribuídos nos conjuntos de treinamento, validação e teste.

Variáveis de simulação	Treinamento	Validação	Teste
Locais de falta (km)	20-30-50-60-80-90 110-120-140-150	10-70-130-160	40-100-160-180
Resistência de falta ( $\Omega$ )	Fase-Fase: 1 e 10 Fase-Terra: 50 e 100		
Ângulo de incidência ( $^\circ$ )	150		
Tipos de falta	AT-BT-CT-AB-AC-BC-ABT-ACT-BCT-ABC		
Total de padrões	11200	4480	4480

Tabela 4.1. Conjunto de variáveis utilizadas na simulação da LT 04V4.

Os registros de faltas reais utilizados para o aprendizado da RNA são referentes a faltas em diversas LTs do sistema de transmissão da CHESF. Em cada caso, os processos de normalização, reamostragem e janelamento são aplicados apenas ao intervalo de falta. Isso garante que os padrões originados nesse processo estejam convertidos para a frequência de 1200 Hz e normalizados pelos máximos valores de tensão e corrente de cada registro, da mesma forma que os padrões simulados.

Diferentes registros reais são escolhidos para serem incorporados aos conjuntos de treinamento, validação e teste, evitando-se que os mesmos padrões sejam adicionados a dois conjuntos distintos. Ao final, os padrões são distribuídos conforme apresentado na Tabela 4.2.

Tipo dos padrões	Número de padrões		
	Treinamento	Validação	Teste
Simulados	11200	4480	4480
Reais	3316	2163	3928
	<b>14516</b>	<b>6643</b>	<b>8408</b>

Tabela 4.2. Distribuição dos padrões nos conjuntos de treinamento, validação e teste.

Devido à natureza senoidal dos sinais, utiliza-se a função de ativação tangente hiperbólica para os neurônios das camadas ocultas, já que essa função possui uma saída definida no intervalo  $[-1,1]$ . Em contra partida, a saída da RNA deve ser, de acordo com a codificação adotada, de natureza binária. Uma função de ativação de *limiar brusco*, que apresenta como saída ou 0 ou 1, a princípio se adapta a esta situação, mas é contra indicada em razão de seu caráter descontínuo. Assim, a função sigmóide é escolhida para os neurônios na camada de saída, por ser uma função contínua que assume valores no intervalo  $[0,1]$ .

O número de neurônios na camada de entrada é fixo em 40, devido ao processo de janelamento empregado. Isso acontece também na camada de saída, onde o número de neurônios é definido como 4 devido a codificação adotada para a saída da RNA. Resta definir o número de camadas ocultas e o número de neurônios em cada uma delas. No entanto, após vários testes, constatou-se que apenas uma camada oculta é suficiente para a classificação da falta.

A configuração da RNA que apresentou uma maior porcentagem de acerto para o conjunto de teste possui 30 neurônios na camada oculta.

O tempo de treinamento foi cerca de 49 minutos empregando-se um computador athlon 1.0 GHz - 384 Mb. Foram necessárias 426 épocas para atingir um erro médio quadrático de 0,002 para o conjunto de validação e uma porcentagem de acerto de 99,83 % na classificação dos padrões do conjunto de teste. O algoritmo de treinamento utilizado foi o RPROP (SOUZA et al., 2004b). A Figura 4.2 é uma representação das curvas do erro médio quadrático para os conjuntos de treinamento e validação nas 180 primeiras épocas de treinamento.




Figura 4.2. Erro médio quadrático para os conjuntos de treinamento e validação.



## 4.2 AVALIAÇÃO DO MÉTODO

### 4.2.1 Registros Simulados no ATP

Nessa etapa, foram simulados 720 cenários de faltas diferentes dos que foram utilizados na fase de aprendizado da RNA (Tabela 4.3). Cada um deles foi avaliado e obteve-se um percentual de acerto de 100 % na classificação do tipo de falta de todos os registros. Quanto a identificação do intervalo de falta, nesse caso só foi possível avaliar a determinação do seu início, já que não foi considerada nas simulações a etapa de pós-falta. O erro máximo encontrado na indicação do início da falta foi de 2 ms.

