


**ROBERTO NAVARRO DE MESQUITA**

**CLASSIFICAÇÃO DE DEFEITOS EM TUBOS DE GERADOR  
DE VAPOR DE PLANTAS NUCLEARES UTILIZANDO MAPAS  
AUTO-ORGANIZÁVEIS**



Tese apresentada à Escola  
Politécnica da Universidade de  
São Paulo para a obtenção do  
título de Doutor em Engenharia.

Área de Concentração:  
Engenharia Mecatrônica e  
Sistemas Mecânicos.

Orientador:  
Prof. Dr.  
Eduardo Lobo Lustosa Cabral

São Paulo

2002

DEDALUS - Acervo - EPMN



31600009411

PMR

Universidade de São Paulo  
Biblioteca da Escola Politécnica

FT- 1712

## FICHA CATALOGRÁFICA

Mesquita, Roberto Navarro de

Classificação de defeitos em tubos de gerador de vapor de plantas nucleares utilizando mapas auto-organizáveis / Roberto Navarro de Mesquita. -- São Paulo, 2002.

p.

Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia Mecatrônica e Sistemas Mecânicos.

1.Reconhecimento de padrões 2.Inteligência artificial  
I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia Mecatrônica e Sistemas Mecânicos II.t.



**UNIVERSIDADE DE SÃO PAULO**  
**ESCOLA POLITÉCNICA**  
**TERMO DE JULGAMENTO**  
**DE**  
**DEFESA DE TESE DE DOUTORADO**

Aos 21 dias do mês de agosto de 2002, às 09:00 horas, no Departamento de Engenharia Mecânica da Escola Politécnica da Universidade de São Paulo, presente a Comissão Julgadora, integrada pelos Senhores Professores Doutores Eduardo Lobo Lustosa Cabral, orientador do candidato(a), Julio Cezar Adamowski, Carlos Alexandre de Jesus Miranda, Newton Maruyama e Miguel Mattar Neto, iniciou-se a Defesa de Tese de Doutorado da Sr.

**ROBERTO NAVARRO DE MESQUITA**

Título da Tese: "**CLASSIFICAÇÃO DE DEFEITOS EM TUBOS DE GERADOR DE VAPOR DE PLANTAS NUCLEARES UTILIZANDO MAPAS AUTO-ORGANIZÁVEIS**".

Concluída a arguição, procedeu-se ao julgamento na forma regulamentar, tendo a Comissão Julgadora considerado o(a) candidato(a):

Prof.Dr.Eduardo Lobo Lustosa Cabral.....	( Aprovado )
Prof.Dr.Julio Cezar Adamowski.....	( Aprovado )
Prof.Dr.Carlos Alexandre de Jesus Miranda.....	( Aprovado )
Prof.Dr.Newton Maruyama.....	( Aprovado )
Prof.Dr.Miguel Mattar Neto.....	( Aprovado )

Para constar, é lavrado o presente termo, que vai assinado pela Comissão Julgadora e pela Secretária de Pós-Graduação.

São Paulo, 21 de agosto de 2002.  
A COMISSÃO JULGADORA

---


---


---


---

Secretária: Elisabete Ap<sup>a</sup> F.S.Ramos

Obs.: Resolução 4476, de 17.09.1997 Altera dispositivos do Regimento Geral da USP Art.109 - Imediatamente após o encerramento da arguição da dissertação ou da tese cada examinador expressará seu julgamento em sessão secreta, considerando o candidato aprovado ou reprovado.

Homologado pela C.P.G. em reunião realizada 23/09/2002.

## AGRADECIMENTOS

Ao professor Eduardo Cabral por sua colaboração inestimável.

Ao professor Belle Upadhyaya, sem o qual este trabalho seria impossível.

Ao professor Daniel Ting, pela ajuda com suas instigantes discussões.

Ao Ipen por ter me financiado nesta pesquisa.

Ao CNPq por ter financiado parte desta pesquisa.

Ao Paulo Masotti, companheiro de todos os dias.

À Rosani Penha, por seu incentivo em horas difíceis.

À colaboração dos amigos.

Ao amor de minha família.

## RESUMO

Esta tese desenvolve um novo método de classificação de defeitos em tubos de gerador de vapor de plantas nucleares, utilizando sinais do teste de correntes parasitas (“eddy current test”). O método utiliza a técnica conhecida como mapeamento auto-organizável para comparar a importância de diferentes características do sinal do teste de correntes parasitas na identificação e classificação destes defeitos. Um sistema de inferência múltipla é proposto que utiliza diversos mapas treinados individualmente com as diferentes características extraídas, para a classificação final do tipo de defeito. Os métodos de extração de características utilizados são a representação de “wavelet zero-crossings”, a codificação preditiva linear (LPC), e características de representação do sinal no tempo como módulo e fase. São montados diversos vetores característicos do sinal com combinações das características obtidas dos sinais de correntes parasitas. Estes vetores são testados quanto à sua eficiência na classificação e os vetores com melhor índice de acerto são utilizados no sistema de inferência múltipla. É desenvolvido um estudo sistemático dos critérios de pré-processamento, calibração e métodos de análise dos sinais relacionados com os defeitos das tubulações de plantas nucleares. Demonstra-se a eficiência do método de classificação e obtêm-se mapas característicos com protótipos representativos referentes a cada tipo de degradação.

## ABSTRACT

This thesis obtains a new classification method for different steam generator tube defects in nuclear power plants using Eddy Current Test signals. The method uses self-organizing maps to compare different signal characteristics efficiency to identify and classify these defects. A multiple inference system is proposed which composes the different extracted characteristic trained maps classification to infer the final defect type. The feature extraction methods used are the Wavelet zero-crossings representation, the linear predictive coding (LPC), and other basic signal representations on time like module and phase. Many characteristic vectors are obtained with combinations of these extracted characteristics. These vectors are tested to classify the defects and the best ones are applied to the multiple inference system. A systematic study of pre-processing, calibration and analysis methods for the steam generator tube defect signals in nuclear power plants is done. The method efficiency is demonstrated and characteristic maps with the main prototypes are obtained for each steam generator tube defect type.

## ERRATA

PÁGINA	LINHA	ONDE SE LÊ	LEIA-SE
3	1	(2000)	(2001)
9	30	acessar	obter
11	4	no acesso ao	na obtenção do
16	27	dois tipos	duas configurações
39	5	por tensão	sob tensão
40	12	dissoluçãodo	dissolução do
41	18	estresse	tensão
42	1	Trincamento por Tensão e Corrosão por Água do Primário (PWSCC)	Trincamento sob Tensão e Corrosão por Água do Primário (PWSCC) e de Diâmetro Externo (ODSCC)
42	5	circular	circunferencial
42	16	trinca típica	trinca externa
43	5	requerimentos	requisitos
43	22	volume do tubo	volume da parede do tubo
46	21	Os sete mecanismos ... são quatro entre	Dos sete mecanismos ... quatro estão entre
46	25	por tensão	sob tensão
47	18	tabela 2.3	tabela 2.2
48	tabela 3.1	Pilha	Pilha de lama
49	33	base	espelho
59	3	base	espelho
72	figura 3.25	pontos amostrados	Volts
79	3	quatro	cinco
84	20	1999	1998
85	11	com maior	com maiores
87	29	varia	variam
88	21	assimétrica	axissimétrica
92	2	1990	1989
118	31	5.5	5.6
121	10	5.6	5.5
124	27	Esta seção apresenta o algoritmo básico utilizado para implementar a SOM neste trabalho	O algoritmo básico apresentado na última seção foi utilizado para implementar o SOM neste trabalho
127	17	6.15, em três	6.16, em
140	13	2.8	2.6
147	figura 6.20	Amostrados	Amostrados
148	24	proporcionais	proporcional
151	1	vizualização	visualização
152	10	na seção 7.2	ao fim desta seção
152	figura 7.2	Diagrama de blocos	Passos
160	1	realizam	realiza
161	13	(7.1)	(7.3)
166	tabela 7.3	SPH	SPH (SRI+PHM)
173	1	dos do	dos protótipos do
176	1	dos do	dos protótipos do

1. Na página 121, onde se lê a figura 5.6, a mesma figura, mais nítida, é apresentada abaixo:




Figura 5.6 – Matriz Ud de distâncias topológicas quadradas entre as coordenadas das células para mapa de 54 células em morfologia hexagonal.

2. 'Na página 151, onde se lê a figura 7.1, leia-se:

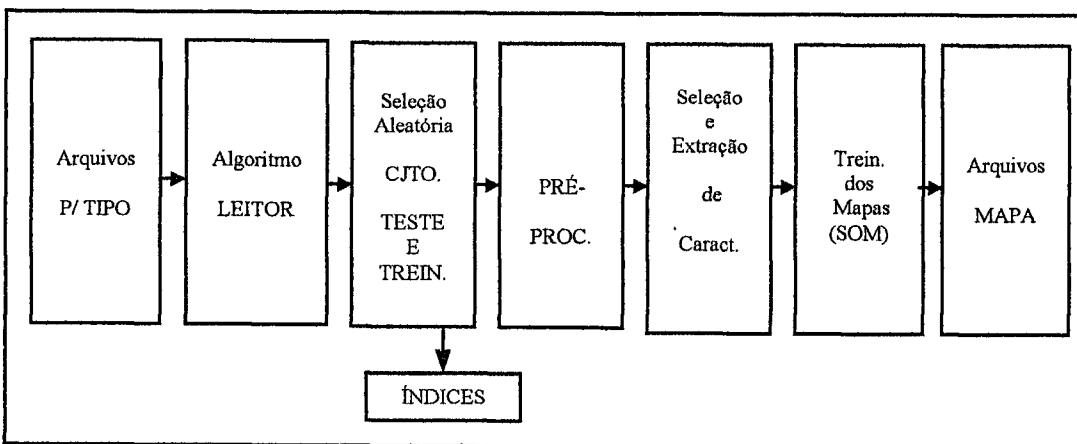
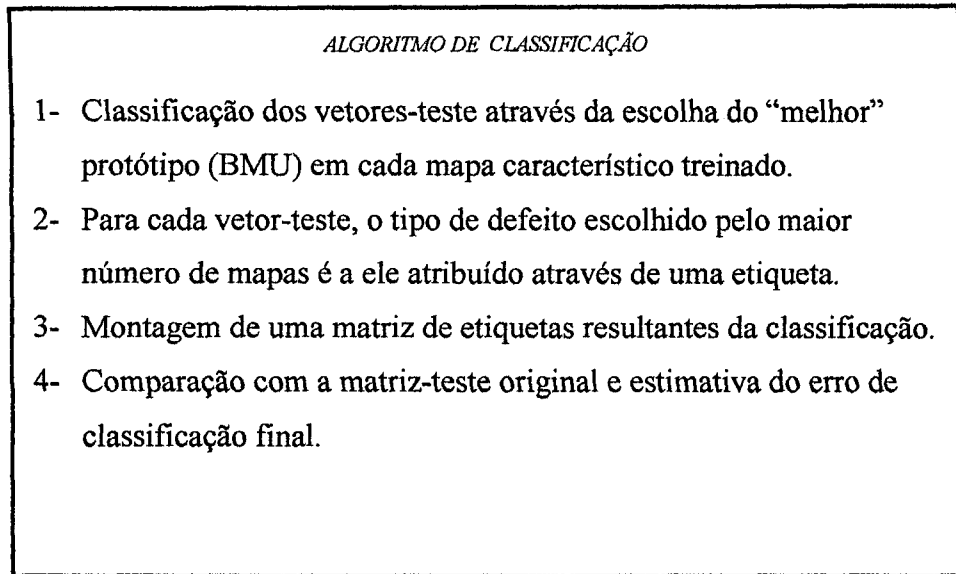


Figura 7.1 - Diagrama de blocos das etapas de treinamento.

3. Na página 160, onde se lê a figura 7.6, leia-se:



**Figura 7.6- Algoritmo de inferência múltipla utilizado na classificação.**

4. Na página 189, linha 29, leia-se: BARRO, S; FERNANDEZ-DELGADO, M; VILA-SOBRINO, JÁ; et al. Classifying multichannel ECG patterns with an adaptive neural network. **IEEE Engineering in Medicine and Biology Magazine 1998**, v.17, n.1,p.45-55, February 1998.

## SUMÁRIO

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE ABREVIATURAS E SIGLAS

LISTA DE SÍMBOLOS

1. INTRODUÇÃO.....	01
1.1 Contexto.....	01
1.2 Objetivo.....	04
1.3 Organização do texto.....	05
2. TESTE DE CORRENTES PARASITAS (“EDDY CURRENT TEST”).....	07
2.1 Ensaios não destrutivos.....	07
2.2 a História do ECT.....	11
2.3 A Técnica de ECT.....	13
2.3.1 Princípio físico .....	13
2.3.2 Procedimentos experimentais da medida de ECT.....	16
2.3.3 Campos de aplicação e objetivos do ensaio.....	25
2.4 Aplicação de ECT em TGV de plantas nucleares.....	27
2.4.1 Equipamentos de aquisição e processamento dos sinais de ECT.....	27
2.4.2 O gerador de vapor.....	31
2.4.3 Os tubos de gerador de vapor.....	34
2.4.4 Defeitos típicos em TGV de plantas nucleares.....	37
2.4.4.1 Afinamento (THI).....	40
2.4.4.2 Perfuração (PIT).....	40
2.4.4.3 Trincamento e corrosão intergranular (IGA/SCC ou ISC).....	41
2.4.4.4 Trincamento por tensão e corrosão por água do primário (PWSCC).....	42
2.4.4.5 Desgaste (WEA).....	43
2.4.4.6 Dano por colisão (IMP).....	43
2.4.4.7 Fadiga.....	44

3. BASE DE DADOS DE ECT UTILIZADA.....	45
3.1 Organização da base de dados.....	45
3.2 Montagem dos conjuntos de treinamento.....	49
3.2.1 Sinais relativos ao trincamento intergranular (ISC).....	59
3.2.2 Sinais relativos à perfuração (PIT).....	61
3.2.3 Sinais relativos ao desgaste (WEA).....	65
3.2.4 Sinais relativos ao afinamento (THI).....	69
3.2.5 Sinais relativos ao dano por colisão (IMP).....	70
3.3 Visualização e pré-processamento dos sinais de ECT.....	72
4. TÉCNICAS DE RECONHECIMENTO DE PADRÕES EM SINAIS DE ECT...78	
4.1 Reconhecimento de padrões.....	78
4.1.1 Reconhecimento de padrões em sinais.....	83
4.2 Extração de características em reconhecimento de padrões.....	84
4.3 Propostas de sistemas automatizados de diagnóstico de defeitos em TGV de plantas nucleares.....	86
5. MAPAS DE KOHONEN (“SELF-ORGANIZING MAPS”) .....	91
5.1 Redes neurais.....	91
5.2 Treinamento e aprendizado de redes neurais.....	98
5.2.1 Métodos e aprendizado competitivo.....	101
5.3 Mapas auto-organizáveis de Kohonen.....	107
5.3.1 Treinamento em Lote (“batch”).....	111
5.4 Métodos estatísticos de redução de dados e de dimensionalidade.....	112
5.4.1 Interpretação estatística do SOM.....	116
5.5 Descrição do algoritmo.....	118
5.5.1 SOM supervisionado.....	123
5.6 Algoritmo utilizado neste trabalho.....	124
6. EXTRAÇÃO DE CARACTERÍSTICAS DO SINAL DE ECT.....	126
6.1 Segmento do sinal.....	126
6.2 Módulo.....	139
6.3 Fase.....	140
6.4 Número de cruzamentos com o zero da transformada de “wavelet”.....	142
6.4.1 Transformada de “wavelet”.....	142

6.4.2 Método do número de cruzamentos com o zero da transformada de “wavelet”.....	144
6.5 Codificação preditiva linear .....	148
7. INFERÊNCIA E CLASSIFICAÇÃO FINAL.....	150
7.1 Aspectos gerais sobre o sistema de inferência e classificação de defeitos.....	150
7.2 Etapa de treinamento do sistema de classificação.....	151
7.3 Etapa de classificação de defeitos.....	159
7.3.1 Resultados de classificação e mapas característicos obtidos.....	162
8. CONCLUSÕES.....	184
8.1 Contribuições da tese.....	185
8.2 Sugestões e perspectivas para trabalhos futuros .....	187
REFERÊNCIAS BIBLIOGRÁFICAS.....	189

## LISTA DE FIGURAS

FIGURA 2.1	Interação eletromagnética entre sonda-bobina e amostra .....	14
FIGURA 2.2	Sonda tipo bobina diferencial.....	17
FIGURA 2.3	Sonda tipo panqueca.....	18
FIGURA 2.4	Tubo de calibração com defeitos de diâmetro externo (padrão ASME).....	19
FIGURA 2.5	Plano de impedância de tubo padrão de calibração (400kHz).....	19
FIGURA 2.6	Plano de impedância de tubo padrão de calibração (100kHz).....	20
FIGURA 2.7	Sinais típicos de calibração, resistência e reatância .....	20
FIGURA 2.8	Diagrama de blocos de um sistema de aquisição de ECT .....	21
FIGURA 2.9	Definição dos parâmetros de calibração ASME.....	23
FIGURA 2.10	Curva de avaliação correspondente aos padrões de calibração.....	24
FIGURA 2.11	Equipamento de aquisição de ECT típico.....	29
FIGURA 2.12	Interface gráfica típica de programa de gerenciamento de aquisição de ECT.....	30
FIGURA 2.13	Interface gráfica típica de programa comercial de análise de ECT.....	30
FIGURA 2.14	Seções transversais de geradores de vapor PWR de tubo reto vertical e de tubo em "U" .....	32
FIGURA 2.15	Esquemas típico de suportes de TGV utilizando a nomenclatura típica.....	35
FIGURA 2.16	Arranjos típicos de barras anti-vibração.....	36
FIGURA 2.17	Estruturas de suporte de TGV típicos.....	37
FIGURA 2.18	Gerador de Vapor em "U" e Defeitos Típicos.....	39
FIGURA 2.19	Seção Transversal de trinca em tubo.....	42

FIGURA 3.1	Formato Típico de um Relatório final de Análise de ECT.....	50
FIGURA 3.2	Critério de segmentação do sinal utilizando a IC como referência.....	51
FIGURA 3.3	Segmentos de 64 pontos de sinais de ECT diferenciais em diferentes freqüências de excitação (400kHz, 200kHz, 100kHz, e 10kHz) relativos a ISC.....	54
FIGURA 3.4	Segmentos de 64 pontos de sinais de ECT absolutos em diferentes freqüências de excitação (400kHz, 200kHz, 100kHz, e 10kHz) relativos a ISC.....	54
FIGURA 3.5	Sinal resistivo diferencial de 400kHz de extensão completa de tubo em “U”.....	56
FIGURA 3.6	Sinais resistivo, indutivo e plano de impedância, característicos (assinaturas) de: (a) suportes de tubos (TSP) sem defeito e (b) TSP com defeito.....	57
FIGURA 3.7	Sinal resistivo, indutivo e plano de impedância de sinal característico da base de tubos (TSH).....	58
FIGURA 3.8	Segmento do sinal indutivo de 400kHz (diferencial).....	59
FIGURA 3.9	Segmento com 100 pontos amostrados de sinal resistivo, indutivo e plano de impedância de 400kHz (diferencial) sem filtragem (a) e filtrado (b) referente a ISC.....	60
FIGURA 3.10	Plano de Impedância com 64 pontos do sinal de 400 kHz (diferencial) filtrado e IC referente ao defeito ISC.....	61
FIGURA 3.11	Sinal resistivo de 600kHz (diferencial) com indicação de perfuração (PIT).....	62
FIGURA 3.12	Segmento de 128 pontos de sinal resistivo de 600 kHz (diferencial) com indicação de perfuração (PIT).....	63
FIGURA 3.13	Segmento de 64 pontos de sinal resistivo de 600 kHz (diferencial) com indicação de perfuração (PIT).....	63
FIGURA 3.14	Plano de Impedância de 600kHz (diferencial) com IC de PIT.....	64

FIGURA 3.15	Segmento de 64 pontos de sinal resistivo de 600 kHz relativo à indicação de defeito desgaste (WEA) localizado sobre barra anti-vibração (AVB).....	66
FIGURA 3.16	Segmento de sinal resistivo de canal diferencial mixado (600/100 kHz) e filtrado, relativo à indicação de WEA.....	66
FIGURA 3.17	Segmento de 64 pontos de sinal diferencial indutivo de 600 kHz relativo à indicação de WEA.....	67
FIGURA 3.18	Segmento de sinal resistivo de canal diferencial mixado (600/100 kHz) e filtrado, relativo à indicação WEA.....	67
FIGURA 3.19	Plano de impedância de sinal diferencial de 600 kHz com 64 pontos relativo à indicação de WEA sobre sinal de AVB.....	68
FIGURA 3.20	Plano de impedância de 64 pontos relativo à canal diferencial mixado de 600/100 kHz e filtrado, correspondente à indicação de WEA.....	68
FIGURA 3.21	Segmento de sinal indutivo de 400kHz apresentando dois sinais distintos de afinamento (THI).....	69
FIGURA 3.22	Plano de impedância de canal diferencial de 400kHz apresentando a justaposição de duas figuras de Lissajous correspondentes às duas IC da THI.....	70
FIGURA 3.23	Segmento de sinal resistivo diferencial de 600kHz com duas indicações de dano por IMP ao lado de sinal de TSP característico.....	71
FIGURA 3.24	Segmento de sinal indutivo diferencial de 600 kHz com duas indicações de IMP ao lado de sinal de TSP característico.....	71
FIGURA 3.25	Plano de impedância com 64 pontos relativos às indicações de IMP contendo duas indicações.....	72
FIGURA 3.26	Interface gráfica do módulo de filtragem seletiva de sinal de ECT.....	74
FIGURA 3.27	Etapas de pré-processamento da base de dados utilizada.....	77

