

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA

ELÉTRICA

CRISLUCI KARINA SOUZA SANTOS CÂNDIDO

CLASSIFICAÇÃO DE DISTÚRBIOS NA REDE

ELÉTRICA USANDO REDES NEURAIS E

WAVELETS

NATAL, RN

JUNHO, 2008

CLASSIFICAÇÃO DE DISTÚRBIOS NA REDE
ELÉTRICA USANDO REDES NEURAIS E
WAVELETS

CRISLUCI KARINA SOUZA SANTOS CÂNDIDO

Tese apresentada ao Programa de Pós-Graduação
em Engenharia Elétrica da UFRN, como parte
dos requisitos para a obtenção do grau de Doutor
em Engenharia Elétrica.

Professor Orientador:
Dr.-Ing. Manoel Firmino de Medeiros Júnior

Professor Co-orientador:
D. Sc. José Tavares de Oliveira

NATAL, RN

JUNHO, 2008

CLASSIFICAÇÃO DE DISTÚRBIOS NA REDE ELÉTRICA USANDO
REDES NEURAIIS E WAVELETS

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da UFRN, como parte dos requisitos para a obtenção do grau de Doutor em Engenharia Elétrica.

Defendida e aprovada em 13 de Outubro de 2008.

Prof. Dr.-Ing Manoel Firmino de Medeiros Jr.
(Orientador)

Prof. D. Sc. José Tavares de Oliveira
(Co-orientador)

Prof. Dr. Jorge Dantas Melo
(Examinador Interno)

Prof. Dr. Benemar Alencar de Souza
(Examinador Externo)

Prof. Dr. Ubiratan Holanda Bezerra
(Examinador Externo)

Dr. José Júlio de Almeida Lins Leitão
(Examinador Externo)

NATAL, RN

Aos meus pais, Graça e Jaime, por tudo que fizeram e fazem por mim, ao meu marido, Flávio, por seu apoio constante e à minha filha, Bruna, a razão da minha vida.

AGRADECIMENTOS

Primeiramente, a Deus, pela certeza de poder sempre contar com ele em todos os momentos da minha vida, iluminando os meus caminhos e me dando coragem para vencer obstáculos e alcançar meus objetivos.

À minha filha, Bruna, e ao meu marido, Flávio, pela compreensão e abdicção do tempo que temos de convívio em prol da realização deste trabalho. A sua existência, minha filha, e o seu apoio, Flávio, foram responsáveis por encorajar-me a prosseguir na execução desta tese. Vocês trazem muita luz à minha vida.

Aos meus pais, Jaime e Graça, e irmãs, Cristina, Cristiane e Crislene, grandes incentivadores nessa caminhada, pela presença, às vezes silenciosa, mas sempre constante em todos os momentos. A vocês sou eternamente grata.

Ao meu orientador, professor Firmino, pela amizade, apoio e conhecimento essenciais ao desenvolvimento deste trabalho.

Aos Professores José Tavares de Oliveira, Adrião Duarte Dória Neto, Jorge Dantas de Melo, Paulo Sérgio da Motta Pires e Estefane Lacerda pela disponibilidade e pelas discussões de grande importância para obtenção dos resultados apresentados nessa tese.

À Chesf pela definição do tema que inspirou o presente trabalho.

E a todos que direta ou indiretamente contribuíram no desenvolvimento desta tese.

RESUMO

Análises pós-despacho de sinais oriundos de registradores de perturbações fornecem muitas vezes informações importantes para identificação e classificação de distúrbios nos sistemas, visando a uma gestão mais eficiente do fornecimento de energia elétrica. Para auxiliar nessa tarefa, faz-se necessário recorrer a técnicas de processamento de sinais, a fim de automatizar o diagnóstico sobre os tipos de distúrbio presentes nos sinais registrados. A transformada wavelet constitui-se em uma ferramenta matemática bastante eficaz na análise de sinais de tensão ou corrente, obtidos imediatamente após a ocorrência de distúrbios na rede. Este trabalho apresenta uma metodologia baseada na transformada wavelet discreta e na comparação de curvas de distribuição da energia de sinais, com e sem distúrbio, para diferentes níveis de resolução de sua decomposição, com o objetivo de obter descritores que permitam a sua classificação através do uso de redes neurais artificiais.

PALAVRAS-CHAVE:

- Distúrbios
- Qualidade de Energia
- Redes Neurais Artificiais
- Transformada Wavelet

ABSTRACT

Post dispatch analysis of signals obtained from digital disturbances registers provide important information to identify and classify disturbances in systems, looking for a more efficient management of the supply. In order to enhance the task of identifying and classifying the disturbances - providing an automatic assessment - techniques of digital signal processing can be helpful. The Wavelet Transform has become a very efficient tool for the analysis of voltage or current signals, obtained immediately after disturbance's occurrences in the network. This work presents a methodology based on the Discrete Wavelet Transform to implement this process. It uses a comparison between distribution curves of signals energy, with and without disturbance. This is done for different resolution levels of its decomposition in order to obtain descriptors that permit its classification, using artificial neural networks.

KEYWORDS:

- Disturbances
- Electric Power Quality
- Artificial Neural Networks
- Wavelet Transform

Sumário

1	Introdução	1
1.1	Objetivos	1
1.2	Estado da Arte	3
1.3	Contribuições	13
2	Teoria Básica de Redes Neurais Artificiais e de Transformada <i>Wavelet</i>	15
2.1	Redes Neurais Artificiais	15
2.1.1	O Neurônio Artificial	18
2.1.2	Topologias Básicas de Redes Neurais	22
2.1.3	Processos de Aprendizagem	23
2.1.3.1	O Algoritmo Backpropagation	25
2.1.3.2	Resilient Propagation	28
2.1.4	Projeto de Redes Neurais	30
2.2	Teoria <i>Wavelet</i>	32

2.2.1	Análise Wavelet	32
2.2.1.1	Aproximações e Detalhes	34
2.2.2	Análise Multiresolução	34
2.2.3	Famílias <i>Wavelets</i>	36
2.2.3.1	Haar	36
2.2.3.2	Daubechies	37
2.2.3.3	Coiflets	37
2.2.3.4	Symlets	38
2.2.4	Transformada <i>Wavelet</i>	39
2.2.4.1	A Transformada <i>Wavelet</i> Discreta	39
2.2.5	Algoritmo de Mallat	40
2.2.6	Esquema <i>Lifting</i>	41
3	Algoritmo Básico Para Classificação dos Fenômenos	45
3.1	Etapas Desenvolvidas	45
3.1.1	Etapa 1: Obtenção do Sinal de Entrada	47
3.1.1.1	Sinais Registrados	47
3.1.1.2	Sinais Simulados	48
3.1.2	Etapa 2: Pré-Processamento do Sinal de Entrada	49
3.1.3	Etapa 3: Classificador Neural	58

4	Pré-Processamento e Sua Importância	61
4.1	Evolução dos Resultados	61
4.2	Pré-Processamento dos Sinais	62
4.2.1	Sinais Analisados	62
4.2.2	Mudança dos Descritores	63
4.2.3	Definição do Sinal de Referência	64
4.2.4	Localização do Distúrbio no Tempo	67
4.2.5	Normalização	70
5	Análise de Resultados	76
5.1	Considerações Gerais	76
5.2	Resultados	77
5.2.1	Resultados Obtidos Para Sinais Com 128 Amostras/Ciclo .	78
5.2.2	Resultados Obtidos Para Sinais Com 32 Amostras/Ciclo .	82
5.2.3	Resultados Obtidos Para Sinais com 64 Amostras/Ciclo Provenientes da Redução da Taxa de Amostragem dos Si- nais com 128 Amostras/Ciclo	86
5.2.4	Resultados Obtidos Para Sinais com 32 Amostras/Ciclo Provenientes da Redução da Taxa de Amostragem dos Si- nais com 128 Amostras/Ciclo	89

6	Conclusões e Recomendações	92
6.1	Conclusões	92
6.2	Recomendações	94
A	Equipamentos Registradores de Perturbações	95
A.1	Equipamentos de Medição da Qualidade da Energia	95
A.1.1	Registradores de Oscilografia	96
A.1.1.1	Oscilografia Convencional	97
A.1.1.2	Oscilografia Digital	97
A.1.2	Registradores de Qualimetria	98
B	Descrição dos Trechos dos Procedimentos de Rede Referentes aos Dis-	
	túrbios de Afundamento e Elevação de Tensão	100
B.1	Variação de Tensão de Curta Duração (VTCD)	100
B.1.1	Considerações iniciais	100

Lista de Figuras

2.1	Neurônio biológico	16
2.2	Representação da sinapse neural	17
2.3	Modelo não-linear de um neurônio	18
2.4	Transformação afim produzida pela presença de um bias.	20
2.5	Outro modelo não-linear de um neurônio.	21
2.6	Rede neural direta	23
2.7	Rede neural recorrente	24
2.8	a) e b) Representação gráfica de padrão linearmente separável; c) Representação gráfica do padrão não linearmente separável	26
2.9	Árvore de decomposição wavelet (S - sinal; A_i - coeficientes de aproximação do nível i ; D_i - coeficientes de detalhes do nível i) .	35
2.10	<i>Wavelet</i> Haar	36
2.11	<i>Wavelet</i> Daubechies	37
2.12	<i>Wavelet</i> Coiflets	38

2.13	<i>Wavelet</i> Symlets	38
2.14	Bloco básico de decomposição do sinal	42
2.15	Árvore de decomposição <i>wavelet</i>	43
2.16	Esquema <i>lifting</i>	44
3.1	Diagrama esquemático das etapas desenvolvidas no trabalho	46
3.2	Gráfico de tensão obtido para um sinal registrado pela oscilografia (128 amostras/ciclo em 14 ciclos) com afundamento de tensão	48
3.3	Gráfico de tensão obtido para um sinal registrado pela qualimetria (32 amostras/ciclo em 54 ciclos) com afundamento de tensão	49
3.4	Trecho de um sistema real de transmissão - ambiente ATP-Draw. . . .	50
3.5	Gráfico de tensão obtido pelo software ATP com afundamento de tensão.	51
3.6	Sinal de entrada sem passar por nenhum pré-processamento	52
3.7	Sinal contendo apenas o trecho com distúrbio.	53
3.8	Sinal com distúrbio com o seu respectivo sinal de referência. . . .	55
3.9	Gráfico contendo apenas o ciclo de referência considerado o <i>mais</i> <i>normal</i>	56
3.10	Gráfico da diferença percentual das energias dos sinais com e sem distúrbio para o caso de uma elevação de tensão.	57

4.1	Gráficos dos sinais com e sem distúrbios usados no pré-processamento no qual o sinal de referência é obtido a partir do seu primeiro algoritmo de definição.	67
4.2	Gráficos dos sinais com e sem distúrbios usados no pré-processamento no qual o sinal de referência é obtido a partir do seu segundo algoritmo de definição.	68
4.3	Sinal registrado com distúrbio no primeiro ciclo.	69

Lista de Tabelas

3.1	Tabela com a definição de cada descritor	59
3.2	Classes definidas para o classificador neural	60
4.1	Tabela com a antiga definição de cada descritor	73
4.2	Porcentagem de acerto para diferentes arquiteturas da rede neural RPROP, considerando no pré-processamento o primeiro algoritmo de obtenção do sinal de referência.	74
4.3	Porcentagem de acerto para diferentes arquiteturas da rede neural RPROP, considerando no pré-processamento o segundo algoritmo de obtenção do sinal de referência.	74
4.4	Porcentagem de acerto para diferentes arquiteturas da rede neural RPROP, considerando no pré-processamento o terceiro algoritmo de obtenção do sinal de referência.	74

4.5	Porcentagem de acerto para diferentes arquiteturas da rede neural RPROP, considerando no pré-processamento o terceiro algoritmo de obtenção do sinal de referência e também o sinal contendo apenas a parte com distúrbio.	75
5.1	Porcentagem de acerto e tempo de treinamento para diferentes arquiteturas da rede neural utilizando o algoritmo RPROP e o Back-propagation.	79
5.2	Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:20:4.	79
5.3	Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:40:4.	80
5.4	Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:60:4.	80
5.5	Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:80:4.	81
5.6	Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:100:4.	81
5.7	Classes definidas para o classificador neural	83
5.8	Porcentagem de acerto para diferentes arquiteturas da rede neural utilizando o algoritmo RPROP e sinais com taxa de 32 amostras/ciclo.	83

5.9	Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:20:4 para sinais com taxas de 32 amostras/ciclo.	84
5.10	Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:40:4 para sinais com taxas de 32 amostras/ciclo.	84
5.11	Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:60:4 para sinais com taxas de 32 amostras/ciclo.	84
5.12	Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:80:4 para sinais com taxas de 32 amostras/ciclo.	85
5.13	Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:100:4 para sinais com taxas de 32 amostras/ciclo.	85
5.14	Porcentagem de acerto para diferentes arquiteturas da rede neural utilizando o algoritmo RPROP e sinais com taxa de 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.	86
5.15	Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:20:4 para os sinais com 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.	87

5.16	Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:40:4 para os sinais com 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.	87
5.17	Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:60:4 para os sinais com 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.	87
5.18	Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:80:4 para os sinais com 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.	88
5.19	Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:100:4 para os sinais com 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.	88
5.20	Porcentagem de acerto para diferentes arquiteturas da rede neural utilizando o algoritmo RPROP e sinais com taxa de 32 amostras/ciclo, obtidos pela redução das taxas de amostragem dos sinais com 128 amostras/ciclo.	89

5.21	Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:20:4 para os sinais com 32 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.	90
5.22	Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:40:4 para os sinais com 32 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.	90
5.23	Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:60:4 para os sinais com 32 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.	91
5.24	Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:80:4 para os sinais com 32 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.	91
5.25	Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:100:4 para os sinais com 32 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.	91
B.1	Denominação das variações de tensão de curta duração.	103

Lista de Abreviaturas e Siglas

MRA: Análise de Multi Resolução

RDP: Registrador Digital de Perturbação

ATP: Alternative Transients Program

RNA: Redes Neurais Artificiais

PMC: Perceptron de Múltiplas Camadas

RProp: Resilient Propagation

SVM: Máquinas de Vetor Suporte

ONS: Operador Nacional do Sistema Elétrico

THD: Distorção Harmônica Total

IEEE: Institute of Electrical and Electronics Engineers

CWT: Transformada Wavelet Contínua

DWT: Transformada Wavelet Discreta

Lista de Símbolos

w_{kj} : Peso Sináptico na entrada j conectado ao neurônio k

Δ_{kj} : Taxa de variação do peso w_{kj}

$\varphi(\cdot)$: Função de ativação

η : Taxa de aprendizado

$\psi(t)$: Sinal de tempo contínuo ou discreto que define uma wavelet-mãe

$\psi_{a,b}(t)$: Notação de wavelets filhas

a e b : Parâmetros de dilatação e translação

$f(t)$: Sinal discreto no tempo

$f(n)$: Sinal amostrado no tempo

$f_o(n)$: Elementos de índices ímpares do conjunto de entrada $f(n)$

$f_e(n)$: Elementos de índices pares do conjunto de entrada $f(n)$

$a_j(n)$: Coeficiente wavelet de aproximação de nível j

$d_j(n)$: Coeficiente wavelet do detalhe de nível j

$\sum_{n=1}^N |f(n)|^2$: Energia do sinal analisado

$\sum_{n=1}^N |a_j(n)|^2$: energia concentrada na versão aproximada de nível j

$\sum_{j=1}^J \sum_{n=1}^N |a_j(n)|^2$: energias nas versões detalhadas de níveis 1 a j

$dp(j)$: diferença percentual entre as distribuições de energias dos sinais com e sem distúrbio em cada nível da versão detalhada

$en\ dist(j)$: energia em cada nível da versão detalhada do sinal com distúrbio

$max(en\ ref)$: maior energia dos dez níveis do sinal senoidal de referência.

Capítulo 1

Introdução

Este capítulo apresenta uma revisão bibliográfica sobre os estudos relacionados ao assunto desenvolvido nesta tese, além de relacioná-la com o estado da arte e ainda mostrar os seus principais objetivos.

1.1 Objetivos

A atual complexidade do sistema elétrico, aliada às novas demandas por parte dos consumidores e à privatização do setor elétrico tornaram o mercado de energia cada vez mais competitivo e exigente. Uma análise eficiente de uma perturbação no sistema elétrico é de fundamental importância na busca de melhores índices de qualidade da energia.

O conceito de "Qualidade da Energia" está relacionado a um conjunto de alterações que podem ocorrer no sistema elétrico. Entre muitos apontamentos da lite-

ratura, pode-se então caracterizar o assunto como qualquer problema manifestado na tensão, corrente ou desvio de frequência, que resulta em falha ou má operação de algum equipamento dos consumidores (OLESKOVICZ, 2004). Tais alterações podem ocorrer em várias partes do sistema de energia, seja nas instalações de consumidores ou no sistema supridor da concessionária. Como causas mais comuns pode-se citar: chaveamentos de bancos de capacitores, curto-circuito nos sistemas elétricos, introdução de harmônicos na rede, etc.

Em um passado não muito distante, os problemas causados pela má qualidade no fornecimento de energia não eram tão expressivos, visto que os equipamentos existentes eram pouco sensíveis aos efeitos dos fenômenos ocorridos. Entretanto, com o desenvolvimento tecnológico, principalmente da eletrônica, consumidores e concessionárias de energia elétrica têm-se preocupado muito com a qualidade da energia. Isto se justifica, principalmente, pelos seguintes motivos (RCE, 2008):

- Os equipamentos atualmente utilizados são mais sensíveis às variações nas formas de onda de energia fornecidas. Muitos deles possuem controles baseados em microprocessadores e dispositivos eletrônicos sensíveis a muitos tipos de distúrbios;
- O crescente interesse pela racionalização e conservação da energia elétrica, com vistas a otimizar a sua utilização, tem aumentado o uso de equipamentos que, em muitos casos, aumentam os níveis de distorções harmônicas e podem levar o sistema elétrico a condições de ressonância;
- Maior conscientização dos consumidores em relação aos fenômenos ligados à Qualidade de Energia, visto que os mesmos estão se tornando mais infor-

dados a respeito de fenômenos como interrupções, subtensões, transitórios de chaveamento etc., passando a exigir que as concessionárias melhorem a qualidade da energia fornecida;

- A crescente integração dos processos, significando que a falha de qualquer componente traz conseqüências ainda mais importantes para o sistema elétrico;
- As conseqüências resultantes de variações nas formas de onda sobre a vida útil dos componentes elétricos.

Diante do exposto, fica evidente a importância de uma análise e diagnóstico da qualidade da energia elétrica, no intuito de determinar as causas e as conseqüências dos distúrbios no sistema, além de apresentar medidas técnicas e economicamente viáveis para solucionar o problema.

Dessa forma, fica claro que o principal objetivo do trabalho é o desenvolvimento de um classificador automático de distúrbios.

1.2 Estado da Arte

O problema da detecção e classificação de faltas e distúrbios em sistemas elétricos utilizando redes neurais artificiais e os fundamentos da teoria *wavelets* têm sido abordados em trabalhos recentes.

Em 1994 o artigo de *Santoso, Powers e Grady* (SANTOSO; POWERS; GRADY, 1994) propõe uma abordagem baseada na utilização da transformada

wavelet para detecção e localização de distúrbios. Os distúrbios tratados são flutuações rápidas de tensão, variações de tensão de curta e longa duração e distorções harmônicas. São utilizadas decomposições da forma de onda dos distúrbios em até dois níveis de resolução, sob a justificativa de que, em níveis maiores, a localização no tempo não é importante. As *wavelets* utilizadas são do tipo Daubechies 4 e 6 (para transitórios rápidos) e 8 e 10 (para transitórios lentos). Os coeficientes do sinal com distúrbio são comparados com aqueles de um sinal semelhante sem distúrbio.

Liang, Elangovan e Devotta (1998) (LIANG; ELANGO VAN; DEVOTTA, 1998) propõem um algoritmo para detecção e classificação de faltas usando Análise de Multi Resolução por Wavelets (MRA) em tempo real. O primeiro estágio de detalhes do sinal da MRA extraídos do sinal original é usado como critério para este problema. As faltas no sistema de potência podem ser detectadas medindo-se a variação brusca dos valores dos detalhes do sinal da MRA. O tipo de falta é então identificado através da comparação da variação brusca da MRA das três fases. Os efeitos da distância da falta, o ângulo de incidência e a impedância da falta são analisados e uma rotina de classificação é desenvolvida para seus efeitos.

Uma abordagem modular e integrada para o problema da detecção e classificação rápida de faltas é proposto por *Chowdhury e Aravena* (1998) (CHOWDHURY; ARAVENA, 1998). Muito embora o exemplo específico estudado seja um sistema de potência, o método pode ser aplicado para um sistema dinâmico arbitrário. A abordagem é muito flexível no sentido de que pode ser baseada ou não no modelo existente. No caso em que não é baseada no modelo, enfatiza-se o uso de conceitos da teoria de processamento de sinais e *wavelets* para criar indicadores de faltas

rápidos e sensíveis. Por outro lado, se o modelo for disponível, então resíduos gerados de forma convencional (diferença entre a saída do modelo e os dados reais) podem servir como indicadores de faltas. Os indicadores podem então ser analisados através de hipóteses padrões de estatísticas ou por redes neurais artificiais a fim de se criar regras de decisões inteligentes. Após a detecção, o indicador de falta é processado por uma rede de Kohonen para classificá-la.

Coury e Gionaninia (1999) (GIOVANINI; COURY, 1999) apresentam o desenvolvimento de um *software* baseado em redes neurais do tipo Perceptron de Múltiplas Camadas, cujo treinamento usa o algoritmo da retropropagação do erro (backpropagation) para a classificação de faltas em linhas de transmissão. Para os testes, simulou-se uma linha de transmissão de 100 km. Diversos tipos de faltas, tais como trifásica, fase-fase, fase-terra, fase-fase-terra foram simulados sob diferentes situações de ângulo de incidência, distância e resistência da falta. O objetivo buscado é a melhoria do bloco classificador dos sistemas de proteção de linhas, sobretudo do ponto de vista de tempo de processamento para a estimação da falta.