Variáveis de simulação	Cenários de falta
Locais de falta (km)	10-20-30-40-50-60-70-80-90 100-110-120-130-140-150-160-170-180
Resistência de falta ( $\Omega$ )	Fase-Fase: 0,1 e 5 Fase-Terra: 30 e 80
Ângulo de incidência ( $^\circ$ )	60 e 120
Tipos de falta	AT-BT-CT-AB-AC-BC-ABT-ACT-BCT-ABC

**Tabela 4.3.** Conjunto de variáveis utilizadas na simulação da LT 04V4.

### 4.2.2 Registros Simulados por um Sistema de Teste de Relés de Proteção

Um experimento foi realizado para verificar o desempenho do método proposto, quando integrado a um sistema de monitoramento de uma LT. O esquema da montagem do experimento é apresentado na Figura 4.3. Um sistema de teste de relés de proteção foi utilizado para a geração de sinais referentes a uma grande diversidade de faltas (FREJA, 2004). De fato, esse experimento é uma tentativa de reproduzir o funcionamento do sistema de monitoramento da LT 04V4, já que o computador e o RDP utilizados possuem a mesma configuração e parametrização dos equipamentos instalados na subestação CGD. Na Figura 4.4 é apresentada uma fotografia da montagem real realizada nas dependências da CHESF.




Figura 4.3. Representação da montagem do experimento.




Figura 4.4. Fotografia da montagem do experimento.

O procedimento de programação do equipamento consiste basicamente em informar os valores das tensões e correntes, em módulo e fase, referentes as etapas de pré-falta e falta que se deseja simular e escolher o tempo de simulação de cada umas dessas etapas (Figura 4.5). As informações dos módulos e fases das tensões e correntes são obtidas mediante simulações de faltas na LT 04V4 utilizando-se o software ATP, considerando um ângulo de incidência de  $60^\circ$ , uma resistência de falta de  $0,1 \Omega$  e diversas localizações de falta. O desempenho do método é apresentado na Tabela 4.4.




Figura 4.5. Janela do software de programação do equipamento.

Tipo da falta	Número de registros avaliados	Diagnósticos corretos
AT	4	4
BT	4	4
CT	7	7
AB	7	5
AC	5	4
BC	5	4
ABT	6	6
ACT	7	7
BCT	6	6
ABC	5	5
	56	52

Tabela 4.4. Resultados para os registros simulados pelo sistema de teste de relés de proteção.

A partir dos resultados apresentados na Tabela 4.4, percebe-se que os diagnósticos incorretos estão associados apenas a faltas bifásicas sem o envolvimento da terra. De fato, foram constatadas algumas anormalidades nas componentes de seqüência zero das tensões e correntes nesses casos. A causa mais provável está relacionada aos canais de corrente do equipamento. Como as componentes de seqüência não podem ser medidas diretamente, o próprio RDP disponibiliza uma rotina de cálculo das mesmas, que consiste simplesmente de somar as amostras das tensões e correntes nas três fases para se obter. Na verdade, o fato é que devido a

problemas com os canais de corrente do equipamento, a variação da componente de seqüência zero quando da ocorrência de faltas bifásicas, que a princípio deveria ser insignificante frente as outras correntes de fase, algumas vezes era da mesma ordem de grandeza que elas. Mesmo assim, na maioria dos casos a classificação não foi comprometida. Por outro lado, para todos os registros avaliados o critério de determinação do início da falta foi eficiente, apresentado um erro máximo de 2 ms. Já para o instante final da falta, no pior caso o erro foi de 33 ms, mas na maioria deles ele foi determinado com exatidão.