FIGURA 5.1	Modelo neurônio natural e correspondente artificial.....	93
FIGURA 5.2	Exemplo arquitetura de rede neural artificial.....	94
FIGURA 5.3	a) conjunto de pontos em R <sup>2</sup> ; b) tecedura de Voronoi; c) triangulação de Delaunay.....	103
FIGURA 5.4	Grade hexagonal com representação dos vetores paramétrico da rede correspondentes ao espectro de fala natural.....	109
FIGURA 5.5	Grade hexagonal com representação dos vetores paramétrico da rede correspondentes ao espectro de fala natural.....	120
FIGURA 5.6	Matriz U <sub>d</sub> de distâncias topológicas quadradas entre as coordenadas das células para mapa de 54 células em morfologia hexagonal .....	121
FIGURA 6.1	Segmentos de 64 pontos do sinal real relativos à degradação ISC.....	128
FIGURA 6.2	Segmentos de 64 pontos do sinal imaginário relativos à degradação ISC.....	128
FIGURA 6.3	Segmentos de 64 pontos relativos à degradação ISC no plano de impedância.....	129
FIGURA 6.4	Segmentos de 64 pontos do sinal real relativos à degradação PIT.....	130
FIGURA 6.5	Segmentos de 64 pontos do sinal imaginário relativos à degradação PIT.....	130
FIGURA 6.6	Segmentos de 64 pontos relativos à degradação PIT no plano de impedância.....	131
FIGURA 6.7	Segmentos de 64 pontos do sinal real relativos à degradação WEA.....	132
FIGURA 6.8	Segmentos de 64 pontos do sinal imaginário relativos à degradação WEA.....	132
FIGURA 6.9	Segmentos de 64 pontos relativos à degradação WEA no plano de impedância.....	133

FIGURA 6.10	Segmentos de 64 pontos do sinal real relativos à degradação THI.....	134
FIGURA 6.11	Segmentos de 64 pontos do sinal imaginário relativos à degradação THI.....	134
FIGURA 6.12	Segmentos de 64 pontos relativos à degradação THI no plano de impedância.....	135
FIGURA 6.13	Segmentos de 64 pontos do sinal real relativos à degradação IMP.....	136
FIGURA 6.14	Segmentos de 64 pontos do sinal imaginário relativos à degradação IMP.....	136
FIGURA 6.15	Segmentos de 64 pontos relativos à degradação IMP no plano de impedância.....	137
FIGURA 6.16	Segmentos de 128 pontos de sinal real (a) e imaginário (b), correspondentes à uma indicação ISC.....	138
FIGURA 6.17	Vetor que define o módulo do sinal de ECT no plano de impedância.....	139
FIGURA 6.18	Vetor módulo com 128 pontos referente a uma indicação de degradação ISC.....	140
FIGURA 6.19	Vetor fase característico com 128 pontos referente a indicação de degradação ISC.....	141
FIGURA 6.20	Vetor característico utilizando a representação de WZC de um segmento real de 128 pontos de sinal de ECT correspondente à uma indicação de degradação tipo ISC.....	147
FIGURA 6.21	Vetor característico utilizando a representação de WZC de um segmento imaginário de 128 pontos de sinal de ECT correspondente à uma indicação de ISC.....	147
FIGURA 6.22	Vetores característicos obtidos pela aplicação da LPC com 30 coeficientes a segmento de 128 pontos de um sinal de ECT correspondente a uma indicação de degradação tipo ISC. (a) real (b) imaginário.....	149
FIGURA 7.1	Diagrama de blocos das etapas de treinamento.....	151
FIGURA 7.2	Diagrama de blocos das etapas de treinamento.....	152

FIGURA 7.3	Interface gráfica para sistema de classificação de defeitos em ECT.....	153
FIGURA 7.4	Interface gráfica que permite a seleção dos mapas de Kohonen característicos a serem utilizados na classificação final.....	154
FIGURA 7.5	Comportamento típico do erro de quantização (QE) durante treinamento em lote de mapa de Kohonen com 19x12 unidades e vetores de dimensão 256 (SRI de 128 pontos). (a) treinamento em fase “bruta”; (b) treinamento em fase “fina”.....	157
FIGURA 7.6	Algoritmo de inferência múltipla utilizado na classificação.....	160
FIGURA 7.7	Diagrama de blocos das etapas de teste.....	161
FIGURA 7.8	Representação no plano de impedância do livro-código com 32x24 (768) unidades, contendo vetores-protótipos SRI de 128 elementos treinados com 160 amostras (2/3) do número total de vetores da base de dados utilizada.....	170
FIGURA 7.9	Mapa de Kohonen (32 x 24) treinado com segmentos de 128 pontos de sinais de ECT (real e imaginário concatenados).....	171
FIGURA 7.10	Representação aproximada do livro código dos vetores SRI sobrepostos ao mapa classificado obtido com índice de acerto de classificação de 92%.....	172
FIGURA 7.11	Representação dos do livro-código com 30x26 (780) unidades, contendo vetores-dos protótipos LRI, treinados com 160 amostras (2/3) do número total de vetores da base de dados utilizada.....	173
FIGURA 7.12	Mapa de Kohonen (30 x 26) treinado com segmentos de 32 coeficientes de LPC de segmentos de sinais de ECT (real e imaginário concatenados).....	174

FIGURA 7.13	Representação aproximada do livro código dos vetores LRI sobrepostos ao mapa classificado obtido com índice de acerto de classificação de 65%.....	175
FIGURA 7.14	Representação dos do livro-código com 32x21 (672) unidades, contendo vetores-dos protótipos WRI de 128 elementos, treinados com 120 amostras (1/2) do número total de vetores da base de dados utilizada.....	176
FIGURA 7.15	Mapa de Kohonen (32 x 21) treinado com segmentos de 128 pontos de coeficientes de WZC de sinais de ECT (real e imaginário concatenados).....	177
FIGURA 7.16	Representação aproximada do livro código dos vetores WRI sobrepostos ao mapa classificado obtido com índice de acerto de classificação de 55%.....	178
FIGURA 7.17	Principais protótipos classificados como tipo WEA, representados no plano da impedância.....	179
FIGURA 7.18	Principais protótipos classificados como tipo PIT, representados no plano da impedância.....	180
FIGURA 7.19	– Principais protótipos classificados como tipo THI, representados no plano da impedância.....	181
FIGURA 7.20	Principais protótipos classificados como IMP, representados no plano da impedância.....	182
FIGURA 7.21	Principais protótipos classificados como ISC, representados no plano da impedância.....	183

## LISTA DE TABELAS

TABELA 2.1	Aplicações típicas da inspeção de ECT.....	26
TABELA 2.2	Valores típicos do processo de aquisição de dados do ECT em TGV.....	28
TABELA 2.3	Parâmetros Típicos de Geradores de Vapor.....	33
TABELA 3.1	Base de Dados de sondas tipo bobina de ECT extraídas do PDD.....	48
TABELA 7.1	Índices de acerto para os diferentes mapas de Kohonen obtidos para as diferentes características do sinal de ECT com 50% da base para treinamento.....	164
TABELA 7.2	Índices de acerto para os diferentes mapas de Kohonen obtidos para as diferentes características do sinal de ECT com 66,7% da base para treinamento.....	165
TABELA 7.3	Índices de acerto para inferência utilizando múltiplos mapas de Kohonen obtidos para as diferentes características do sinal de ECT.....	166
TABELA 7.4	Índices de acerto para inferência utilizando múltiplos mapas de Kohonen obtidos para as diferentes características do sinal de ECT.....	166

## LISTA DE ABREVIATURAS E SIGLAS

- ART:** teoria da ressonância adaptativa
- ASME:** American Society of Mechanical Engineers
- AVB:** barras anti-vibração (“anti-vibration bar”)
- BMU:** melhor unidade semelhante (“best match unit”)
- BWR:** reatores nucleares de água em ebulição (“boiling water reactor”)
- CANDU:** reatores nucleares de deutério-urânio do Canadá
- ECT:** técnica de correntes parasites (“eddy current test”)
- EPRI:** (“Electric Power Research Institute”)
- FCM:** “fuzzy cluster mean”
- GLA:** algoritmo generalizado de Lloyd (“generalized Lloyd algorithm”)
- IAEA:** Agência Internacional de Energia Atômica (“International Atomic Energy Agency”)
- IC:** indicação central
- ICA:** análise de componentes independentes (“independent component analysis”)
- IGA/SCC:** Trincamento e Corrosão Intergranular (“intergranular attack” e “stress corrosion cracking”)
- IGA:** ataque intra-granular (“intragranular attack”)
- IMP:** danos por colisão (“impingement”) (degradações por corrosão mecânica)
- ISC:** IGA/SCC
- ISC:** trincamento e corrosão intergranular (degradação por corrosão química)
- LPC:** codificação preditiva linear (“linear predictive coding”)
- LVQ:** algoritmo de aprendizado de quantização vetorial (“linear vector quantization”)
- MDL:** escalamento multi-dimensional
- ML:** máxima semelhança
- MLP:** “multilayer perceptron”
- NDE:** ensaios não destrutivos

**ODSCC:** trincamento externo circunferencial ou axial (“outer diameter stress corrosion cracking”)

**ORNL:** Oak Ridge National Laboratory

**OTSG:** gerador de vapor de tubos reto (“once-through steam generator”)

**PCA:** análise de componente principal (“principal component analysis”)

**PDD:** “Performance Demonstration Database”

**PIT:** perfurações (“pitting”)

**PNNL:** Pacific Northwest National Laboratory

**POD:** probabilidade de detecção

**PSP:** densidade espectral de potência

**PWR:** reatores de água pressurizada (“pressurized water reactor”)

**PWSCC:** trincamento por corrosão por tensão de água primária (“primary water stress corrosion cracking”)

**RBF:** “radial-basis function” (redes)

**RMSE:** raiz da média do erro quadrático (“root mean squared error”)

**RSG:** gerador de vapor de recirculação ou de tubos em U (“recirculating steam generator”)

**SCC :** trincamento por corrosão e estresse (“stress corrosion cracking”)

**SFS:** “sequential forward search”

**SNN:** “structured neural network”

**SOM:** mapas auto-organizáveis (“self-organized maps”)

**SQUID:** efeito quântico (“superconducting quantum interference device”)

**TEC:** fim de tubo frio (“tube end cold”)

**TEH:** fim de tubo quente (“tube end hot”)

**TEHTEC:** fim de tubo quente - fim de tubo frio (“tube end hot - tube end cold”)

**TGV:** tubos de gerador de vapor

**THI:** afinamento (degradação por corrosão química) (“thinning”)

**TS:** base de tubos “tube sheet”

**TSC:** base de tubos fria (“tube sheet cold”)

**TSC:** vão entre tubo e base de tubos (“tube sheet crevice”)

**TSH:** placa de tubos quente (“tube sheet hot”)

**TSP:** placas de suporte dos tubos (“tube support plates”)

**TTS:** topo da base de tubos (“top of tube sheet”)

**WEA:** desgastes (“wear –”)

**WWER:** reatores de água resfriada (“water cooled energy reactor”)

**WZC:** cruzamentos com o zero da transformada de “wavelet” (“wavelet zero-crossings”)

## LISTA DE SÍMBOLOS

$J_s$ : densidade de corrente

$A$ : vetor potencial magnético

$\mu$ : permeabilidade magnética

$\sigma$ : condutividade do material

$\omega$ : freqüência de excitação

$J_x$ : densidade de corrente na direção da profundidade do material testado

$J_\theta$ : densidade das correntes na superfície do material testado

$\alpha$ : valor do ângulo de fase

$d$ : profundidade de penetração padrão

$f$ : freqüência de teste

$V_x$  potencial elétrico na direção x

$V_y$  potencial elétrico na direção y

$f_I$ : função de transferência ou de ativação

$\theta_I$ : limiar de ativação

$x_j$ : vetores de entrada daquele neurônio

$w_{ij}$ : pesos a cada uma destas entradas

$n$ : número de vetores de entrada conectados

$X$ : vetor de entrada

$W$ : matriz de pesos referente ao conjunto de conexões entre os neurônios de diferentes camadas

$Y$ : vetor de saída

$K$ : constante de proporcionalidade

$w$ : vetor peso,

$\varepsilon$ : erro definido pela relação 5.2

$\eta$ : constante de aprendizado

$\Phi$ : valor de ativação do neurônio

$\delta$ : constante de proporcionalidade entre a saída e a atualização do peso

$w_{AB}$ : peso da conexão sináptica entre o neurônio A e B

$\alpha$ : termo de “esquecimento”

$w_c$ : vetor de referência

$q_e$ : erro de quantização

$t_e$ : erro topográfico

$m_{units}$ : número de unidades do mapa de Kohonen

$d_{len}$ : quantidade de vetores de treinamento

$\epsilon$ : erro de classificação

$n_e$ : número de vetores-teste erroneamente classificados

$n_t$ : número total de vetores-teste

$\phi$ : índice de acerto de classificação

## 1 - INTRODUÇÃO

### 1.1 - Contexto

Os geradores de vapor são componentes característicos de plantas nucleares de potência do tipo água pressurizada (“pressurized water reactor” - PWR). O princípio básico do gerador de vapor é a transferência de calor. Os milhares de tubos que o compõe funcionam como interface entre o líquido refrigerante do sistema primário do reator, que contém a energia térmica provenientes das fissões nucleares ocorridas no núcleo, e o líquido do sistema secundário, que tem por função movimentar as turbinas da usina.

A eficiência de um gerador de vapor de uma planta nuclear está diretamente relacionada à potência que esta planta pode gerar. Esta eficiência é afetada de forma significativa quando uma fração dos milhares de tubos que compõe o gerador de vapor começa a apresentar defeitos que requeiram seu tamponamento. A degradação das paredes destes tubos ocorre por diferentes mecanismos, como corrosão por química alterada do líquido refrigerante, tensão, vibração ou uma associação entre estes mecanismos.

A técnica de correntes parasitas (“eddy current test” - ECT) tem sido utilizada por muitos anos e é a única inspeção não destrutiva normalizada para detecção das falhas nos tubos de gerador de vapor (TGV). As manutenções de rotina destes geradores de vapor consistem de inspeções periódicas utilizando ECT para a detecção de falhas ou defeitos nos tubos visando a prevenção de vazamentos. A tecnologia envolvida no teste ECT em plantas nucleares é bastante desenvolvida, tanto na automação da aquisição dos sinais como no seu processamento. A aquisição dos sinais é feita por sistemas controlados por robôs que deslocam e posicionam as sondas nos tubos.

O processamento e a visualização dos sinais incluem programas comerciais que possibilitam a sua manipulação e a posterior análise por inspetores qualificados.

A análise dos dados de ECT é geralmente executada por múltiplos grupos de especialistas que têm que decidir sobre o tamponamento ou reparo de cada tubo do gerador. Esta análise envolve considerações econômicas e de segurança e é baseada na comparação entre as medidas realizadas e uma extensa base de dados de defeitos prévios em TGV de plantas similares. Além da grande quantidade de dados a ser analisada, existe uma exiguidade no tempo para que esta análise seja feita pois as inspeções de rotina ocorrem durante o período de recarga do combustível da usina. Estes períodos são da ordem de algumas semanas e, dependendo da planta, ocorrem em intervalos de anos.

A automação desta análise, mesmo que parcial, tem sido vista como parte do esforço para o aumento da vida útil do gerador de vapor pois poderia aumentar a confiabilidade da manutenção preditiva. O risco de erro neste tipo de diagnóstico ainda apresenta níveis consideráveis, levando as equipes de inspetores a uma postura conservadora na tomada de decisão pelo tamponamento ou não dos tubos examinados. Este conservadorismo significa necessariamente uma redução extra da capacidade e vida útil destes equipamentos e pode levar à necessidade de troca do gerador de vapor. O aumento da vida útil destes geradores de vapor tem sido uma meta estabelecida em todo o mundo visando minimizar esta ameaça às plantas nucleares tipo PWR. O custo total da manutenção, paradas e reposição de um gerador de vapor, pode chegar a centenas de milhões de dólares.

**Udpa e Udpa (1990)** iniciaram vários trabalhos com o objetivo de automatizar corretamente a detecção e classificação de defeitos em TGV utilizando ECT. Um sistema automatizado que pudesse ser utilizado como auxiliar na análise de um inspetor tem sido buscado por diferentes equipes (**Upadhyaya et al., 1993; Kurtz et al., 1996; Kang et al., 1998**). Uma revisão completa dos trabalhos realizados com este intuito é encontrada no item 4.3 deste trabalho (“Propostas de Sistemas Automatizados de Diagnóstico de Defeitos em TGV de Plantas Nucleares”).

Este tipo de sistema automatizado depende, em primeira instância, do algoritmo classificador. Esta classificação, por sua vez, tem-se mostrado fortemente dependente de uma organização da base de dados, coordenada com uma descrição coerente dos defeitos encontrados. Uma dificuldade comum ao desenvolvimento de qualquer sistema especializado é a representação do conhecimento envolvido. No caso da classificação dos sinais de ECT esta dificuldade é singularmente importante devido à escassez de descrições coerentes das características dos sinais que estão associadas a cada tipo de defeito. Além de contar com poucas descrições coerentes das características associadas a cada defeito, a dificuldade ainda se agrava devido à existência de diferentes plantas nucleares apresentando tubos e desenhos diferentes e portanto características diferentes. Sistemas de inferência “fuzzy”, utilizando características diversas, foram desenvolvidos com resultados importantes (Upadhyaya et al., 1999a). No entanto, estes sistemas foram aplicados em sua maioria, em sinais de defeitos fabricados, ou em sinais padrão para calibração (vide item 2.3.2).

A literatura relata poucas tentativas de classificação dos sinais de ECT quanto ao tipo de defeito (Yan e Upadhyaya, 1996; Udpa e Udpa, 1990). Ainda assim, nestas tentativas não houve comparação da importância de cada característica na classificação e foram relatados uso de bases de dados muito reduzidas.

Uma tentativa de classificação é feita por Mesquita et al. (2000) utilizando coeficientes de código preditivo linear (LPC) e rede auto-organizável. O relato sugere futuro desenvolvimento e obtenção de resultados.

A importância desta proposta está no ineditismo de um estudo sistematizado e parametrizado, da contribuição de diferentes características do sinal de defeitos de ECT com vistas à uma classificação automatizada.

Este estudo terá como diferencial a utilização do algoritmo baseado em mapas auto-organizáveis (“self organized maps” - SOM) que possibilitará, pela sua rapidez e facilidade de visualização, a percepção das relações entre características em

espaços multi-dimensionais destas características. A utilização deste algoritmo possibilita ao mesmo tempo um acesso a configuração deste espaço-característico multi-dimensional do problema, assim como a sua utilização para classificar os sinais de defeitos de ECT.

Além disto, uma classificação de sucesso que não dependa das informações da base de dados quanto à localização do defeito no tubo, ao canal de frequência de excitação, ou mesmo a que planta nuclear ele se refere, se aproximaria de um classificador universal que estaria implicitamente descobrindo no sinal características mais fortes para identificação, detecção e até mesmo modelagem do defeito.

## 1.2 - Objetivo

O objetivo deste trabalho é a implementação de um algoritmo baseado em mapas auto-organizáveis (SOM), ou mapas de Kohonen (Kohonen, 2001) para a classificação de defeitos encontrados em TGV de usinas nucleares, utilizando sinais obtidos através do ECT.

Este algoritmo, por princípio básico, faz diferentes agrupamentos (“clustering”) das características importantes do sinal, possibilitando uma classificação eficaz dos defeitos típicos dos TGV. Mapas baseados em diferentes características do sinal são avaliados quanto à sua capacidade de classificação dos diferentes tipos de defeitos em TGV, obtendo-se assim uma estimativa da importância de cada uma destas diferentes características para identificação destes defeitos. Tal avaliação é fundada em uma base de dados utilizada para o treinamento de inspetores de ECT. Através destes mapas é possível gerar uma inferência utilizando várias características simultaneamente para a decisão da classificação.

Este trabalho portanto, tem o objetivo de avaliar a importância de diferentes características dos sinais de ECT em TGV para a classificação quanto ao tipo de defeito, assim como estabelecer um algoritmo de classificação de defeitos eficiente

que possa ser utilizado como ferramenta auxiliar na análise dos dados de ECT nas inspeções de rotina dos TGV em plantas nucleares.

### 1.3 - Organização do Texto

O *capítulo 2* apresenta uma breve introdução à técnica de ECT dentro do universo das técnicas de ensaio não destrutivos. Um histórico do ECT é apresentado, enfocando a sua aplicação na detecção de defeitos em TGV. É feita uma descrição da técnica de ECT que inclui o princípio físico, os procedimentos experimentais da técnica e as aplicações gerais. Por fim, o problema da aplicação da técnica em TGV de plantas nucleares é descrito incluindo uma breve descrição dos defeitos mais comumente encontrados na rotina de operação destas usinas.

O *capítulo 3* descreve a base de dados utilizada e a metodologia empregada para a sua utilização no sistema de classificação desenvolvido nesta tese. Neste contexto, são apresentados os sinais selecionados relacionados a cada defeito, a descrição disponível associada a esta base de dados e uma breve descrição da metodologia empregada pelo especialista na identificação do defeito através da visualização e processamento do sinal. São descritos, também neste capítulo, as restrições e opções feitas na escolha e pré-processamento dos sinais para entrada no algoritmo de classificação.