Zhao, Songb e Minb (2000) (ZHAOA; SONGB; MINB, 2000) apresentam um novo método para detecção e classificação de faltas transitórias em sistemas de cabos subterrâneos, baseada no uso da transformada wavelet discreta. Um sistema subterrâneo de 400 kV é simulado usando ATP sob várias condições de falta e carregamento. A transformada wavelet de Daubechies D8 é empregada para analisar os transitórios de falta e alimenta um novo esquema para sua detecção e classificação. Resultados de simulação mostram que o esquema é eficiente e robusto. O procedimento de análise é baseado na adoção de uma *wavelet* protótipo

(*wavelet mãe*). A análise temporal é feita utilizando-se uma versão contraída e de alta-frequência da wavelet protótipo, enquanto a análise em frequência é feita com uma versão expandida e de baixa-frequência do mesmo protótipo. Feito isto, busca-se investigar a aplicação das wavelets na análise transitória das faltas em cabos subterrâneos e assim estabelecer resultados preliminares sobre um novo conceito de detecção e classificação de faltas.

Em 2002 o trabalho de *Fernández e Rojas* (FERNÁNDEZ; ROJAS, 2002) teve como objetivo avaliar a bibliografia disponível em um período significativo, cerca de dez anos, de modo que se pudesse apresentar uma visão geral sobre a aplicação da transformada wavelet em sistemas de potência. As 116 publicações coletadas e analisadas foram selecionadas segundo critérios da relevância da contribuição ou fortalecimento de linhas de pesquisa, utilizando transformadas wavelet em sistemas de potência. Os autores identificaram que o primeiro trabalho relatando a aplicação de técnicas de wavelets nesta área ocorreu em 1994 e que, a partir de então, o crescimento na utilização desta técnica na área em questão ocorreu de forma bastante significativa. As aplicações mais importantes das transformadas *wavelet* na área de sistemas de potência, segundo as 116 referências avaliadas, foram em:

- Proteção de Sistemas de Potência (36% dos trabalhos)
- Qualidade de Energia (32% dos trabalhos)
- Transitórios de Sistemas de Potência (11% dos trabalhos)
- Descargas Parciais (4% dos trabalhos)
- Balanceamento de Cargas (3% dos trabalhos)

- Medições em Sistemas de Potência (2% dos trabalhos)
- Outras áreas relacionadas (12% dos trabalhos)

Os autores relatam que as técnicas de transformadas *wavelet* foram utilizadas com mais ênfase na implementação de métodos de identificação e de classificação. Os dados para esse tipo de análise foram obtidos, em geral, a partir de simulações utilizando programas de análise de transitórios como o ATP. As análises foram realizadas utilizando programas especializados como o *toolbox wavelet* disponível para o *software* MATLAB. Além disso, identificam que o uso de transformadas *wavelet* para a implementação de métodos rápidos de detecção e localização de faltas é uma linha de pesquisa bastante promissora.

Gengyin, Ming e Zhiyuan (2002) (GENGYIN; MING; ZHIYUAN, 2002) propõem um classificador baseado na transformada *wavelet* e em redes neurais. Os distúrbios tratados são ligados à variações de tensão do tipo: swell, sag, interrupção momentânea e impulsos. Inicialmente o sinal é decomposto em cinco níveis usando-se *wavelets* do tipo Daubechies 3, para depois serem determinados os tempos de início e fim do distúrbio, para distinguir aqueles que são dinâmicos e aqueles que são estacionários. Descritores são então extraídos dos coeficientes obtidos e dizem respeito à variância do sinal, valor máximo, valor mínimo, valor médio e valor integral. Um critério de distância associado com a probabilidade de ocorrência do distúrbio é utilizado para testar a similaridade entre os diferentes descritores. Para o classificador é usada uma rede neural para cada tipo de distúrbio com arquitetura 10:5:1. As redes são treinadas com algoritmos genéticos e com o algoritmo de backpropagation tradicional. Foram usados dois conjuntos de dados, sendo um de treinamento e outro de teste, com 229 e 335 amostras res-

pectivamente. Para os distúrbios analisados, as taxas de reconhecimento variaram entre 75% (oscilação com mudança de amplitude) e 90,9% (transitório com oscilação) para a rede treinada com algoritmo genético e entre 70% (oscilação com mudança de amplitude) e 87,5% (sag) para a rede treinada com o algoritmo de backpropagation. Como resultado mais importante pode-se citar o uso de redes especializadas para a classificação de cada tipo de distúrbio.

Uma metodologia baseada em redes neurais para a detecção, classificação e localização de faltas em sistemas elétricos é apresentada em *Arruda (2002)* (ARRUDA, 2002). O trabalho busca identificar faltas nos sistemas, utilizando o conhecimento adquirido pela rede neural. Para o treinamento da rede, foram empregadas simulações de curtos circuitos via ATP e o emprego previsto dos resultados é na concepção de um sistema automatizado para análise de faltas, baseado em amostras das tensões e correntes trifásicas obtidas através de registradores digitais de perturbação - RDP.

O objetivo do trabalho apresentado por *Dash, Chilukuri e Chun (2003)* (DASH; CHUN; CHILUKURI, 2003) é a utilização de uma transformada *wavelet* modificada, chamada de transformada S de multi-resolução, para obter características de distúrbios em sistemas de potência. Essas características são classificadas através do uso de uma rede neural fuzzy perceptron multi-camada. A transformada S é originada da transformada de Fourier de curta duração (STFT - Short Time Fourier Transform) e da transformada *wavelet* e é equivalente a uma transformada *wavelet* com correção de fase. A versão fuzzy da rede neural perceptron multi-camada é utilizada para inferir a classe à qual pertence uma determinada amostra e para gerar regras de produção que serão responsáveis por associar um fator de

confiabilidade à classificação realizada.

A classificação de distúrbios adotada em *Gaing (2004)* (GAING, 2004) consiste em usar o Power System Blockset *Toolbox* do MATLAB para gerar um sinal senoidal puro e seis amostras de sinais com distorções transitórias representando distúrbios conhecidos. Neste processo, a taxa de amostragem foi considerada igual a 256 amostras por ciclo e a *wavelet* usada foi a db4 (Daubechie 4) para realizar a transformada wavelet discreta. Além disso foi usada uma rede neural probabilística (PNN - Probabilistic Neural Network), que faz parte do Neural Network Toolbox do software MATLAB, para fazer a classificação.

Entre as publicações nacionais o trabalho de *Souza et al (2004)* (SOUZA et al., 2004) apresenta resultados obtidos pela implementação de algoritmos de inteligência artificial, usados para identificar e classificar faltas em linhas de transmissão. A metodologia proposta usa dados amostrados de sinais de tensão e corrente obtidos por Registradores Digitais de Falta (DFRs). O desempenho dos algoritmos do tipo resilient propagation (RPROP) e backpropagation são avaliados para faltas monofásicas, bifásicas e trifásicas. Os resultados obtidos atestam a eficiência e eficácia do uso das redes neurais, principalmente as redes MLP (multi-layer perceptron) em classificação de faltas em linhas de transmissão. Pela investigação dos resultados, verificou-se que o algoritmo RPROP obteve um melhor desempenho. A sua superioridade, quando comparado ao backpropagation, é atestada pela análise das curvas do erro médio quadrático dos conjuntos de treinamento e validação.

Lira et al (2004) (LIRA et al., 2004) apresenta um método para classificação de distúrbios elétricos baseado em redes neurais artificiais, utilizando no treina-

mento sinais reais de tensão coletados através de registradores digitais de perturbação existentes no sistema de monitoração da CHESF. O sinal de tensão perturbado é coletado a uma taxa de amostragem de 128 amostras/ciclo na frequência de 60 Hz durante 14 ciclos. O sinal de tensão real coletado é processado em duas etapas: inicialmente é decomposto através da transformada wavelet até o quinto nível de resolução; em seguida os coeficientes wavelet são processados via análise de componentes principais que opera projetando os dados linearmente em um subespaço de menor dimensão. A classificação é realizada pela combinação de três redes MLP com diferentes arquiteturas. O algoritmo Resilient Backpropagation foi utilizado no treinamento das redes. Foram obtidos bons resultados para os cinco tipos de distúrbios testados (afundamentos e elevação de tensão, harmônicos, transitórios, interrupção e para ausência de distúrbio).

Brito et al (2005) (SILVA et al., 2005) apresenta um método de detecção e classificação de faltas em linhas de transmissão. A detecção da falta e de seu intervalo de duração é realizada por um conjunto de regras estabelecidas a partir da análise dos sinais de corrente no domínio do tempo e dos coeficientes wavelet. Na etapa de classificação emprega-se uma RNA, cujos sinais de entrada são as tensões e correntes nas linhas de transmissão. O método é avaliado para faltas reais e simuladas em linhas de transmissão de 230 kV do sistema elétrico da CHESF. A principal contribuição do método está relacionada à pré-análise e triagem dos registros capturados pelos equipamentos registradores de perturbação. Além da situação normal de operação em regime permanente do sistema, as faltas foram diferenciadas de distúrbios associados à qualidade de energia elétrica e de operações de manobra para manutenção do sistema. 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 linhas de transmissão.

O trabalho de *Bezerra, Machado e Palaes (2005)* (MACHADO; BEZERRA; PELAES, 2005) tem como objetivo usar os dados disponíveis nos centros de controle e operação das concessionárias de energia elétrica obtidos pelos registradores de perturbação (RP's), para classificar e quantificar de forma automática sinais que caracterizem problemas de qualidade da energia, quanto a variações de tensão de curta duração: afundamentos, elevações e interrupções. O método proposto usa a transformada wavelet para obter um vetor característico para as tensões das fases A, B e C, e uma rede neural probabilística para classificação. Os sinais classificados como apresentando variações de curta duração são quantificados quanto a duração e amplitude, usando-se as propriedades da análise multiresolução da decomposição do sinal. Esses parâmetros, então, irão formar uma base de dados onde procedimentos de análise estatística podem ser usados para gerar relatórios com as características da qualidade da energia.

Em 2006 *Gao e Wu* (GAO; WU, 2006) apresentaram um método baseado na análise multiresolução Wavelet (wavelet multiresolution analysis - MRA) e em máquinas de vetor de suporte (support vector machines - SVMs) para classificação de distúrbios de qualidade de energia em sistemas de potência. Após a decomposição multiresolução do sinal com distúrbios de qualidade de energia, vetores característicos podem ser obtidos. Máquinas de vetor de suporte são então usadas para classificar os vetores característicos de distúrbios de qualidade da energia. Para finalizar o trabalho, os autores comparam SVM X Rede Neural Artificial.

Um novo método de detecção e classificação de distúrbios de qualidade de energia baseado na transformada *wavelet* e redes neurais de funções de base radial (RBF) é apresentado em 2007 por *Liu, Yuguo e Zhao* (HUA; YUGUO; WEI, 2007). As *wavelets* são empregadas para extrair características do sinal com distúrbio. Tais características obtidas dos coeficientes *wavelets* são colocadas como entrada nas redes RBF para classificação de distúrbios de qualidade de energia. O modelo de classificação é estabelecido e combinado com o método dos mínimos quadrados ortogonais recursivos (Recursive Orthogonal Least Squares Algorithm - ROLSA) para determinar os parâmetros da rede. O tipo de distúrbio pode ser obtido quando o sinal com falta é usada como entrada na rede treinada.

Como exposto, o estado da arte apresenta vários estudos que tratam da classificação de faltas nos sistemas elétricos de potência, porém, como este trabalho tem como foco a qualidade de energia, foi mais apropriado trabalhar com a classificação de distúrbios. E para realizar tal classificação, usou-se nesta tese apenas sinais de tensão, entretanto, sinais de corrente também podem ser analisados, como observa-se em outros trabalhos.

Os sinais de tensão analisados precisam passar, então, por um pré-processamento e para isso a maioria dos trabalhos, assim como este, utilizou a transformada *wavelet*, cujo o tipo *wavelet* utilizada foi a de Daubechies 4. Porém, outros tipos de *wavelets*, como Daubechies 3, 6, 8 e 10 também são encontradas em outras referências.

Como será descrito nos próximos capítulos, a classificação dos distúrbios é realizada através do uso de redes neurais artificiais. Além desta, o estado da arte

apresenta trabalhos que usam outras técnicas inteligentes de classificação, como por exemplo, máquinas de vetor suporte (Support Vector Machines - SVM). Os distúrbios aqui classificados foram quatro: harmônicos, transitórios, afundamento e elevação de tensão. Em outros trabalhos relacionados à área é possível encontrar outros eventos em análise, tais como interrupção momentânea de tensão ou até mesmo a ausência de distúrbios.

1.3 Contribuições

Os registros de perturbações em sistemas de energia elétrica são indispensáveis à avaliação dos índices da qualidade da energia.

Porém à grande quantidade de registros existentes, torna indispensável a automatização da análise. Foi com este objetivo que este trabalho foi desenvolvido, afim de realizar a classificação automática dos distúrbios presentes nos sinais registrados.

A técnica desenvolvida para realizar a classificação automática dos distúrbios, em resumo, consiste em pré-processar as amostras de sinais de tensão, obtidas por equipamentos Registradores de Perturbação (RDPs), de forma a preparar estes sinais para classificação, realizada por redes neurais artificiais, apresentando como resultado o tipo de distúrbio presente nas amostras de sinais que estão sendo analisadas.

Através de um estudo mais aprofundando, foi possível observar a importância do pré-processamento dos sinais para a classificação dos distúrbios. Tal estudo,

que será detalhado no capítulo 4 dessa tese, foi significativo para alcançar uma melhora na qualidade da classificação, sendo esta a principal contribuição do trabalho.

Além disso, destaca-se a análise de sinais com diferentes taxas de amostragem. Pela metodologia desenvolvida foi possível observar que a taxa de amostragem do sinal está relacionada com o índice de acerto obtido na classificação dos distúrbios.

Capítulo 2

Teoria Básica de Redes Neurais Artificiais e de Transformada

Wavelet

Este trabalho tem como objetivo obter a classificação automática dos distúrbios presentes nos sistemas elétricos de potência. Para isso foram desenvolvidos estudos sobre técnicas inteligentes de classificação e o uso de ferramentas matemáticas. Dentre estas destaca-se neste capítulo os conceitos fundamentais de redes neurais artificiais e de transformada *wavelet*.

2.1 Redes Neurais Artificiais

O funcionamento do cérebro humano é uma das mais ricas obras da natureza. A rede neural biológica é formada por milhões de unidades fundamentais chamadas

de neurônios. Um neurônio típico é composto por um corpo celular ou soma, um axônio tubular e várias ramificações arbóreas conhecidas como dendritos. Os dendritos formam uma malha de filamentos finíssimos ao redor do neurônio, ao passo que o axônio consta de um tubo longo e fino que ao final se divide em ramos que terminam em pequenos bulbos que quase tocam os dendritos dos outros neurônios. O pequeno espaço entre o fim do bulbo e o dendrito é conhecido como sinapse, através da qual as informações se propagam. Nas figuras 2.1 e 2.2 são mostradas ilustrações de um neurônio biológico e de uma sinapse (VIEIRA; ROISENBERG, 2008).




Figura 2.1: Neurônio biológico

Uma rede neural artificial é inspirada na rede neural biológica, pois a rede neural artificial simula de forma matemática e lógica o funcionamento de um neurônio humano.

Um modelo neural foi proposto por McCulloch e Pitts (MCP) em 1943 que




Figura 2.2: Representação da sinapse neural

simplificava o que se sabia a respeito do neurônio biológico naquela época (PANICKI, 2004).

A descrição matemática proposta por McCulloch e Pitts resultou em um modelo matemático com n terminais de entrada x_1, \dots, x_n representando os dendritos, e com apenas um terminal de saída y representando o axônio.

Os terminais de entrada do neurônio têm pesos w_1, \dots, w_n , com valores que podem variar positivamente ou negativamente dependendo das sinapses correspondentes serem inibitórias ou excitatórias.

O efeito de uma sinapse particular no neurônio pós-sináptico é dado por: $x_i w_i$. Os pesos determinam em que grau o neurônio deve considerar sinais de disparo que ocorrem naquela conexão.

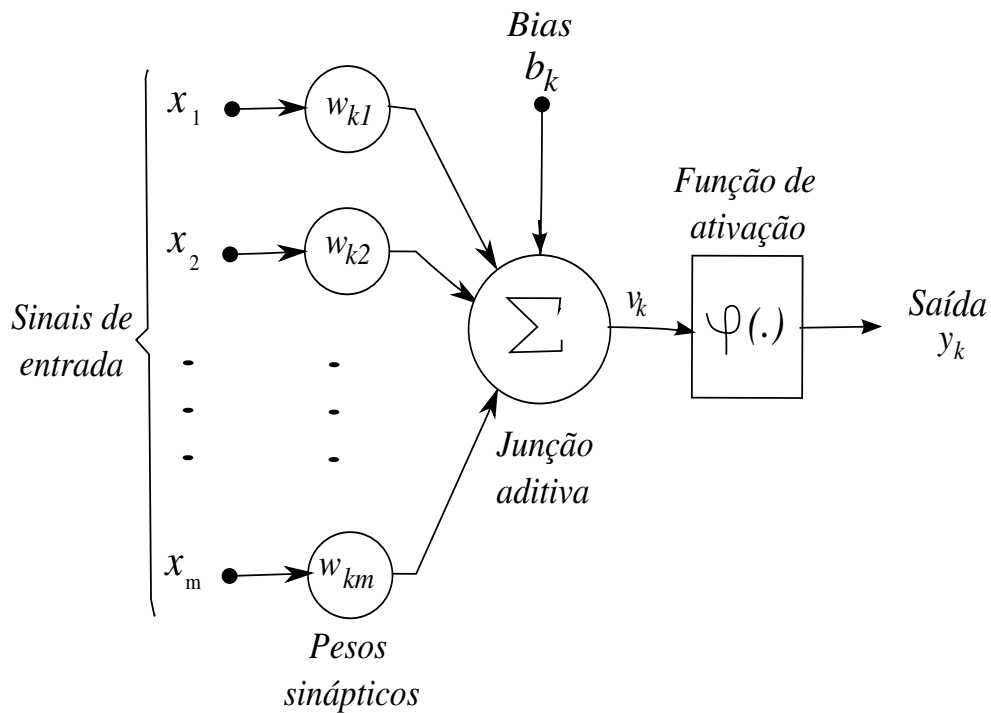


Figura 2.3: Modelo não-linear de um neurônio

2.1.1 O Neurônio Artificial

Um neurônio é uma unidade de processamento da informação fundamental para a operação de uma rede neural. O diagrama da figura 2.3 mostra o modelo de um neurônio artificial, que forma a base para o projeto de redes neurais. Nele é possível identificar três elementos básicos (HAYKIN, 1999):

1. Um conjunto de *sinapses*, em que cada uma é caracterizada por um peso ou força própria. Especificamente, um sinal x_j na entrada j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} . O primeiro índice do peso sináptico se refere ao neurônio em questão e o segundo se refere ao terminal de entrada da sinapse à qual o peso se refere.

2. Um *somador* para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio; as operações descritas aqui constituem um combinador linear.
3. Uma *função de ativação* para restringir a amplitude da saída de um neurônio.

O modelo da figura 2.3 inclui também um *bias* aplicado externamente, representado por b_k . O bias b_k tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo.

Em termos matemáticos, pode-se descrever um neurônio k a partir do seguinte par de equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.1)$$

e

$$y_k = \varphi(u_k + b_k) \quad (2.2)$$

onde x_1, x_2, \dots, x_m são os sinais de entrada (descritores); $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o bias; $\varphi(\cdot)$ é a função de ativação; e y_k é o sinal de saída do neurônio. O uso do bias b_k tem o efeito de aplicar uma transformação afim à saída u_k do combinador linear no modelo da figura 2.3, como mostrado por

$$v_k = u_k + b_k \quad (2.3)$$

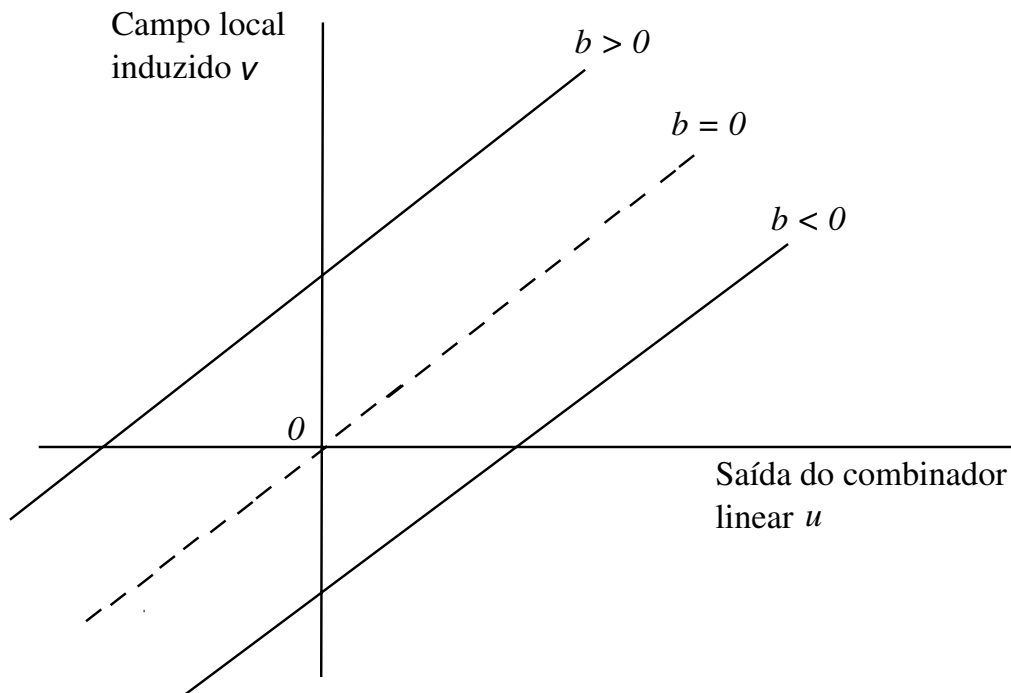


Figura 2.4: Transformação afim produzida pela presença de um bias.