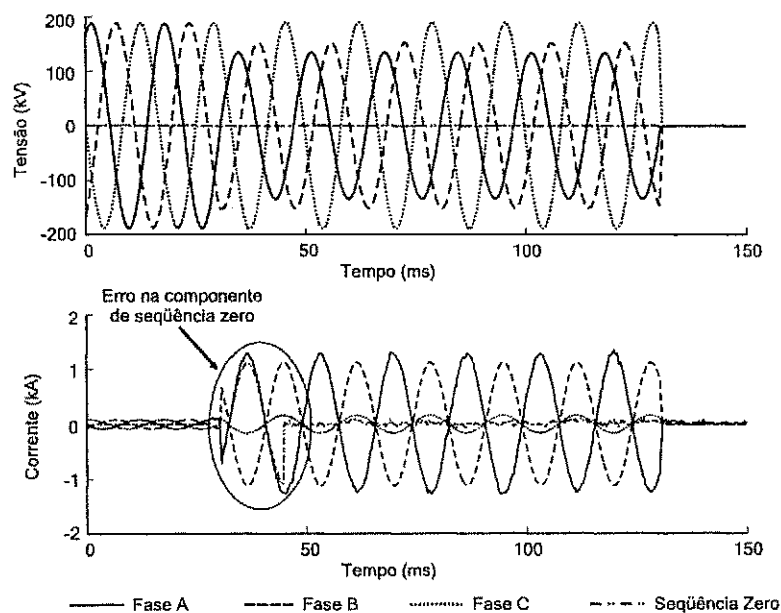


Figura 4.6. Registro que apresenta anormalidade na componente de seqüência zero das correntes.

Para avaliar a capacidade de generalização da RNA e a robustez do método, foi realizado o seguinte teste: tentar diagnosticar faltas com valores de resistência duas vezes maiores que o maior valor utilizado para a geração da base de dados de aprendizado da RNA.

A depender do valor da resistência de falta, em faltas que envolvam a terra, as tensões podem praticamente não variar e o transitório nas correntes ser suave, o que dificulta a classificação.

Os resultados obtidos são apresentados na Tabela 4.5. Foram consideradas resistências de 1, 5 e 10  $\Omega$  para faltas entre fases e 50, 100 e 200  $\Omega$  para faltas entre fases e a terra. O ângulo de incidência utilizado foi de 60° e foram simuladas faltas apenas a 100 e 150 km da subestação CGD. Nesse caso, os erros obtidos foram associados a deformação nas tensões devido aos valores de resistência utilizados. O maior erro na determinação do instante inicial da falta foi de 3 ms, enquanto que o final foi de 10 ms.

Tipo da falta	Número de registros avaliados	Diagnósticos corretos
AT	3	2
BT	3	3
CT	3	3
AB	6	6
AC	3	3
BC	3	3
ABT	6	5
ACT	3	3
BCT	3	3
ABC	6	6
	<b>39</b>	<b>37</b>

Tabela 4.5. Resultados para faltas com vários valores de resistência.

#### 4.2.3 Registros Reais do Sistema de Transmissão da CHESF

Além de faltas, afundamentos de tensão, transitórios de chaveamento, desligamentos e energizações de LTs, há diversos outros distúrbios que também podem ser registrados pelos RDPs. Por exemplo, anormalidades na componente de seqüência zero das correntes, geralmente provocadas por defeitos na isolação de algum equipamento que acarreta a circulação de corrente para a terra. Há também registros nos quais não é visualmente possível identificar o distúrbio, mas por algum motivo o RDP registrou os sinais mesmo assim.

Na Tabela 4.6, são apresentados os resultados para registros reais na LT 04V4.

Diagnóstico real	Número de registros avaliados	Diagnósticos corretos
Sem defeito perceptível	109	109
Anormalidade em $I_0$	17	17
Afundamentos de tensão	16	15
Transitórios de chaveamento	10	10
Desligamento da LT	19	19
Energização da LT	19	19
Falta monofásica na fase C	1	1
	<b>191</b>	<b>190</b>

Tabela 4.6. Resultados para os registros reais na LT 04V4.

Notadamente, só foi encontrado um registro com falta na LT 04V4, que foi classificado corretamente e os instantes de início e fim da falta foram determinados com exatidão, obtendo-se um erro de 1 ms e 3 ms, respectivamente.

Para avaliar o desempenho do método para outras LTs, foram utilizados registros reais referentes a LTs localizadas em outras áreas do sistema de transmissão da CHESF e até mesmo de outros níveis de tensão. Os resultados para as linhas de 230 kV e 500 kV são apresentados, respectivamente, nas Tabelas 4.7 e 4.8.