O *capítulo 4* faz uma revisão das técnicas utilizadas para reconhecimento de padrões em sinais, incluindo técnicas de extração de características e inferências utilizando inteligência artificial. Por fim é realizada uma revisão das propostas de automação do diagnóstico de defeitos em TGV de plantas nucleares.

O *capítulo 5* faz uma revisão sobre os mapas de Kohonen descrevendo a técnica no contexto das redes neurais e de outros algoritmos de aprendizado competitivo. Também são descritos as variações do algoritmo empregadas nesta tese para o treinamento e obtenção dos mapas de Kohonen associados à cada característica do sinal utilizada nesta tese.

O *capítulo 6* descreve a metodologia e as técnicas utilizadas na obtenção das características do sinal de ECT. São apresentados neste capítulo exemplos dos vetores característicos obtidos para a classificação final.

O *capítulo 7* apresenta o algoritmo de treinamento e teste utilizados para classificação dos defeitos a partir das características. São apresentados os critérios para escolha dos parâmetros de treinamento dos mapas, a metodologia empregada e os resultados obtidos por esta classificação. Mapas de Kohonen treinados e testados, são apresentados em conjunto com representações dos sinais que apresentaram o melhor grau de classificação.

No *capítulo 8* são feitas as considerações finais, discussão, conclusões e perspectivas futuras de aplicação e aperfeiçoamento da metodologia e sistema de classificação estabelecidos nesta tese.

## **2 - TESTE DE CORRENTES PARASITAS (“EDDY CURRENT TEST”)**

O teste de correntes parasitas (ECT) é um dos muitos ensaios não destrutivos (NDE) aplicados à inspeção de falhas em produtos ou partes de mecanismos industriais ou de segurança. No item 2.1 serão tratados brevemente alguns destes ensaios.

### **2.1 - Ensaios não Destrutivos**

A inspeção visual de materiais e superfícies é um método testado ao longo do tempo e tem se mostrado efetivo para uma série de procedimentos de inspeção. O aumento da imagem por meios óticos ou iluminação podem melhorar o método mas ao mesmo tempo tornar a inspeção mais lenta. O compromisso entre os fatores qualidade e tempo de inspeção tem determinado muitas vezes uma solução ideal para cada caso de inspeção e o método mais apropriado para atender as necessidades de cada caso.

Métodos como o visual, ruído de toque, teste de prova, e testes de óleo e branqueamento têm sido usados para detectar falhas em materiais e estruturas há muitos anos. Toque acústico de fundição ou outro componente é um método antigo para detectar trincas mais grossas. Quando uma batida é dada em um componente suspenso, um som característico pode ser ouvido se não existem rachaduras. Uma parte com trincas não irá soar com a mesma duração ou intensidade.

No teste de prova se aplica uma carga maior que a esperada a uma parte mecânica. Algumas vezes é destrutivo, mas se aplicado apropriadamente pode ser um método efetivo para testar não destrutivamente vasos de pressão e grandes bombas. No método de óleo e branqueamento as partes são mergulhadas em óleo por algumas horas, removidas do banho, limpas, e pintadas com uma mistura de giz e álcool que seca rapidamente. O óleo de qualquer trinca iria extravasar na superfície branca,

tornando-se visíveis ao inspetor. Esta técnica teve uso em trilhos de trem para encontrar rachaduras em partes críticas.

A inspeção visual é a mais antiga e ainda a mais importante forma de teste não destrutivo, na qual são inspecionados componentes, para observação de sintomas e detecção de anomalias.

Outras tecnologias têm sido utilizadas para melhorar esta inspeção como a holografia ótica. O progresso na aplicação desta técnica foi feito pelo advento do laser no começo dos anos 1960 (**Bray e McBride, 1992**).

Nos últimos dez anos, novas tecnologias têm surgido envolvendo uma mudança drástica na forma pela qual os produtos são desenhados, manufaturados e testados. Estas novas tecnologias têm ampliado a percepção humana do ambiente à sua volta. A melhora da resolução da câmara de vídeo tem feito o monitoramento remoto ser prático, e a miniaturização faz possível se pensar em quadros boroscópicos num ambiente de luz relativamente baixa. Uma nova forma de detecção utilizando a saída de vídeo permite a obtenção de imagens de padrões de calor, som, e raio-X.

Entre os métodos radiográficos podemos citar o raio-X , que foi usado com propósitos de inspeção durante a Primeira Guerra Mundial, mas que foi estabelecido como método prático de inspeção industrial a partir de 1922 com o estabelecimento do laboratório radiográfico de Watertown Arsenal, MA, Estados Unidos (**Bray e McBride, 1992**). A radiografia Gamma, que foi desenvolvida utilizando o rádio (elemento químico) no final dos anos 1920, foi amplamente utilizada em estaleiros durante os anos 1930, sendo que alguns métodos descritos por **Kallman (1948)** ainda estão sendo utilizados. Melhoramentos nesta técnica permitem a sua utilização para inspeção de materiais e mecanismos contendo elementos como o hidrogênio, berílio, lítio, e o boro. É especialmente útil para inspecionar mecanismos eletrônicos e explosivos que contenham materiais não metálicos.

A tomografia de raio-X computadorizada provocou uma revolução no teste radiográfico. O computador tem se tornado o instrumento principal na implementação de técnicas de diagnóstico na prática médica.

O método de Mossbauer tem sido utilizado para a verificação do efeito “red shift” em teoria astronômica, para estudos biológicos, investigações catalíticas, e física nuclear. Este método também tem sido utilizado como base para um relógio extremamente acurado e para pesquisas em técnicas não destrutivas.

Métodos de ativação de neutron foram descobertos em 1936 e tornaram-se aplicáveis após 1948 com a descoberta da contagem de cintilação. A construção de um reator nuclear em 1942 e a habilidade de acelerar partículas carregadas com cíclotrons trouxe uma fase de consolidação destes métodos. De 1949 a 1959, muitas aplicações da técnica foram desenvolvidas, com quase 600 artigos publicados sobre uma grande variedade de aplicações.

A tecnologia de ultra-som provavelmente se desenvolveu a partir de métodos antigos de testes com som. O primeiro trabalho importante nesta área foi o desenvolvimento de métodos de detecção submarina durante a Primeira Guerra Mundial. Posteriormente utilizou-se cristais de quartzo para transmitir e receber sinais ultra-sônicos, através do efeito piezelétrico destes cristais. Experimentos significantes utilizando ultra-som para detecção de falhas foram conduzidos na Alemanha em 1933 para um sistema de transmissão de onda contínua. Este método de teste requer acesso a lados opostos e paralelos do objeto teste. O som de alta frequência é transmitido por um lado e recebido pelo outro. Um defeito dentro de um objeto eliminaria ou reduziria o som recebido dependendo do tamanho do defeito. Um desenvolvimento subsequente do radar de “pulso-eco” durante a Segunda Guerra Mundial foi um instrumento chamado refletoscópio. Este instrumento usava reflexão de ecos das falhas nos objetos teste. A distância da falha podia ser indicada por um osciloscópio. Esta tecnologia tem sido utilizada para acessar as propriedades dos materiais e para detecção de falhas. As aplicações médicas do ultra-som são amplamente difundidas. Especificações técnicas e padrões para testes não destrutivos

aparecem na literatura desde o meio da década de 50. Mais recentemente as aplicações de ultra-som se estendem à avaliação de materiais em situações como tensão, dureza, e medidas de textura.

Um desenvolvimento natural com a explosão do desenvolvimento dos computadores foi o surgimento de imagens por ultra-som como o B-scan, C-scan, holografia acústica, tomografia ultra-sônica e métodos de imagem (Bray e McBride, 1992).

A tecnologia de emissão acústica, empregada conjuntamente com ultra-som, tem sido utilizada em pesquisas recentes, levando ao desenvolvimento da chamada ultra-sônica acústica.

Os métodos de Medida de Propriedades Dinâmicas pode ser utilizado para avaliar certas propriedades dos materiais de forma não destrutiva, através da aplicação de uma vibração de força conhecida à uma amostra de material e observando sua resposta.

Outra técnica existente é o chamado Teste de Partícula Magnética que foi desenvolvido no começo dos anos 1920 e usada nos anos 1930 para localizar trincas em materiais magnéticos. A técnica “molhada” usa partículas magnéticas finas suspensas em um líquido que flui sobre uma parte magnetizada. As partículas são atraídas pelos campos de fuga, através das trincas, indicando a presença de trincas e outras anomalias. A técnica “sêca” utiliza pó sobre as amostra enquanto elas são magnetizadas.

Outros métodos de campo magnético podem incluir métodos de radiação de microonda, ressonância magnética nuclear, ressonância paramagnética eletrônica e métodos de alta frequência. Pode-se incluir também nesta classe o método de correntes parasitas (ECT).

Dentro da classe de métodos de vazamento de campo magnético, tem-se o método de perturbação do campo magnético, o método de injeção de corrente elétrica e o método de medida de tensão em materiais ferromagnéticos pelo efeito Barkhausen. Estes métodos exploram fenômenos magnéticos e elétricos no acesso ao estado ou condição do objeto sendo testado, e medem diretamente o fenômeno magnético sendo utilizado.

Existem também desenvolvimentos recentes em métodos químicos não destrutivos e em inspeção térmica. Outra análise disponível utiliza a microonda para analisar diretamente o material em termos de dimensões, detecção de falhas e análise de umidade.

## 2.2 - A História do ECT

Entre os NDE, o ensaio de correntes parasitas tem uma história rica em criatividade científica e desenvolvimento prático nos quase um século e meio de seu surgimento. Os conceitos básicos do teste de correntes parasitas foram demonstrados por **Hughes (1879)** na década de 1860, que demonstrou ser possível encontrar diferenças entre moedas metálicas condutoras por um arranjo simples de bobina magnetizadora e indução de correntes parasitas nas moedas (**McMaster, 1981**). Os fenômenos das correntes parasitas aparecem quando meios condutores estão sujeitos a campos magnéticos variantes e são governados pela lei da indução, a Lei de Faraday (**Tegopoulos e Kriezis, 1985**). Muitos comparadores de indução magnética ou correntes parasitas foram patenteados nos E.U.A. entre o ano de 1925 e a Segunda Guerra Mundial (**McMaster, 1981**). No fim dos anos 1930 e começo dos anos 1940, muitos investigadores começaram aplicar a indução magnética ou as técnicas de correntes parasitas para problemas de avaliação de materiais (**Bray e McBride, 1992**). O rápido desenvolvimento e aceitação industrial do ensaio de correntes parasitas teve um grande impulso entre 1950 e 1965 nos E.U.A. pelo surgimento de um equipamento de testes quantitativo, estável e sofisticado, bem como o surgimento de métodos práticos de análise destes sinais no plano complexo desenvolvido por

Friedrich Föster (**McMaster, 1981**). Este desenvolvimento se deu no laboratório de Dr. Föster em Reutlingen, Alemanha Ocidental. Muitos acadêmicos e funcionários especializados de indústrias foram enviados nesta época dos Estados Unidos para estágios no laboratório de Dr. Föster, com o objetivo de aprender estas novas técnicas. Muitas instalações começaram a desenvolver pesquisas para testar novos conceitos e instrumentação, incluindo um esforço considerável no “Oak Ridge National Laboratory” (ORNL) e outras instituições. Após 1952 houve uma transferência completa da avançada tecnologia de Dr. Föster para produção e distribuição de equipamentos de ensaio de correntes parasitas. Após concluídas as patentes do Dr. Föster, os instrumentos foram adaptados pelo uso de componentes e tubos norte-americanos e posteriormente aperfeiçoados pela Magnaflux Corporation (**McMaster, 1981**). Muitos dos instrumentos típicos usados para várias necessidades e aplicações, sondas de diferentes tipos são descritos no *Nondestructive Testing Handbook* (**McMaster, 1959**).

A aplicação do ECT para inspeção de tubos de gerador de vapor em usinas nucleares foi uma decorrência deste desenvolvimento. Este teste, inicialmente utilizado nas usinas, era considerado altamente confiável (**Wehrmeister, 1981**). Os conceitos de gerador de vapor mais utilizados são o gerador de vapor de recirculação (“recirculating steam generator” - RSG) ou de tubos em U e o da Babcock & Wilcox (B&W) que é o gerador de vapor de tubos retos (“once-through steam generator” – OTSG). Um gerador de vapor de uma usina nuclear típica contém 15.500 tubos de aço Inconel 600 com 20 metros de comprimento (ver tabela 2.3 na seção 2.4.2). Estão localizadas ao longo do comprimento dos tubos de cerca de 15 placas de sustentação. Estas placas fornecem o suporte para os tubos e são feitas de placas de aço-carbono de uma polegada e meia de espessura. (**Wehrmeister, 1981**).

## 2.3 - A Técnica de ECT

### 2.3.1 - Princípio Físico

O ECT pode ser aplicado a cilindros, tubos, chapas e camadas metálicas e fornece um meio de medir a condutividade, detectar a descontinuidades e determinar a espessura de camadas metálicas. Esta técnica tem sido, por isso, muito utilizado em diversos ramos da indústria para controle de qualidade de peças recém produzidas (E.U.A., 1967). A automação de sua utilização permitiria a elaboração de métodos que se aproximassem da inspeção de qualidade peça a peça.

A técnica de ECT consiste da aproximação entre o campo eletromagnético gerado por uma sonda e uma amostra de material condutor (figura 2.1). A sonda é basicamente composta de uma bobina sujeita a uma corrente alternada sendo portanto o campo magnético de excitação da amostra também alternado. Este campo magnético primário induz um conjunto de correntes circulares na amostra. As trajetórias circulares das correntes geradas no material condutor acontecem em planos perpendiculares à direção do campo primário. Estas correntes são chamadas de correntes parasitas e geram por sua vez um campo magnético secundário na mesma direção e sentido oposto. Quando a amostra é composta de material não magnético, este campo secundário implica numa redução do fluxo magnético composto no interior da bobina. A presença de um defeito ou uma não homogeneidade no material da amostra causa uma redistribuição das correntes parasitas, alterando a impedância complexa da bobina da sonda (Rajesh et al., 1993).




Figura 2.1 - Interação eletromagnética entre sonda-bobina e amostra condutora (McMaster, 1959).

Levando-se em conta as dimensões do arranjo experimental e as frequências características de operação, o fenômeno eletromagnético que engloba a técnica pode ser considerado como quase-estático. Se desprezarmos então as correntes de deslocamento, a equação que descreve o fenômeno sob estado, estacionário de excitação é dada por **Rajesh et al. (1993)**:

$$\nabla \times \left( \frac{1}{\mu} \nabla \times \vec{A} \right) = \vec{J}_s - j\omega\sigma \vec{A} \quad (2.1)$$

onde  $J_s$  representa a densidade de corrente fonte;  $A$  representa o vetor potencial magnético;  $\mu$  é a permeabilidade magnética;  $\sigma$  é a condutividade do material e  $\omega$  é a frequência de excitação. Para um meio homogêneo a equação (2.1) é reduzida à (**Rajesh et al., 1993**):

$$\frac{1}{\mu} \nabla^2 \vec{A} = j\omega\sigma \vec{A} - \vec{J}_s \quad (2.2)$$

As mudanças na impedância da bobina são captadas pelas variações do potencial elétrico nas suas extremidades. Para que se possa visualizar estas variações no plano complexo da impedância, os aparelhos de ECT obtêm dois sinais: o da resistência e o da reatância indutiva. Desta forma, tradicionalmente, as trajetórias no plano da impedância são utilizadas para caracterização do defeito. A formação das correntes parasitas depende de três características do material a ser testado: geometria, condutividade elétrica e permeabilidade magnética.

Uma outra característica importante nesta interação eletromagnética é a penetração do campo no material condutor da amostra. A profundidade de penetração (“skin depth”) pode ser descrita a partir da solução da equação de difusão simplificada para a densidade de corrente, ou seja:

$$\nabla^2 \vec{J} = \sigma \mu \frac{d\vec{J}}{dt} \quad (2.3)$$

A solução desta equação para um material de volume semi-infinito é dada por (Alencar, 1995),

$$J_x = J_0 e^{-\alpha} \text{sen}(\omega t - \alpha) \quad (2.4)$$

onde  $J_x$  é a densidade de corrente na direção da profundidade do material testado;  $J_0$  é a densidade das correntes na superfície do material testado e  $\alpha$  é o valor do ângulo de fase, dado por:

$$\alpha = \frac{x}{d} \quad (2.5)$$

com  $d$  sendo a profundidade de penetração padrão que é definida por (Alencar, 1995):

$$d = \frac{1}{2\pi (\mu_{rel} \sigma f 10^{-7})^{1/2}} \quad (2.6)$$

onde  $f$  é a frequência de teste.

Pode-se verificar que nesta distribuição de correntes, quanto maior for a frequência de excitação ou de teste, menor é a profundidade de penetração e consequentemente maior a densidade de corrente na superfície do material testado.


Outro aspecto importante a ser observado nesta relação é a ocorrência da chamada “rotação de fase” em que se observa o aumento da fase das correntes com o aumento da profundidade de penetração no material. O fenômeno da rotação de fase é uma característica muito utilizada no ECT já que possibilita a estimativa da profundidade do defeito.

### 2.3.2 - Procedimentos Experimentais da Medida de ECT

Os três tipos mais utilizados de sondas de ECT são: sondas de superfície, sondas circundantes e sondas internas. A inspeção de tubos de gerador de vapor usa sondas internas. Dois tipos específicos de configurações são utilizadas entre as sondas internas: a chamada sonda tipo panqueca rotativa e a sonda bobina.

A sonda de ECT mais frequentemente utilizada em inspeção de tubulação de geradores de vapor é a chamada sonda-bobina. Esta sonda pode ser configurada para medir mudanças absolutas ou diferenciais. A sonda-bobina tem uma bobina circunferencialmente fixada excitada por uma corrente alternada. A impedância da bobina acompanha a variação do ambiente à sua volta. Existem dois tipos de sondas-bobina, as absolutas e as diferenciais. A diferença entre elas é que a sonda diferencial utiliza duas bobinas para compor o campo magnético de excitação. Ela está apta a detectar diferenças entre estas bobinas, anulando os efeitos de variações espúrias no

tubo ou no processo de medida, que poderiam introduzir ruídos no sinal de ECT. A figura 2.2 mostra um esquema da sonda-bobina.



**Figura 2.2 - Sonda tipo bobina diferencial (Yan e Upadhyaya, 1996).**

A figura 2.3 mostra uma sonda tipo panqueca rotativa. Existem várias bobinas circulares nesta sonda. O eixo das bobinas é orientado ao longo de um raio da seção transversal do tubo e se localiza na circunferência interna do tubo. O campo de correntes parasitas gerado por estas bobinas faz esta sonda sensível tanto a defeitos axiais como circunferenciais. No entanto esta sonda só é utilizada para confirmar os resultados da sonda bobina (“bobbin coil”) para detecção de rachaduras circunferenciais e exame de regiões do tubo onde a sonda bobina não possa funcionar adequadamente.




Figura 2.3 - Sonda tipo panqueca (Yan e Upadhyaya, 1996).

A figura 2.4 apresenta um tubo de calibração tipo ASME (**American Society of Mechanical Engineers, 1992**) com defeitos de diâmetro externo, representando uma seqüência de furos padronizados com profundidades típicas de 20%, 40%, 60%, 80% e 100% da parede do tubo. A figura 2.5 mostra os sinais típicos de ECT para os defeitos presentes no tubo de calibração. Pode se notar a existência dos sinais correspondentes à parte real (resistência) e à parte imaginária (reatância) da impedância da bobina, formando a figura de Lissajous.

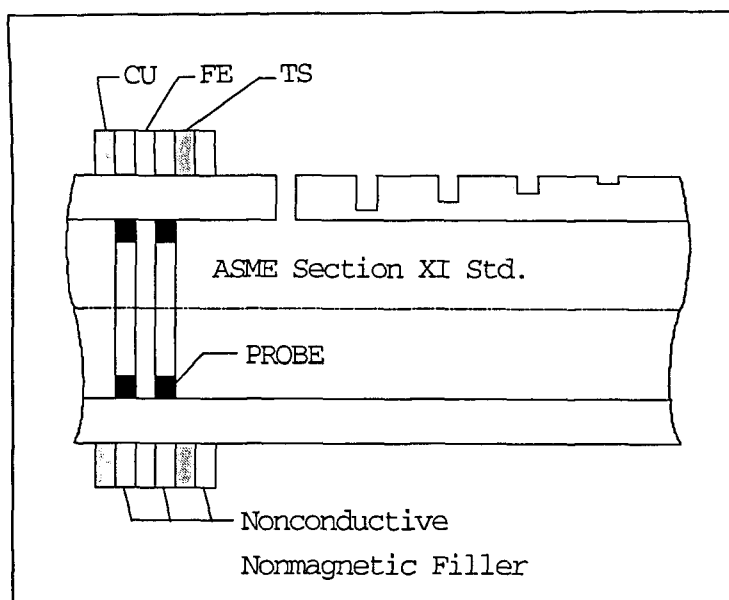


Figura 2.4 - Tubo de calibração com defeitos de diâmetro externo (padrão ASME)  
(Yan e Upadhyaya, 1996).