Em particular, dependendo se o bias b_k é positivo ou negativo, a relação entre o potencial de ativação v_k do neurônio k e a saída do combinador linear u_k é modificada na forma da figura 2.4. Como resultado desta transformação afim, o gráfico de v_k em função de u_k não passa mais pela origem. O bias b_k é um parâmetro externo do neurônio artificial k . Pode-se considerar a sua presença como na equação (2.2). Equivalentemente, pode-se formular a combinação das equações (2.1) até (2.3) como segue:

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (2.4)$$

$$y_k = \varphi(v_k) \quad (2.5)$$

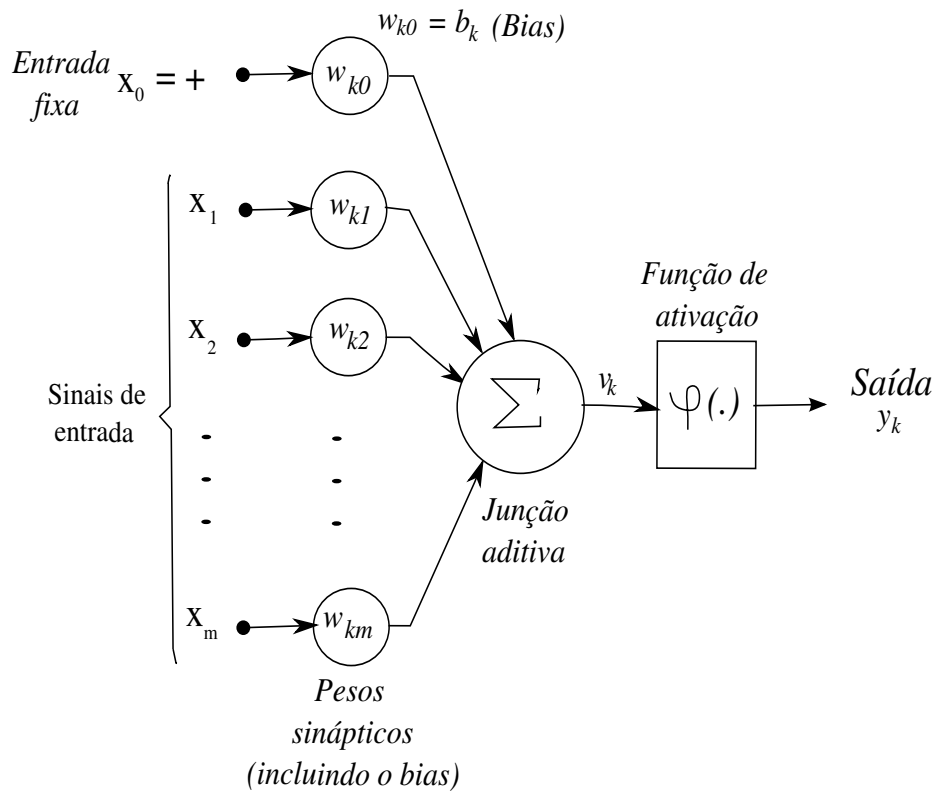


Figura 2.5: Outro modelo não-linear de um neurônio.

Na equação 2.4, adiciona-se uma nova sinapse. A sua entrada é:

$$x_0 = +1 \quad (2.6)$$

e o seu peso é

$$w_{k0} = b_k \quad (2.7)$$

Pode-se, portanto, reformular o modelo do neurônio k como na figura 2.5. Nesta figura, o efeito do bias é levado em conta de duas maneiras: (1) adicionando-se um novo sinal de entrada fixo, igual a +1 e (2) adicionando-se um novo peso sináptico igual ao bias b_k .

2.1.2 Topologias Básicas de Redes Neurais

Para a vasta maioria dos problemas práticos um único neurônio não é suficiente. Por isso, utilizam-se neurônios interconectados, sendo que a decisão de como interconectar os neurônios é uma das mais importantes decisões a se tomar em um projeto de uma rede neural artificial.

No tocante de como os neurônios se interligam, é conveniente ressaltar a utilização de camadas intermediárias (ou ocultas) que permitem as RNAs implementar superfícies de decisão mais complexas. Estas camadas permitem que seus elementos se organizem de tal forma que cada neurônio aprenda a reconhecer características diferentes do conjunto de entrada. Assim, o algoritmo de treinamento deve decidir que características devem ser extraídas do conjunto de treinamento. A desvantagem em utilizar camada oculta é que o aprendizado se torna muito mais difícil (VIEIRA; ROISENBERG, 2008).

As redes neurais artificiais podem ser diretas ou recorrentes, sendo que a principal diferença entre elas é que, na primeira, os neurônios não recebem realimentação em suas entradas, ou seja, seu grafo não tem ciclos.

Atualmente as redes neurais diretas são as mais utilizadas, principalmente pelo advento da popularização do algoritmo de treinamento backpropagation. Este tipo de rede pode ser considerado um aproximador universal de funções, sendo que seu nível de precisão dependerá principalmente do número de neurônios, bem como da escolha eficiente do conjunto de descritores usados no treinamento.

Nas redes neurais recorrentes existe pelo menos um ciclo de retroalimentação, onde algum neurônio fornece o seu sinal de saída para a entrada de outro neurônio.




Figura 2.6: Rede neural direta

Este tipo de rede se comporta melhor com problemas dinâmicos e que portanto necessitam de dinâmica da rede neural.

As figuras 2.6 e 2.7 ilustram redes neurais diretas e recorrentes, respectivamente. É importante salientar que as conexões entre neurônios podem ser feitas de outras maneiras, ou seja, pode-se fazer ligações entre neurônios da mesma camada, pode-se fazer ligações entre todos neurônios de uma camada com apenas alguns de outra camada, e assim por diante. A disposição das ligações dependerá de que tipo de rede neural se deseja utilizar, bem como novas arquiteturas ainda são objeto de pesquisa e o campo ainda está aberto para inovações nesse sentido.

2.1.3 Processos de Aprendizagem

A utilização de uma RNA na solução de uma tarefa passa inicialmente por uma fase de aprendizagem, quando a rede extrai informações relevantes de padrões de




Figura 2.7: Rede neural recorrente

informação que lhe forem apresentados, criando assim uma representação própria para o problema. A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, dos pesos das conexões entre as unidades de processamento, que guardam ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando.

Quanto à forma de aprendizado, as RNA's podem ser classificadas em dois tipos:

- **Aprendizado Supervisionado:** tem em sua estrutura uma espécie de instrutor que confere o quanto a rede está próxima de uma solução aceitável, adaptando na concepção do treinamento os pesos entre os neurônios, de modo a prover uma menor diferença entre as saídas desejadas e a obtida.
- **Aprendizado Não Supervisionado (auto-organização):** não possui conhecimento a priori das saídas da rede e funciona de modo a distinguir classes

de padrões diferentes dos dados apresentados à rede, através de algoritmos de aprendizado baseados geralmente em conceitos de vizinhança e agrupamento.

Na aprendizagem não-supervisionada não existem saídas desejadas. O objetivo é descobrir padrões significativos ou características nos dados de entrada e fazer essa descoberta sem o conhecimento da sua respectiva saída. Esse processo de aprendizagem consiste em modificar repetidamente os pesos sinápticos de todas as conexões do sistema em resposta a padrões de entrada e de acordo com regras pré-determinadas, até se desenvolver uma configuração final.. Para mais informações sobre aprendizado não supervisionado, consultar (KOHONEN, 1987) e (FREEMAN; SKAPURA, 1992).

Neste trabalho foi utilizado o tipo de aprendizado supervisionado, cujo algoritmo de treinamento foi o Resilient Propagation (Rprop), que é uma variação do algoritmo backpropagation, o qual é a alternativa mais utilizada para treinamento de redes neurais diretas e por esse motivo será melhor detalhado a seguir.

2.1.3.1 O Algoritmo Backpropagation

O algoritmo backpropagation provê um aprendizado supervisionado, isto é, procura achar iterativamente a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural, segundo um erro mínimo, ajustando os pesos entre as camadas através da retropropagação do erro encontrado em cada iteração.

Uma solução para superar o problema do aprendizado da classificação de padrões não-linearmente separáveis (onde não é possível construir uma linha reta




Figura 2.8: a) e b) Representação gráfica de padrão linearmente separável; c) Representação gráfica do padrão não linearmente separável

como fronteira de decisão entre as classes - figura 2.8) é a utilização de uma camada intermediária de neurônios, chamada Camada Oculta, de modo a poder implementar superfícies de decisão mais complexas. A característica principal da camada oculta é que seus elementos se organizam de tal forma que cada neurônio aprenda a reconhecer características diferentes do conjunto de entrada. Assim, o algoritmo de treinamento deve decidir que características devem ser extraídas do conjunto de treinamento.

Como até o início dos anos 70 nenhum algoritmo de aprendizado para estas redes multicamadas havia sido desenvolvido, as pesquisas na área de redes neurais acabaram caindo em descrédito, até que nos anos 80, um algoritmo chamado retropropagação (do inglês, Backpropagation), veio fazer renascer o interesse geral pelas redes neurais.

Um resumo da operação da rede é apropriada neste instante para ilustrar como o Backpropagation é utilizado para o aprendizado de problemas de mapeamento complexo. Basicamente, a rede aprende um conjunto pré-definido de pares de

exemplos de entrada/saída em ciclos de propagação/adaptação. Depois que um padrão de entrada foi aplicado como um estímulo aos elementos da primeira camada da rede, ele é propagado por cada uma das outras camadas até que a saída seja gerada. Este padrão de saída é então comparado com a saída desejada e um sinal de erro é calculado para cada elemento de saída.

O sinal de erro é então retro-propagado da camada de saída para cada elemento da camada intermediária anterior que contribui diretamente para a formação da saída. Entretanto, cada elemento da camada intermediária recebe apenas uma porção do sinal de erro total, proporcional apenas à contribuição relativa de cada elemento na formação da saída original. Este processo se repete, camada por camada, até que cada elemento da rede receba um sinal de erro que descreva sua contribuição relativa para o erro total. Com base no sinal de erro recebido, os pesos das conexões são então atualizados para cada elemento de modo a fazer a rede convergir para um estado que permita a codificação de todos os padrões do conjunto de treinamento.

Como se pode observar da descrição acima, o Backpropagation faz a minimização de uma função custo, no caso, a soma dos erros médios quadráticos sobre um conjunto de treinamento, utilizando a técnica de busca do gradiente-descendente.

É também importante ressaltar que a aplicação do algoritmo Backpropagation requer a escolha de um conjunto de parâmetros (número de iterações do algoritmo, critério de parada, pesos iniciais, taxa de aprendizado), cuja influência pode ser decisiva para a capacidade de generalização da rede.

O critério de parada do treinamento exige considerar a capacidade de generalização da rede. Um treinamento prolongado demais pode levar a um sobreajuste da rede, especialmente no caso de dispormos de poucos pares de entrada e saída para o conjunto de treinamento, o que pode piorar o desempenho da rede quando o conjunto de teste lhe for apresentado.

A escolha da taxa de aprendizado η depende da função a aproximar. Valores muito pequenos de η tornam o treinamento lento, enquanto valores muito grandes podem provocar divergência do processo de treinamento.

A rede neural baseia-se nos dados a ela exibidos para extrair o modelo desejado. Portanto, a fase de treinamento deve ser rigorosa e verdadeira, a fim de serem evitados modelos espúrios.

2.1.3.2 Resilient Propagation

A principal deficiência do algoritmo Backpropagation é o longo tempo, em geral, necessário ao treinamento. O algoritmo Resilient Propagation (*Rprop*) tem como proposta variações simples deste algoritmo para acelerar o processo de aprendizado. A principal característica deste algoritmo é que o ajuste dos pesos (w) dos neurônios da rede e da taxa de aprendizado (η) depende apenas dos sinais dos gradientes da função erro $E(w)$, não dependendo portanto de sua amplitude. A função $E(w)$ é responsável pela especificação de um critério de desempenho que está associado à rede.

No algoritmo *Rprop*, os pesos e a taxa de aprendizado são alterados apenas uma única vez em cada época de treinamento (para cada rodada de simulação,

um conjunto de treinamento de exemplos, é repetidamente circulado através da rede, cada ciclo de treinamento representa uma época). Cada peso w_{ji} possui sua própria taxa de variação Δ_{ji} , a qual varia em função do tempo t da seguinte forma:

$$\Delta_{ij}(t) = \begin{cases} \eta^+ \Delta_{ij}(t-1) & \text{se } \frac{\partial E}{\partial \Delta w_{ji}}(t-1) \frac{\partial E}{\partial \Delta w_{ji}} > 0 \\ \eta^- \Delta_{ij}(t-1) & \text{se } \frac{\partial E}{\partial \Delta w_{ji}}(t-1) \frac{\partial E}{\partial \Delta w_{ji}} < 0 \\ \Delta_{ij}(t-1) & \text{caso contrário} \end{cases}$$

onde $0 < \eta^- < 1 < \eta^+$. Uma mudança no sinal das derivadas parciais correspondentes ao peso w_{ji} indica que a última mudança foi grande suficiente para que o sistema saltasse sobre um ponto de mínimo da função $E(w)$, o que implica então numa diminuição do valor de Δ_{ji} proporcional ao fator η^- . Já as derivadas consecutivas com o mesmo sinal indicam que o sistema está se movendo permanentemente em uma única direção, o que permite acelerar Δ_{ji} proporcional ao fator η^+ .

Os pesos da rede são então alterados através das seguintes equações:

$$\Delta w_{ij}(t) = \begin{cases} -\Delta_{ij}(t) & \text{se } \frac{\partial E}{\partial \Delta w_{ji}}(t) > 0 \\ +\Delta_{ij}(t) & \text{se } \frac{\partial E}{\partial \Delta w_{ji}}(t) < 0 \\ 0 & \text{caso contrário} \end{cases}$$

É importante notar que a mudança nos pesos da rede depende apenas do sinal das derivadas parciais, independentemente de seu valor. Se a derivada for positiva, o peso é decrementado por $\Delta_{ji}(t)$; se a derivada for negativa, o peso será incrementado por $\Delta_{ji}(t)$ (FREITAS; SILVA; SOUZA, 2002).

2.1.4 Projeto de Redes Neurais

Existem vários tipos de redes neurais artificiais e cada um deles possui suas características próprias quanto à forma de representar e de adquirir conhecimentos. De uma forma geral, o desenvolvimento de aplicações que utilizam redes neurais artificiais engloba seis etapas principais (SOARES et al., 2002).

1ª. Etapa: Coleta de Dados - Nesta etapa há uma minuciosa análise sobre o problema a ser resolvido. Esta análise tem como objetivo a coleta de dados relativos ao problema em questão. Os dados coletados não devem conter erros nem ambigüidades e devem ser significativos o bastante para cobrir, amplamente, o domínio do problema.

2ª. Etapa: Separação dos Dados em Conjuntos - Aqui, os dados coletados são analisados e, de acordo com suas categorias, são separados em conjuntos. Os dados utilizados para o treinamento da rede ficam no conjunto de dados de treinamento; e os dados utilizados para verificar a generalização da rede sob condições reais de utilização ficam no conjunto de dados de teste. Estes dados podem sofrer normalizações, escalonamentos e até conversões de formato para que possam ser, corretamente, utilizados pela rede.

3ª. Etapa: Configuração da Rede - O sucesso dessa etapa vai depender da experiência dos projetistas, pois essa é uma das etapas mais complexas do processo de desenvolvimento das aplicações de redes neurais, e tem um grande impacto no desempenho do sistema resultante. Para definir a configuração da rede é necessário determinar a topologia ou arquitetura da rede a ser utilizada (o número de camadas, o número de unidades de processamento em cada camada, etc) e

determinar os parâmetros do algoritmo de treinamento e as funções de ativação.

4ª. Etapa: Treinamento da Rede - O aprendizado em uma rede neural é realizado por um processo de adaptação dos seus pesos sinápticos, os quais são representados por valores numéricos que caracterizam a *força* da conexão entre dois neurônios. Nesta etapa os pesos sinápticos serão ajustados de acordo com o algoritmo de treinamento escolhido. Os aspectos importantes dessa etapa são: a escolha dos valores iniciais dos pesos sinápticos, os quais podem diminuir o tempo de treinamento; o modo de treinamento da rede, cuja eficiência vai depender do problema que está sendo tratado; e o tempo de treinamento da rede (é necessário adotar um critério de parada).

5ª. Etapa: Teste da Rede - Nesta fase o desempenho, o comportamento e os pesos sinápticos da rede são analisados e testados utilizando um conjunto de dados específicos e desconhecidos pela rede.

6ª. Etapa: Integração da Rede - Nesta fase a rede é integrada ao ambiente operacional da aplicação a que se destina. O sucesso da integração vai depender da facilidade de uso e de aquisição de dados pela rede; e da qualidade da documentação e do treinamento dos usuários da aplicação.

Concluídas as etapas de desenvolvimento, pode-se fazer uso da rede neural resultante em várias aplicações diferentes. A escolha de uma aplicação adequada à rede resultante vai depender do comportamento da rede e do tipo de saída fornecido pela rede.

2.2 Teoria *Wavelet*

Na última década as *wavelets* têm despertado interesse tanto do ponto de vista teórico como aplicado. O rápido avanço da teoria *wavelet* se deve, basicamente, à sua origem interdisciplinar, que tem seduzido pesquisadores de diferentes áreas do conhecimento, e à forma simples e versátil com que certos conceitos são abordados, de forma unificada.

Wavelets são funções que satisfazem a certos requisitos matemáticos e são usadas na representação de dados ou de outras funções. Elas utilizam a idéia de aproximação usando a superposição de funções. Esta idéia tem sua origem no trabalho de Joseph Fourier, que no século XIX descobriu que poderia utilizar senos e cossenos para representar outras funções. A novidade em relação a Fourier é que a análise em *wavelet* não é feita segundo a frequência mas sim segundo a escala. Assim, os algoritmos *wavelet* processam dados em diferentes escalas e resoluções, permitindo que sejam vistos tanto o global quanto os detalhes de um sinal (GRAPS, 1995).

2.2.1 Análise *Wavelet*

O termo *wavelet* associa-se a idéia de *pequenas ondas*. No sentido desta análise, esse termo está associado a ondas localizadas, ou seja, ondas que crescem e decaem em um período limitado de tempo. Formalmente, para que uma função seja denominada de *wavelet*, usualmente denotada pela letra ψ , deve satisfazer às propriedades a seguir:

a) A integral dessa função (*wavelet*) deve ser zero, isto é:

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0. \quad (2.8)$$

Isso garante que a função *wavelet* tenha uma forma do tipo onda. Essa condição é conhecida como condição de admissibilidade.

b) A função *wavelet* deve ter energia unitária, ou seja,

$$\int_{-\infty}^{+\infty} |\psi(t)|^2 dt = 1. \quad (2.9)$$

Isso garante que a função *wavelet* possua suporte compacto, ou com um decaimento rápido de amplitude, garantindo a localização temporal.

De modo geral, as funções *wavelet* possuem a propriedade de dupla localização: em frequência e em tempo. A localização temporal ocorre por ser a função *wavelet* localizada em um intervalo finito. Dessa forma, à medida que a escala aumenta, as funções *wavelet* ficam localizadas em intervalos de comprimento cada vez menores. Em cada nível de escala, todas as funções *wavelet* possuem a mesma forma, só mudando seus pontos de localização, isto é, transladando. A localização em frequência deve-se à transformada de Fourier da função *wavelet* poder ser interpretada como um filtro passa-faixa. Devido à propriedade de dupla localização das funções *wavelet*, a transformada wavelet é dita do tipo local em tempo-frequência, com resolução temporal e em frequência inversamente proporcionais (DOMINGUES; JÚNIOR; COSTA, 2003).

A análise de *wavelet* é ainda uma ferramenta para decomposição em nível

hierárquico em um conjunto de aproximações e detalhes. O nível hierárquico corresponde à Escala Diática (escala de potência dois). Ela permite a descrição de uma função em termos globais, mais termos que variam de detalhes globais até detalhes finos, aumentando o nível de resolução. As *wavelets* oferecem uma técnica elegante para representar os níveis de detalhes presentes.

2.2.1.1 Aproximações e Detalhes

Pode-se observar um sinal através de uma escala grande, onde se notam as características globais do sinal. Ou, por uma escala menor, como por uma lupa, onde se notam os detalhes finos.

Em análise *wavelet*, um sinal S é decomposto em coeficientes de aproximação A_1 e coeficientes de detalhes D_1 do nível 1. A aproximação do nível 1 A_1 é, também, decomposta em coeficientes de aproximação A_2 e coeficientes de detalhes D_2 do nível 2. Este processo ocorre, de forma recursiva, até o n -ésimo nível de decomposição. A figura 2.9 nos mostra a Árvore de Decomposição *Wavelet* até o terceiro nível.

A decomposição *wavelet* consiste em aproximações e detalhes. As aproximações representam o conteúdo de baixa frequência do sinal original. Os detalhes representam o conteúdo de alta frequência do sinal original.

2.2.2 Análise Multiresolução

O objetivo da análise multiresolução (AMR) é representar uma dada função em diferentes níveis de resolução e obter a informação necessária para se poder pas-





Figura 2.9: Árvore de decomposição wavelet (S - sinal; A_i - coeficientes de aproximação do nível i ; D_i - coeficientes de detalhes do nível i)

sar de um nível de resolução para outro de uma forma eficaz. Com a análise multiresolução é possível obter uma boa resolução no tempo e em frequência, que se torna útil pelo fato de que os sinais encontrados em aplicações práticas geralmente apresentam componentes de alta frequência por curtas durações de tempo e componentes de baixa frequência por longa duração de tempo (SANTOS, 2004).

Resumindo, o objetivo básico da AMR é dividir o espectro de um dado sinal em sub-bandas de frequência e então tratar individualmente cada uma das sub-bandas, através de bancos de filtros passa-alta e passa-baixa.

Para se conseguir uma representação não redundante e uma reconstrução única do sinal original, são necessários bancos de filtros ortogonais. A transformada *wavelet* e a AMR estão estreitamente relacionados.

Figura 2.10: *Wavelet* Haar

O número máximo de níveis de decomposição *wavelet* é determinado pelo comprimento do sinal original, pela *wavelet* mãe selecionada e pelo nível de detalhe exigido. Os filtros passa-alta e passa-baixa são determinados respectivamente pela função escala e função *wavelet*.