Diagnóstico real	Número de registros avaliados	Diagnósticos corretos
Sem defeito perceptível	27	27
Afundamentos de tensão	28	28
Transitórios de chaveamento	2	2
Desligamento da LT	1	1
Energização da LT	2	2
Falta monofásica na fase A	2	2
Falta monofásica na fase B	7	6
Falta monofásica na fase C	6	5
Falta bifásica entre as fases A e B	1	1
	<b>76</b>	<b>74</b>

Tabela 4.7. Resultados para outras LTs de 230 kV.

Diagnóstico real	Número de registros avaliados	Diagnósticos corretos
Sem defeito perceptível	6	6
Afundamentos de tensão	19	18
Transitórios de chaveamento	3	3
Desligamento da LT	4	4
Energização da LT	1	1
Falta monofásica na fase A	5	5
Falta monofásica na fase B	6	5
Falta monofásica na fase C	1	1
	<b>45</b>	<b>43</b>

Tabela 4.8. Resultados para outras LTs de 500 kV.

Observa-se que mesmo com as regras sendo elaboradas tomando por base LTs de 230 kV, a detecção de faltas em LTs de 500 kV foi, de um modo geral, bem sucedida. Por outro lado,

verificou-se que a classificação foi falha para algumas faltas. Isso se deve ao fato de que as simulações de faltas nem sempre condizem com a realidade encontrada em registros reais, o que pode comprometer, em alguns casos, o desempenho da RNA.

As regras para a determinação da duração da falta em alguns casos foi imprecisa, principalmente na indicação do instante final, apresentando erro máximo de 33 ms. Mesmo assim, a classificação nesses casos não foi comprometida. Esse resultado é atribuído ao fato de que quando ocorre erro na indicação do instante final da falta, há padrões que serão apresentados a RNA referentes a etapa de pós-falta, que, na maioria das vezes, são classificados como sem falta.

# CONCLUSÕES

Um método de diagnóstico de faltas foi desenvolvido e implementado para LTs de 230 kV do sistema de transmissão da CHESF. Contudo, seu desempenho também foi avaliado para outras LTs de níveis de tensão diferentes e resultados satisfatórios foram obtidos.

A principal contribuição do método está relacionada à pré-análise e triagem dos registros capturados pelos RDPs. De fato, um novo conceito de oscilografia foi considerado. Além da situação normal de operação em regime permanente do sistema, as faltas foram diferenciadas de distúrbios associados à QEE e de operações de manobra para manutenção do sistema.

O algoritmo de determinação da duração da falta foi sempre bem sucedido na indicação do instante inicial. No entanto, em alguns casos, a determinação do instante final apresentou erro significativo. Mesmo assim, a classificação não foi comprometida nesses casos.

Apesar dos resultados evidenciarem uma possível generalização das regras de detecção, elas ainda não podem ser tidas como gerais. Outras regras devem ser incorporadas ao método, contemplando outros tipos de distúrbios em diferentes LTs, tornando seu diagnóstico mais robusto. Dessa forma, são propostos como trabalhos futuros:

1. Estudar de forma mais detalhada a capacidade de generalização do método proposto, no que diz respeito a detecção e classificação de faltas em outras LTs.
2. Diagnosticar os registros que não tenham sido associados com faltas, identificando os registros das operações de manutenção e classificando aqueles associados à QEE.
3. Melhorar o critério de determinação dos instantes de início e fim da falta, de forma a também analisar faltas evolutivas, identificando o intervalo de duração de cada tipo presente no registro.
4. Utilizar um conjunto de regras *fuzzy* para diminuir as incertezas nas etapas de detecção e classificação da falta.



## REFERÊNCIAS BIBLIOGRÁFICAS

BRITO, N. S. D. *Teoria Wavelet e Sua Aplicação em Sistemas de Energia Elétrica*. Dissertação (Mestrado) — Universidade Estadual de Campinas, Campinas, 1996.