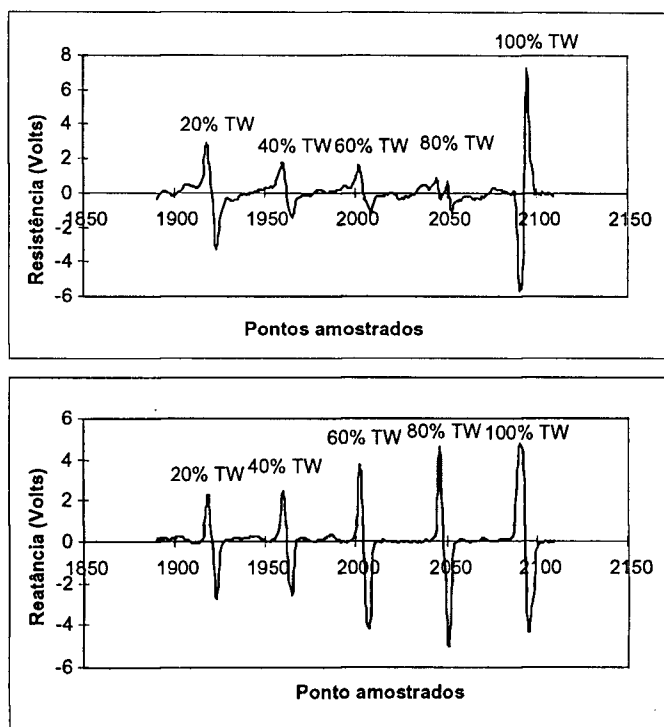
Figura 2.5 - Plano de impedância de tubo padrão de calibração (400kHz)  
(Hooper e Upadhyaya, 1998).

A figura 2.6 mostra a mesma situação da figura 2.5 só que com uma frequência de excitação menor. Pode-se observar que os ângulos de fase dos sinais

com frequência menor têm menores separações quando comparados com aos de alta frequência.



**Figura 2.6 - Plano de impedância de tubo padrão de calibração (100 kHz)  
(Hooper e Upadhyaya, 1998).**



**Figura 2.7 - Sinais típicos de calibração, resistência (superior) e reatância (inferior)  
(Hooper e Upadhyaya, 1998).**

Como pode ser visto na figura 2.7, a mera mudança da profundidade de um furo padronizado altera significativamente a forma das pétalas da figura de Lissajous que aparece no plano da impedância e a amplitude relativa dos sinais de resistência e reatância indutiva. Fica mais evidente ainda que para cada profundidade existe uma inclinação característica da pétala. Esta inclinação é medida pelo chamado ângulo de fase que é definido na norma ASME (1992), como o ângulo entre o eixo das coordenadas e a pétala nos sentido horário. A mesma norma ASME (1992) define que esta característica (ângulo de fase) deve ser utilizada na determinação da profundidade do defeito. O inspetor utiliza como base o ângulo de fase, porém outras características do sinal também apresentam correlação com o tipo, profundidade e dimensões do defeito.

O sistema de aquisição do aparelho de ECT é representado no diagrama de blocos da figura 2.8. Como pode ser visto, o sinal da sonda é amplificado, demodulado e separado em duas componentes (resistiva e indutiva) para visualização.

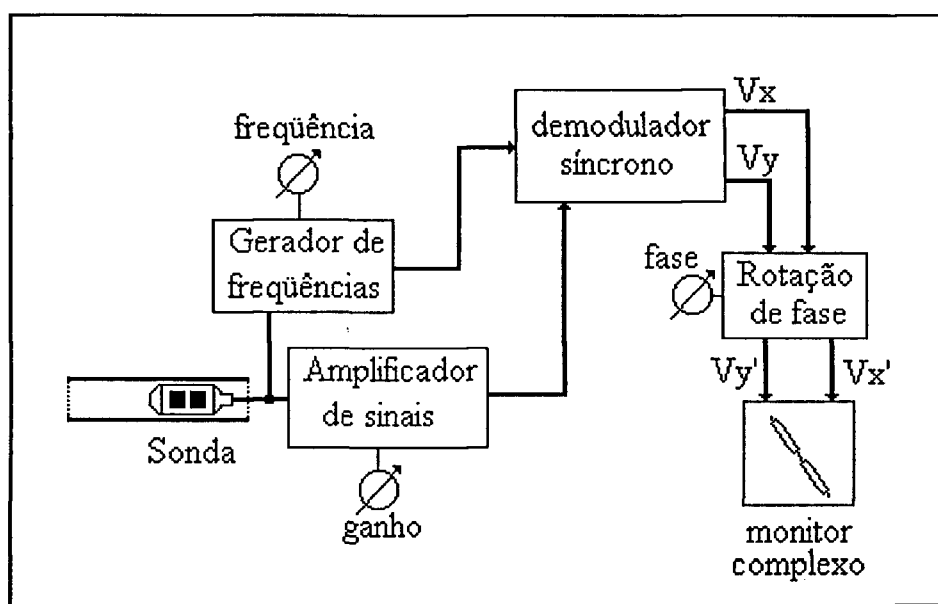


Figura 2.8 - Diagrama de blocos de um sistema de aquisição de ECT (Alencar, 1995).

A inspeção de tubos por correntes parasitas requer a utilização de sistemas de testes que apresentem resultados no plano de impedância. O bloco gerador de frequências é responsável pela criação de correntes alternadas, dentro de uma faixa de frequências que pode ser variada entre 10 Hz e 10 MHz, devendo, ainda ser capaz de alimentar com estas correntes as bobinas da sonda de teste, e fornecer frequências de referência ao circuito demodulador síncrono.

Os sinais resultantes da detecção das discontinuidades existentes passam por um amplificador com ganho controlado que permite o controle da amplitude dos sinais processados. O sinal processado pode ser definido como modulação de fase e amplitude com frequência portadora gerada por um gerador de frequências.

Um demodulador síncrono elimina a componente de frequência da portadora e transforma as modulações detectadas em duas componentes de tensão,  $V_x$  e  $V_y$  que podem ser visualizadas em um plano complexo, formando a figura tipo Lissajous. Um circuito de rotação de fase permite o ajuste da fase das modulações detectadas.

O ajuste da fase da figura de Lissajous apresentada é um dos critérios fundamentais utilizados na calibração do aparelho de medida, já que a fase desta figura é associada diretamente com a profundidade da discontinuidade medida.

O código ASME (1992) define um conjunto de procedimentos para calibração do sinal. Assim, para ASME, a aplicação do teste com bobina diferencial estabelece os seguintes passos:

- 1) A partir da frequência de ensaio definida, ajusta-se o controle do ganho do sistema para a discontinuidade-padrão de 20% de perda de material, de forma que o sinal visualizado tenha pelo menos 30% da altura total da tela de apresentação do osciloscópio.

2) O controle de fase do sistema é ajustado de forma que a figura de Lissajous observada esteja nas direções definidas na figura 2.9 enquanto a sonda é puxada através do tubo padrão de referência.

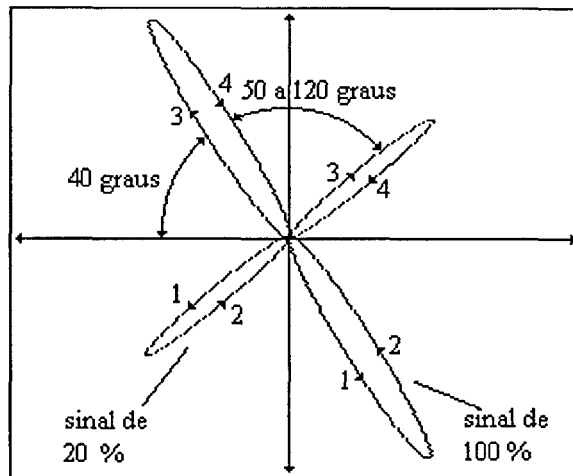


Figura 2.9 - Definição dos parâmetros de calibração ASME (Alencar, 1995).

3) A partir do sinal relativo à descontinuidade de 100% deve-se ajustar o controle de fase de modo a garantir que a diferença entre as inclinações das figuras relativas às descontinuidades de 20% e 100% estejam entre 50 e 120 graus.

4) O controle de fase do sistema é ajustado para que o sinal correspondente ao rasgo interno de 10% de espessura de perda de material fique posicionado ao longo do eixo das abcissas, com tolerância de 5 graus.

5) Verifica-se que a inclinação da figura correspondente à descontinuidade de 100% de perda de espessura apresenta uma inclinação de aproximadamente 40 graus.

Uma vez estabelecidas as condições de calibração para uma determinada condição de operação, deve ser obtida uma curva de avaliação desta calibração, a partir do registro e medição das inclinações das descontinuidades existentes no tubo-

padrão de referência. A figura 2.10 mostra a curva de calibração obtida para estes sinais.




Figura 2.10 - Curva de avaliação correspondente aos padrões de calibração (Alencar, 1995).

Durante o teste, a sonda é introduzida nos tubos até sair na extremidade oposta à da inserção. A sonda é puxada com velocidade constante, de poucos cm/s até 137 cm/s, até ser completamente retirada do tubo. A existência de descontinuidades é traduzida na formação de figuras de Lissajous no dispositivo visualizador do aparelho ou no gráfico dos dados arquivados em análise posterior. A partir destas figuras, correlações entre a inclinação das figuras e os valores correspondentes obtidos na calibração podem ser utilizadas para inferir o tipo, tamanho e profundidade da falha.

Em linhas gerais, o ensaio de tubos por correntes parasitas, utilizando a técnica de frequência simples e sonda interna em arranjo diferencial, realiza-se deste modo. Técnicas especiais têm sido utilizadas, no sentido de tornar as inspeções mais eficazes. Contudo, para os objetivos estabelecidos para este trabalho, é suficiente a abordagem apresentada.

Segundo Yan e Upadhyaya (1996), em termos operacionais, as condições que podem mudar a intensidade de campo da bobina teste são: dimensões do objeto, distância entre a bobina teste e o objeto medido, condutividade do objeto, permeabilidade do objeto teste e falhas no objeto teste.

Entre as vantagens do método pode-se destacar as seguintes: é relativamente rápido, é bastante sensível à mudança de propriedades da amostra e não existe necessidade de contato físico entre a sonda de teste e o objeto.

Entre as desvantagens do método destacam-se a necessidade de mão de obra especializada e a imprecisão por variações na permeabilidade do objeto teste ou pela orientação da falha. A sensibilidade reduz rapidamente com a profundidade do objeto.

### **2.3.3 - Campos de Aplicação e Objetivos do Ensaio**

O ECT é útil nas aplicações em áreas que requeiram determinação de propriedade dos materiais, medidas de espessura, detecção de falhas e medidas de posição ou fluxo de líquidos e gases. A tabela 2.1 lista um conjunto de aplicações.

Diferentes tipos de critério de aceitação ou rejeição são requeridos para cada área de utilização. Os critérios para medidas de espessura ou posição são geralmente simples. Critérios de aceitação para propriedades de materiais envolve usualmente uma faixa estreita de valores de condutividade. A condutividade elétrica é razoavelmente simples de ser medida e é portanto prática para este tipo de aplicação.

Os critérios de rejeição para falhas dependem da especificação de quantidade, tamanho e proximidade entre as descontinuidades que podem ser permitidas em componentes de engenharia de cada classe, espessura de material, tipo de material, tipo de solda, tamanho da estrutura e condições de utilização.

Em termos práticos, para componentes críticos, estes critérios podem ser equivalentes à capacidade de detecção da técnica. Por exemplo, nenhuma trinca discernível é aceitável em parafusos usados para fixar engrenagem de aterrissagem de aeronaves.

Fazer medidas quantitativas de falhas e determinar a significância de falhas específicas em materiais e estruturas de engenharia são dois problemas importantes mas geralmente difíceis de serem equacionados e resolvidos. A evolução recente da tecnologia, tanto na área de processamento de sinais (através do aumento da capacidade computacional), quanto na área do desenvolvimento de novas sondas, como as sondas de ECT que utilizam o efeito quântico (“superconducting quantum interference device” – SQUID) (Kreutzbruck et al., 1996), permitem que novas perspectivas para novas soluções e critérios de rejeição sejam desenvolvidas.

**Tabela 2.1 – Aplicações típicas da inspeção de ECT (Bray e McBride, 1992).**

<b>APLICAÇÕES TÍPICAS DA INSPEÇÃO DE ECT</b>			
<b>Determinação de Propriedades dos Materiais</b>	<b>Medidas de Espessura</b>	<b>Deteção de Falhas</b>	<b>Medidas de Posição ou Fluxo de Líquidos e Gases</b>
Avaliação de tratamento de calor	Chapa metálica	Chapa metálica	Medidas de pequenos movimentos
Medidas de dureza	Tintas	Fios	Monitoramento de fluxo de líquidos em bombas
Determinação de dano por calor	Revestimentos anódicos	Barras	Medida de concentração de líquidos em uma bomba
Determinação de conteúdo de impureza	Lacas	Teste de tubos	Monitoramento de níveis de líquido em tanques
Escolha para composição química	Isolações finas	Inspeção de buraco de parafuso	Determinação de limites de gases ionizados
Medidas de dano por corrosão	Revestimentos de motores	Inspeção de solda	
Medidas de condutividade de gás ionizado		Teste de rolamentos	

Dentre os diversos campos de aplicação onde o ECT é empregado, destacam-se os setores aeroespacial e nuclear. No primeiro utilizam-se muitas técnicas de inspeção especificamente recomendadas nos manuais de serviço das aeronaves. Os ensaios por correntes parasitas ocupam posição de destaque e, dentre os testes efetuados, pode-se citar a detecção e avaliação de trincas superficiais e sub-superficiais; a detecção e avaliação de trincas em furos de rebites e parafusos; a medição de espessura de chapas; a medição de espessura de pinturas e revestimentos; a separação de materiais.

No setor nuclear, além destes objetivos, surge um campo de aplicação muito importante em termos de segurança nas instalações das usinas nucleo-elétricas: a inspeção de tubos. Neste caso os testes por correntes parasitas são utilizados para: detecção e avaliação de descontinuidades em tubos instalados em trocadores de calor e geradores de vapor; medição de desgastes e variações dimensionais em varetas combustíveis.

## **2.4 - Aplicação de ECT em TGV de Plantas Nucleares**

O teste de ECT é a técnica normalizada para inspeção dos TGV de plantas nucleares. As técnicas e equipamentos envolvidos na aquisição dos sinais são totalmente automatizadas e exigem um mínimo de presença humana no próprio gerador de vapor. Os sinais são posteriormente (“off-line”) analisados e um diagnóstico de cada tubo é obtido por equipes de inspetores especializados.

### **2.4.1 - Equipamentos de Aquisição e Processamento dos Sinais de ECT**

Os equipamentos de aquisição serão brevemente descritos nesta seção. Uma descrição mais detalhada destes equipamentos fugiria ao escopo desta tese. Em geral, estes equipamentos são de tecnologia avançada e empresas de grande vulto

estão envolvidas na fabricação e realização dos testes. Algumas destas empresas serão referenciadas.

A sonda mais comumente utilizada na inspeção normalizada é a bobina diferencial. O ECT utilizando a bobina diferencial pode possibilitar velocidades relativamente altas de inspeção (até 54 polegadas por segundo). Esta sonda é usualmente utilizada para detectar mecanismos de danos volumétricos. Os mecanismos de danos aos tubos são causados por condições críticas de operação de longo prazo que incluem alta pressão, alta temperatura, alto fluxo e reações severas de química da água.

Existem conjuntos de normas para ensaio de ECT que são utilizadas na detecção dos defeitos nos TGV. Estas normas são baseadas no conhecimento obtido sobre os sinais de defeitos historicamente observados nos geradores de vapor em geral, com uma adaptação para cada planta específica. A tabela 2.2 mostra valores típicos de aquisição de ECT utilizando bobina diferencial. A figura 2.11 mostra arranjo experimental típico para aquisição de ECT utilizando o aparelho chamado MIZ da Zetec Inc., Estados Unidos da América.

Para cada defeito típico se estabelecem quais canais de frequência de excitação devem ser utilizados na inspeção e as localizações preferenciais para que aquele defeito seja encontrado.

**Tabela 2.2 – Valores típicos do processo de aquisição de dados do ECT em TGV.**

Valores Típicos da Técnica de Aquisição de ECT com Bobina-Diferencial	
Instrumento	MIZ18 ou MIZ30 ou MIZ43 da Zetec
Sonda	Comprimento de 83 pés e um fator de preenchimento de 86%
Velocidade da sonda	12"/segundo ou 30 cm/segundo aproximadamente
Mínima taxa de amostragem	400 amostras/segundo

A aquisição de ECT é bastante automatizada com robôs matriciais para gerenciar a introdução da sonda e é normalmente gerenciado por programas de computador bastante sofisticados, como mostra a figura 2.12, onde uma interface gráfica de um programa gerenciador de aquisição de ECT em um gerador de vapor de uma planta nuclear pode ser observado. A matriz com círculos representa a base de tubos, e cada círculo corresponde a um tubo. Cada símbolo da legenda representa se o tubo já foi inspecionado ou não, se apresentou algum problema para ser inspecionado novamente (com outra sonda), ou outro procedimento semelhante.

A visualização do sinal de ECT para análise pelo inspetor também utiliza conjuntos de programas comerciais (figura 2.13), que têm como característica principal permitir que o usuário possa percorrer visualmente toda a extensão do tubo em teste, através de sinais de diferentes canais de frequência, canais mixados e, principalmente, através de “janelas” com o plano de impedância desejado pelo analista do sinal.




Fig. 2.11 – Equipamento de aquisição de ECT típico (Zetec, 2002)

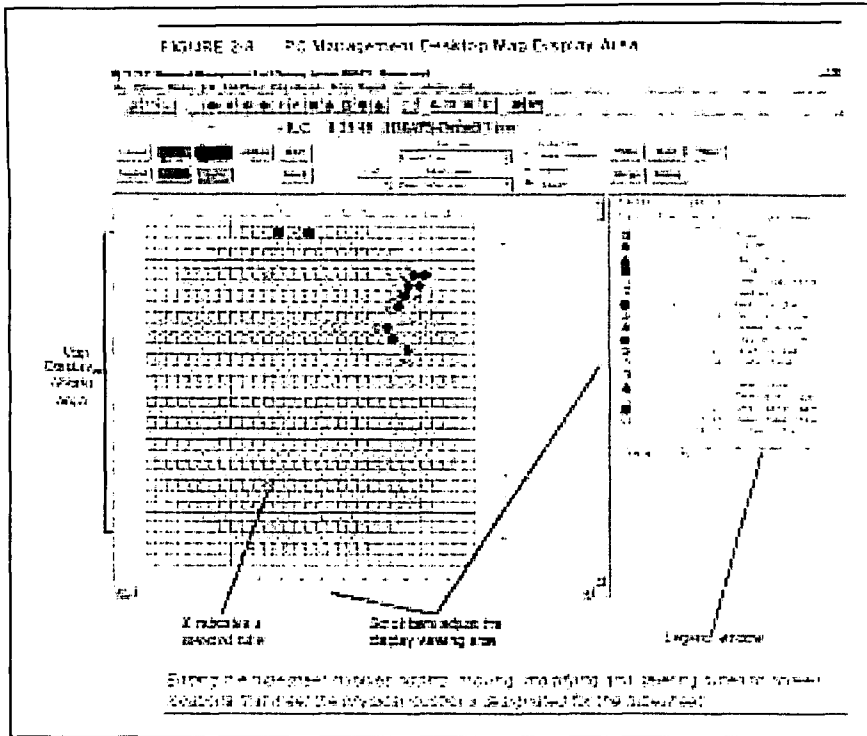


Figura 2.12 – Interface gráfica típica de programa de gerenciamento de aquisição de ECT (Zetec, 2002).




Figura 2.13 – Interface gráfica típica de programa comercial de análise de ECT (Zetec, 2002).

## 2.4.2 - O Gerador de Vapor

Existem cerca de 400 plantas nucleares em países membros da Agência Internacional de Energia Atômica (“International Atomic Energy Agency” - IAEA) (IAEA, 1997). Esta agência mantém um programa de controle e manutenção preditiva com monitoramento do envelhecimento e degradação de diferentes componentes de reatores nucleares pelo mundo como os de deutério-urânio (CANDU) do Canadá, os de água em ebulição (“boiling water reactor – BWR”), os de água pressurizada (“pressurized water reactor – PWR”) e os de água resfriada (“water cooled energy reactor – WWER”) (IAEA, 1997).

Neste trabalho será focalizada a atenção nos geradores de vapor dos reatores PWR, já que são os utilizados no Brasil e que poderiam vir a ter um interesse de desenvolvimento futuro deste trabalho. Nada impede no entanto, que o núcleo desta dissertação seja aplicado em outros tipo de TGV. A base de dados aqui utilizada se refere a reatores PWR. Seções transversais dos dois tipos principais de geradores de vapor PWR são mostrados na figura 2.14.

No TGV em forma de U os tubo são fixos por uma placa (“tube sheet” – TS) posicionada na base do gerador e as dobras em “U” estão posicionadas no topo do feixe de tubos. O refrigerante do sistema primário, escoar no interior dos tubos, entrando no gerador de vapor a uma temperatura de 315 a 330 °C e deixando o gerador numa temperatura de aproximadamente 288 °C. A água do sistema secundário (água de alimentação) é alimentada através de um bico injetor, pra dentro de um tubo de descenso, onde se mistura com a água recirculante drenada dos separadores de umidade. A água proveniente do tubo de descenso flui para a base do gerador de vapor, e então através do feixe de tubos onde o vapor é gerado. Cerca de 25% do refrigerante secundário é convertido em vapor em cada passagem através do gerador e o restante é recirculado. Alguns parâmetros típicos de modelos de gerador de vapor são mostrados na tabela 2.3.




Figure 2.14 - Seções transversais de geradores de vapor PWR de tubo reto vertical (à esquerda) e de tubo em “U” (à direita) (IAEA, 1997).

Tabela 2.3 – Parâmetros típicos de geradores de vapor (IAEA, 1997).