2.2.3 Famílias *Wavelets*

Existem diferentes tipos de famílias *wavelets*. Porém, descrevem-se apenas alguns tipos de bases *wavelets*: Haar, Daubecheis, Coiflets e Symlets (FONSECA, 2004). Nas figuras a seguir, o eixo horizontal representa o tempo ou posição e o eixo vertical a amplitude das *wavelets*.

2.2.3.1 Haar

A base de Haar é a primeira e mais simples das bases. Ela é descontínua, se parece com a função degrau e, também, equivale a *Wavelet* de Daubechies db1 (Figura 2.10).

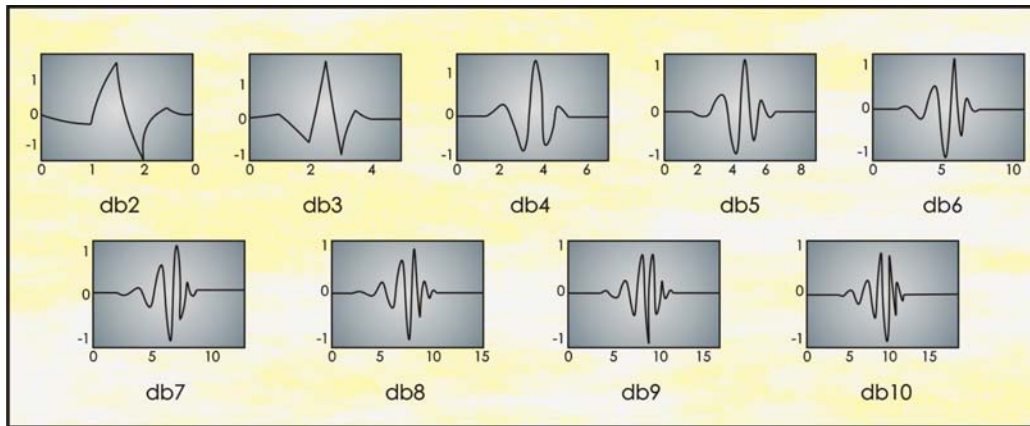


Figura 2.11: Wavelet Daubechies

2.2.3.2 Daubechies

A família de bases *wavelet* de Daubechies, leva o sobrenome de Ingrid Daubechies, uma das mais importantes pesquisadoras no campo das *wavelets*. Ela descobriu as *wavelets* ortonormais com suporte compacto, o que tornou possível a análise discreta das *wavelets*.

O nome da família *wavelet* Daubechies é geralmente escrito por três caracteres como dbN , onde db é uma indicação de seu sobrenome (Daubechies) e N é o número de sua ordem (Figura 2.11).

2.2.3.3 Coiflets

A *wavelet* de Coiflets é denominada pelo nome $CoifN$, onde $Coif$ descreve seu nome N é o número de sua ordem.

As Coiflets têm função *wavelet* mãe, ou seja, Ψ com $2N$ momentos iguais a 0 (zero) e função escala, Φ com $2N - 1$ momentos iguais a 0 (zero) (Figura




Figura 2.12: Wavelet Coiflets




Figura 2.13: Wavelet Symlets

2.12).

2.2.3.4 Symlets

$SymN$ denomina a família wavelet Symlets, onde Sym é o nome e N é a ordem. As Symlets são próximas das wavelets simétricas propostas por Daubechies, como uma modificação da família db . Ela apresenta as mesmas propriedades da família db (Figura 2.13).

2.2.4 Transformada *Wavelet*

As transformações matemáticas são empregadas no mapeamento de funções de um domínio para outro. As transformações são particularmente importantes na análise de sinais porque no domínio transformado algumas propriedades relevantes do sinal ficam mais evidentes.

A transformada *wavelet* é uma ferramenta que permite decompor um sinal em diferentes componentes de frequências, permitindo assim, estudar cada componente separadamente em sua escala correspondente.

São duas as variantes da transformada *wavelet*: a transformada *wavelet* contínua (CWT - Continuous *Wavelet* Transform), definida no tempo contínuo; e a transformada *wavelet* discreta (DWT - Discrete *Wavelet* Transform), definida no tempo discreto. Como os sinais analisados neste trabalho foram sinais discretizados, dá-se destaque a transformada *wavelet* discreta.

Além da transformada direta, a transformada inversa também desempenha um papel muito importante na análise de sinais, permitindo que seja obtida a reconstrução do sinal original através de sua representação em escalas.

2.2.4.1 A Transformada *Wavelet* Discreta

Na transformada *wavelet* discreta (DWT) os parâmetros de dilatação e translação não variam continuamente, como no caso da transformada *wavelet* contínua, mas sim discretamente.

Quando $f(t)$ é um sinal discreto no tempo, ($t \in \mathbb{Z}$), as *wavelets* filhas apenas

serão definidas em argumentos inteiros. Em certas aplicações, incluindo a análise de sinal, podem-se restringir os valores dos parâmetros de dilatação e translação a, b a uma grade discreta, fixando um passo de dilatação $a_0 > 1$ e um passo de translação $b_0 \neq 0$. A família de *wavelets* de interesse, para $j, k \in \mathbb{Z}$, torna-se então (SANCHES, 2001):

$$\psi_{ab}(t) = \frac{1}{\sqrt{a_0^j}} \psi \left(\frac{t - kb_0 a_0^j}{a_0^j} \right) \quad (2.10)$$

ou

$$\psi_{jk}(t) = a_0^{-j/2} \psi(a_0^{-j}t - kb_0) \quad (2.11)$$

Note que isto corresponde a

$$a = a_0^j \quad (2.12)$$

$$b = kb_0 a_0^j \quad (2.13)$$

indicando que o parâmetro de translação b depende da taxa de dilatação escolhida. Para j grande e positivo, a função ψ_{j0} é bastante dilatada, e os passos de translação grandes ($b_0 a_0^j$) são adaptados a esta grande largura. Para j grande e negativo ocorre o contrário; a função ψ_{j0} é bastante contraída e os passos de translação pequenos $b_0 a_0^j$ são necessários para ainda cobrir toda a extensão.

2.2.5 Algoritmo de Mallat

Um dos esquemas de transformação discreta mais utilizados dentre os disponíveis na literatura opera com escalas e posições baseadas em potências de dois (as chamadas escalas e posições *diádicas*). Tal esquema foi organizado na maneira

como se conhece atualmente por Mallat em 1988, que enxergou uma analogia bastante apropriada entre o algoritmo de decomposição diádico (análise de multi-resolução) e o uso de um banco de filtros, conceito este oriundo da teoria geral de processamento de sinais. Por ser provavelmente o esquema de decomposição mais conhecido e empregado, o termo *transformada wavelet discreta (DWT)* se refere especificamente ao algoritmo de Mallat, embora outros esquemas de transformação discreta existam.

As figuras 2.14 e 2.15 ilustram a decomposição de um sinal através do bloco básico de decomposição do algoritmo de Mallat (MALLAT, 1989). Nesse processo o sinal original S passa através de filtros complementares H e L , passa-alta e passa-baixa respectivamente. Destes filtros emergem dois sinais com o mesmo número de amostras que S . Após a operação *downsampling*, que consiste em desprezar cada segunda amostra da seqüência, originam-se os sinais cA e cD , que são os coeficientes DWT. O filtro passa-baixa L tem o efeito de "suavizar" o sinal, gerando o que é denominado de *aproximação do sinal*. O filtro passa-alta H retém a parte de de alta freqüência que é denominada *detalhe do sinal* (MALLAT, 1989).

2.2.6 Esquema *Lifting*

A transformada *wavelet* discreta é uma das formas de transformada *wavelet* que consiste em transformar um sinal discreto no domínio do tempo para o domínio *wavelet*. Além do tradicional algoritmo de Mallat uma outra forma de se obter esta transformada é utilizando o esquema *lifting*, no qual um sinal amostrado no tempo é transformado para o domínio *wavelet* através de técnicas de filtragem




Figura 2.14: Bloco básico de decomposição do sinal

digital.

A principal característica do esquema *lifting* é que todas as construções são derivadas no domínio do tempo, contrastando com a abordagem tradicional, que usa no domínio da frequência (DAUBECHIES; SWELDENS, 1998; SWELDENS, 1997). A principal diferença entre a construção clássica e o *lifting* é que este não é introduzido usando a transformada de Fourier.

O esquema *lifting* (CLAYPOOLEA; BARANIUK, 1998) realiza passos sucessivos onde cada estágio deste processo envolve três etapas principais: (Figura 2.16).

- SPLIT: Divide o conjunto dos dados de entrada $f(n)$ em dois subconjuntos, um com os elementos de índice par e o outro com os elementos de índice ímpar:

$$f_e(n) = f(2n), \text{ elementos de índices pares do conjunto de entrada}$$

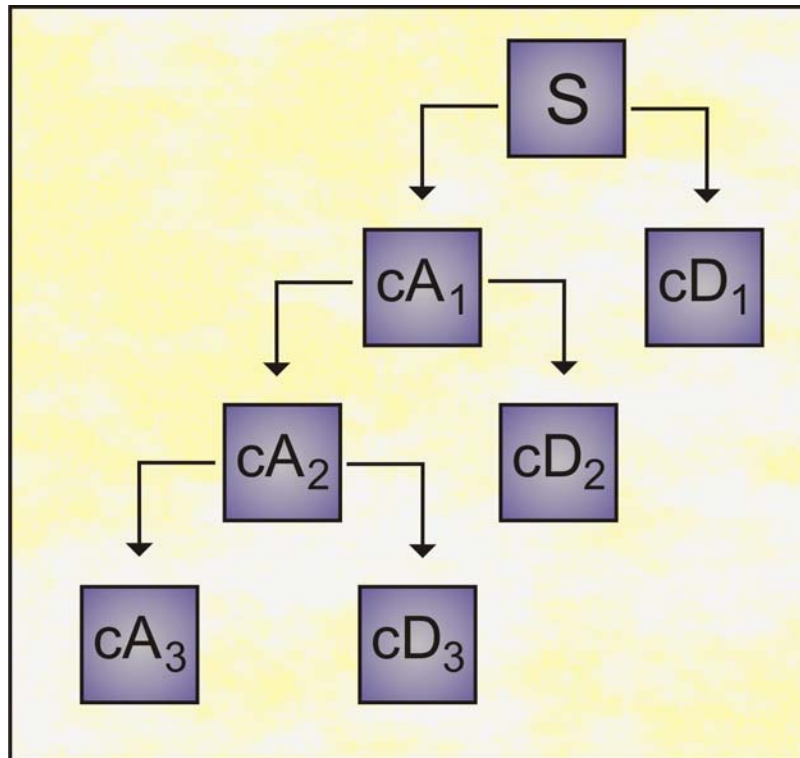


Figura 2.15: Árvore de decomposição *wavelet*

$f_o(n) = f(2n + 1)$, elementos de índices ímpares do conjunto de entrada.

- PREDICT: Geram coeficientes *wavelets* $d(n)$ pela diferença entre os elementos ímpares $f_o(n)$ e os para $f_e(n)$ usando o operador de predição P :

$$d(n) = f_o(n) - P(f_e(n)) \quad (2.14)$$

- UPDATE: combina $f_e(n)$ e $d(n)$ para obter os coeficientes $a(n)$ que representam uma aproximação do sinal original $f(n)$. Isto é obtido pela aplicação de um operador update U para os coeficientes *wavelets* e somando a $f_e(n)$:

$$a(n) = f_e(n) + U(d(n)) \quad (2.15)$$

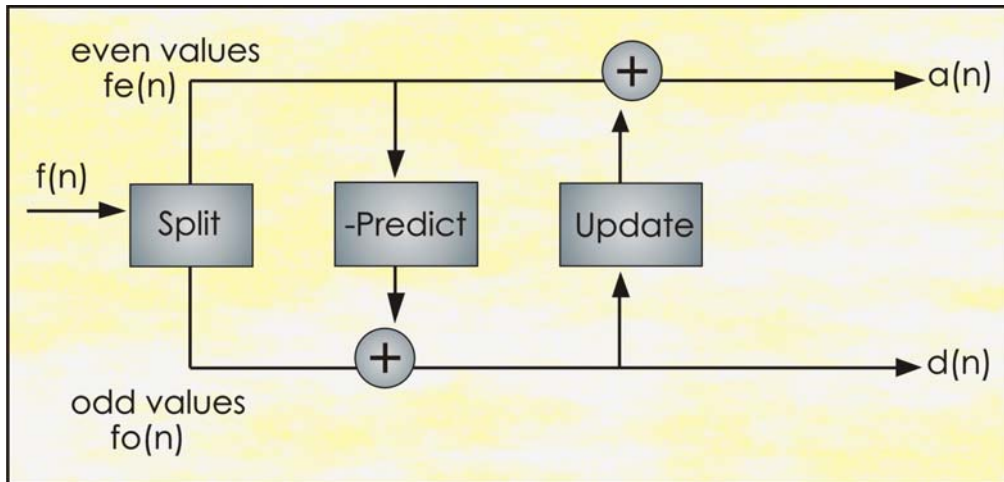


Figura 2.16: Esquema *lifting*.

Transformar um sinal discreto do domínio do tempo para o domínio *wavelet* implica em se utilizar sucessivas vezes o algoritmo ilustrado na figura 2.16, o qual serve para decompor o sinal original em diferentes escalas (ou níveis), com diferentes resoluções no tempo e em frequência.

A saída de um estágio do algoritmo torna-se a entrada para o próximo passo. O conjunto de dados de entrada consiste de 2^n elementos. Cada passo sucessivo opera 2^{n-i} elementos, onde $i = 1, 2, \dots, n - 1$. Após n estágios a transformada *wavelet* do sinal original é obtida de $[a(1) d(1) d(2) \dots d(n)]$.

Os passos *lifting* são facilmente invertidos. Arrumando as equações (2.14) e (2.15), temos:

$$f_e(n) = a(n) - U(d(n))$$

$$f_o(n) = d(n) + P(f_e(n))$$

A transformada inversa é representada pela simples inversão de cada passo realizado na obtenção da transformada direta.

Capítulo 3

Algoritmo Básico Para Classificação dos Fenômenos

Este capítulo mostra um algoritmo básico para classificação de distúrbios elétricos através da apresentação das principais etapas desenvolvidas neste trabalho.

3.1 Etapas Desenvolvidas

Este trabalho tem como objetivo obter a classificação dos distúrbios da qualidade de energia de forma automatizada com uma taxa próxima ou de até mesmo 100% de acerto. Resumidamente, o trabalho se divide em algumas etapas principais, conforme mostra o esquema da figura 3.1 (MEDEIROSJR. et al., 2006).

A primeira etapa do trabalho consiste na obtenção de amostras de sinais de tensão, simulados e reais. Após a fase de obtenção dos sinais, a fase seguinte

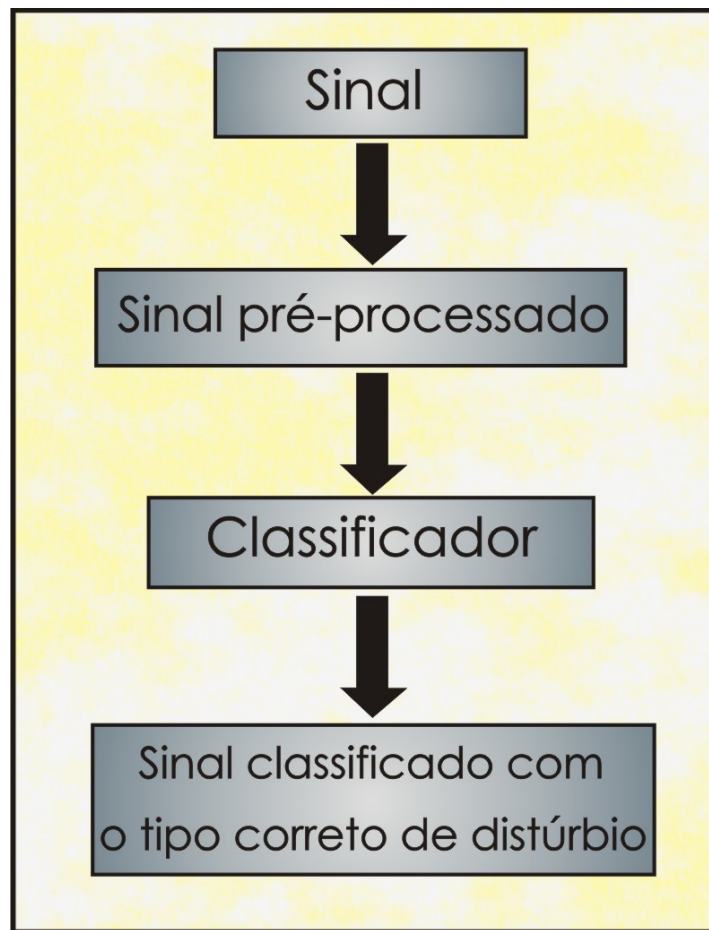


Figura 3.1: Diagrama esquemático das etapas desenvolvidas no trabalho

diz respeito ao tratamento desses dados. Os sinais registrados devem ser pré-processados de forma a obter descritores que possam ser usados na etapa seguinte, que corresponde à classificação do sinal.

A próxima etapa diz respeito à classificação do distúrbio. Tal classificação realiza-se a partir do uso de redes neurais artificiais (RNA's). Após o final desta etapa, o resultado obtido deve ser a classificação correta do distúrbio presente no sinal analisado.

A seguir, descreve-se com mais detalhes cada uma destas etapas.

3.1.1 Etapa 1: Obtenção do Sinal de Entrada

A base de dados utilizada neste trabalho é composta de sinais de distúrbios de tensão obtidos por meio de equipamento registradores instalados em vários pontos de um sistema real de transmissão. Além disso, foram usados também sinais obtidos por meio de simulações através do software ATP (Alternative Transient Program). Analisaram-se quatro tipos de distúrbios na rede: transitórios, distorções harmônicas, elevação e afundamento de tensão.

3.1.1.1 Sinais Registrados

Os sinais de tensão registrados foram obtidos através das Redes de Oscilografia e Qualimetria de um sistema real de transmissão.

Os sinais obtidos pela rede de oscilografia foram coletados a uma taxa de amostragem de 128 amostras/ciclo durante 14 ciclos. A título de exemplo, a figura 3.2 mostra o gráfico obtido para um dos sinais de tensão registrados pela oscilografia contendo o distúrbio de afundamento de tensão.

Os sinais registrados pela rede de qualimetria foram coletados com taxas de amostragem iguais a 16 amostras/ciclo durante 18 ciclos e 32 amostras/ciclo durante 54 e 28 ciclos. Optou-se por trabalhar com os sinais de qualimetria com a taxa de amostragem igual a 32 amostras/ciclo com duração de 54 ciclos, tendo em vista que esta já é uma taxa de amostragem relativamente baixa, comparativamente às taxas de amostragens dos qualímetros atualmente disponíveis no mercado. A figura 3.3 mostra um gráfico do sinal de tensão obtido pela rede de qualimetria.

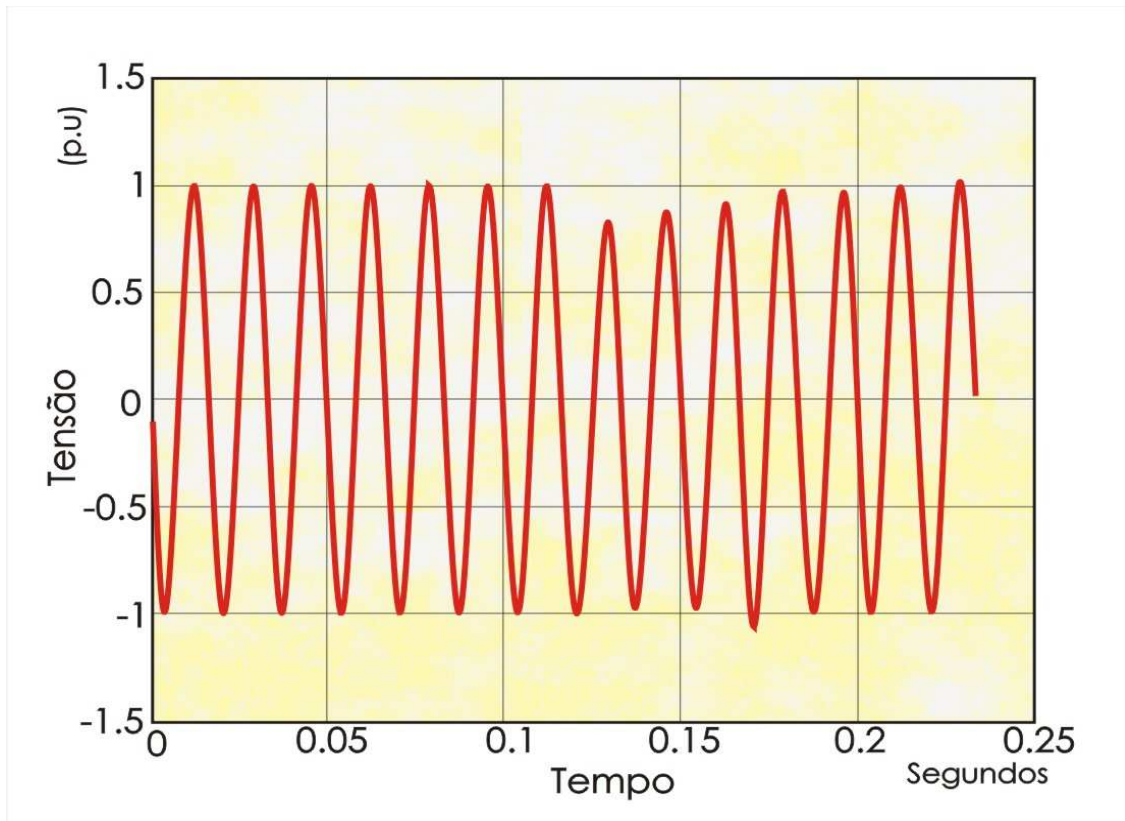


Figura 3.2: Gráfico de tensão obtido para um sinal registrado pela oscilografia (128 amostras/ciclo em 14 ciclos) com afundamento de tensão .

Para estes sinais não foi realizado nenhum método para redução de ruído (MACHADO, 2006).