BRITO, N. S. D. *Teoria das Wavelets - Estudo e Aplicação na Análise de Transitórios em Sistemas de Potência*. Tese (Doutorado) — Universidade Federal da Paraíba, Campina Grande, 2001.

BRITO, N. S. D.; NEVES, W. L. A.; SOUZA, B. A.; DANTAS, K. M. C.; FONTES, A. V.; COSTA, F. B.; FERNADES, A. B.; SILVA, S. S. B. Influência do modelo de linhas de transmissão no diagnóstico de faltas. *Transmission and Distribution Latin America Conference*, São Paulo, Ago. 2004.

BURRUS, C. S.; RAMESH, A. G.; GUO, H. *Introduction to Wavelets and Wavelet Transforms*. New Jersey, USA: Prentice Hall, 1998.

DAUBECHIES, I. The wavelet transform, time-frequency localization and signal analysis. *IEEE Transactions on Information Theory*, v. 36, n. 5, p. 961–1005, Sep. 1990.

DAUBECHIES, I. *Ten Lectures on Wavelets*. Philadelphia, USA: CBMS-NSF Regional Conference Series, SIAM, 1992.

DAUSTEN, T.; KULIEKE, B. Neural network approach to fault classification for high speed protective relaying. *IEEE Transactions on Power Delivery*, v. 10, n. 2, p. 1002–1009, Apr. 1995.

FREJA. *FREJA 300/FREJA Win 4.0: Sistema de Teste de Relé - Manual do Usuário*, 2004.

GIOVANINI, R.; COURRY, D. V. Classificação rápida de faltas em sistemas elétricos utilizando redes neurais artificiais. *Congresso Brasileiro de Redes Neurais*, São José do Campos, p. 281–286, Jul. 1999.

HAYKIN, S. *Redes neurais, princípios e prática*. 2a. ed. Porto Alegre: Bookman, 2001.

IEEE POWER SYSTEM RELAYING COMMITTEE. *IEEE Standard Common Format for Transient Data exchange (COMTRADE) for Power Systems*. New York, USA, 1991.

JIANG, J.-A.; FAN, P.-L.; CEN, C.-S.; YU, C.-S.; SHEU, J.-Y. A fault detection and faulted-phase selection approach for transmission lines with haar wavelet transforms. *Proc. 2003 IEEE/PES Transmission and Distribution Conf. and Exp.*, v. 1, p. 285–289, Dallas, USA, Sep. 2003.

KASHYAP, K. H.; SHENOY, U. J. Classification of power system faults using wavelet transforms and probabilistic neural networks. *Proceedings of the 2003 International Symposium on Circuits and Systems*, Bangkok, Thailand, May 2003.

KEZUNOVIC, M.; RIKALO, I. Detect and classify transmission line faults using neural nets. *IEEE Computer Applications in Power*, v. 9, n. 4, p. 42–47, Oct. 1996.

KEZUNOVIC, M.; VASILIC, S.; GUL-BAGRIYANIK, F. Advanced approaches for detecting and diagnosing transients and faults. *Mediterranean Conference on Power Generation*, Athens, Greece, Nov. 2002.

KIM, C. H.; AGGARWAL, R. Wavelet transform in power system: Part 2 examples of application to actual power system transients. *Power Engineering Journal*, p. 193–202, Aug. 2001.

KIM, C.-H.; KIM, H.; KO, Y.-H.; BYUN, S.-H.; JOHNS, R. K. A. A. T. A novel fault-detection technique of high-impedance arcing faults in transmission lines using the wavelet transform. *IEEE Trans. Power Delivery*, v. 17, n. 4, p. 921–929, Oct. 2002.

LEUVEN EMTP CENTER. *ATP - Alternative Transient Program: Rule book*. Herverlee, Belgium, 1987.

LIRA, M. M. da S. *Wavelets na Compactação e Processamento de Sinais de Distúrbios em Sistemas de Potência Classificados Via Redes Neurais Artificiais*. Tese (Doutorado) — Universidade Federal de Pernambuco, Recife, 2004.