	Tipo de Gerador de Vapor		
	Tipo I	Tipo II	Tipo III
Número de Tubos #	~3000 a 5000	~15000	~ 8000 a 10000
Espaçamento entre os Tubos (polegadas)	~ 0,98 a 1,28	~0,87	~1,0
Dimensões do Tubo (polegadas)	0,875 x 0,050 0,750 x 0,043	0,625 x 0,034	0,0750 x 0,042
Material do Tubo	Alloy 600	Alloy 600	Alloy 600
Método de Expansão da Placa de Tubos ("Tube sheet")	por rolo	por rolo	por explosão
Altura do Gerador de Vapor	~ 22 m	( não disponível)	( não disponível)
Temperatura Ent <sup>Saída</sup> do Refrigerante (°C)	325°C/291°C	( não disponível)	( não disponível)

O funcionamento do gerador de vapor com tubos retos tem basicamente o mesmo princípio de funcionamento, só variando a geometria dos tubos. Esta variação geométrica tem uma série de implicações nos defeitos potenciais existentes nos TGV correspondentes.

### 2.4.3 - Os Tubos de Gerador de Vapor

Os materiais e métodos utilizados para fabricar os componentes do gerador de vapor afetam de forma importante a susceptibilidade à corrosão, especialmente quanto ao trincamento por corrosão e tensão. A degradação dos TGV também é influenciada por outros aspectos de projeto e construção, tais como o projeto dos suportes e o método da instalação do tubo (IAEA, 1997).

A instalação e fixação dos tubos nas suas bases (TS) é realizada basicamente de quatro formas diferentes: por rolamento mecânico, por expansão hidráulica, por expansão explosiva e por solda vedando a base dos tubos dentro do revestimento de superfície. Nas primeiras plantas PWR, os tubos laminados e temperados foram conectados à base utilizando rolamento mecânico por um comprimento de 60 a 100 mm. Isto deixou uma fenda radial de aproximadamente 0.2 mm entre o tubo e a base ao longo de 460mm, onde impurezas químicas podiam se concentrar. Em geradores posteriores os tubos foram expandidos no resto da altura da base usando o processo de expansão explosiva no campo, ou por rolamento mecânico na fabricação. Nos casos em que o rolamento adicional foi feito, a experiência de campo mostrou que tensões residuais foram introduzidas (IAEA, 1997). O método hidráulico em geradores de vapor mais recentes deixa bem menos tensão residual nos tubos.

Vários tipos de suporte de tubos têm sido utilizados em geradores de PWR como mostrado na figura 2.15.




Figura 2.15 – Esquemas típico de suportes de TGV utilizando a nomenclatura típica (IAEA, 1997).

Muitos geradores de vapor têm suporte de tubos tipo placa, onde os tubos passam através de buracos perfurados na placa. Esta construção deixa um vão estreito em volta do tubo, entre o tubo e a placa, permitindo o refrigerante secundário fluir. Furos menores nas bases dos tubos ao lado dos furos permitem também o fluxo do refrigerante secundário. Outros modelos de geradores de vapor usam suportes

formados por arranjos de varas (suportes tipo “egg-crate”), mas também usam placas furadas em alguns locais na região da dobra em “U” como mostrado na figura 2.16.




Figura 2.16 – Arranjos típicos de barras anti-vibração (IAEA, 1997).

Outros modelos recentes de grades em rede feitas de aço inoxidável podem ser vistos na figura 2.17.




Figura 2.17 – Estruturas de suporte de TGV típicos (IAEA, 1997).

#### 2.4.4 - Defeitos Típicos em TGV de Plantas Nucleares

A classificação dos diferentes tipos de degradação pode obedecer diferentes critérios, como por exemplo, a causa da degradação, ou o tipo de planta em que ela surge, ou ainda a localização do defeito no tubo de gerador de vapor. Neste texto será utilizada uma classificação baseada na causa da degradação, pois é o critério utilizado na base de dados utilizada (ver capítulo 3). Alguns elementos da

classificação por morfologia (formato físico da degradação) são também utilizados. Na classificação por causa de degradação pode-se inicialmente dividir as degradações entre as de origem mecânica e as de origem química. A classificação por morfologia divide as degradações entre superficiais ou volumétricas, e entre axiais e circunferenciais. Em ambas as classificações é possível encontrar degradações que assumem mais de uma categoria.

De um modo genérico, os tipos de degradação mais reconhecidas recentemente são mostradas na figura 2.18 e são relacionados abaixo com as localizações preferenciais de ocorrência:

- trincamento externo circunferencial ou axial (“outer diameter stress corrosion cracking” – ODSCC) em suportes de tubos (“tube support plates” – TSP);
- degradações volumétricas como perfurações (“pitting” – PIT) e desgastes (“wear” – WEA) em estruturas de suporte ou interações com partes soltas;
- trincas (“stress corrosion cracking” – SCC) e/ou ataque intergranular (“intergranular attack” – IGA) no diâmetro externo em suporte de tubos (TSP) e na base dos tubos (TS);
- trincas (SCC) de diâmetro interno na base dos tubos (TS) e elevações da dobra em “U”;
- fadiga de alto ciclo;
- erosão/corrosão;
- trincamento e amassamento (“denting”);




Figura 2.18 - Gerador de vapor em "U" e defeitos típicos (IAEA, 1997).

Classificando as degradações quanto às suas causas pode-se descrever sete tipos principais. As degradações por corrosão química são: o afinamento (“thinning” – THI), a perfuração (“pitting” – PIT), o trincamento e corrosão intergranular (“intergranular attack” e “stress corrosion cracking” - IGA/SCC ou ISC), e o trincamento por corrosão por tensão de água primária (“primary water stress corrosion cracking” - PWSCC). As degradações por corrosão mecânica são: o desgaste (“wear” - WEA), os danos por colisão (“impingement” - IMP) e a fadiga. Em geral, o amassamento (“denting”) não é considerado mecanismo de dano por não degradar a integridade do tubo por si só. Este mecanismo contribui ou inicia um SCC.

Em geral, processos relacionados à corrosão são mais comuns em unidades recirculantes enquanto processos mecânicos são prevalentes em geradores com tubos retos. Os mecanismos de degradação citados, são descritos a seguir.

#### **2.4.4.1- Afinamento (THI)**

Este termo é genericamente referente à perda de material volumétrico do tubo. O ataque inicia-se pela superfície pela dissolução do material do tubo no refrigerante local do gerador de vapor. As condições da química local são alteradas antes que a corrosão comece a ocorrer. A morfologia atravessa a micro-estrutura sem evidência de que os limites dos grãos sejam corroídos preferencialmente. Em geral, é encontrado próximo à base de tubos (TS) e tem relação com a profundidade da pilha de lama (acúmulo de material químico depositado na base de tubos). Também são encontrados nos TSP e outras estruturas de suporte.

O afinamento, quando uniforme, mantém a seção transversal do tubo circular e a profundidade da degradação é uniforme tanto axial como circunferencialmente. O afinamento axial ocorre principalmente próximo aos TSP, sendo limitado na direção axial apenas pela espessura do TSP.

#### **2.4.4.2- Perfuração (PIT)**

Esta forma de degradação ocorre por um processo de corrosão geral ou é causada por diferenças galvânicas locais e ataque ácido por compostos de cobre. A PIT consiste na dissolução do material de superfície sem preferência por ataque de borda de grão e não tende a crescer para as dimensões do THI.

Em geral é uma degradação de extensão bem limitada, tipicamente em torno de 0.1” tanto na direção do arco como na direção axial, sendo que algumas profundidades de 90% da parede do tubo podem ser aceitáveis para operação do tubo. A origem da degradação somente é observada a partir do diâmetro externo do tubo e pode crescer até a profundidade total gerando a falha do tubo por falha do cisalhamento em volta das bordas externas da área furada.

O crescimento da degradação ocorre por depósitos de óxido e metálicos que, em geral têm estrutura em camadas.

#### **2.4.4.3- Trincamento e Corrosão Intergranular (IGA/SCC ou ISC)**

Esta denominação de degradação é genérica e descreve a degradação que ocorre pela ação simbiótica de um material suscetível, um ambiente corrosivo e tensão. O processo corrosivo é, em geral, função da temperatura e assume diferentes morfologias: o ataque intergranular (“intergranular attack” - IGA), o trincamento por corrosão e estresse (“stress corrosion cracking” – SCC) e morfologias mistas.

O IGA é uma morfologia caracterizada por um ataque uniforme às bordas dos grão pela superfície do tubo. Para esta morfologia, a tensão não é um fator de contribuição. Esta degradação pode assumir morfologia volumétrica.

O SCC consiste de múltiplas trincas com poucas ramificações. Em geral se propagam intergranularmente, mas existem exemplos isolados em que ocorre o trincamento transgranular. Esta degradação é tipicamente descrita como bi-dimensional com comprimento e profundidade, podendo ser axial, circunferencial ou com dois eixos.

A morfologia mista consiste em um conjunto de muitas variações de formas híbridas de IGA e SCC.

#### 2.4.4.4- Trincamento por Tensão e Corrosão por Água do Primário (PWSCC)

Esta forma de degradação ocorre pela presença de tensões fortes e ao mesmo tempo, de material susceptível. Geralmente ocorre em locais com mudanças de geometria como nas dobras em “U” dos geradores de vapor recirculantes, em amassamentos próximos aos TSP, nas fixações dos tubos à placa por rolo, por explosão e outras. A morfologia predominante é circular e é geralmente inspecionado utilizando-se uma sonda tipo rotativa (“panqueca”).

O PWSCC com elementos axiais e circunferenciais também tem sido encontrado em fixações de expansão. Outros trincamentos de origem externa têm sido observados em bases de tubo (TS) furados ou do tipo “egg crate”, em acúmulos de lama e em expansões livres. A figura 2.19 mostra a seção transversal de uma trinca típica.




Figura 2.19 - Seção transversal de trinca em tubo (McMaster, 1959).

A forma da degradação pode ser celular, ou de comprimento limitado e com algum aspecto circunferencial.

Os trincamentos axiais iniciados no diâmetro externo podem ser de profundidade parcial ou total. Quando parcial se estabelecem os requerimentos mínimos de espessura levando em conta a incerteza de ECT, assim como o crescimento projetado da trinca durante o próximo intervalo de operação. As trincas axiais de profundidade total ou que excedam os mínimos requisistos são causa de tamponamento do tubo.

#### **2.4.4.5- Desgaste (WEA)**

Esta degradação pode ser causada por um objeto estranho ou por um dano pela interação do tubo com o TSP ou as barras anti-vibração (“anti-vibration bar” - AVB). O desgaste também pode ocorrer se um tubo tamponado é afetado e sofre uma vibração induzida por fluxo grande o suficiente para resultar em contato com o tubo vizinho. Esta mesma degradação pode ocorrer se o alinhamento dos tubos é muito próximo e a vibração é suficiente para permitir o contato entre eles.

O desgaste pela intersecção com as AVB resultam em superfícies “achatadas” sendo “cavadas” dentro do volume do tubo. Esta degradação atravessa os grãos indiscriminadamente. Geralmente a morfologia é regular, pois depende da geometria do objeto que se choca com o tubo.

#### **2.4.4.6- Dano por Colisão (IMP)**

Este tipo de degradação é uma forma de erosão causada por sólidos suspensos que se chocam com a superfície do tubo. Ocorre apenas em reatores com tubos retos

em que existe um fluxo de fragmentos distribuído pelo secundário do gerador de vapor.

#### **2.4.4.7- Fadiga**

Este tipo de degradação ocorre pela existência de ciclos alternados de tensão produzidos por vibrações dos tubos acelerados por processo de corrosão concorrentes. É predominantemente circunferencial e inspecionada por ECT pela utilização de sonda tipo rotativa.

### **3 - BASE DE DADOS DE ECT UTILIZADA**

#### **3.1 - Organização da Base de Dados**

Quase todo método de automatização de decisões, reconhecimento de padrões, ou áreas correlatas dentro do campo da “inteligência artificial” utiliza, em última instância, a informação do chamado “especialista”. O “especialista” nada mais é do que um ser humano, ou uma associação deles, que detêm um conhecimento sobre um processo ou diagnóstico que, em geral, não consegue ser representado por regras muito exatas ou com linguagem definida. Dentro desta visão mais geral de processos de automatização utilizando o recente desenvolvimento do computador, os limites do campo da “inteligência artificial” vêm sendo estabelecidos nas últimas décadas.

É intenção deste trabalho automatizar, ou pelo menos, servir como instrumento de análise dos sinais de ECT dos defeitos observados em TGV de plantas nucleares. Como foi exposto no primeiro capítulo desta dissertação, grande parte desta análise ainda é feita posteriormente às medidas (“off-line”) por grupos de especialistas. A análise se constitui de observação das figuras formadas no plano da impedância em diferentes frequências de excitação. Estes especialistas, chamados inspetores de ECT, passam por longos períodos de treinamento e para atuarem em uma análise de dados de planta nuclear precisam que ter sido aprovados em vários níveis de qualificação.

A base de dados utilizada neste trabalho é relativa a um conjunto de treinamento destes inspetores de ECT em usinas nucleares. Portanto o algoritmo proposto neste trabalho, pode funcionar com o devido treinamento, como um inspetor que dá uma terceira ou quarta opinião sobre o tipo de defeito. Esta base de dados é chamada de PDD (“Performance Demonstration Database”) (EPRI, 1995) de propriedade da EPRI (“Electric Power Research Institute”). Os dados aqui apresentados foram cedidos pelo professor Belle R. Upadhyaya do Departamento de Energia Nuclear da Universidade do Tennessee para fins acadêmicos, numa

continuidade do trabalho desenvolvido durante um estágio naquela faculdade pelo autor deste trabalho.

Estes dados se apresentam originalmente em formato codificado e sem pré-processamento. A descrição associada aos dados (EPRI, 1995) está originalmente organizada por tipo de planta nuclear (empresa fabricante), localização do defeito no tubo, e tipo de defeito. Cada planta nuclear apresenta características específicas da estrutura, composição e geometria dos geradores de vapor. Cada sinal apresenta vários canais de diferentes frequência de excitação e representam uma aquisição feita ao longo de todo um tubo. Como é uma base de treinamento, cada sinal apresenta defeitos característicos em tubos com defeitos identificados após terem sido retirados das plantas e analisados metalograficamente em boa parte dos casos. Para cada conjunto de dados, estão associadas as calibrações e os ajustes utilizados para aquelas medidas assim como as análises associadas em formato do chamado relatório final de análise primária. São fornecidos exemplos de indicações de defeitos atribuídos a diferentes classes de mecanismos de dano, em diferentes localizações através do gerador de vapor para plantas de diferentes fabricantes.

Como faz parte de um curso de formação de inspetores, o teste de final de curso, e o documento utilizam seis dos sete mecanismos de dano descritos. Os sete mecanismos descritos segundo o PDD são quatro entre os relacionados à corrosão: o afinamento (“thinning” – THI), os furos (“pitting” – PIT), o ataque intergranular com trincamento por corrosão por tensão (“intergranular attack” e “stress corrosion cracking” – IGA/SCC), e o trincamento por corrosão por tensão de água primária (primary water stress corrosion cracking “ – PWSCC). Os três mecanismos relacionados à degradação mecânica são: fadiga (“fatigue”), dano por colisão (“impingement” – IMP), e desgaste (“wear” – WEA). Desta forma, apesar de ser um dos danos descritos, a fadiga não está inserida entre os tipos de defeito para o treinamento.

As indicações de mecanismos de degradação do PDD incluem diferentes técnicas de aquisição: a sonda bobina, a sonda giratória e a sonda matriz (8 x 1).

Além dos diagnósticos respectivos, são fornecidos as regras de análise e o critério que deve ser utilizado para elaboração do relatório final. O documento relata que o sucesso no exame prático do inspetor requer que o examinado demonstre uma probabilidade de detecção de 80% (com 90% de confiança), com uma taxa de falsa chamada menor ou igual a 10%. A acuidade no dimensionamento deve ser menor ou igual a 10% da raiz da média do erro quadrático (“root mean squared error” - RMSE).

Neste trabalho foram utilizados alguns critérios para selecionar os dados de treinamento. Para que a comprovação da robustez do método não fosse prejudicada, apenas os dados de sonda tipo bobina foram utilizados. Isto não impede que futuramente sejam incorporados ao algoritmo, ou utilizado em paralelo, outra inferência que utilize dados de outro tipo de sonda. Os dados da sonda tipo bobina são os mais comuns e constituem a grande maioria dos bancos de dados disponíveis, já que é o método comumente utilizado nas inspeções de rotina. Como foi visto no capítulo 2, tabela 2.3, a velocidade típica de inspeção de uma sonda tipo bobina é 0,3 metros por segundo enquanto a inspeção com bobina tipo rotatória ou panqueca é de cerca de 0,01 metros por segundo, ou seja um fator de 30 vezes. Esta diferença de velocidade de inspeção faz com que a grande maioria dos diagnósticos seja feita através de inspeção com a sonda tipo bobina (diferencial e absoluta). A inspeção que utiliza a sonda tipo panqueca é utilizada para casos em que haja dúvida quanto ao diagnóstico. Desta forma, neste trabalho, a escolha em utilizar dados de sonda tipo bobina se deve ao fato de haver mais dados relativos a cada defeito e, assim, a igual representação de cada defeito no treinamento dos mapas poder ser mantida. Desta forma o algoritmo pode ser utilizado na primeira fase da análise do inspetor onde os dados disponíveis são os relativos à sonda tipo bobina (a chamada análise primária). Por outro lado, os dados relativos à sonda tipo panqueca são bem mais claros visualmente, sendo raros os casos em que ainda restem dúvidas depois de sua utilização. Portanto, a primeira utilidade deste algoritmo está na possibilidade de diagnóstico a partir de informações contidas no sinal que não necessariamente seriam aparentes visualmente para um inspetor humano.

Na tabela 3.1 estão descritas as características da base de dados utilizada neste trabalho extraída do PDD.

**Tabela 3.1 – Base de Dados de sondas tipo bobina de ECT extraídas do PDD.**

TIPO DE DEGRADAÇÃO	Número de Indicações	Número de Tubos	Número de Diferentes Plantas	Localizações
ISC (Trincamento Intergranular)	161	78	9	TSP; Vão; Pilha; Dobra “U”
PIT (Perfuração)	38	19	3	Pilha
THI (Afinamento)	24	22	2	Pilha; TSP
WEA (Desgaste)	38	34	4	TSP; AVB, Placa defletora
IMP (Dano por Colisão)	24	12	1	TSP
IGA (Corrosão Intergranular)	8	3	1	Expansão Livre
SCC (Trincamento por Tensão)	3	1	1	Expansão Livre

Pode-se observar nesta tabela a existência de uma desproporção entre o número de defeitos característicos ou indicações de degradação para cada tipo. Além disto, estas indicações estão distribuídas em diferentes localizações do gerador de vapor e em diferentes plantas nucleares.

Cada tubo, em geral, tem um relatório final de análise primária associado às condições de calibração e tipo de sondas utilizadas na aquisição do sinal de ECT. Cada sinal se refere à aquisição de um tubo e é composto, na média, de 30.000 a 40.000 amostras referentes ao comprimento total do tubo que está aproximadamente na faixa de 20 a 30 metros. Muitas vezes os arquivos se referem a trechos menores de

interesse dos tubos. Este procedimento é comum no campo, em situações nas quais só se inspecionam determinados trechos dos tubos. No caso desta base de dados, os sinais aproveitados neste trabalho apresentam características de aquisição de ECT fixas. As principais características são: aquisição feita com 4 canais de diferentes frequências de excitação (em geral 600, 400, 200 e 10 KHz), podendo haver variações; velocidade de deslocamento da sonda de 0,03 metros por segundos e amostragem digital em torno de 30 amostras/polegada (em torno de 12 amostras/cm). Outras características deste tipo de aquisição podem ser vistas na seção 2.4.1. Como pode ser observado, a taxa de amostragem característica é em torno de 396 amostras/segundo ou 396 Hz. Os arquivos referentes às indicações dos defeitos são compostos de 16 colunas, referentes às partes real e imaginária dos canais absolutos e diferenciais de cada um dos quatro canais de frequência de excitação.

### **3.2 - Montagem dos Conjuntos de Treinamento**

O formato do relatório final de análise primária tem o aspecto de uma tabela padrão, mostrada na figura 3.1, onde cada linha se refere a uma indicação. Neste formato, cada coluna se refere a uma informação típica da referida aquisição. No exemplo da figura 3.1, as indicações se referem à degradação PIT. A primeira coluna se refere a um indicador de identificação do gerador de vapor em análise. As segundas e terceira colunas se referem respectivamente à linha e à coluna da matriz identificadora do tubo no gerador de vapor em questão, ou seja, cada dupla de valores representa um único tubo. A quarta e quinta coluna se referem a voltagem e fase relatadas para aquele sinal diagnosticado como indicação de falha. A sexta coluna se refere a estimativa da porcentagem da parede afetada pelo defeito daquela indicação. A sétima coluna se refere ao canal de frequência de excitação utilizado para o diagnóstico. A oitava coluna se refere à localização da indicação no tubo. Esta informação se refere a uma localização típica no tubo que no processo de aquisição e análise de ECT são marcadas por “etiquetas” codificadas. Neste exemplo é expressa por TSC que se refere a “tube sheet cold” (base de tubos fria). A nona coluna se refere à distância (em polegadas) da indicação à localização característica especificada na oitava coluna. A décima coluna se refere ao comprimento do sinal

para o qual a décima-primeira coluna se referirá. Esta indicação também é codificada, e no exemplo da figura 3.1 é expressa por 01CTEC que se refere a um sinal que foi adquirido a partir de 01C (primeiro suporte de tubo da “perna fria” do tubo) até TEC (“tube end cold” ou fim de tubo frio). Finalmente a décima primeira coluna se refere ao ponto dos dados amostrados onde fica o centro da indicação daquela linha. Como pode ser visto na figura, os números desta coluna giram em torno do mesmo valor pois são indicações de PIT encontradas em regiões semelhantes dos tubos analisados.