3.1.1.2 Sinais Simulados

Os sinais de tensão simulados foram obtidos a partir de simulação de distúrbios em um trecho de um sistema real de transmissão (SOARES, 2001), através do software ATP, conforme diagrama mostrado na figura 3.4. Para a simulação dos eventos causadores de distúrbios foram usadas quatro barras distintas. Duas outras barras, diferentes destas, onde se pressupõe a existência de equipamentos regis-




Figura 3.3: Gráfico de tensão obtido para um sinal registrado pela qualimetria (32 amostras/ciclo em 54 ciclos) com afundamento de tensão .

tradores, foram adotadas como local de observação dos eventos. Dessa maneira, registra-se o mesmo distúrbio em diferentes pontos da rede. A figura 3.5 mostra o gráfico gerado por simulação, para as tensões nas três fases, obtidas em uma das barras de observação. O gráfico mostra sinais com afundamento de tensão.

3.1.2 Etapa 2: Pré-Processamento do Sinal de Entrada

Com base em pesquisas desenvolvidas no decorrer deste trabalho, é possível afirmar que esta é uma das mais importantes etapas desenvolvidas. Isso se deve ao fato de que foi a partir do estudo mais aprofundado desta que os resultados obtidos

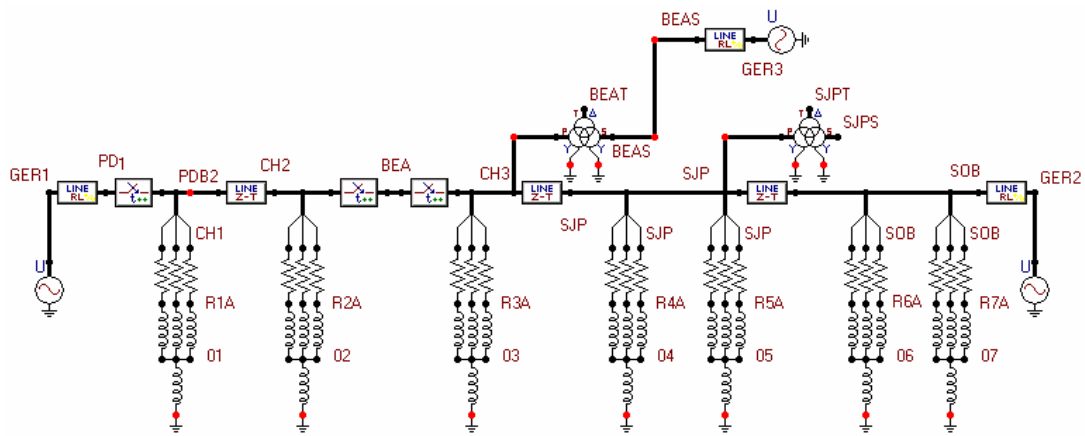


Figura 3.4: Trecho de um sistema real de transmissão - ambiente ATP-Draw.

evoluiram, atingindo uma taxa de acerto na classificação próxima dos 100%. O próximo capítulo desta tese irá detalhar a influência do pré-processamento de sinais na eficiência dos algoritmos usados para classificar os distúrbios, mostrando a evolução dos estudos realizados nesta etapa.

Afim de estabelecer descritores que caracterizem os diferentes tipos de distúrbio, desenvolveu-se uma metodologia que consiste no uso da transformada *wavelet*.

Utilizando as propriedades da transformada *wavelet*, podem-se extrair informações importantes do sinal distorcido, as quais podem ser utilizadas para identificar os principais distúrbios da qualidade da energia. A metodologia proposta (RESENDE; PENNA, 2001) foi desenvolvida e programada para utilização no MATLABTM. Os procedimentos podem ser resumidos em quatro passos:

- Passo 1: constitui-se em decompor o sinal com distúrbio em diferentes níveis de resolução. Isso é conseguido mediante a determinação dos coeficientes *wavelet* do sinal;

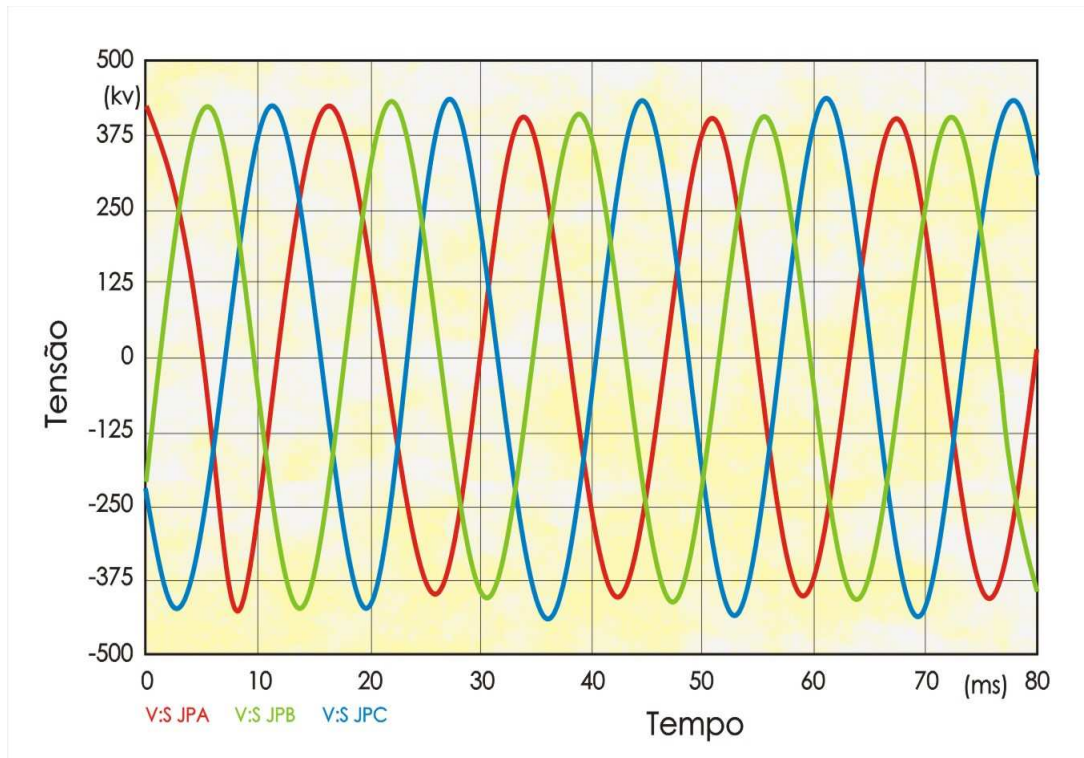


Figura 3.5: Gráfico de tensão obtido pelo software ATP com afundamento de tensão.

É importante esclarecer que antes do sinal com distúrbio ser decomposto em diferentes níveis de resolução *wavelets* este já passou por um pré - processamento. Na maioria dos sinais analisados nem todos os ciclos possuem distúrbios. Por esse motivo, foi elaborado um algoritmo que localizasse apenas a parte que contém o distúrbio, analisando apenas os distúrbios em si e desprezando as partes do sinal consideradas sem perturbações (MEDEIROSJR et al., 2007). Para realizar a seleção apenas da parte do sinal com distúrbio elaborou-se um algoritmo que realizava a comparação entre o sinal registrado e o seu respectivo sinal de referência. A partir da diferença desses sinais, sincronizados a partir do primeiro ciclo do sinal registrado,




Figura 3.6: Sinal de entrada sem passar por nenhum pré-processamento .

localizava-se o início do distúrbio. Já, pela diferença desses sinais, sincronizados a partir do último ciclo do sinal registrado, localizava-se o fim do distúrbio. A figura 3.6 mostra o sinal de entrada sem passar por nenhum pré-processamento (original) e a figura 3.7 mostra o mesmo sinal desprezando a parte sem perturbações, contendo apenas o distúrbio.

O cálculo da decomposição dos sinais em níveis de resolução *wavelet* foi realizado utilizando-se o *Wavelet Toolbox do MATLABTM*. A função utilizada para realizar a decomposição através deste *toolbox* (*wavedec*) foi desenvol-




Figura 3.7: Sinal contendo apenas o trecho com distúrbio.

vida baseada no algoritmo tradicional de Mallat (MATHWORKS, 2005).

- Passo 2: compreende o cálculo da energia concentrada em cada um dos níveis de decomposição;

A determinação das energias está fundamentada no teorema de Parseval (HSU, 1973), que estabelece: *a energia contida no sinal distorcido é igual à soma das energias concentradas nos diferentes níveis de resolução da*

sua transformada wavelet. Isso significa que a energia do sinal pode ser decomposta em termos dos seus coeficientes *wavelets*, na forma:

$$\sum_{n=1}^N |f(n)|^2 = \sum_{n=1}^N |a_j(n)|^2 + \sum_{j=1}^J \sum_{n=1}^N |d_j(n)|^2 \quad (3.1)$$

As variáveis utilizadas nessa equação têm o seguinte significado:

⇒ $f(n)$: representa o sinal com distúrbio, amostrado no domínio do tempo;

⇒ N : corresponde ao número total de amostras do sinal;

⇒ $\sum_{n=1}^N |f(n)|^2$: energia do sinal analisado;

⇒ $\sum_{n=1}^N |a_j(n)|^2$: energia concentrada na versão aproximada de nível j do sinal analisado;

⇒ $\sum_{j=1}^J \sum_{n=1}^N |d_j(n)|^2$: energias concentradas nas versões detalhadas de níveis de 1 a j do sinal analisado.

- Passo 3: consiste na repetição dos passos 1 e 2, porém apenas para o sinal de referência relativo ao sinal com distúrbio em análise;

Para obtenção dos sinais de referência elaborou-se um algoritmo que, a partir do sinal de tensão com distúrbio (sem nenhum pré-processamento) seleciona, dentre todos os seus ciclos, aquele que mais se ajuste às condições de um sinal sem perturbação (em termos de amplitude e distorção). Este ciclo de referência é repetido até que a quantidade de amostras do sinal com distúrbios seja alcançada. Além disso, para aplicação desta metodologia de classificação, o sinal de referência é sincronizado em relação ao primeiro ciclo do sinal registrado. A figura 3.8 mostra o gráfico de um sinal com distúrbio juntamente com o seu respectivo sinal de referência e a figura 3.9

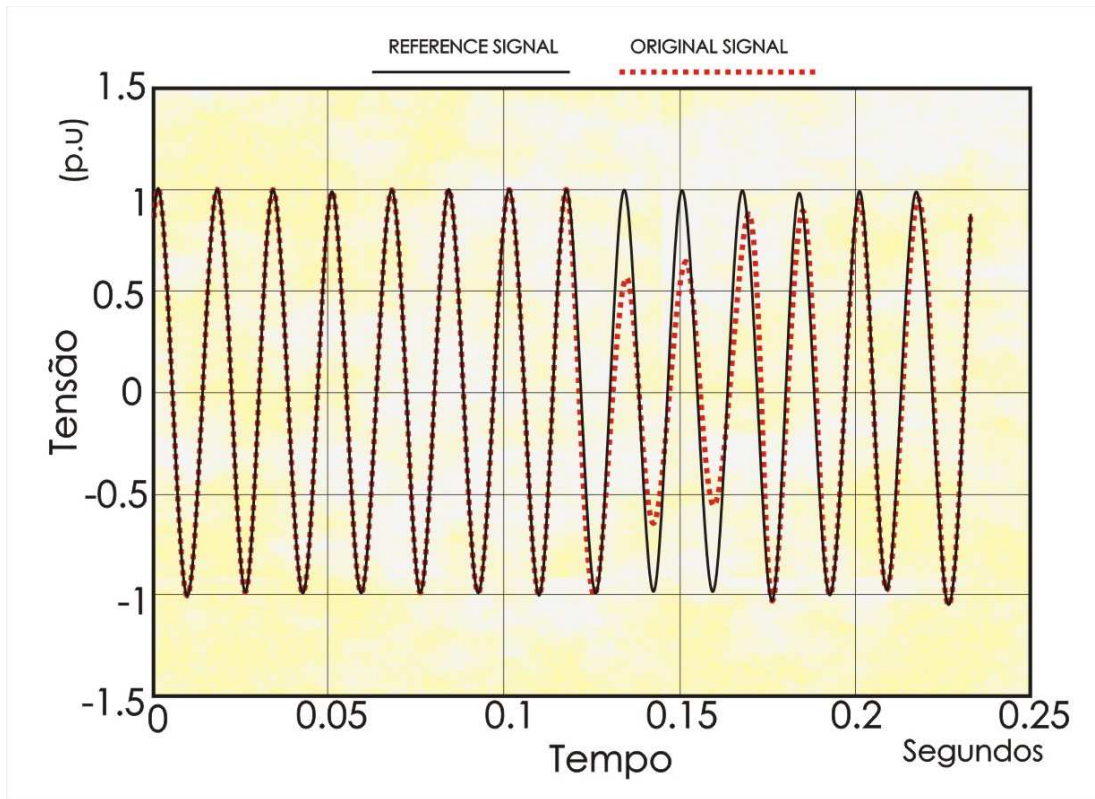


Figura 3.8: Sinal com distúrbio com o seu respectivo sinal de referência.

apresenta o gráfico contendo apenas o ciclo de referência considerado o *mais normal* obtido a partir do sinal de entrada.

- Passo 4: finalmente, faz-se uma comparação entre as energias concentradas em cada um dos níveis do sinal com distúrbio (passo 2) e do sinal de referência (passo 3). Essa comparação é feita através do cálculo da diferença percentual entre as distribuições das energias dos sinais com distúrbio e de referência. O cálculo é feito segundo a relação:

$$dp(j)(\%) = \left[\frac{en_dist(j) - en_ref(j)}{max(en_ref)} \right] * 100 \quad (3.2)$$

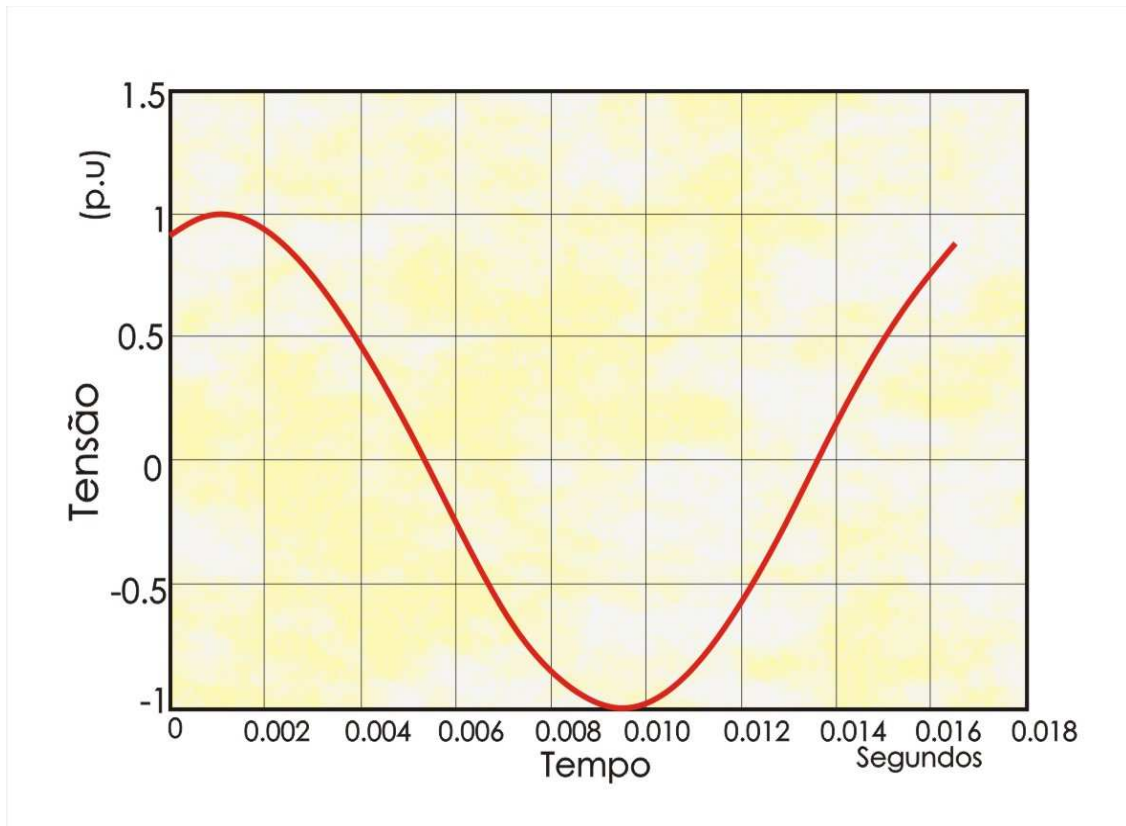


Figura 3.9: Gráfico contendo apenas o ciclo de referência considerado o *mais normal*.

onde:

⇒ j : nível da transformada;

⇒ $dp(j)$: diferença percentual entre as distribuições de energias dos sinais com distúrbio e de referência em cada nível da versão detalhada;

⇒ $en_{dist}(j)$: energia concentrada em cada nível da versão detalhada do sinal com distúrbio;

⇒ $en_{ref}(j)$: energia concentrada em cada nível da versão detalhada do sinal de referência;

$\Rightarrow \max(en_ref)$: maior energia de todos os níveis do sinal de referência.

A figura 3.10 mostra o gráfico da diferença percentual das energias dos sinais com e sem distúrbio nos diferentes níveis da versão detalhada.



Figura 3.10: Gráfico da diferença percentual das energias dos sinais com e sem distúrbio para o caso de uma elevação de tensão.

A análise destas curvas de diferença percentual indicam que distúrbios do mesmo tipo possuem tais curvas com características similares. São essas individualidades que podem ser usadas para o reconhecimento do tipo de distúrbio presente em um determinado sinal (SANTOS, 2004).

As características similares observadas na análise das curvas de diferença percentual para um mesmo tipo de distúrbio podem ser definidas como:

- Nível de decomposição wavelet em que ocorre a maior concentração de energia, ou seja, o pico das curvas das diferenças percentuais;
- Sinal da maior concentração de energia (positiva ou negativa);
- Número de elevações ocorridas em cada curva. Essas elevações podem ser positivas e/ou negativas;
- Amplitude de cada elevação e o nível em que ocorreram.

Assim, é possível afirmar, que através da comparação entre as distribuições de energia do sinal em análise e o seu correspondente sinal de referência, pode-se determinar um padrão característico para cada tipo de distúrbio. Definem-se, então, descritores que podem ser usados como padrões de entrada para a classificação por redes neurais artificiais.

3.1.3 Etapa 3: Classificador Neural

Esta etapa realiza a classificação dos distúrbios através da utilização de redes neurais artificiais. Após o seu término, o resultado obtido deve ser a classificação correta do distúrbio presente no sinal analisado.

O procedimento utilizado na classificação dos distúrbios por meio de uma estrutura neural (HAYKIN, 1999) é baseado nos descritores obtidos da decomposição dos sinais em diferentes níveis de resolução wavelets. Para os distúrbios

estudados neste trabalho foram definidos 10 descritores, de acordo com a análise das curvas de diferença percentual, e apresentados na tabela 3.1.

Tabela 3.1: Tabela com a definição de cada descritor

Descritores	
<i>descritor</i> ₁	Maior diferença percentual de energia (em módulo) entre os diferentes níveis da decomposição <i>wavelet</i> dos sinais com e sem distúrbio;
<i>descritor</i> ₂	Nível onde ocorreu a maior diferença percentual;
<i>descritor</i> ₃	Segunda maior diferença percentual de energia (em módulo) entre os diferentes níveis da decomposição <i>wavelet</i> dos sinais com e sem distúrbio;
<i>descritor</i> ₄	Nível onde ocorreu a segunda maior diferença percentual;
<i>descritor</i> ₅	Terceira maior diferença percentual de energia (em módulo) entre os diferentes níveis da decomposição <i>wavelet</i> dos sinais com e sem distúrbio;
<i>descritor</i> ₆	Nível onde ocorreu a terceira maior diferença percentual;
<i>descritor</i> ₇	Quarta maior diferença percentual de energia (em módulo) entre os diferentes níveis da decomposição <i>wavelet</i> dos sinais com e sem distúrbio;
<i>descritor</i> ₈	Nível onde ocorreu a quarta maior diferença percentual;
<i>descritor</i> ₉	Quinta maior diferença percentual de energia (em módulo) entre os diferentes níveis da decomposição <i>wavelet</i> dos sinais com e sem distúrbio;
<i>descritor</i> ₁₀	Nível onde ocorreu a quinta maior diferença percentual;

Para o classificador neural foram definidas 4 classes, cada uma representando um tipo de distúrbio considerado. A tabela 3.2 caracteriza cada uma dessas classes.

A rede neural artificial usada como classificador foi do tipo perceptron de múltiplas camadas (PMC), com treinamento do tipo retropropagação do erro.

Tabela 3.2: Classes definidas para o classificador neural

Classes	
$Classe_1$	Afundamento de tensão
$Classe_2$	Elevação de tensão
$Classe_3$	Distorções harmônicas
$Classe_4$	Transitórios

Destaca-se que a essência da aprendizagem por retropropagação é codificar um mapeamento de entrada-saída (representado por um conjunto de exemplos rotulados) nos pesos sinápticos e limiares de um perceptron de múltiplas camadas. Dessa forma é esperado que a rede se torne bem-treinada de modo que aprenda o suficiente sobre os dados de treinamento para ser capaz de generalizar esse aprendizado sobre novas entradas. Desta perspectiva, o processo de aprendizagem se transforma em uma escolha de parametrização para os pesos sinápticos da rede. Mas especificamente, pode-se ver o problema de seleção da rede como a escolha, dentre um conjunto de estruturas de modelo candidatas a *melhor* de acordo com um certo critério.

O classificador neural, com o objetivo de obter excelentes índices de acerto na classificação, foi testado com dois algoritmos de treinamento: o Backpropagation e o Resilient Propagation. Foram ainda avaliadas várias arquiteturas para a rede, variando o número de camadas ocultas e ainda o número de neurônios nestas camadas.

Capítulo 4

Pré-Processamento e Sua Importância

Este capítulo tem por objetivo apresentar a importância da etapa de pré - processamento dos sinais analisados na evolução dos resultados, mostrando que o aprimoramento dessa etapa tem grande influência na obtenção de melhores índices de acerto na classificação dos distúrbios.