MAHANTY, R. N.; GUPTA, P. B. D. Application of rbf neural network to fault classification and location in transmission lines. *IEE Proceedings of Generation, Transmission and Distribution*, v. 151, n. 2, Mar. 2004.

MALLAT, S. G. A theory for multiresolution signal decomposition: The wavelet representation. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, v. 11, n. 7, Jul. 1989.

NEVES, W. L. A.; BRITO, N. S. D.; SOUZA, B. A.; FONTES, A. V.; DANTAS, K. M. C.; FERNADES, A. B.; SILVA, S. S. B. Influência da frequência de amostragem dos registradores digitais de perturbação no diagnóstico de faltas. *Transmission and Distribution Latin America Conference*, São Paulo, Ago. 2004.

OLESKOVICZ, M.; COURY, D. V.; AGGARWAL, R. K. Redes neurais artificiais aplicadas à classificação rápida de faltas em sistemas elétricos de potência. *SBA Controle & Automação*, v. 11, n. 03, p. 160–168, Dez. 2000.

OLESKOVICZ, M.; COURY, D. V.; AGGARWAL, R. K. O emprego de redes neurais artificiais na detecção, classificação e localização de faltas em linhas de transmissão. *SBA Controle & Automação*, v. 14, n. 02, 2003.

PHADKE, A. G.; THORP, J. S. *Computer Relaying for Power Systems*. New York, USA: John Wiley & Sons Inc, 1990.

POULARIKAS, A. D. *The Transforms and Applications - Handbook*. 2a. ed. Boca Raton, USA: CRC Press - IEEE Press, 1996.

PRADHAN, A. K.; ROUTRAY, A.; PATI, S.; PRADHAN, D. K. Wavelet fuzzy combined approach for fault classification of a series-compensated transmission line. *IEEE Transaction on Power Delivery*, v. 19, n. 4, Oct. 2004.

PROBERT, S. A.; SONG, Y. H. Detection and classification of high frequency transients using wavelet analysis. *Proc. 2002 IEEE Power Engineering Society Summer Meeting*, v. 2, p. 801–806, Chicago, USA, Jul. 2002.

RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: The rprop algorithm. *Proceedings of the IEEE Int. Conf. on Neural Networks*, San Francisco,

- RIOUL, O.; VETTERLI, M. Wavelets and signal processing. *IEEE Transaction on Signal Processing*, v. 8, n. 4, p. 14–38, Oct. 1991.
- RODRIGUES, M. A. P.; RODRIGUES, M. A. M.; DINIZ, S. S.; FIGUEIREDO, M. V. F.; MIRANDA, A. L. L. Sistema para análise automática de oscilogramas na light. *VII Seminário Técnico de Proteção e Controle*, Rio de Janeiro, Jun. 2003.
- SILVA, S. S. B. da. *Uso de Inteligência Artificial para Análise de Ocorrências em Sistemas de Potência*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, Recife, 2002.
- SOLANKI, M.; SONG, Y. H. Transient protection of ehv transmission line using discrete wavelet analysis. *Proc. 2003 IEEE Power Engineering Society General Meeting*, v. 3, p. 1868–1873, Toronto, Canada, Jul. 2003.
- SOLANKI, M.; SONG, Y. H.; POTTS, S.; PERKS, A. Transient protection of transmission line using wavelet transform. *Developments in Power System Protection*, Amsterdam, Netherlands, n. 479, p. 299–302, 2001.
- SONG, Y. N.; XUAN, Q. Y.; JOHNS, A. T. Comparison studies of five neural network based fault classifiers for complex transmission lines. *Electrical and Computer Engineering*, v. 2, n. 3, p. 26–29, May 1996.
- SOUZA, B. A.; BRITO, N. S. D.; NEVES, W. L. A.; SILVA, K. M.; COSTA, F. B.; DANTAS, K. M. C.; FONTES, A. V.; FERNADES, A. B.; LIRA, M. M. S. *Implantação de Técnicas de Inteligência Artificial para Identificação e Análise de Ocorrências no Sistema Elétrico*. Campina Grande, Jul. 2004. Relatório de Projeto de Pesquisa e Desenvolvimento CT-I-92.2002.2420.00.
- SOUZA, B. A.; BRITO, N. S. D.; SILVA, K. M.; LIMA, R. V.; SILVA, S. S. B. Comparison between backpropagation and rprop algorithms to fault classification in transmission lines. *International Joint Conference on Neural Networks*, Budapeste, Hungria, Jul. 2004.
- SOUZA, B. A.; BRITO, N. S. D.; SILVA, S. S. B.; SILVA, K. M.; COSTA, F. B.; MELO FILHO, A. C. M. Um classificador de faltas para análise de ocorrências no sistema Chesf. *Congresso Brasileiro de Automática*, Gramado, Set. 2004.
- VASILIC, S.; KEZUNOVIC, M. An improved neural network algorithm for classifying the transmission line faults. *IEEE PES Winter Meeting*, New York, USA, Jan. 2002.