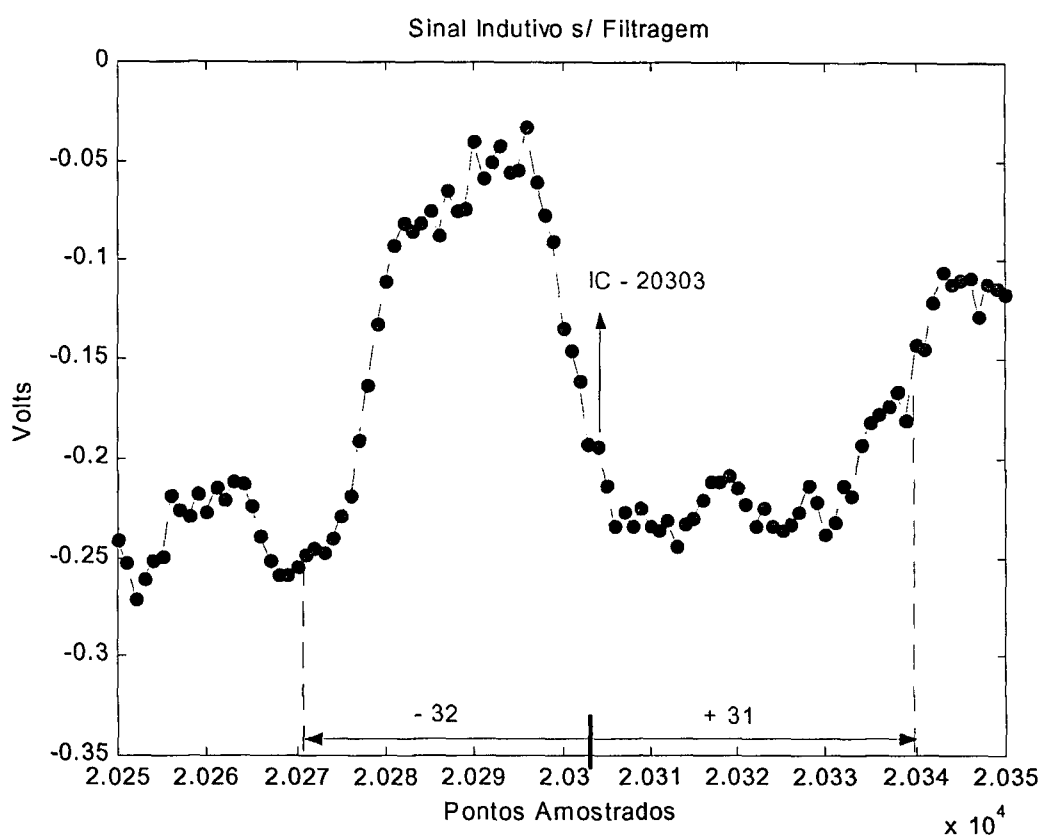
20	19	27	0.46	135	15	P	2	TSC	+	0.88	01CTEC	3740
20	19	27	0.38	96	56	P	2	TSC	+	1.82	01CTEC	3704
20	19	27	0.59	102	50	P	2	TSC	+	2.03	01CTEC	3696
20	6	29	0.43	114	39	P	2	TSC	+	1.34	01CTEC	4857
20	11	73	0.90	118	35	P	2	TSC	+	1.02	01CTEC	3732
20	9	72	0.90	79	70	P	2	TSC	+	1.32	01CTEC	4089
20	6	68	1.67	109	44	P	2	TSC	+	1.23	01CTEC	4095
20	6	60	0.81	76	72	P	2	TSC	+	1.84	01CTEC	4071
20	26	58	1.34	98	54	P	2	TSC	+	1.94	01CTEC	3977
20	26	58	0.46	137	13	P	2	TSC	+	2.57	01CTEC	3951
20	26	58	0.30	114	39	P	2	TSC	+	1.38	01CTEC	4000
20	27	50	0.38	109	44	P	2	TSC	+	1.37	01CTEC	4884
20	27	50	0.85	113	40	P	2	TSC	+	2.19	01CTEC	4852

Figura 3.1 - Formato típico de um relatório final de análise de ECT.

A seleção dos sinais desta base de dados para o treinamento teve que levar em conta a representatividade de cada sinal relativa ao defeito, à planta de origem e à localização no tubo. A princípio o método proposto não pretende utilizar estas informações para a identificação dos tipos de defeitos, por isto quanto mais diversificado estiver a base mais independente destas informações estará sendo a classificação.

Uma das características do “relatório final” (figura 3.1) é a chamada indicação central (IC) que se refere à localização do centro do sinal degradado no conjunto de dados de análise do respectivo tubo. Na figura 3.2 pode ser visto o

critério estabelecido nesta tese para a segmentação do sinal correspondente à IC do relatório final. Este critério segmenta trechos de 32, 64 e 128 amostras utilizando a IC como centro. Desta forma, o segmento de 64 amostras do sinal de interesse se inicia na amostra (IC - 32) e vai até a amostra (IC + 31). Por este procedimento, foi obtido um conjunto de segmentos de sinais representativos de cada defeito estudado.



**Figura 3.2 – Critério de segmentação do sinal utilizando a IC como referência.**

A seleção dos sinais levou em conta o fato de que para o treinamento do mapa de Kohonen (capítulo 5) é necessário um número igual de dados (segmentos de sinais) para cada defeito. Isto limitou ainda mais o tamanho do banco de dados utilizável para o treinamento, pois a limitação é sempre pelo defeito com menor número de segmentos associados. Como pode ser visto na tabela 3.1, para que o algoritmo levasse em conta os 7 defeitos característicos, seria necessário limitar a três segmentos de sinais para cada defeito, pois este era o número de indicações para

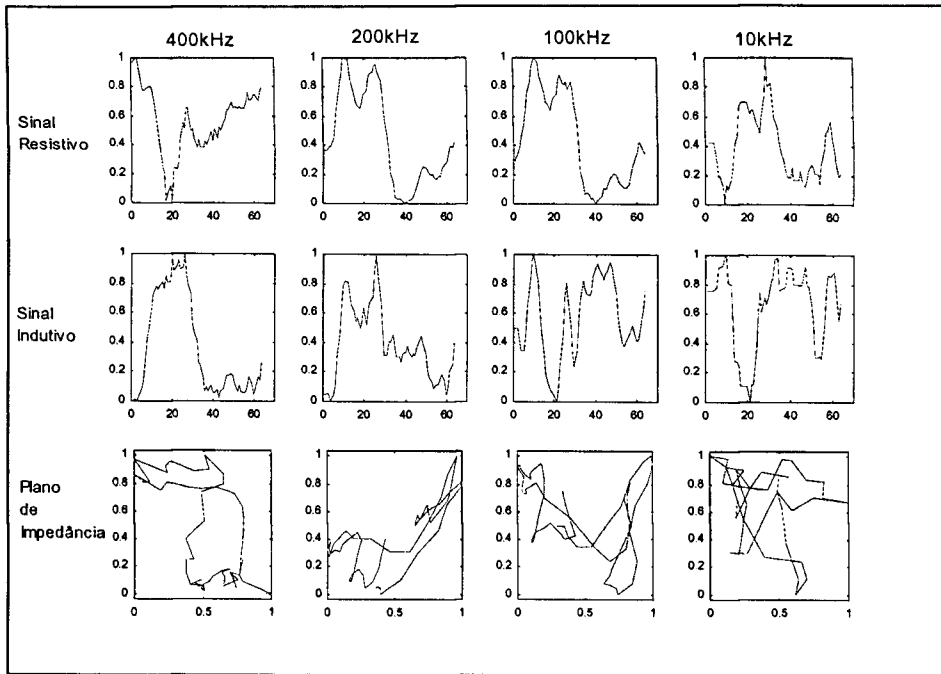
o tipo SCC “puro”. Desta forma, decidiu-se pela utilização de cinco defeitos (ISC, PIT, THI, WEA e IMP) com a utilização de 24 indicações para cada tipo de defeito. Cada uma destas indicações apresentam sinais referentes a quatro diferentes canais de frequência, sendo cada um deles apresentando aquisições absolutas e diferenciais. Além disto, deve-se observar que um dos cinco tipos de defeitos utilizados é o chamado “corrosão intergranular” (ISC), que é um mecanismo composto de “ataque intergranular” (IGA) e “trincamento por corrosão” (SCC), justamente os dois tipos de defeitos “puros” deixados de fora do banco de treinamento. Outra observação importante a ser feita é que o ISC é citado como um dos tipos mais frequentes de ocorrências em plantas com Inconel 600. Em muitas classificações a categoria ISC engloba IGA e SCC.

Outro procedimento escolhido para selecionar os dados de entrada para esta tese, foi a decisão pela utilização dos sinais adquiridos por bobinas diferenciais. Isto se deve ao fato de que a grande maioria dos procedimentos definidos para identificação do tipo de defeito, utiliza ou canais diferenciais ou sinais diferenciais mixados. Existem exceções, mas os aspectos e formatos dos sinais diferenciais apresentam maior regularidade entre indicações diferentes.

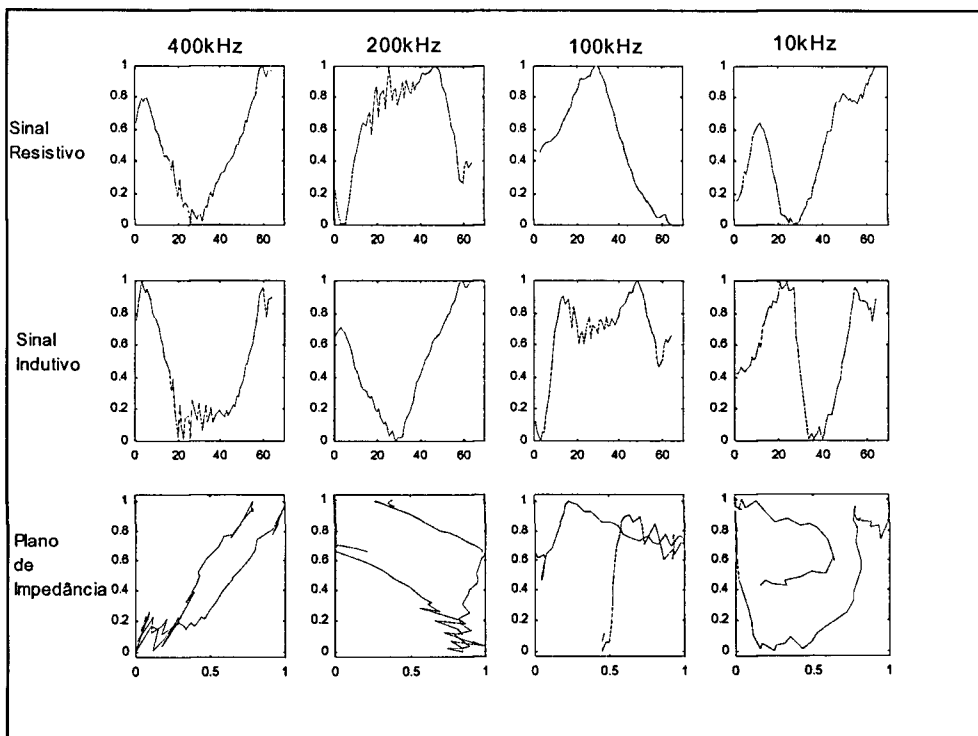
Como mencionado, a base de dados para treinamento e teste do algoritmo de classificação se constitui de cinco diferentes conjuntos (tipos de defeito) de 24 indicações cada. Para cada indicação, existem quatro canais disponíveis. Por razões semelhantes às anteriormente alegadas (maior frequência de utilização nos procedimentos para diagnóstico e maior regularidade dos sinais) foram utilizados os dois canais diferenciais de maior frequência de excitação. Desta forma, cada indicação é representada por dois conjuntos de sinais no plano de impedância.

Nas figuras 3.3 e 3.4 são apresentados segmentos de sinais de ECT diferenciais e absolutos respectivamente. Estes segmentos de 64 pontos são apresentados em diferentes gráficos para os diferentes canais de frequência de excitação (400kHz, 200kHz, 100kHz, e 10kHz). Também são apresentados em gráficos separados o sinal resistivo, o sinal de reatância indutiva e o plano de

impedância para as quatro frequências de excitação. Todos os gráficos apresentados nas duas figuras referem-se à mesma região de degradação (ISC) do tubo, e foram segmentados de acordo com o critério da IC.



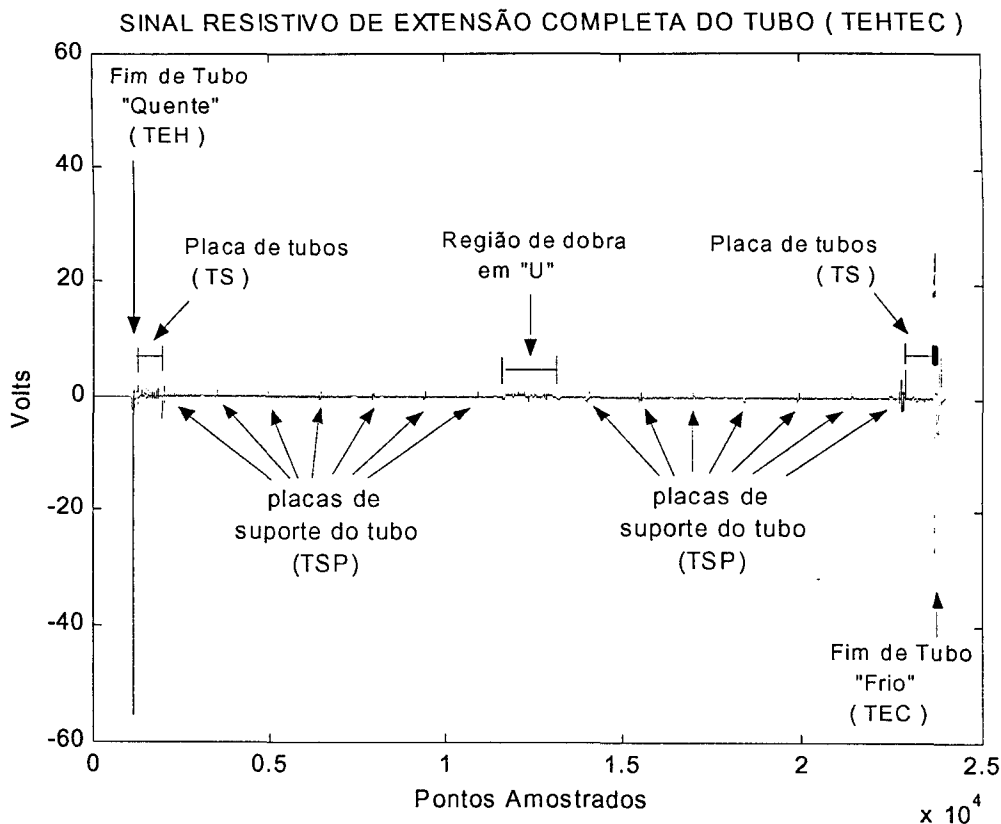
**Figura 3.3 – Segmentos de 64 pontos de sinais de ECT diferenciais em diferentes freqüências de excitação (400kHz, 200kHz, 100kHz, e 10kHz) relativos a ISC.**



**Figura 3.4 - Segmentos de 64 pontos de sinais de ECT absolutos em diferentes freqüências de excitação (400kHz, 200kHz, 100kHz, e 10kHz) relativos a ISC.**

Um sinal resistivo de ECT relativo à extensão completa de um tubo é mostrado na figura 3.5. Este sinal representa um conjunto de 25.000 pontos amostrados aproximadamente, correspondentes a uma extensão aproximada de 20m de tubo. Estão representados na figura as localizações típicas do sinal de ECT correspondentes às diferentes regiões do tubo de gerador de vapor e às estruturas de suporte que o circundam. O trecho de dados apresentado é comumente descrito como o trecho entre o “fim de tubo quente” (“tube end hot” – TEH ) e o “fim de tubo frio” (“tube end cold” – TEC), representando assim toda a extensão do tubo e formando a sigla TEHTEC.

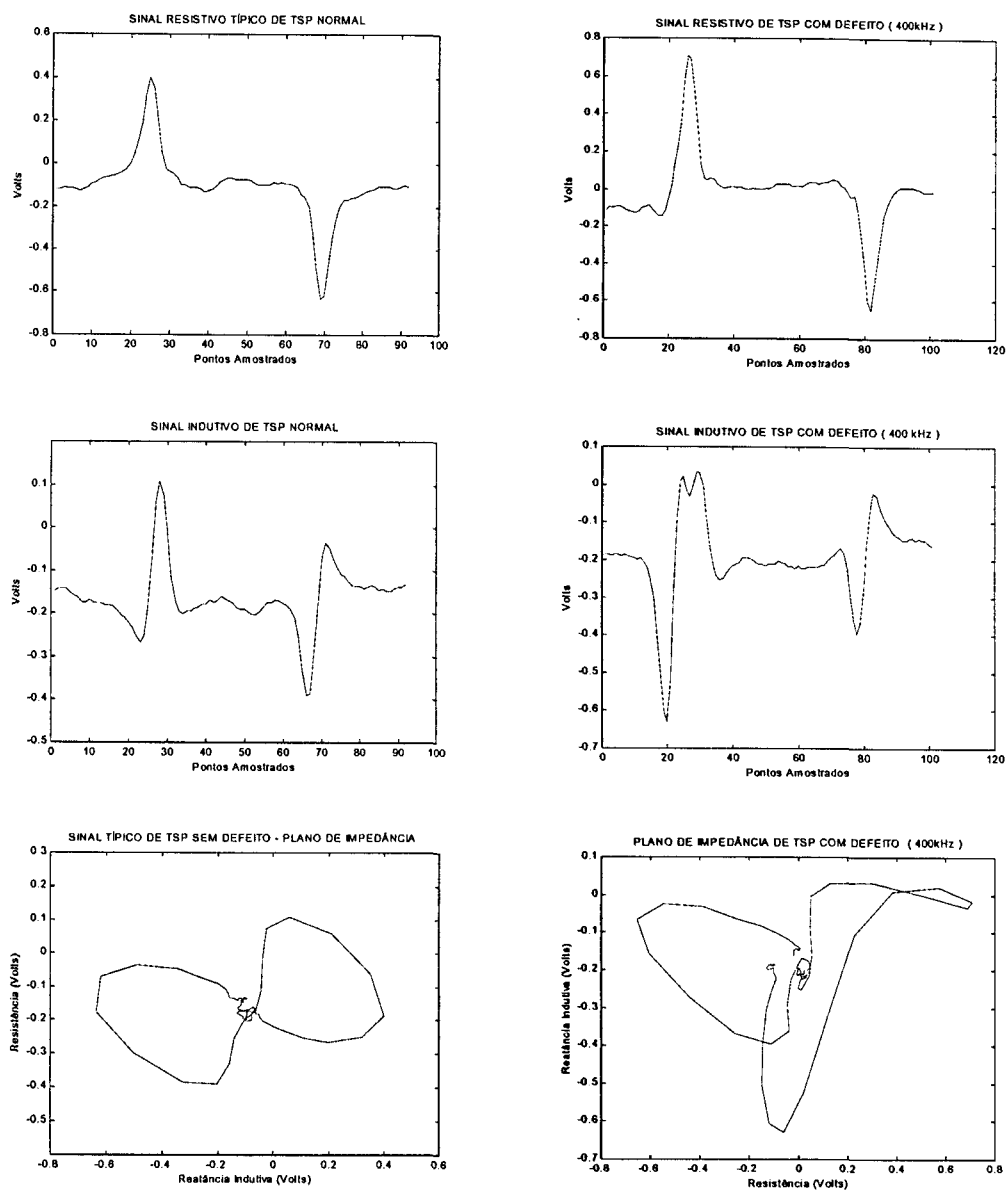
Nesta figura pode-se notar a presença dos sete picos referentes às placas de suporte dos tubos (TSP) do lado “quente” do tubo (perna quente) à esquerda do sinal, e do mesmo número de picos referentes ao lado “frio” do tubo (perna fria) à direita do sinal. Deve-se ressaltar que a intensidade destes picos é muito maior do que a dos picos referentes às degradações normalmente encontradas. Pode-se observar, na mesma figura, a presença no centro do sinal, da região correspondente à dobra em U do tubo. Esta região é mais ruidosa e apresenta picos correspondentes às barras anti-vibração (AVB) que não são visíveis nesta figura. Ainda nesta figura estão indicadas nos extremos, as regiões do sinal correspondentes ao fim do tubo, TEH e TEC, que têm uma intensidade dezenas de vezes maior que o resto do sinal correspondem aos picos do sinal que ocorrem no momento em que a sonda entra e sai do tubo, respectivamente. Outras regiões características do sinal simetricamente apresentadas nesta figura, são as referentes à base dos tubos (TS). Comumente apresentam um nível de ruído maior por apresentarem acúmulo de lama (“sludge pile”) ao redor dos tubos, e no espaço (existente em muitas plantas) entre a base dos tubos e o próprio tubo (“tube sheet crevice” – TSC).