4.1 Evolução dos Resultados

Um trabalho de pesquisa passa por vários estudos e avaliações. Por esse motivo, esta tese, até chegar ao seu resultado final, passou por várias fases de evolução. Tais fases referem-se às etapas apresentadas no capítulo 3: sinais analisados, pré-processamento e classificador neural. Dentre estas, destaca-se a etapa de pré-processamento dos sinais, uma vez que resultados mais significativos foram

obtidos após uma análise mais detalhada desta fase.

4.2 Pré-Processamento dos Sinais

A metodologia utilizada no pré-processamento, conforme apresentou o capítulo 3, é baseada na transformada *wavelet* discreta e na comparação de curvas de distribuição da energia de sinais, com e sem distúrbio, para diferentes níveis de resolução de sua decomposição.

A seguir são apresentadas as principais alterações realizadas nesta fase do pré-processamento, passando desde a análise dos sinais, dos descritores, entre outras aqui descritas, apresentando suas evoluções e a melhora dos resultados obtidos.

4.2.1 Sinais Analisados

Os sinais com distúrbio, são os sinais a serem classificados, sendo a sua base de dados formada por sinais simulados pelo *software* ATP e sinais registrados por oscilógrafos e qualímetros. Já os sinais sem distúrbios são os sinais senoidais de referência, ou seja, são os sinais *puros*, sem perturbações.

Inicialmente é importante destacar a evolução do uso dos sinais com distúrbio analisados. Durante os primeiros testes realizados com os sinais registrados, os resultados obtidos pelo classificador neural não foram considerados bons. Esses sinais eram pré-classificados de acordo com normas disponíveis nos procedimentos de rede do Operador Nacional do Sistema Elétrico (ONS) (ONS, 2002). A análise mais detalhada de muitos destes sinais apresentava mais de um tipo de dis-

túrbio. O sinal nestes casos era pré-classificado como sendo do tipo de distúrbio que mais se destacou entre os detectados. Suspeitava-se, então, que por esse motivo a classificação realizada pelo classificador neural era prejudicada. Por outro lado, os sinais que eram simulados apresentavam mais garantia quanto a existência do tipo de distúrbio nele presente. Com base neste fato, optou-se por misturar os sinais simulados e os registrados a fim de se obter bons resultados na classificação.

4.2.2 Mudança dos Descritores

O procedimento utilizado na classificação dos distúrbios por meio de uma estrutura neural é baseado nos descritores obtidos na etapa de pré-processamento dos sinais.

Atualmente a quantidade de descritores obtidos neste trabalho são dez (10), os quais já foram apresentados na tabela 3.1. Porém, antes desta atual definição, os descritores utilizados foram definidos como apresenta a tabela 4.1. Por esta tabela é possível observar que para se obter tais descritores era necessário ter disponível as três fases (A, B e C) do sinal. Diferentemente desse procedimento, para obter os descritores definidos atualmente não são usadas as três fases de um sinal, mas apenas uma fase. Isso produz um aumento na quantidade de padrões em relação ao procedimento anterior. Além disso, os experimentos iniciais mostraram que utilizar as três fases juntas prejudicava o desempenho da rede neural. Uma vez que, por exemplo, um afundamento de tensão presente em uma determinada fase pode ocasionar o surgimento de outro tipo de distúrbio nas outras duas. Portanto, a nova definição dos descritores apresenta melhores condições de analisar uma

fase sem uma possível influência das outras.

4.2.3 Definição do Sinal de Referência

O sinal de referência é usado neste trabalho na parte do pré-processamento dos sinais sendo aplicado na metodologia proposta para obtenção dos descritores característicos de cada distúrbio que serão utilizados na etapa de classificação do sinal.

Descrevem-se abaixo os três algoritmos adotados para a obtenção do sinal de referência:

1. Inicialmente a obtenção do sinal de referência era feita sem a preocupação de caracterizar a defasagem entre os sinais comparados (ele próprio e o sinal com distúrbio). Apenas reproduzia-se um sinal puramente senoidal com amplitude de 1 p.u., com a mesma taxa de amostragem e até a quantidade de ciclos que o sinal analisado com distúrbio possuía.
2. Ao contrário do sinal de referência obtido anteriormente, que era definido sem a preocupação de caracterizar a defasagem entre os sinais comparados, em uma nova fase do trabalho, os sinais de referência foram obtidos utilizando os próprios sinais com distúrbios. A partir destes sinais, usando o método dos mínimos quadrados para funções não lineares, realizou-se a extrapolação do primeiro ciclo do sinal, considerado um ciclo de pré-falta.
3. A última modificação realizada em relação ao sinal de referência, foi que este passou a ser obtido a partir da análise de cada ciclo do seu respectivo

sinal com distúrbio. Com esta análise separava-se o ciclo considerado o mais normal (em relação a amplitude e distorção). Este ciclo normal era então sincronizado com o primeiro ciclo do sinal com distúrbio e a partir daí reproduzido até a quantidade de ciclos que o seu respectivo sinal analisado com distúrbio possuía, como mostra a figura 3.8 do capítulo anterior.

A cada modificação realizada no algoritmo de obtenção dos sinais de referência o índice de acerto obtido na classificação dos distúrbios foi se elevando, como mostram os resultados apresentados nas tabelas 4.2, 4.3 e 4.4.

É importante destacar que os resultados apresentados referem-se a uma rede neural artificial do tipo Perceptron de Múltiplas Camadas (PMC) utilizando para o treinamento o algoritmo Resilient Propagation (Rprop).

Uma vez que a determinação da topologia "ótima" da rede é obtida por modo empírico, foram analisadas várias arquiteturas, verificando-se, após a realização de alguns testes, que apenas uma camada oculta seria o suficiente para a rede. Porém para esta camada oculta foram testadas algumas quantidades de neurônios: 10:20:4; 10:40:4; 10:60:4; 10:80:4; 10:100:4 (o primeiro número indica a quantidade de neurônios na camada de entrada, o segundo número indica a quantidade de neurônios na primeira camada oculta, e o último número indica a quantidade de neurônios da camada de saída).

Os sinais analisados para a obtenção destes resultados foram sinais reais obtidos por oscilógrafos que possuem taxa de amostragem de 128 amostras/ciclo registrados durante 14 ciclos.

Pela análise dos resultados é possível observar que para o primeiro algoritmo

de obtenção do sinal de referência (tabela 4.2) o melhor índice de acerto obtido entre as arquiteturas testadas foi de 85,46%. Enquanto que para o segundo algoritmo (tabela 4.3) obteve-se um melhor índice (89,25%). Isso representa um aumento de 3,79%.

Essa melhora no índice de acerto é atribuída à redução da defasagem entre os sinais comparados com e sem distúrbio. Assim, como mostram as figuras 4.1 e 4.2, após a aplicação do segundo algoritmo de obtenção do sinal de referência, os sinais com e sem distúrbio usados para serem comparados, passaram a possuir uma defasagem muito menor em relação à defasagem anterior, contribuindo para um aumento no índice de acerto do classificador neural.

Porém, através de uma análise mais detalhada dos gráficos dos sinais analisados, observou-se que em alguns registros os primeiros ciclos já se iniciavam com distúrbio (figura 4.3). Isso se constituiu em um problema, uma vez que pelo segundo algoritmo a obtenção do sinal de referência, até então, estava sendo realizada a partir da extrapolação do primeiro ciclo do sinal, que era considerado sem distúrbio. Por esse motivo, mais uma vez se fez necessário alterar o algoritmo de obtenção do sinal de referência.

Como mostram os resultados (tabela 4.4), o índice de acerto obtido na classificação após o uso do terceiro algoritmo de obtenção dos sinais de referência foi de 96,22%. Em comparação ao índice obtido pelo segundo algoritmo, conseguiu-se um aumento de 6,97%.

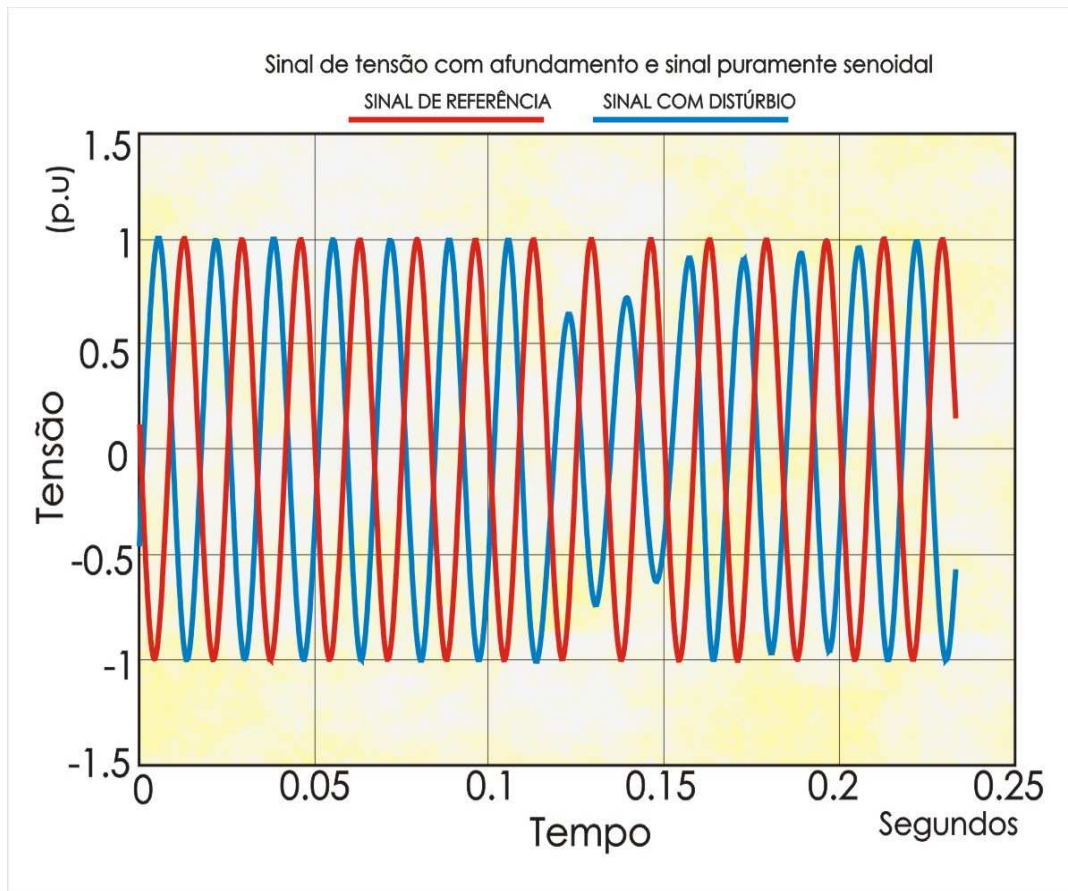


Figura 4.1: Gráficos dos sinais com e sem distúrbios usados no pré-processamento no qual o sinal de referência é obtido a partir do seu primeiro algoritmo de definição.

4.2.4 Localização do Distúrbio no Tempo

Da mesma forma que os sinais de referência, os sinais com distúrbio são usados na etapa de pré-processamento dos sinais. Durante o desenvolvimento deste trabalho, o pré-processamento dos sinais se deu de duas formas:

1. Primeiramente os sinais analisados com distúrbio eram pré-processados exatamente como se apresentavam, sem modificação do seu conteúdo.

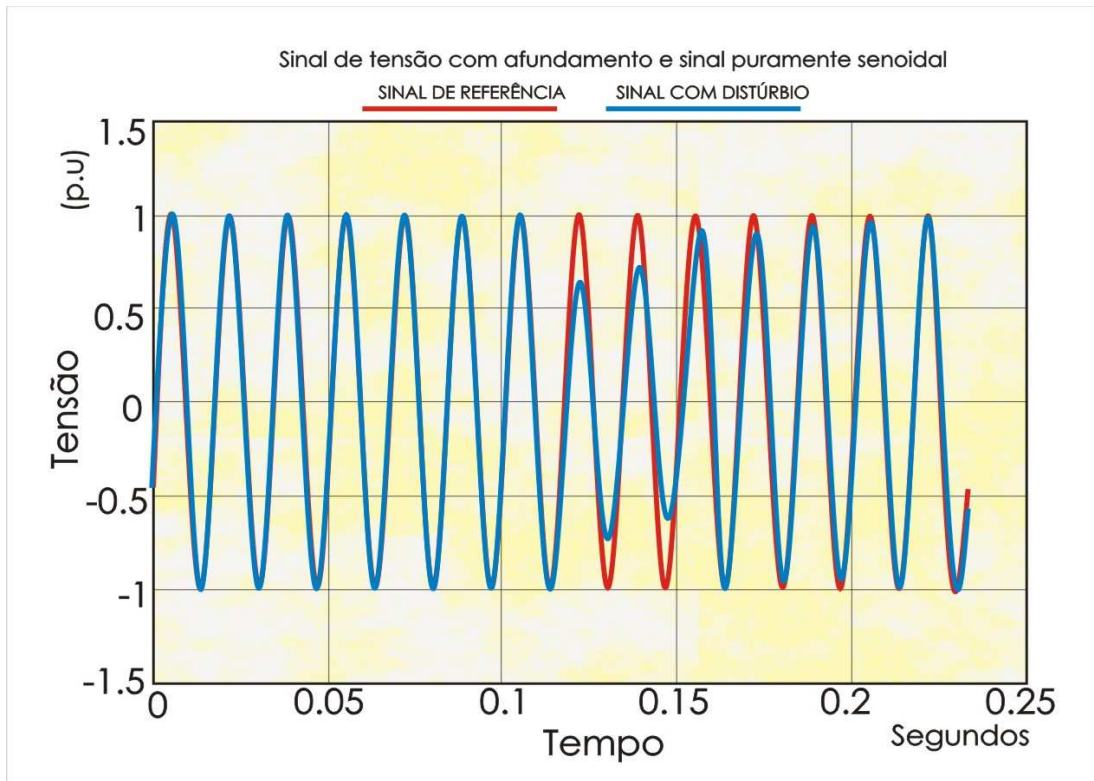


Figura 4.2: Gráficos dos sinais com e sem distúrbios usados no pré-processamento no qual o sinal de referência é obtido a partir do seu segundo algoritmo de definição.

2. A segunda forma trata apenas da parte do sinal que continha o distúrbio, sendo o restante do sinal, ou seja, a parte sem distúrbio descartada (figuras 3.6 e 3.7). Para isso, criou-se um algoritmo no qual se seleciona apenas a parte do distúrbio. Inicialmente este algoritmo compara o sinal analisado contendo o distúrbio com o seu respectivo sinal de referência, e a partir da obtenção da diferença destes sinais realiza-se a localização do início e do fim do distúrbio, com base nas normas do ONS (Procedimentos de Rede).

É importante ressaltar que a seleção do distúrbio reduz a quantidade de amostras totais do sinal, uma vez que a parte do sinal que não contém o distúrbio é




Figura 4.3: Sinal registrado com distúrbio no primeiro ciclo.

descartada. Dessa forma, os sinais analisados podem possuir números de amostras diferentes, o que mesmo assim, não representa um problema. A única dificuldade seria se estas quantidades de amostras fossem inferiores a uma quantidade mínima, conforme se explica a seguir. Se por acaso isso ocorresse, o algoritmo elaborado se adaptaria para que os sinais não possuam o número de amostras menores que o mínimo preestabelecido. Esta quantidade mínima de amostras tem como base a definição dos descritores, na qual usa até no máximo o nível onde ocorreu a quinta maior diferença percentual de energia (em módulo) entre os diferentes níveis da decomposição wavelet dos sinais com e sem distúrbio. Ou seja,

para decompor o sinal até o quinto nível *wavelet*, no qual o nível hierárquico corresponde à escala diática, é necessário que o sinal possua no mínimo $2^5 = 32$ amostras. Porém, para se fazer uma melhor avaliação das maiores diferenças percentuais, este número mínimo foi definido como sendo igual a $2^8 = 256$ amostras, o que permite analisar cada sinal até o oitavo nível de decomposição *wavelet*.

A localização do distúrbio no tempo começou a ser utilizada na etapa do pré-processamento logo após a utilização do terceiro método de obtenção do sinal de referência.

A tabela 4.5 apresenta os resultados obtidos considerando no pré-processamento o terceiro algoritmo de obtenção dos sinais de referência juntamente com esta nova alteração, ou seja, o sinal contendo apenas a parte do distúrbio.

O melhor resultado obtido entre todas as arquiteturas de rede testadas após esta alteração realizada na etapa do pré-processamento foi de 98,26%, o que representa um aumento de 2,04% no índice de acerto na classificação dos distúrbios em relação ao que foi obtido anteriormente.

Estes resultados mostram que além das alterações realizadas na obtenção do sinal de referência, dentre outros fatores, o tratamento dado ao sinal analisado com distúrbio para ser usado no pré-processamento também influencia no aumento do índice de acerto da classificação dos distúrbios.

4.2.5 Normalização

Antes de entrar no assunto da normalização é interessante reafirmar as seguintes hipóteses:

- O procedimento utilizado na classificação dos distúrbios por meio de uma estrutura neural é baseado nos descritores obtidos da decomposição dos sinais usando wavelets.
- Para o classificador neural foram obtidos um total de 10 descritores para servirem de entrada para a rede. Tais descritores são apresentados na tabela 3.1 do capítulo anterior.
- Um padrão é representado por cada conjunto de 10 descritores e é conhecido como um padrão de entrada ou também como uma variável de entrada.

As alterações realizadas na etapa de pré-processamento dos sinais provocaram um aumento considerável no índice de acerto, que de 89,25% passou a ser de 98,26%.

Para obtenção do índice de acerto igual a 100% apenas foi feita a normalização dos padrões de entrada utilizados pela rede neural.

Normalizar as entradas significa que cada variável de entrada é pré-processada de modo que o seu valor médio, calculado sobre todo o conjunto de treinamento seja próximo de zero, ou pequeno, comparado com o desvio padrão (HAYKIN, 1999). Isso contribui para acelerar o processo de aprendizagem, uma vez que este processo coloca o intervalo de dados dentro de limites que facilitam a tarefa da rede para realizar a minimização do erro de saída.

De acordo com o que foi visto e apresentado neste capítulo o bom resultado obtido na classificação se deve principalmente ao aprimoramento na etapa do pré-

processamento dos sinais. A normalização também foi importante na obtenção final dos resultados, porém o aumento significativo ocorreu mesmo após a análise mais detalhada do pré-processamento, uma vez que alterações realizadas nessa fase provocaram os maiores aumentos obtidos na taxa de acerto.

Tabela 4.1: Tabela com a antiga definição de cada descritor

Descritores	
descritor ₁	Maior diferença percentual de energia (em módulo) entre os diferentes níveis da decomposição wavelet dos sinais com e sem distúrbio - fase A;
descritor ₂	Nível onde ocorreu a maior diferença percentual - fase A;
descritor ₃	Segunda maior diferença percentual (em módulo) - fase A
descritor ₄	Nível onde ocorreu a segunda maior diferença percentual - fase A;
descritor ₅	(Maior diferença percentual da fase A)-(Maior diferença percentual da fase B);
descritor ₆	(Nível da maior diferença percentual na fase A)- (Nível da maior diferença percentual na fase B);
descritor ₇	(Maior diferença percentual da fase A)-(Maior diferença percentual da fase C);
descritor ₈	(Nível da maior diferença percentual na fase A) - (Nível da maior diferença percentual na fase C);
descritor ₉	(Maior diferença percentual da fase B) - (Maior diferença percentual da fase C);
descritor ₁₀	(Nível da maior diferença percentual na fase B) - (Nível da maior diferença percentual na fase C);
descritor ₁₁	Maior diferença percentual de energia (em módulo) entre os diferentes níveis de decomposição wavelet dos sinais com e sem distúrbio - fase B;
descritor ₁₂	Nível onde ocorreu a maior diferença percentual - fase B;
descritor ₁₃	Segunda maior diferença percentual (em módulo) - fase B;
descritor ₁₄	Nível onde ocorreu a segunda maior diferença percentual - fase B;
descritor ₁₅	(Maior diferença percentual da fase B)-(Maior diferença percentual da fase A);
descritor ₁₆	(Nível da maior diferença percentual na fase B)- (Nível da maior diferença percentual na fase A);
descritor ₁₇	(Maior diferença percentual da fase B)-(Maior diferença percentual da fase C);
descritor ₁₈	(Nível da maior diferença percentual na fase B) - (Nível da maior diferença percentual na fase C);
descritor ₁₉	(Maior diferença percentual da fase C) - (Maior diferença percentual da fase A);
descritor ₂₀	(Nível da maior diferença percentual na fase C) - (Nível da maior diferença percentual na fase A);
descritor ₂₁	Maior diferença percentual de energia (em módulo) entre os diferentes níveis da decomposição wavelet dos sinais com e sem distúrbio - fase C;
descritor ₂₂	Nível onde ocorreu a maior diferença percentual - fase C;
descritor ₂₃	Segunda maior diferença percentual (em módulo) - fase C;
descritor ₂₄	Nível onde ocorreu a segunda maior diferença percentual - fase C;
descritor ₂₅	(Maior diferença percentual da fase C)-(Maior diferença percentual da fase A);
descritor ₂₆	(Nível da maior diferença percentual na fase C)- (Nível da maior diferença percentual na fase A);
descritor ₂₇	(Maior diferença percentual da fase C)-(Maior diferença percentual da fase B);
descritor ₂₈	(Nível da maior diferença percentual na fase C) - (Nível da maior diferença percentual na fase B);
descritor ₂₉	(Maior diferença percentual da fase A) - (Maior diferença percentual da fase B);
descritor ₃₀	(Nível da maior diferença percentual na fase A) - (Nível da maior diferença percentual na fase B);

Tabela 4.2: Porcentagem de acerto para diferentes arquiteturas da rede neural RPROP, considerando no pré-processamento o primeiro algoritmo de obtenção do sinal de referência.

Arquitetura	Índice de acerto
10:20:4	83,27%
10:40:4	81,69%
10:60:4	84,01%
10:80:4	85,17%
10:100:4	85,46%

Tabela 4.3: Porcentagem de acerto para diferentes arquiteturas da rede neural RPROP, considerando no pré-processamento o segundo algoritmo de obtenção do sinal de referência.