VASILIC, S.; KEZUNOVIC, M. Fuzzy art neural network algorithm for classifying the power system faults. *IEEE Transactions on Power Delivery*, Apr. 2005.

YOUSSEF, O. A. S. Fault classification based on wavelet transforms. *Transmission and Distribution Conference and Exposition*, Atlanta, USA, v. 1, p. 531–536, Nov. 2001.

YOUSSEF, O. A. S. Combined fuzzy-logic wavelet-based fault classification technique for power system relaying. *IEEE Transactions on Power Delivery*, v. 19, n. 2, Apr. 2004.

---

## APÊNDICE A

### PADRÃO COMTRADE

As informações geradas pelos RDPs e programas de simulação têm feito com que quantidades cada vez maiores de dados se formem continuamente. Estas informações podem ser geradas, transmitidas e armazenadas em diferentes formatos, dependendo do sistema de aquisição e transmissão empregado.

A diversidade de formatos dificultava a análise dos dados, uma vez que exige mais do analista, até que adotou-se em 1991 o padrão COMTRADE<sup>1</sup> (IEEE POWER SYSTEM RELAYING COMMITTEE, 1991): Um formato aberto, para o qual todos os outros formatos pudessem ser convertidos. Este padrão foi revisado em 1997 e em 1999, definindo um formato comum dos arquivos de dados que possibilita o intercâmbio dos arquivos entre os vários sistemas de análise de falta, testes e simulação.

Três tipos de arquivos são gerados no padrão COMTRADE. Cada qual possui uma classe específica de informação. O nome desses arquivos tem extensão que designa o tipo (Tabela A.1).

Tipo	Extensão
Cabeçalho	<i>.hdr</i>
Configuração	<i>.cfg</i>
Dados	<i>.dat</i>

**Tabela A.1.** Tipos de arquivos do padrão COMTRADE.

Os arquivos são seqüenciais e os campos de cada registro são delimitados por vírgula. Isto é, as informações são organizadas em linhas numa ordem padronizada, sendo os dados em cada linha separados por vírgulas.

- **Arquivos de cabeçalho:** São arquivos de texto criados pelo programa conversor com o objetivo de permitir que os dados possam ser impressos e entendidos pelo usuário.

Arquivos deste tipo podem conter qualquer informação desejada. Por exemplo: nome da subestação, identificação do equipamento (linha de transmissão, transformador, reator, dentre outros), comprimento da linha, relação de transformação do transformador de potencial ou de corrente e localização do defeito. As informações contidas em um arquivo de cabeçalho dependem apenas do conversor fornecido pelo fabricante do dispositivo de registro.

- **Arquivos de configuração:** São criados pelo programa conversor como um arquivo de texto. O formato dos dados é predefinido para que possam ser lidos e interpretados corretamente pelo programa computacional de análise, o qual os associará aos valores armazenados no arquivo de dados correspondente. Os arquivos de configuração são organizados conforme a Tabela A.2.

O campo *cccc* no registro tipo 3 quase não é usado. O fator de conversão do canal é  $ax+b$ , sendo  $a$  e  $b$  números reais dados nos campos correspondentes do registro tipo 3.  $x$  é o valor da amostra do arquivo *.dat* a ser convertido. Isto é, o valor convertido de  $x$  corresponde a  $ax+b$  em unidades *uu* especificadas no campo correspondente.