**Figura 3.5 – Sinal resistivo diferencial de 400kHz de extensão completa de tubo em “U”.**

A figura 3.6 apresenta os sinais resistivo, indutivo e no plano de impedância característicos (assinaturas) de um suporte de tubo (TSP) sem defeito e com defeito (a) e (b) respectivamente. Observa-se na figura 3.6b relativa ao plano de impedância, que o lobo direito da figura de Lissajous se deforma completamente, sinalizando ao inspetor de ECT a presença de degeneração nesta região do tubo. O tipo de degeneração mostrada na figura é o desgaste (WEA). Este método de observação de alteração da forma da figura de Lissajous nos sinais de ECT relativos às estruturas de suporte do tubo é complementado pela observação dos sinais de canais mixados. Estes canais são obtidos por uma composição entre sinais de dois canais com frequência de excitação diferentes. A mixagem supõe que as assinaturas relativas às estruturas de suporte em diferentes canais de frequência têm a mesma forma, apenas com uma rotação da fase e um fator de escala. A obtenção dos canais mixados é procedimento de rotina, dos programas comerciais utilizados pelo analista de ECT. Nesta tese, utiliza-se um algoritmo de regressão numérica para se encontrar os

parâmetros da matriz de transformação entre diferentes canais. Este processo é melhor explicado na seção 3.3.




(a)

(b)

**Figura 3.6 – Sinais resistivo, indutivo e plano de impedância, característicos de: (a) suportes de tubos (TSP) sem defeito e (b) TSP com defeito.**

O mesmo formato básico do sinal relativo ao TSP pode ser observado em outras estruturas. A figura 3.7 mostra a assinatura do sinal da base de tubos (TS).

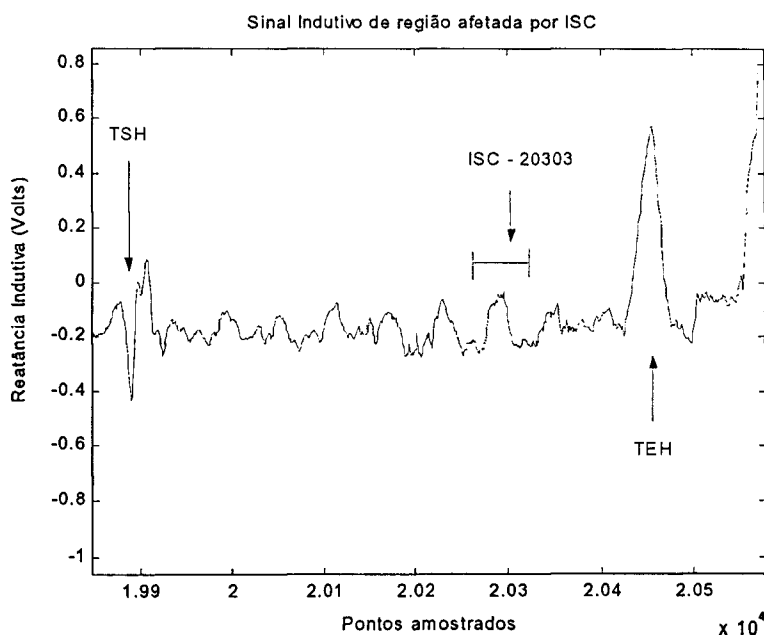


**Figura 3.7 – Sinal resistivo, indutivo e plano de impedância de sinal característico da base de tubos (TS). A frequência de excitação do canal é 400kHz.**

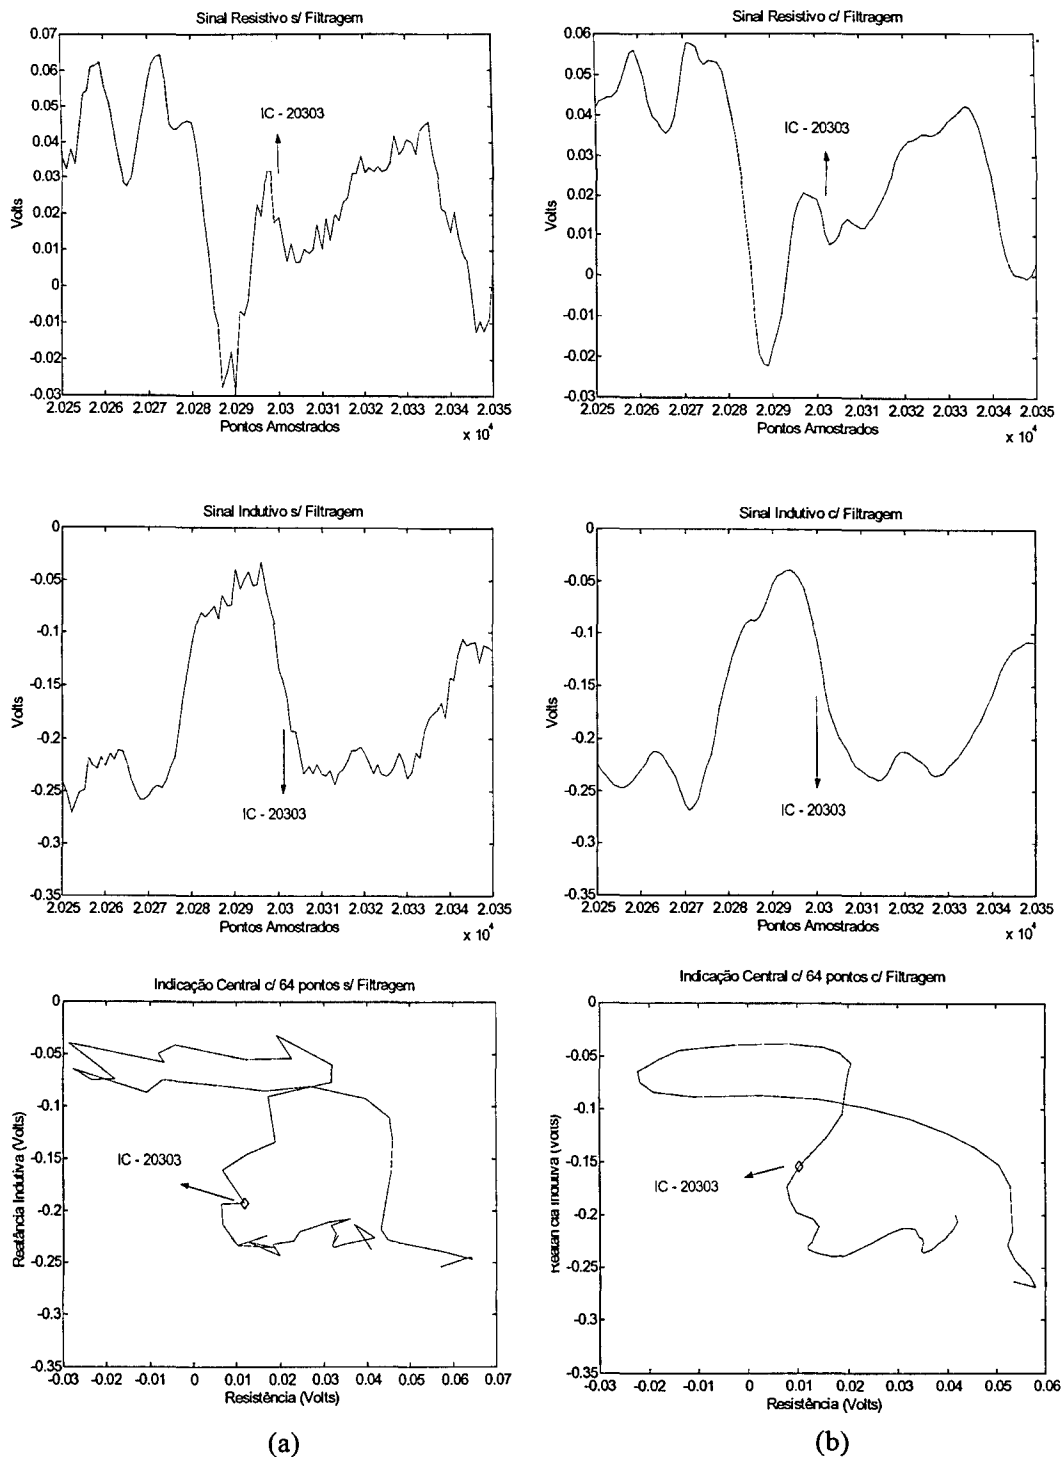
### 3.2.1 - Sinais Relativos ao Trincamento Intergranular (ISC)

Nesta seção, são apresentados alguns sinais característicos de ISC utilizados nesta tese. Os sinais utilizados correspondem às degradações ocorridas no vão entre tubo e base de tubos (“crevice”), no topo da base de tubos (“top of tube sheet” – TTS) relativos à chamada “pilha de lama” e nas dobras em “U”.

Um exemplo de um sinal indutivo relativo a um tubo que apresenta a degradação ISC (trincamento por corrosão) é mostrado na figura 3.8. Tal região corresponde ao “vão entre tubo e placa de tubo” (“crevice”). Como pode ser visto, o nível de ruído é alto nesta região. A indicação está assinalada entre a placa de tubos quente (“tube sheet hot” – TSH) e o “tube end hot” (TEH). Como pode ser visto, a detecção da falha utilizando somente a intensidade do sinal diferencial indutivo é quase impossível. A mesma degradação é apresentada em detalhe no sinal diferencial resistivo, indutivo e plano de impedância na figura 3.9.

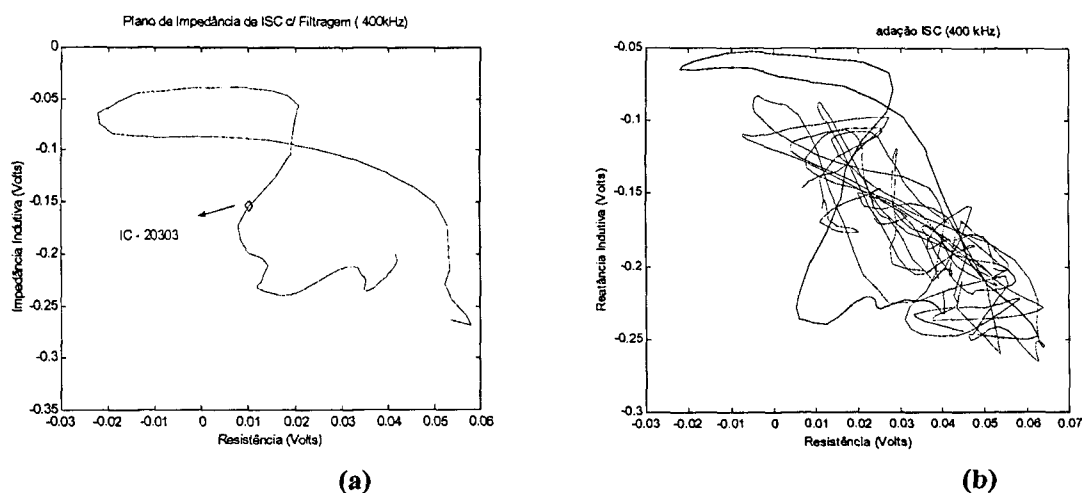


**Figura 3.8 – Segmento do sinal indutivo de 400kHz (diferencial). A região corresponde ao “vão entre tubo e placa de tubo” (“crevice”). A indicação de ISC está assinalada entre a “placa de tubos quente” (TSH) e o “fim de tubo quente” (TEH).**



**Figura 3.9 – Segmento com 100 pontos amostrados de sinal resistivo, indutivo e plano de impedância de 400kHz (diferencial) sem filtragem (a) e filtrado (b) referente a ISC.**

Observando-se a figura 3.9 é possível perceber no plano da impedância, o padrão similar à figura de Lissajous buscado normalmente pelo inspetor de ECT para a detecção do defeito. Existem outros critérios para a detecção, como a observação simultânea da alteração em outros canais de frequência, inclusive canais mixados. A figura 3.10 mostra a mesma degradação com segmentos de diferentes tamanhos do sinal no plano da impedância. Na figura 3.10a é apresentado um segmento de 64 amostras e na figura 3.10b é apresentado um segmento de 495 amostras que inclui o segmento anterior (destacado na cor vermelha). A detecção do defeito, no entanto, foge ao escopo desta tese. Todo o trabalho de classificação desenvolvido baseia-se na identificação já realizada pelo especialista e registrado no relatório final do PDD através da IC. Apesar disto, o procedimento de detecção pode vir a ser um desdobramento dos resultados obtidos nesta tese (ver capítulo 8).




**Figura 3.10 – Plano de impedância com 64 pontos do sinal de 400 kHz (diferencial) filtrado e IC referente ao defeito ISC.**

### 3.2.2 - Sinais Relativos à Perfuração (PIT)


Nesta seção, são apresentados alguns sinais característicos de PIT utilizados nesta tese. Os sinais utilizados correspondem às degradações ocorridas na chamada pilha de lama (“sludge pile”) na região do tubo que fica acima da (TTS).

Um exemplo de indicação de perfuração é mostrado na figura 3.11. O sinal foi obtido com sonda tipo bobina diferencial com frequência de excitação de 600kHz. Este segmento de sinal (01CTSC) corresponde à região entre a primeira placa de suporte de tubos “fria” (01C) e a placa de tubos “fria” (TSC).

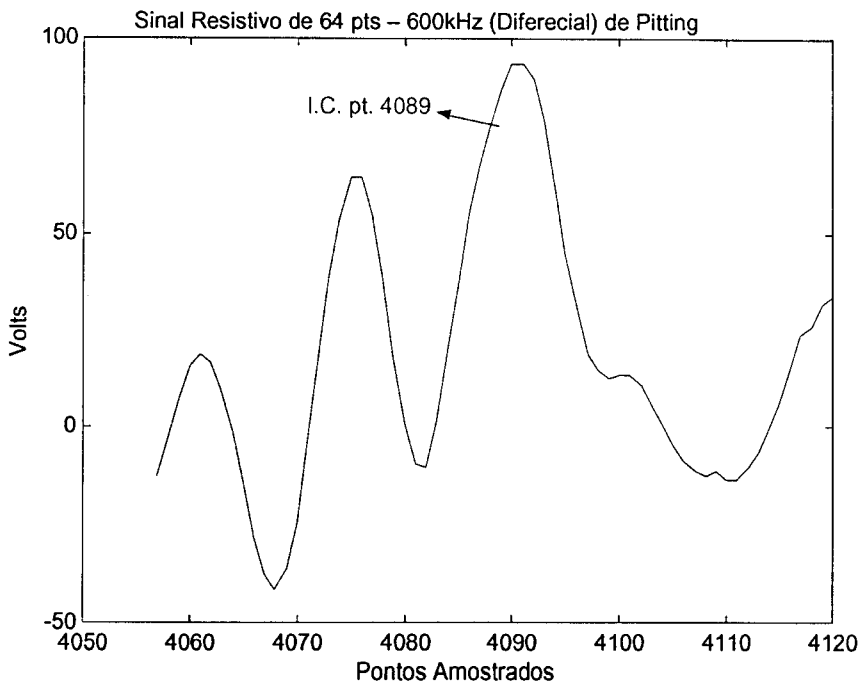


**Figura 3.11 – Sinal resistivo de 600kHz (diferencial) com indicação de perfuração (PIT).**

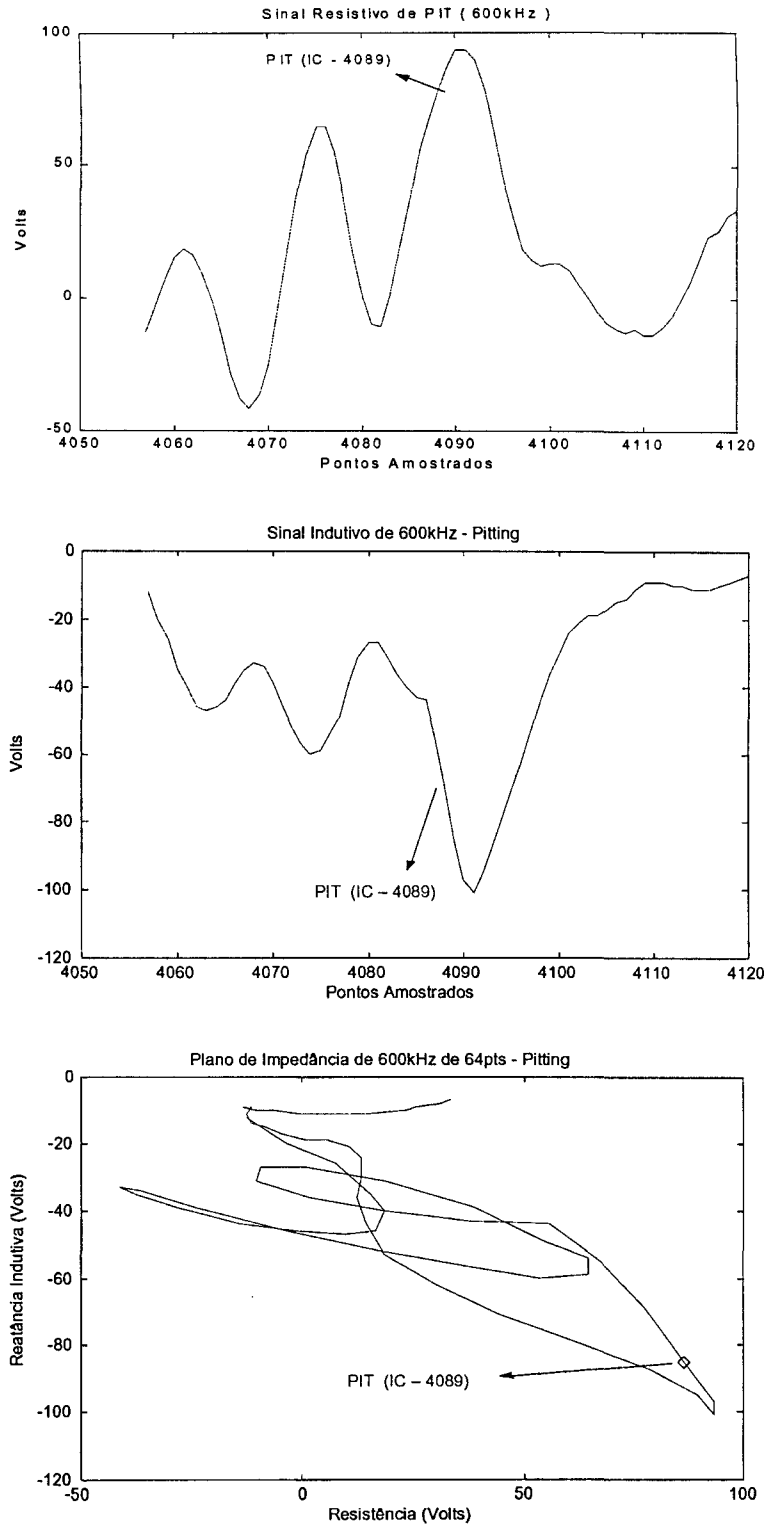
Observa-se na figura 3.12 um segmento de 128 pontos em torno da IC, em que o sinal da base de tubos está incluído. Para analisar este tipo de segmento, onde o sinal forte de uma estrutura de suporte está presente, pode-se utilizar o recurso da mixagem de canais. A mesma indicação inserida em um segmento de sinal resistivo é mostrada em um segmento de 64 pontos na figura 3.13. Em boa parte dos dados é possível caracterizar o sinal do defeito sem a utilização do recurso de mixagem, utilizando segmentos menores que 100 pontos amostrados (em torno de 0,075m). A desvantagem de sua utilização é que, por ser basicamente uma subtração entre sinais, corre-se o risco dela extrair uma informação do sinal que pudesse ser importante para a sua caracterização. A figura 3.14 apresenta o gráfico resistivo, indutivo e do plano de impedância do mesmo segmento de 64 pontos correspondente à degradação PIT.



**Figura 3.12 – Segmento de 128 pontos de sinal resistivo de 600 kHz (diferencial) com indicação de perfuração (PIT).**



**Figura 3.13 – Segmento de 64 pontos de sinal resistivo de 600 kHz (diferencial) com indicação de perfuração (PIT).**




**Figura 3.14 – Plano de impedância de 600kHz (diferencial) com IC de PIT.**

Os programas comerciais utilizados pelos operadores de ECT para visualização, aquisição e análise dos sinais possuem recursos para criar canais mixados que são muito comumente utilizados. No entanto alguma modificação substancial pode ocorrer no sinal de interesse. A utilização de um segmento de 64 pontos em torno da IC pode ser uma solução razoável para robustez e velocidade na caracterização destes defeitos.


### **3.2.3 - Sinais Relativos ao Desgaste (WEA)**

Nesta seção, são apresentados alguns sinais característicos de WEA utilizados nesta tese. Os sinais utilizados correspondem às degradações ocorridas próximas às AVB que se localizam na dobra em “U” do tubos, nas placas defletoras e próximo às estruturas de suporte.


Um exemplo de sinal associado ao defeito desgaste (WEA) é mostrado nas figuras 3.15, 3.16, 3.17 e 3.18, onde são mostrados segmentos de sinais resistivos e indutivos utilizando canais diferenciais que sofreram e que não sofreram o processo de mixagem. Os sinais mixados e filtrados apresentam intensidades dez vezes menor do que seus correspondentes sem mixagem (ver seção 3.3). Este decréscimo na intensidade é devido ao processo de subtração entre os sinais de diferentes canais de frequência de excitação que corresponde à mixagem de canais. O efeito no formato do sinal no plano da impedância pode ser observado nas figuras 3.19 e 3.20. Da mesma forma que as placas de suporte dos tubos (TSP), as barras anti-vibração (AVB) têm um sinal característico no plano da impedância semelhante ao observado na figura 3.6a. A detecção de defeitos nesta região é muitas vezes baseada na deformação da figura de Lissajous usual para AVB como mostrado nas figuras 3.19 e 3.20.