Arquitetura	Índice de acerto
10:20:4	85,34%
10:40:4	87,62%
10:60:4	87,95%
10:80:4	88,60%
10:100:4	89,25%

Tabela 4.4: Porcentagem de acerto para diferentes arquiteturas da rede neural RPROP, considerando no pré-processamento o terceiro algoritmo de obtenção do sinal de referência.

Arquitetura	Índice de acerto
10:20:4	93,60%
10:40:4	94,19%
10:60:4	96,22%
10:80:4	93,02%
10:100:4	95,06%

Tabela 4.5: Porcentagem de acerto para diferentes arquiteturas da rede neural RPROP, considerando no pré-processamento o terceiro algoritmo de obtenção do sinal de referência e também o sinal contendo apenas a parte com distúrbio.

Arquitetura	Índice de acerto
10:20:4	90,69%
10:40:4	98,26%
10:60:4	84,59%
10:80:4	89,53%
10:100:4	82,55%

Capítulo 5

Análise de Resultados

Este capítulo apresenta os resultados obtidos através da aplicação da metodologia desenvolvida, para classificação de distúrbios em redes de energia elétrica. Tais resultados são provenientes da classificação de sinais com distúrbios com diferentes taxas de amostragem, o que proporcionou interessantes conclusões a este respeito, as quais serão também aqui discutidas.

5.1 Considerações Gerais

Devido à grande quantidade de dados provenientes dos equipamentos registradores de perturbações, torna-se indispensável automatizar o diagnóstico sobre os tipos de distúrbios presentes nos sinais registrados. Com esse objetivo, desenvolveu-se nesta tese uma metodologia, baseada no uso da transformada *wavelet* e de redes neurais artificiais (RNA's). As principais etapas do trabalho são: a obtenção dos sinais analisados, a qual utiliza sinais de tensão registrados e simulados, sendo esta

seguida pelo pré-processamento desses sinais, que é o responsável pela preparação dos sinais analisados para a classificação por meio de uma estrutura neural, que é a última etapa do trabalho e cuja saída deve ser a identificação do tipo de distúrbio.

5.2 Resultados

Os resultados que serão apresentados neste capítulo correspondem à análise de sinais provenientes de simulações e de registradores de perturbações (oscilógrafos e qualímetros). É importante destacar que os sinais registrados analisados neste trabalho possuem diferentes taxas de amostragem e que estes foram utilizados juntamente com os sinais simulados. Dessa forma, a base de dados usada para a classificação dispõe de sinais com taxas de amostragem:

- 128 amostras por ciclo → esta foi a taxa de amostragem que a rede de oscilografia estava ajustada para registrar os sinais. A duração de cada registro correspondeu a 14 ciclos.
- 32 amostras por ciclo → esta foi a taxa de amostragem que a rede de qualimetria estava ajustada para registrar os sinais. A duração de cada registro correspondeu a 54 ciclos.
- 64 amostras por ciclo → esta foi a taxa de amostragem obtida a partir da redução da taxa dos sinais registrados pela oscilografia que possuíam 128 amostras por ciclo. Esta redução na taxa de amostragem foi realizada com a intenção de analisar o impacto da diminuição da taxa na classificação dos

distúrbios. Essa influência será mostrada com mais detalhes no decorrer deste capítulo.

5.2.1 Resultados Obtidos Para Sinais Com 128 Amostras/Ciclo

Os equipamentos de oscilografia disponíveis na obtenção de dados para este trabalho estavam ajustados para registrarem sinais com taxas de amostragem de 128 amostras/ciclo durante 14 ciclos. Para estes sinais foram analisados quatro tipos de distúrbios presentes na rede elétrica: afundamento e elevação de tensão, harmônicos e transitórios.

Cada distúrbio analisado representa uma classe para o classificador neural (Tabela 3.2). Além disso, utilizou-se para a classificação uma rede neural do tipo Perceptron de Múltiplas Camadas (PMC), com treinamento segundo o algoritmo Resilient Backpropagation (Rprop). Deve-se ressaltar que para o treinamento também foi testado o algoritmo Backpropagation, o qual obteve taxas de acerto menores que a obtida pelo Rprop e que, além disso, possui um tempo de treinamento um pouco maior. A tabela 5.1 mostra os resultados obtidos, assim como, o tempo de treinamento gasto, utilizando os dois algoritmos (Rprop e Backpropagation) e 1000 épocas para o treinamento.

Várias arquiteturas foram analisadas para a rede neural. Dentre elas, destacam-se 10:20:4, 10:40:4, 10:60:4, 10:80:4 e 10:100:4, as quais obtiveram, para um tempo de treinamento de poucos minutos, resultados muito bons. Utilizou-se um total de 800 padrões para o treinamento (200 padrões para cada classe) e 344

padrões para a validação (86 padrões para cada classe).

Tabela 5.1: Porcentagem de acerto e tempo de treinamento para diferentes arquiteturas da rede neural utilizando o algoritmo RPROP e o Backpropagation.

Arquitetura	Índice de acerto		Tempo de treinamento	
	RPROP	BACKPROP	RPROP	BACKPROP
10:20:4	96,51%	96,22%	45,4 seg	48,5 seg
10:40:4	99,70%	96,80%	76,8 seg	82,1 seg
10:60:4	100,00%	96,80%	97,8 seg	103,2 seg
10:80:4	98,26%	96,51%	131,6 seg	133,9 seg
10:100:4	95,64%	96,51%	175,8 seg	203,2 seg

A análise da tabela 5.1 comprova que os melhores resultados realmente foram obtidos utilizando-se o algoritmo Rprop e para que seja possível avaliar com mais detalhes estes resultados apresenta-se nas tabelas 5.2, 5.3, 5.4, 5.5 e 5.6 a Matriz de Confusão de cada uma das taxas de acerto obtida pelo algoritmo. Essa matriz é usada para avaliar o resultado da classificação, para isso ela compara os dados corretamente classificados com os dados obtidos pelo classificador neural. As componentes da diagonal principal da matriz indicam o número de distúrbios corretamente classificados para cada classe correspondente.

Tabela 5.2: Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:20:4.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	86	0	0	0
Elevação	0	78	6	2
Transitórios	0	2	83	1
Harmônicos	0	0	1	85

Tabela 5.3: Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:40:4.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	86	0	0	0
Elevação	0	85	1	0
Transitórios	0	0	86	0
Harmônicos	0	0	0	86

Tabela 5.4: Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:60:4.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	86	0	0	0
Elevação	0	86	0	0
Transitórios	0	0	86	0
Harmônicos	0	0	0	86

Pela tabela 5.2 observa-se que dentre os distúrbios analisados o de afundamento de tensão foi o que apresentou o melhor índice de acerto, 86 dos 86 padrões foram bem classificados, representando uma taxa de 100% de acerto individual. Elevação de tensão foi o que apresentou o pior índice, classificou 78 dos 86 padrões corretamente, representando uma taxa 90,6977% de acerto individual. Já transitórios obteve um total 83 dos 86 padrões corretamente classificados, significando 96,5116% de acerto individual e harmônicos apresentou um total de 85 padrões, dos 86, bem classificados, o que resulta em um índice de 98,8372% de acerto individual.

A tabela 5.3 mostra que para esta arquitetura (10:40:4) a rede neural só não

Tabela 5.5: Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:80:4.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	86	0	0	0
Elevação	0	82	2	2
Transitórios	0	0	86	0
Harmônicos	0	1	1	84

Tabela 5.6: Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:100:4.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	86	0	0	0
Elevação	0	77	7	2
Transitórios	0	5	81	0
Harmônicos	0	1	0	85

conseguiu classificar corretamente um padrão, que deveria ser classificado como elevação de tensão e não como transitórios.

Para a arquitetura da rede neural mostrada na tabela 5.4 (10:60:4) todos os padrões foram corretamente classificados, ou seja, a classificação dos distúrbios obteve 100% de acerto.

A tabela 5.5 mostra que mais uma vez o distúrbio de elevação de tensão foi o que obteve a pior classificação, tendo os distúrbios de afundamento e transitórios apresentado uma taxa de 100% de acerto individual e o de harmônico 97,6744% de acerto individual (84 dos 86 padrões foram corretamente classificados).

A arquitetura da rede neural usada na tabela 5.6 (10:100:4) foi a que obteve o

pior índice de acerto na classificação entre todas as outras arquiteturas. Observe-se por esta tabela que mais uma vez o pior índice de acerto individual foi obtido para o distúrbio de elevação de tensão (89,5349%) e o melhor índice individual foi obtido para afundamento de tensão (100%). Os distúrbios de transitório e harmônicos obtiveram respectivamente índices de acerto individual iguais a 94,1860% e 98,8372%.

Através da análise dos resultados apresentados anteriormente é possível concluir que apesar da rede neural ter atingido a meta de classificar 100% dos distúrbios corretamente com a arquitetura 10:60:4, pelas outras arquiteturas foi possível observar que a maior dificuldade da rede em realizar a classificação está no distúrbio de elevação de tensão, o qual apresentou para todas os outros casos os piores índices de acerto individual, ao contrário do afundamento que em todos os resultados obteve 100% de acerto individual.

5.2.2 Resultados Obtidos Para Sinais Com 32 Amostras/Ciclo

Os equipamentos de qualimetria disponíveis para obtenção de dados para este trabalho estavam ajustados para registrarem sinais com taxas de amostragem de 32 amostras/ciclo durante 54 ciclos. Devido a esta baixa taxa de amostragem, não foi possível registrar sinais com transitórios, sendo por este motivo analisados sinais com afundamento e elevação de tensão, harmônicos, sinais considerados normais de acordo com as normas técnicas e sinais sem registro. Os sinais sem registro são aqueles cujo arquivo não apresentou leitura: registra-se um distúrbio, porém os valores discretizados não estão disponíveis (falha do equipamento ou de tratamento da informação). Por esse motivo não precisam ser classificados pelo

rede neural, sendo a sua identificação realizada logo após a leitura dos dados.

Dessa forma, as novas classes utilizadas pela rede neural são apresentadas na tabela 5.7. Para o treinamento foram usados 800 padrões (200 para cada classe) e 212 padrões foram usados para a validação (53 padrões para cada classe).

Tabela 5.7: Classes definidas para o classificador neural

Classes	
Classe ₁	Afundamento de tensão
Classe ₂	Elevação de tensão
Classe ₃	Harmônicos
Classe ₄	Normal

A mudança da taxa de amostragem dos sinais analisados, que anteriormente era de 128 amostras por ciclo e que passou a ser de 32 amostras por ciclo, mostrou que tal redução teve como consequência resultados não tão bons como os obtidos anteriormente (Tabela 5.1). O melhor índice de acerto obtido foi de 84,43%, como mostra a tabela 5.8.

Tabela 5.8: Porcentagem de acerto para diferentes arquiteturas da rede neural utilizando o algoritmo RPROP e sinais com taxa de 32 amostras/ciclo.

Arquitetura	Índice de acerto
10:20:4	80,19%
10:40:4	84,43%
10:60:4	83,02%
10:80:4	83,02%
10:100:4	82,55%

As tabelas 5.9, 5.10, 5.11, 5.12 e 5.13 apresentam a Matriz de Confusão das taxas de acerto, obtida por cada arquitetura da rede neural. É possível observar a partir dessas tabelas que a classe que obteve o melhor índice de acerto individual

foi a de elevação de tensão, sendo seguido por afundamento, normais e harmônicos, o qual obteve a pior taxa de acerto individual.

Tabela 5.9: Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:20:4 para sinais com taxas de 32 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Harmônicos	Normais
Afundamento	42	4	5	2
Elevação	0	53	0	0
Harmônicos	0	1	37	15
Normais	1	3	11	38

Tabela 5.10: Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:40:4 para sinais com taxas de 32 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Harmônicos	Normais
Afundamento	47	1	3	2
Elevação	0	53	0	0
Harmônicos	1	1	39	12
Normais	2	3	8	40

Tabela 5.11: Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:60:4 para sinais com taxas de 32 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Harmônicos	Normais
Afundamento	47	1	3	2
Elevação	0	53	0	0
Harmônicos	1	1	38	13
Normais	3	3	9	38

Pelos resultados, em que estão sendo analisados sinais com taxas de 32 amostras por ciclo, pode-se concluir que houve uma piora significativa na qualidade da

Tabela 5.12: Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:80:4 para sinais com taxas de 32 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Harmônicos	Normais
Afundamento	45	3	1	4
Elevação	0	53	0	0
Harmônicos	0	3	37	12
Normais	1	2	9	41

Tabela 5.13: Matriz de Confusão obtida para a rede PMC utilizando o algoritmo RPROP com arquitetura 10:100:4 para sinais com taxas de 32 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Harmônicos	Normais
Afundamento	44	1	4	4
Elevação	0	53	0	0
Harmônicos	1	3	39	10
Normais	1	1	12	39

classificação em relação aos resultados anteriores, obtidos para sinais com taxas de 128 amostras por ciclo.

Os próximos resultados do trabalho foram obtidos com o intuito de verificar se a redução no índice de acerto está relacionada com a taxa de amostragem do sinal. Para isso, novamente, recorreu-se aos sinais com taxa de amostragem de 128 amostras por ciclo e que apresentaram índice de acerto igual a 100%. Estes sinais tiveram sua taxa de amostragem reduzida de 128 para 64 e 32 amostras por ciclo.

5.2.3 Resultados Obtidos Para Sinais com 64 Amostras/Ciclo Provenientes da Redução da Taxa de Amostragem dos Sinais com 128 Amostras/Ciclo

Para verificar a relação da taxa de amostragem com o índice de acerto, os sinais analisados com 128 amostras por ciclo, cuja a classificação atingiu um índice de 100% de acerto, como apresentou a Tabela 5.1, tiveram a sua taxa de amostragem reduzida, diminuindo-se de 128 para 64 e 32 amostras por ciclo.

Para obtenção dos resultados utilizando-se os sinais com a taxa de amostragem reduzida, a única mudança realizada foi novamente a alteração das classes usadas na classificação. Tais classes são as mesmas apresentadas na Tabela 3.2: classe₁ → afundamento; classe₂ → elevação; classe₃ → transitórios; e classe₄ → harmônicos.

Mais uma vez, utilizaram-se 800 padrões para realizar o treinamento e 344 padrões para a validação.

A Tabela 5.14 apresenta os resultados obtidos para as diferentes arquiteturas analisadas, para os sinais com 64 amostras por ciclo.

Tabela 5.14: Porcentagem de acerto para diferentes arquiteturas da rede neural utilizando o algoritmo RPROP e sinais com taxa de 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.

Arquitetura	Índice de acerto
10:20:4	92,15%
10:40:4	92,44%
10:60:4	92,44%
10:80:4	91,57%
10:100:4	90,12%

Pela Tabela 5.14 observa-se que o melhor índice de acerto obtido foi de 92,44%. Esse índice representa uma queda de 7,56% em relação ao melhor índice obtido para os sinais com taxa de 128 amostras/ciclo. As matrizes de confusão dos resultados obtidos por esta tabela são apresentadas nas tabelas 5.15, 5.16, 5.17, 5.18 e 5.19.

Tabela 5.15: Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:20:4 para os sinais com 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	75	0	0	11
Elevação	0	82	1	3
Transitórios	0	1	83	2
Harmônicos	0	7	2	77

Tabela 5.16: Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:40:4 para os sinais com 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	77	0	0	9
Elevação	0	77	5	4
Transitórios	0	1	80	5
Harmônicos	0	0	2	84

Tabela 5.17: Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:60:4 para os sinais com 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	76	0	0	10
Elevação	0	76	1	9
Transitórios	1	0	82	3
Harmônicos	0	0	2	84

Tabela 5.18: Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:80:4 para os sinais com 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	77	0	0	9
Elevação	0	75	1	10
Transitórios	0	0	80	6
Harmônicos	0	2	1	83

Tabela 5.19: Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:100:4 para os sinais com 64 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	76	0	0	10
Elevação	1	67	15	3
Transitórios	0	0	83	3
Harmônicos	0	0	2	84

A análise dos resultados obtidos para os sinais com taxa de 64 amostras por ciclo leva mais uma vez à conclusão de que a redução no índice de acerto na classificação realizada pela rede neural está diretamente relacionada com a taxa de amostragem dos sinais analisados. Para os sinais com taxa de 128 amostras por ciclo a rede atingiu o índice de 100% de acerto na classificação, enquanto que o melhor índice de acerto obtido para a taxa de amostragem reduzida para 64 amostras por ciclo foi de 92,44%.

5.2.4 Resultados Obtidos Para Sinais com 32 Amostras/Ciclo Provenientes da Redução da Taxa de Amostragem dos Sinais com 128 Amostras/Ciclo

Para confirmar a relação da taxa de amostragem dos sinais com a redução do índice de acerto na classificação da rede neural, analisaram-se também sinais com taxa de 32 amostras por ciclo obtidos da redução da taxa dos sinais com 128 amostras por ciclo. A Tabela 5.20 apresenta os resultados obtidos analisando-se estes sinais para as diferentes arquiteturas das redes neurais.

Tabela 5.20: Porcentagem de acerto para diferentes arquiteturas da rede neural utilizando o algoritmo RPROP e sinais com taxa de 32 amostras/ciclo, obtidos pela redução das taxas de amostragem dos sinais com 128 amostras/ciclo.

Arquitetura	Índice de acerto
10:20:4	84,88%
10:40:4	85,17%
10:60:4	85,76%
10:80:4	86,63%
10:100:4	86,05%

As tabelas 5.21, 5.22, 5.23, 5.24 e 5.25 apresentam as Matrizes de Confusão referentes a cada índice de acerto obtido pelas diferentes arquiteturas da rede neural.

Tabela 5.21: Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:20:4 para os sinais com 32 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	82	1	0	3
Elevação	0	71	15	0
Transitórios	0	0	74	12
Harmônicos	0	4	17	65

Tabela 5.22: Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:40:4 para os sinais com 32 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	81	0	1	4
Elevação	1	68	16	1
Transitórios	0	0	72	14
Harmônicos	0	3	11	72

Para estes sinais, com taxa de 32 amostras por ciclo, o melhor índice de acerto atingido pela rede neural foi de 86,63%, o que representa uma queda de 13,37% em comparação ao melhor resultado obtido para os sinais com 128 amostras por ciclo. Este fato confirma a relação entre a taxa de amostragem e a redução no índice de acerto na classificação da rede neural. É importante destacar ainda que a redução da taxa de amostragem mostra-se proporcional a redução da taxa de acerto, ou seja, quanto menor a taxa de amostragem, menor o índice de acerto.

Tabela 5.23: Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:60:4 para os sinais com 32 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	82	1	1	2
Elevação	1	65	16	4
Transitórios	0	0	73	13
Harmônicos	1	2	8	75

Tabela 5.24: Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:80:4 para os sinais com 32 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	81	0	0	5
Elevação	1	66	11	8
Transitórios	0	0	78	8
Harmônicos	0	2	11	73

Tabela 5.25: Matriz de Confusão obtida para rede PMC utilizando o algoritmo RPROP com arquitetura 10:100:4 para os sinais com 32 amostras/ciclo obtidos pela redução da taxa de amostragem dos sinais com 128 amostras/ciclo.

Distúrbios	Afundamento	Elevação	Transitórios	Harmônicos
Afundamento	82	0	1	3
Elevação	1	64	19	2
Transitórios	0	0	77	9
Harmônicos	0	3	10	73

Capítulo 6

Conclusões e Recomendações

6.1 Conclusões

O objetivo desta tese é elaborar um método eficiente para classificação automática de distúrbios responsáveis pela caracterização da qualidade da energia elétrica.

A metodologia desenvolvida considerou quatro tipos de distúrbios: afundamento e elevação de tensão, distorções harmônicas e transitórios. Além destes também foram analisados sinais considerados normais de acordo com as normas técnicas, e sinais sem registro, identificados logo após a leitura dos dados. A base de dados utilizada foi obtida por meio de equipamentos registradores, instalados em um sistema de transmissão de energia real e também por simulações do mesmo sistema através do *software* ATP.

Em resumo, as principais etapas do algoritmo de classificação são três: a etapa de obtenção dos sinais analisados (sinais de tensão discretizados), sendo esta

seguida pela etapa do pré-processamento, que é a mais importante, e a responsável pela preparação dos sinais para a etapa seguinte, a da classificação, realizada por uma rede neural artificial e responsável pela identificação do tipo de distúrbio presente nos sinais analisados.

Por este trabalho foi possível observar através de um estudo mais aprofundado a importância da etapa do pré-processamento dos sinais para a classificação dos distúrbios. Tal estudo se deu por meio do aprimoramento da forma de obtenção dos sinais de referência e da seleção dos distúrbios nos sinais, usados na metodologia para obtenção das curvas das diferenças percentuais de energia através das quais se obtém os descritores usados pela rede neural. Conforme mostraram os resultados, estas melhorias aliadas à normalização dos descritores obtidos nesta etapa foram significativas para obter uma melhora na qualidade da classificação, atingindo-se o índice de 100% de acerto.

Além disso, foram analisados sinais com diferentes taxas de amostragem, 128, 64 e 32 amostras por ciclo. Pela análise dos resultados foi possível concluir que pela metodologia desenvolvida a redução da taxa de amostragem do sinal analisado também reduz o índice de acerto da classificação dos distúrbios. Quanto menor for a taxa, menor será o índice de acerto obtido pelo classificador. A análise dos resultados obtidos mostrou que, para os sinais com taxas de amostragem iguais a 128 amostras por ciclo obteve-se 100% de acerto na classificação, enquanto que os sinais com taxas iguais a 32 amostras por ciclo registrados por qualímetros obtiveram taxas abaixo de 85% de acerto. Dessa forma, pelo que foi exposto no decorrer do trabalho, para garantir 100% de acerto na classificação dos distúrbios presentes nos sinais analisados, as taxas de amostragem ideais devem

ser iguais a 128 amostras por ciclo ou superior.

6.2 Recomendações

Durante as pesquisas que resultaram no presente trabalho, observou-se a existência de distúrbios múltiplos em alguns dos sinais registrados que foram analisados. É, portanto interessante realizar uma investigação mais detalhada desses sinais, a fim de desenvolver uma técnica mais rigorosa para identificar automaticamente todos os distúrbios presentes em um mesmo registro de sinal.