- **Arquivos de dados:** São arquivos do tipo ASCII, ou binário, criados pelo programa conversor. Os dados de um arquivo deste tipo possuem formato predefinido de modo que possam ser lidos e interpretados pelo programa de análise, o qual os associará conforme especificado no arquivo de configuração correspondente.

Um arquivo de dados deve conter os valores organizados em linhas e colunas, de modo que cada linha corresponda a um conjunto de valores da primeira amostra de canal precedido de um número seqüencial e o tempo do conjunto de amostras. Cada linha possui  $n + 2$  colunas, se  $n$  é o número de canais do registro. O número de linhas varia de acordo com o de amostras, o que define o tamanho do arquivo.

A primeira coluna deve conter o número da amostra. A segunda, o tempo da amostra, em microssegundos, do início do registro. As demais colunas devem conter os valores amostrados da tensão, da corrente e do estado, os quais devem ser inteiros com seis dígitos e separados por vírgula. Valores inexistentes devem ser representados por 999999 e as informações de estado por 0 ou 1. Nenhuma outra informação deve constar num arquivo de dados.

Nº	Registro	Campo	Descrição do campo
1	Nome e identificação da subestação	<i>Station name</i> <i>id</i>	Nome da subestação Nome do registrador
2	Número e tipo de canais	<i>TT</i> <i>nnt,nnt</i>	Número total de canais Número de canais do tipo <i>t</i> <i>t =A: analógico/D: digital</i>
3	Nome dos canais, unidades, fatores de conversão e informações dos canais	<i>nn, id</i> <i>p</i> <i>cccccc</i> <i>uu</i> <i>a,b</i> <i>skew</i> <i>min,max</i>  <i>m</i>	Número e nome do canal Identificação de fase (A,B,C,T) Circuito ou componente monitorado Unidade do canal (V,A,kV,etc.) Componentes do fator de conversão Número real Menor e maior valor da taxa de amostragem do canal <i>id</i> Estado normal ou de alarme do canal (apenas para canais digitais)
4	Frequência nominal	<i>if</i>	Frequência nominal em Hz 50, 60
5	Taxa de amostragem e número de amostras	<i>nrates</i>  <i>sssss1, endsamp1</i> <i>:</i> <i>sssssn, endsampn</i>	Nº. de taxas de amostragem diferentes no arquivo <i>.dat</i> Taxa de amostragem em Hz e última amostra nessa taxa
6	Data e hora da primeira amostra	<i>mm/dd/yy</i> <i>hh:mm:ss.ssssss</i>	Mês, dia e últimos dígitos do ano Hora, minuto e segundo
7	Data e hora do trigger	<i>mm/dd/yy</i> <i>hh:mm:ss.ssssss</i>	Mês, dia e últimos dígitos do ano Hora, minuto e segundo
8	Tipo de arquivo de dados	<i>Ft</i>	Informa se o arquivo de dados é ASCII ou binário

Tabela A.2. Registros e campos dos arquivos de configuração.



## PUBLICAÇÕES EM EVENTOS

SOUZA, B. A.; BRITO, N. S. D.; SILVA, S. S. B.; SILVA, K. M.; COSTA, F. B.; MELO FILHO, A. C. M. Um classificador de faltas para análise de ocorrência no sistema CHESF. *Congresso Brasileiro de Automática*, Gramado, Set. 2004.

SOUZA, B. A.; BRITO, N. S. D.; SILVA, K. M.; LIMA, R. V.; SILVA, S. S. B. Comparison between backpropagation and rprop algorithms to fault classification in transmission lines. *International Joint Conference on Neural Networks*, Budapeste, Hungria, Jul. 2004.

SILVA, J. A. C. B.; SILVA, K. M.; BRITO, N. S. D.; NEVES, W. L. A.; SOUZA, B. A.; SILVA, S. S. B. Implementação de um localizador de faltas utilizando redes neurais artificiais. *Transmission and Distribution Latin America Conference*, São Paulo, Ago. 2004.