Durante a fase final do presente trabalho, uma técnica similar de classificação, baseada em Comitê de Máquinas Especialistas, foi investigada cooperativamente com outros pesquisadores. Os resultados obtidos demonstraram-se promissores (MAGALHÃES et al., 2008), (MELO et al., 2008). Recomenda-se intensificar essa investigação, para testar a sua eficácia diante dos problemas aqui relatados, que justificaram o pré-processamento mais detalhado, bem como para classificação de sinais com baixas taxas de amostragem.

Uma outra técnica que pode ser testada para implementar a etapa de classificação propriamente dita é a máquina de vetor suporte (support vector machine - SVM). Encontram-se alguns casos na literatura em que essa técnica substitui com vantagens as RNA's (GAO; WU, 2006).

Apêndice A

Equipamentos Registradores de Perturbações

A.1 Equipamentos de Medição da Qualidade da Energia

Os equipamentos de medição da qualidade da energia pertencem à classe dos Registradores de Perturbações (RP's). São ferramentas que proporcionam maior capacidade e precisão na análise do funcionamento do sistema elétrico, tanto na operação normal como sob anormalidades, a fim de buscar soluções economicamente viáveis para o seu bom funcionamento. São aparelhos inteligentes de monitoração e registro de grandezas elétricas instalados em diversos pontos do sistema elétrico de potência. Os mais conhecidos são:

- Registradores de Oscilografia;

- Registradores de Qualimetria.

Registrar o ocorrido durante um evento é essencial à análise de ocorrências e perturbações. Por esse motivo, foi indispensável recorrer a estes equipamentos para obter alguns dos dados de entradas usados neste trabalho. Sendo assim, é interessante conhecer um pouco mais a respeito desses registradores.

A.1.1 Registradores de Oscilografia

A oscilografia é caracterizada pela medição de grandezas de tensão e corrente com alta resolução no domínio do tempo e cujo registro ocorre em consequência da detecção de uma perturbação (TCHEOU et al., 2006).

Os valores das grandezas e os sinais registrados durante o evento são armazenados em arquivos de dados, que são transferidos para um computador para posterior análise. Estes arquivos de dados contém os valores medidos codificados em um formato proprietário, ou em formato COMTRADE.

Os arquivos em formato proprietário guardam as informações dos eventos em um formato que não é padronizado. Em geral, arquivos com este formato não têm estrutura aberta e não podem ser acessados por outro programa que não seja o do fabricante do equipamento que os criou.

Os arquivos em formato COMTRADE são os padronizados pelo IEEE (Institute of Electrical and Electronics Engineers) para oscilografia digital. O COMTRADE define um formato comum para arquivos de dados digitais e mídias, necessários para troca de vários tipos de dados de perturbações, ensaios e simulação.

Os arquivos definidos por este tipo devem estar, a princípio em formato ASCII, onde para cada evento são definidos 3 tipos de arquivos: cabeçalho, configuração e dados. Estão na forma "xxxxxxxx.yyy" onde "xxxxxxxx" é usado para identificar o evento e ".yyy" é usado para identificar o tipo do arquivo: ".HDR" para cabeçalho (HeaDeR), ".CFG" para configuração (ConFiGuration) e ".DAT" para dados (DATa) (C37.111-1991, 1991).

A.1.1.1 Oscilografia Convencional

Os Registradores de Oscilografia Convencional foram muito utilizados para a análise de perturbações antes da chegada da oscilografia digital. A sua tecnologia era eletromecânica, oscilando conforme a forma de onda de tensão ou corrente, realizando sobre um papel as formas de ondas reconhecidas da oscilografia. Estes primeiros equipamentos não eram capazes de registrar a pré-falta, pois eram acionados por sensores de partida disparados posteriormente ao início do evento.

A.1.1.2 Oscilografia Digital

Quando surgiram os primeiros registradores digitais de perturbações, a primeira preocupação foi a de substituir as funcionalidades existentes na época. Para tal, se projetou um equipamento com uma memória de dados suficiente para armazenar o tempo desejado de pré-falta e pós-falta antes de transferir para uma memória permanente. Dessa forma, tornou-se possível a análise de eventos através de registros digitais, que não necessitavam tinta, revelação de papéis foto sensíveis ou interpretação por outros equipamentos como os registros em fitas magnéti-

cas. Porém a plataforma digital permitiu que várias novas funcionalidades fossem implementadas em um mesmo equipamento. Dessa forma foram agregadas funcionalidades de comunicação remota, localização de defeitos e registros RMS entre outras, incorporando assim funções inexistentes ou que eram executadas por outros equipamentos. Com o advento da capacidade de sincronização temporal dos equipamentos, tornou-se mais simples a análise de eventos com o relacionamento de informações de registros de equipamentos diferentes, como remotas, sequenciais de eventos e registradores de perturbação.

A.1.2 Registradores de Qualimetria

O qualímetro é um equipamento medidor de múltiplas grandezas que une diversas funções, sejam elas: análise de qualidade de energia, capacidade de gerar sinais para controle de outros equipamentos, leitura de dados de outros medidores, entre outras. O equipamento é amplamente usado em pontos de distribuição e cargas com comportamento sensível. Com este medidor é possível fazer medições de grandezas intrinsecamente ligadas à qualidade da energia, pois este tem capacidade de detecção de perturbações extremamente elevada.

Qualímetros modernos fornecem diversas opções de aplicação, devido à sua grande versatilidade e capacidade de trabalhar em conjunto com softwares. Apresenta-se a seguir algumas de suas aplicações usuais.

- Análise de perturbações: capaz de capturar perturbações em um sistema de potência, fornecendo, pelo menos, informações sobre eventos como: harmônicos, Afundamentos/elevações e interrupções.

- Controle de fator de potência e demanda: Essa é uma característica adicional, na maioria dos qualímetros. Através de amostras de tempo previamente especificadas é possível montar-se um histórico do comportamento de demanda e fator de potência de uma instalação, de maneira a analisar causas de picos e outras ocorrências.
- Monitoramento e controle de equipamentos: Possuem saídas analógicas e digitais para controle ou monitoramento de outros equipamentos.

Como objetivo do trabalho é classificar distúrbios da qualidade da energia alguns requisitos desejáveis para os RDP's são apresentados abaixo:

- Medições de tensão trifásica, frequência, fator de potência e corrente instantâneas;
- Harmônicos: THD e individuais até, pelo menos, a 50ª, para 60Hz.
- Detecção de Transitórios de chaveamento;
- Gravação de formas de onda em até 512 amostras/ciclo;
- Detecção de afundamentos/elevações (sag/swell): Máximo, mínimo e duração da perturbação.

Embora essas características sejam desejáveis, a eficiência dos algoritmos apresentados neste trabalho não é dependente do seu atendimento integral.

Apêndice B

Descrição dos Trechos dos Procedimentos de Rede Referentes aos Distúrbios de Afundamento e Elevação de Tensão

B.1 Variação de Tensão de Curta Duração (VTCD)

B.1.1 Considerações iniciais

1. VTCD é um evento aleatório de tensão caracterizado por desvio significativo, por curto intervalo de tempo, do valor eficaz da tensão. Calcula-se o valor eficaz da tensão a partir da média quadrática dos valores instantâneos da tensão, em período mínimo de meio ciclo e máximo de um ciclo. A

VTCD refere-se normalmente à tensão fase-neutro e é descrita monofasicamente pelos parâmetros amplitude e duração.

2. A amplitude da VTCD é definida pelo valor extremo do valor eficaz da tensão em relação à tensão nominal do sistema no ponto considerado, enquanto perdurar o evento.
3. A duração da VTCD é definida pelo intervalo de tempo decorrido entre o instante em que o valor eficaz da tensão em relação à tensão nominal do sistema no ponto considerado ultrapassa determinado limite e o instante em que essa variável volta a cruzar esse limite.
4. A partir da duração e amplitude, as VTCD são classificadas de acordo com o que se apresenta na tabela B.1.
5. A variação momentânea de tensão compreende os eventos com duração inferior ou igual a 3 (três) segundos: interrupção, afundamento e elevação momentâneas de tensão.
6. A variação temporária de tensão compreende os eventos com duração superior a 3 (três) segundos e inferior ou igual a 1 (um) minuto: interrupção, afundamento e elevação temporárias de tensão.
7. Denomina-se Interrupção Momentânea de Tensão (IMT) o evento em que o valor eficaz da tensão é inferior a 0,1 pu da tensão nominal, durante um intervalo de tempo com duração inferior ou igual a 3 (três) segundos.
8. Denomina-se Afundamento Momentâneo de Tensão (AMT) o evento em que o valor eficaz da tensão é superior ou igual a 0,1 e inferior a 0,9 pu da

tensão nominal, durante um intervalo de tempo com duração superior ou igual a um ciclo (16,67 ms) e inferior ou igual a 3 (três) segundos.

9. Denomina-se Elevação Momentânea de Tensão (EMT) o evento em que o valor eficaz da tensão é superior a 1,1 pu da tensão nominal, durante um intervalo de tempo com duração superior ou igual a um ciclo (16,67 ms) e inferior ou igual a 3 (três) segundos.
10. Denomina-se Interrupção Temporária de Tensão (ITT) o evento em que o valor eficaz da tensão é inferior a 0,1 pu da tensão nominal, durante um intervalo de tempo com duração superior a 3 (três) segundos e inferior ou igual a 1 (um) minuto.
11. Denomina-se Afundamento Temporário de Tensão (ATT) o evento em que o valor eficaz da tensão é superior ou igual a 0,1 e inferior a 0,9 pu da tensão nominal, durante um intervalo de tempo com duração superior a 3 (três) segundos e inferior ou igual a 1 (um) minuto.
12. Denomina-se Elevação Temporária de Tensão (ETT) o evento em que o valor eficaz da tensão é superior a 1,1 pu da tensão nominal, durante um intervalo de tempo com duração superior a 3 (três) segundos e inferior ou igual a 1 (um) minuto.

Tabela B.1: Denominação das variações de tensão de curta duração.

Denominação	Duração da variação	Amplitude da tensão (valor eficaz) em relação à tensão nominal
Interrupção momentânea de tensão	inferior ou igual a 3 (três) segundos	inferior a 0,1 pu
Afundamento momentâneo de tensão	superior ou igual a um ciclo e inferior ou igual a 3 (três) segundos	superior ou igual a 0,1 e inferior a 0,9 pu
Elevação momentânea de tensão	superior ou igual a um ciclo e inferior ou igual a 3 (três) segundos	superior a 1,1 pu
Interrupção temporária de tensão	superior a 3 (três) segundos e inferior ou igual a 1 (um) minuto	inferior a 0,1 pu
Afundamento temporário de tensão	superior a 3 (três) segundos e inferior ou igual a 1 (um) minuto	superior ou igual a 0,1 e inferior a 0,9 pu
Elevação temporária de tensão	superior a 3 (três) segundos e inferior ou igual a 1 (um) minuto	superior a 1,1 pu

Referências Bibliográficas

ARRUDA, G. A. G. de. Análise de faltas utilizando redes neurais. In: *Proceedings of The International Joint Conference on Neural Networks*. Honolulu - Hawaii - USA: [s.n.], 2002.

C37.111-1991, N. I. *Resumo da IEEE Standart Common Format for Transient Data Exchange (COMTRADE) for Power Systems*. 1991. Disponível em: <<http://www.sinape.cepel.br/arquivos/O20Formato20COMTRADE.pdf>>. Acesso em: 04 de março de 2008.

CHOWDHURY, F. N.; ARAVENA, J. L. A modular methodology for fast fault detection and classification in power systems. *IEEE Transactions on Control Technology*, v. 6, p. 623–634, 1998.

CLAYPOOLEA, R. L.; BARANIUK, R. G. *Flexible Wavelet Transforms Using Lifting*. Rice University, 1998.

DASH, P. K.; CHUN, I.; CHILUKURI, M. Power quality data mining using soft computing and wavelet transform. In: *IEEE Proceedings of the International Conference on Convergent Technologies for Asia-Pacific Region*. Bangalore - India, [s.n.], 2003. p. 976–980.

DAUBECHIES, I.; SWELDENS, W. Factoring wavelet transforms into lifting steps. *Journal of Fourier Analysis and Applications*, v. 4, n. 3, p. 247–269, 1998.

DOMINGUES, M. O.; JÚNIOR, O. M.; COSTA, A. M. da. Algumas aplicações wavelet na análise de sinais atmosféricos. In: *2o Congresso Temático de Aplicações de Dinâmica e Controle da Sociedade Brasileira de Matemática Aplicada e Computacional (SBMAC)*. São José dos Campos - SP: [s.n.], 2003.

FERNÁNDEZ, R.; ROJAS, H. An overview of wavelet transforms application in power systems. In: *Proceedings of the 14th Power Systems Computation Conference*. Sevilla, Espanha: [s.n.], 2002. p. 1–8.

FONSECA, M. S. da. *Um Estudo sobre a Influência das Famílias Wavelets na Compressão de Imagem*. Dissertação (Mestrado) — Universidade Federal Fluminense, Niterói-RJ, março 2004.

FREEMAN, J. A.; SKAPURA, D. M. *Neural Networks: Algorithms, Applications and Programming Techniques*. 1992.

FREITAS, A. A. C.; SILVA, I. N.; SOUZA, A. N. Aplicação de redes neurais na estimação da temperatura interna de transformadores de distribuição imersos em óleo. *SBA - Controle e Automação*, v. 13, n. 3, 2002.

GAING, Z.-L. Wavelet-based neural network for power disturbance recognition and classification. *IEEE Trans. on Power Delivey*, v. 19, n. 4, p. 1560– 1568, Outubro 2004.

GAO, P.; WU, W. Power quality disturbances classification using wavelet and support vector machines. In: *Intelligent Systems Design and Applications*. [S.l.: s.n.], 2006. p. 201 – 206.

GENGYIN, L.; MING, Z.; ZHIYUAN, Z. Power quality disturbance automatic recognition based on wavelet and genetic network. *IEEE Region 10 Conference on Computers, Communications, Control and Power Engineering*, 2002.

GIOVANINI, R.; COURY, D. V. Classificação rápida de faltas em sistemas elétricos utilizando redes neurais artificiais. In: *Proceedings of the IV Brazilian Conference on Neural Networks - IV Congresso Brasileiro de Redes Neurais*. São José dos Campos - SP: [s.n.], 1999. p. 281–286.

GRAPS, A. L. An introduction to wavelets. *IEEE Computational Sciences and Engineering*, Vol. 2, n. n° 2, p. 50–61, 1995.

HAYKIN, S. *Redes Neurais: Princípios e Práticas*. Segunda edição. [S.l.]: Bookman Companhia Editora - RS, 1999.

HSU, H. P. *Análise de Fourier*. [S.l.]: Livros Técnicos e Científicos Editora - Rio, 1973.

HUA, L.; YUGUO, W.; WEI, Z. Power quality disturbances detection and classification using complex wavelet transformation and artificial neural network. In: *Control Conference - CCC 2007*. China: [s.n.], 2007. p. 208 – 212.

KOHONEN, T. *Self Organization and Associative Memory*. Springer-Verlag, Berlin, 1987.

LIANG, J.; ELANGO VAN, S.; DEVOTTA, J. B. X. A wavelet multi resolution analysis approach to fault detection and classification in transmission lines. *Electrical Power and Energy Systems*, v. 20, n. 5, p. 327–332, 1998.

LIRA, M. M. S.; JÚNIOR, M. A. C.; AQUINO, R. R. B.; VALENÇA, M. J. S.; LEITÃO, J. J. A. L. Classificação de distúrbios elétricos utilizando componentes principais e redes neurais artificiais. In: *XV Congresso Brasileiro de Automática*. Gramado - RS: [s.n.], 2004. p. 1–6.

MACHADO, R. N.; BEZERRA, U. H.; PELAES, E. G. Uso da transformada wavelet para a caracterização de variação de tensão de curta duração a partir de dados de oscilografias em sistemas de potência. In: *VII Congresso Brasileiro de Redes Neurais*. Natal - RN: [s.n.], 2005. p. 1001–105.

MACHADO, R. N. das M. *Detecção, classificação e quantificação automática de variações de tensão de curta duração para aplicação em análise de pós-operatório em sistemas de energia elétrica*. Tese (Doutorado) — Universidade Federal do Pará, 2006.

MAGALHÃES, R. M.; SANTOS, C. K. S.; MELO, J. D.; MEDEIROSJR, M. F.; NETO, A. D. D. Power systems disturbance classification using modular neural networks with multilayers experts. In: INTERNATIONAL CONFERENCE ON RENEWABLE ENERGIES AND POWER QUALITY (ICREPQ'08). *Proceedings of International Conference on Renewable Energies and Power Quality, 2008*. Santander(Espanha), 2008.

MALLAT, S. G. A theory for multiresolution signal decomposition: The wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 11, n. n° 7, p. 674–693, 1989.

MATHWORKS. *Wavelets toolbox*. 2005. Disponível em:

<<http://matlab.izmiran.ru/help/toolbox/wavelet/wavedec.html>>. Acesso em: 16 de abril de 2008.

MEDEIROSJR., M. F.; OLIVEIRA, J. T. de; LACERDA, E. G. M. de; SANTOS, C. K. S.; LEITÃO, J. J. A. L. Classificação automática de distúrbios através de redes neurais e da transformada wavelet combinando dados de simulações e registros de perturbações. In: *VII INDUSCON*. RECIFE - PE: [s.n.], 2006.

MEDEIROSJR, M. F.; SANTOS, C. K. S.; OLIVEIRA, J. T.; PIRES, P. S. da M.; MELO, J. D. de; NETO, A. D. D.; LEITÃO, J. J. A. L. Influence of signal pre-processing in the efficiency of algorithms based on neural networks for disturbance classification. In: *IEEE Symposium on Computational Intelligence in Image and Signal Processing*. Honolulu - Hawaii - USA: [s.n.], 2007.

MELO, J. D.; MAGALHÃES, R. M.; SANTOS, C. K. S.; MEDEIROSJR, M. F.; NETO, A. D. D. Application of a hybrid algorithm in the modular neural nets training with multilayers specialists in electric disturbance classification. In: 12TH INTERNATIONAL CONFERENCE ON INTELLIGENT ENGINEERING SYSTEM. *Proceeding of 12th International Conference on Intelligent Engineering System, 2008*. Miami(USA), 2008.

OLESKOVICZ, M. *Apostila de Qualidade de Energia*. Escola de Engenharia de São Carlos, 2004.

- ONS, O. N. d. S. E. *Submódulo 2.2 - Padrões de Desempenho da Rede Básica*. 2002. Disponível em: <<http://www.ons.org.br/download/procedimentos/submodulo02-02-r2.pdf>>. Acesso em: 05 de maio de 2008.
- PANICKI, L. C. A. *Redes Neurais: (SOM) Mapas auto-organizáveis - Kohonen*. UNIVERSIDADE ESTADUAL DE LONDRINA, 2004.
- RCE, R. C. E. em E. E. . *Qualidade de Energia*. 2008. Disponível em: <<http://www.rce.org.br/rce/distribuicao-predios.html>>. Acesso em: 24 de junho de 2008.
- RESENDE, J. W.; PENNA, C. Identificação de distúrbios da qualidade da energia através da transformada wavelet. In: *IV SBQEE*. Porto Alegre-RS: [s.n.], 2001.
- SANCHES, I. J. *Compressão Sem Perdas de Projeções de Tomografia Computadorizada Usando a Transformada Wavelet*. Dissertação (Mestrado) — Universidade Federal do Paraná, 2001.
- SANTOS, C. K. S. *Caracterização de Distúrbios em Redes de Energia Elétrica Através da Transformada Wavelet de Segunda Geração*. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte, Natal-RN, Junho 2004.
- SANTOSO, S.; POWERS, E. J.; GRADY, W. M. Electric power quality disturbance detection using wavelet transform analysis. In: *Proceedings of The IEEE-SP International Symposium on Time-Frequency and Time Scale Analysis*. Philadelphia, PA, USA: [s.n.], 1994.

SILVA, K. M.; SOUZA, B. A.; BRITO, N. S. D.; COSTA, F. B.; DANTAS, K. M. C. Um algoritmo para detecção e classificação de faltas em linhas de transmissão baseado em transformada wavelet e rna. In: *VII Congresso Brasileiro de Redes Neurais*. Natal - RN: [s.n.], 2005.

SOARES, A. C. N.; FERRER, L. C. d. O.; THOMAZ, L.; GÓES, R. N.; SANTOS, S. *Redes Neurais*. 2002. Disponível em: <<http://www.dei.unicap.br/almir/seminarios/2002.2/ns06/RedesNeurais/desenvolvimento.html>>. Acesso em: 11 de Junho de 2008.

SOARES, L. R. *Wavelets na Identificação e Localização de Faltas em Linhas de Transmissão*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, Recife-PE, Dezembro 2001.

SOUZA, B. A.; BRITO, N. S. D.; NEVES, W. L. A.; SILVA, K. M.; LIMA, R. B.; SILVA, S. S. B. Comparison between backpropagation and rprop algorithms applied to fault classification in transmission lines. In: *International Joint Conference on Neural Networks & International Conference on Fuzzy Systems*. Budapeste: [s.n.], 2004.

SWELDENS, W. The lifting scheme: A construction of second generation wavelets. *SIAM J. Math. Anal.*, v. 29, n. 2, p. 511–546, 1997.

TCHEOU, M. P.; LOVISOLO, L.; RODRIGUES, M. A. M.; SILVA, E. A. B. da; DINIZ, P. S. R.; F., S. M.; RAMOS, M. A. F. Avaliação de um método de compressão para oscilografia com base em procedimentos de análise de perturbações elétricas. In: *X SIMPÓSIO DE ESPECIALISTAS EM PLANEJAMENTO DA OPERAÇÃO E EXPANSÃO ELÉTRICA*. [S.l.: s.n.], 2006.

VIEIRA, R. C.; ROISENBERG, M. *REDES NEURAIS ARTIFICIAIS: UM BREVE TUTORIAL*. [S.l.], 2008. Disponível em: <<http://www.inf.ufsc.br/13c/artigos/TutorialRNA.pdf>>. Acesso em: 17 de março de 2008.

ZHAOA, W.; SONGB, Y. H.; MINB, Y. Wavelet analysis based scheme for fault detection and classification in underground power cable systems. *Electric Power Systems Research*, v. 53, p. 1–71, janeiro 2000.