**Figura 3.15 – Segmento de 64 pontos de sinal resistivo de 600 kHz relativo à indicação de defeito desgaste (WEA) localizado sobre barra anti-vibração (AVB).**




**Figura 3.16 – Segmento de sinal resistivo de canal diferencial misto (600/100 kHz) e filtrado, relativo a indicação de desgaste (WEA).**




**Figura 3.17 – Segmento de 64 pontos de sinal diferencial indutivo de 600 kHz relativo a indicação de desgaste (WEA).**



**Figura 3.18 – Segmento de sinal resistivo de canal diferencial mixado (600/100 kHz) e filtrado, relativo a indicação de desgaste (WEA).**



**Figura 3.19 – Plano de impedância de sinal diferencial de 600 kHz com 64 pontos relativo à indicação de desgaste (WEA) sobre sinal característico de AVB.**




**Figura 3.20 – Plano de impedância de 64 pontos relativo à canal diferencial mixado de 600/100 kHz e filtrado, correspondente à indicação WEA.**


### 3.2.4 - Sinais Relativos ao Afinamento (THI)

Nesta seção, são apresentados alguns sinais característicos da degradação chamada afinamento (THI) utilizados nesta tese. Os sinais utilizados correspondem às degradações ocorridas próximas às placas de suporte de tubos (TSP) e às chamadas “pilhas de lama” que se localizam no topo da base de tubos (TTS).

Um exemplo de sinal desta base de dados associado a este mecanismo de degradação é mostrado na figura 3.21. Esta figura mostra o segmento de sinal indutivo diferencial de 400kHz. Este segmento contém duas indicações relativamente próximas, com diferença de 18 pontos amostrados o que significa para a taxa de amostragem de 33 amostras/polegada uma distância aproximada de meia polegada ou 1,2 cm. Neste exemplo, esta degradação pode ser caracterizada pela presença de dois picos claramente distintos ao lado do sinal da placa de tubos quente (TSH). O plano de impedância relativo a esta degradação pode ser visto na figura 3.22. Nesta figura, o gráfico apresenta a justaposição de duas figuras de Lissajous com as duas IC correspondentes indicadas. Esta figura não inclui o sinal relativo ao TSH.




**Figura 3.21 – Segmento de sinal indutivo de 400kHz apresentando dois sinais distintos de afinamento (THI).**




**Figura 3.22 – Plano de impedância de canal diferencial de 400kHz apresentando a justaposição de duas figuras de Lissajous correspondentes às duas IC da degradação de afinamento (THI).**

### 3.2.5 - Sinais Relativos ao Dano por Colisão (IMP)


O último tipo de degradação utilizado neste trabalho é o dano por colisão (IMP). Os sinais utilizados para esta degradação são correspondentes às regiões próximas às placas de suporte de tubos (TSP). Um exemplo de uma indicação na região de expansão livre é apresentado nas figuras 3.23, 3.24 e 3.25. O plano de impedância apresentado na figura 3.25 corresponde a justaposição de duas figuras de Lissajous correspondentes à degradações próximas.



**Figura 3.23 – Segmento de sinal resistivo diferencial de 600kHz com duas indicações de dano por colisão (IMP) ao lado de sinal de TSP característico.**



**Figura 3.24 – Segmento de sinal indutivo diferencial de 600 kHz com duas indicações de IMP ao lado de sinal de TSP característico.**



**Figura 3.25 – Plano de impedância com 64 pontos relativos às indicações de danos por colisão (IMP) contendo duas indicações.**

### **3.3 - Visualização e Pré-processamento dos Sinais de ECT**

Os sinais da base de dados utilizada foram adquiridos através de um sistema de aquisição padrão em usinas nucleares chamado EddyNet utilizando a norma da ASME (ASME, 1992) para definição da origem da fase do sinal. O aparelho utilizado nesta aquisição é da série MIZ da Zetec Inc., Estados Unidos da América. Um parcela significativa destes dados são codificados sem pré-processamento, de acordo com padrões que só podem ser decodificados e lidos por um programa comercial utilizado pela EPRI chamado MultiView da empresa R/D Tech, Canada.

O próprio EddyNet da Zetec e o MultiView possibilitam, além da decodificação, a visualização e calibração do sinal para uma análise posterior (“off-line”) de acordo com os parâmetros da aquisição (informação contida nos dados). Outra propriedade importante destes programas é que eles possibilitam a detecção automática de anomalias no sinal por um limite de intensidade de sinal (“threshold”).

O inspetor que utiliza esta detecção automática pode então marcar a anomalia e o sinal de interesse para posterior análise.

Ao longo da última década Belle R. Upadhyaya e colaboradores da Universidade do Tennessee, têm desenvolvido módulos de pré-processamento de alguns destes sinais. Estes algoritmos, desenvolvidos em caráter acadêmico, possibilitaram o surgimento de módulos para pré-processamento, detecção e classificação, à parte dos programas comerciais (Yan e Upadhyaya, 1996). Alguns algoritmos de visualização e calibração dos sinais foram adaptados para o uso nesta tese. A base de dados descrita neste capítulo já se apresentava decodificada.

Dentre estes algoritmos, foi desenvolvido um módulo independente (“stand-alone”) de pré-processamento (figura 3.26) do sinal de ECT, utilizando análise de multi-resolução utilizando transformadas de “wavelet” (Mallat, 1989a). Na seção 6.5 encontra-se um resumo dos principais conceitos sobre esta transformada. Para uma revisão mais apurada sobre o assunto pode-se consultar o livro de Meyer (1988). O método de filtragem incluído neste módulo é a extração de ruídos por limites suaves (“de-noising by soft-thresholding”) e foi desenvolvido por Donoho (1994). Este método se aproxima do funcionamento de um filtro para a eliminação seletiva (em diferentes escalas de frequência e limiares de intensidade) do ruído do sinal.

Esta transformada de “wavelet” é uma operação linear que decompõe um sinal em componentes que aparecem em diferentes escalas. A transformada é baseada na convolução de um sinal com um filtro de dilatação (“dilation”). Esta decomposição foi inicialmente estudada em processamento de sinais (Smith e Barnwell, 1986) e visão computacional (Witkin, 1983) e posteriormente reformalizada matematicamente (Daubechies, 1990; Mallat, 1989b).

Este filtro permite a escolha da faixa de frequência que se quer atenuar e o método de atenuação associado. Este módulo foi utilizado neste trabalho qualitativamente para a melhor visualização e seleção da base de dados de

treinamento, mas não como etapa de pré-processamento de toda a base. Alguns sinais em que a relação ruído/sinal era muito alta foram filtrados por este algoritmo, deonstrando que a filtragem com “wavelets” trouxe resultados superiores. Sendo assim, trata-se de abordagem alternativa à filtragem convencional a ser considerada nos módulos de pré-processamento. Esta filtragem tem sido um campo de desenvolvimento científico e tecnológico nos últimos anos, principalmente na utilização da teoria de “wavelets” na análise e processamento de sinais. Nesta análise é possível uma representação do sinal no campo da freqüência e do tempo, permitindo um processamento de sinais mais sofisticado com acesso a um número muito maior de informações presentes no sinal (Upadhyaya et al., 1993). O módulo pode futuramente ser incorporado ao sistema de diagnóstico desenvolvido nesta tese para verificar se a eliminação seletiva do ruído aumentaria a eficiência da identificação dos defeitos.




Figura 3.26 – Interface gráfica do módulo de filtragem seletiva de sinal de ECT.

Como pode ser visto na figura 3.27, o pré-processamento empregado em toda a base de dados utilizada nesta tese consiste em um conjunto de algoritmos para leitura, visualização, calibração, mixagem, segmentação, seleção dos canais e

montagem de matrizes modelo por tipo de degradação. Após o pré-processamento são criados conjuntos de vetores de treinamento e teste que servem de entrada para um outro conjunto de algoritmos de extração de características (capítulo 6) que finalmente gera a entrada para um algoritmo classificador final (capítulo 7).

A primeira etapa de pré-processamento é composta por calibração e mixagem (figura 3.27). A calibração obedece os critérios apresentados no capítulo 2 (seção 2.3.2). Os arquivos originais desta base estão divididos em diretórios organizados por calibração. Cada diretório contém arquivos de diferentes tubos e um ou dois arquivos com sinais da calibração utilizada para aqueles tubos. Desta forma, o primeiro passo de pré-processamento é a calibração de toda a base de dados utilizando os arquivos com as calibrações correspondentes. Portanto foram criados arquivos contendo toda a base de dados devidamente calibrada.

O processo de mixagem de canais consiste de uma subtração entre os dois canais a serem mixados para eliminação do sinal relativo à estrutura. Existem vários métodos de mixagem de canais, mas o mais comumente utilizado baseia-se numa matriz de escalamento, rotação e translação (Stolte et al., 1982). A suposição necessária para a utilização deste método é que os sinais de ECT em duas frequências diferentes de excitação sejam transformáveis por rotação, translação e escalamento. Primeiramente obté-se os parâmetros das duas figuras de Lissajous formadas no plano de impedância pelos dois sinais em diferentes canais de frequência de excitação de uma mesma estrutura de suporte (TSP, AVB, etc.). Através destes parâmetros medidos, são calculados por minimização dos erros quadráticos, os coeficientes da matriz afim. (Sword e Simaan, 1985). Este procedimento foi implementado em um algoritmo utilizado para mixar parte da base de dados de acordo com a metodologia explicada a seguir.

A mixagem foi realizada sobre parte dos sinais que apresentavam indicações em regiões muito próximas às estruturas de suporte. Foram criados dois canais mixados para todos os dados relativos à degradação por colisão (IMP), 40% dos dados relativos à degradação por desgaste (WEA) e para 30% dos dados relativos à

degradação de afinamento (THI). Os canais mixados obedeceram a seguinte metodologia:

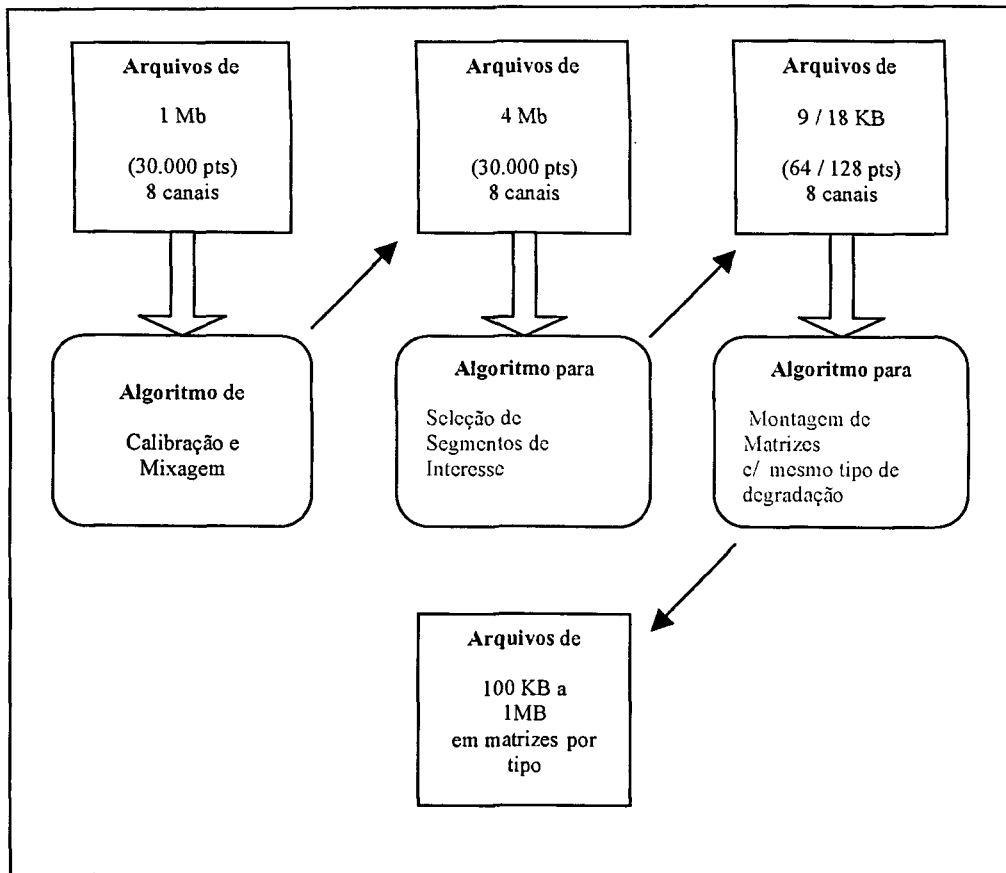
- 1) o primeiro canal de mais alta frequência de excitação (em geral 400kHz) é mixado com o terceiro canal (em geral 100kHz), utilizando sempre os canais diferenciais (figuras 3.3 e 3.4);
- 2) o segundo canal de mais alta frequência (em geral 200kHz) mixado com o o terceiro canal;
- 3) estes dois canais mixados são utilizados como os dois sinais utilizados para cada defeito.

Para o restante dos dados não foi necessária a mixagem pois a indicação se encontrava distante o suficiente do sinal relativo às estruturas de suporte.

A seleção de conjuntos de treinamento e teste utiliza um algoritmo randômico de escolha dos vetores de treinamento, mantendo a proporção de mesmo número de vetores representativos de cada tipo de degradação.

Cada sinal é normalizado entre zero e um pelo máximo do módulo do número complexo formado no plano da impedância, mantendo-se assim a forma da figura de Lissajous neste plano.

Finalmente são gerados arquivos com as matrizes de dados calibrados e mixados e organizados por tipo de degradação em diretórios correspondentes a estes tipos (figura 3.27).



**Figura 3.27 – Etapas de pré-processamento da base de dados utilizada.**

## 4 - TÉCNICAS DE RECONHECIMENTO DE PADRÕES EM SINAIS DE ECT

### 4.1 - Reconhecimento de Padrões

Um número cada vez maior de áreas científicas têm apresentado problemas de reconhecimento, descrição, classificação e agrupamento (“clustering”) automático de padrões. Áreas como a biologia, psicologia, medicina, propaganda (“marketing”), visão computacional, inteligência artificial, e sensoramento remoto têm aparecido na literatura como aplicações destas técnicas baseadas em sistemas computacionais (Jain et al., 2000).

Watanabe (1985) definiu o conceito “padrão” como: “o oposto de caos; é uma entidade, vagamente definida, a qual pudesse ser dado um nome.” Alternativamente, sugerimos uma definição mais operacional em que “padrão” poderia ser definido como forma ou conceito abstrato n-dimensional composto de n diferentes características observáveis (ou mensuráveis). Cada característica equivaleria a uma propriedade do conceito, da mesma forma que dizemos que uma cadeira tem a propriedade de “poder-se sentar sobre” ela. Desta forma um padrão poderia ser uma imagem de impressão digital, uma palavra em escrita manual, uma face humana, ou um sinal de voz.

O reconhecimento de padrões se divide basicamente em dois tipos: o primeiro, baseado em classificação supervisionada na qual o padrão de entrada é um membro de uma classe pré-definida; e o segundo baseado em classificação não-supervisionada, onde o padrão é associado a uma classe desconhecida até então.

Duda et al. (2001) comparam a tarefa de se obter o reconhecimento de padrões automatizado como o desenvolvimento da percepção da máquina. Desde o reconhecimento da fala, da identificação de uma impressão digital, do reconhecimento ótico de caracteres até a identificação de sequências de DNA, todos estes seriam aspectos desejáveis e de grande utilidade que têm sido implementados

como extensões dos sistemas que utilizam computadores como base. Ainda segundo os autores, um sistema classificador é composto de quatro etapas: 1) percepção, que corresponde à obtenção de dados puros, sinal, imagem, etc. (informação digital); 2) eliminação do “ruído”, que inclui a filtragem analógica, digital e até mesmo um tipo de segmentação em que o objetivo é separar a informação útil ou de interesse; 3) extração e seleção de características; 4) criação dos modelos; 5) escolha do modelo que melhor se ajusta.

Ainda segundo **Duda et al. (2001)**, as principais metas em reconhecimento de padrões são: 1) hipotetizar a classe destes modelos; 2) processar o dado “sentido” para eliminar ruídos; 3) para qualquer dado novo escolher o melhor modelo que lhe corresponda.

Tanto o reconhecimento de padrões como mais especificamente a classificação são considerados atualmente dentro de um contexto maior no qual podem ser tratados como subteorias da Teoria da Decisão (**Duda et al., 2001**). O custo envolvido na decisão definiria como consequência imediata o grau de separação necessária entre os “clusters” envolvidos na decisão.

O surgimento de aplicações emergentes que necessitam de uma capacidade computacional maior tem renovado o já grande interesse em técnicas de reconhecimento de padrões. Algumas destas aplicações são: “data mining” (identificação de um “padrão”, por exemplo, correlação, ou um “outlier” em milhões de padrões multidimensionais), classificação de documentos (busca eficiente em documentos texto), previsão financeira, organização e busca em banco de dados de multimídia, e biométrica (identificação pessoal baseada em atributos físicos tais como face ou impressão digital) (**Jain et al., 2000**). Os autores observam que uma boa parte destas aplicações têm em comum que as características disponíveis (“features”) são extraídas e otimizadas com base nos dados (“data-driven”) e não no conhecimento do especialista. Isto vai de encontro à concepção tradicional dos sistemas de inteligência artificial.

**Picard (1997)** relata uma nova aplicação de reconhecimento de padrões, chamada computação afetiva que dará ao computador a habilidade de reconhecer e expressar emoções, e empregar mecanismos de emoção que contribuam para a tomada de uma decisão racional.

Assim como foi relatado no ítem 3.2, nas aplicações em ECT, observa-se que o rápido crescimento e disponibilização de computadores com maior capacidade e velocidade tem facilitado o uso, antes inviável, de métodos mais elaborados tanto de modelamento quanto de reconhecimento de padrões propriamente dito.

Aprender a partir de uma série de exemplos (conjunto de treinamento) é um importante e desejável atributo da maioria dos sistemas de reconhecimento de padrões. Segundo **Jain et al. (2000)** as quatro melhores aproximações conhecidas para reconhecimento de padrões são: 1) ajuste de modelo (“template matching”), 2) classificação estatística, 3) ajuste estrutural ou sintático e 4) redes neurais. Estes modelos não são necessariamente independentes e algumas vezes o mesmo método de reconhecimento de padrão existe com diferentes interpretações. Tentativas têm sido feitas pra designar sistemas híbridos envolvendo múltiplos modelos (**Fu, 1983**).

O ajuste de modelos é uma operação genérica utilizada para determinar similaridade entre duas entidades (pontos, curvas ou formas) do mesmo tipo. Este método é computacionalmente pesado, mas tem sido reavivado. Outras variantes deste método utilizam modelos deformáveis (**Grenander, 1993**) ou deformações de folhas de borracha (**Bajcsy e Kovacic, 1989**).

Na aproximação estatística o objetivo é estabelecer fronteiras de decisão no espaço-característico que separem as diferentes classes de padrões. Este espaço-característico é um espaço n-dimensional em que n características representam um padrão (ponto neste espaço). Estas fronteiras ou limites são determinados pelas distribuições de probabilidade dos padrões pertencentes a cada classe, que deve ser especificada ou aprendida (**Devroye, 1988; Devroye et al., 1996**).

Na aproximação sintática, uma perspectiva hierárquica é adotada na qual um padrão é visto como sendo composto de subpadrões mais simples que por sua vez são compostos de padrões ainda mais simples. Muitas dificuldades surgem com a segmentação de padrões ruidosos e a inferência da gramática a partir dos dados de treinamento (Fu, 1982).

As redes neurais artificiais são sistemas computacionais inspirados pelas características de aprendizado e funcionamento das redes de neurônios biológicos. Desde os seus primeiros esboços há 50 anos, a teoria de redes neurais têm se desenvolvido ao ponto de se tornar ferramenta insubstituível em muitas aplicações e disciplinas científicas atuais (Englehart, 1998). As principais características das redes neurais são que elas têm a habilidade de aprender relações de entrada e saída não-lineares, usam procedimentos de treinamento sequencial, e se adaptam aos dados. Uma descrição completa de seus princípios e aplicações é amplamente encontrado na literatura (Zeidenberg, 1990; Beale e Jackson, 1990; Kosko, 1992; Reed e Marks II, 1999; Tsoukalas e Uhrig, 1996; Hines, 1997).

A família de redes neurais mais comumente utilizada para classificação de padrões é a “feed-forward”, que inclui o “multilayer perceptron” (MLP) e as redes “radial-basis function” (RBF). Estas redes são organizadas em camadas e têm conexões unidirecionais entre as camadas. Uma descrição detalhada de redes neurais aplicadas a reconhecimento de padrões é feita por Ripley (1996) e Bishop (1995). Outra rede popular é a “self-organizing map” (SOM), ou mapa de Kohonen (Kohonen, 2001), que é principalmente usada para agrupamento (“clustering”) de dados e mapeamento de características. O processo de aprendizado envolve a atualização da arquitetura da rede e pesos da conexão de forma que a rede possa desempenhar a tarefa de classificar. O aumento da popularidade de modelos de redes neurais para resolver problemas de reconhecimento de padrões tem sido principalmente devido à sua aparente baixa dependência do conhecimento do domínio específico (relativa às aproximações baseadas em modelos e em regras) e devido à disponibilidade de algoritmos de aprendizado eficientes (Jain et al., 2000).

Apesar de aparentar diferentes princípios subjacentes, a maioria dos modelos de redes neurais são implicitamente equivalentes ou similares aos métodos de reconhecimento de padrões estatísticos clássicos (Jain et al., 2000).

Anderson et al. (1990) e Ripley (1993) também discutem esta relação entre redes neurais e reconhecimento estatístico de padrões. Anderson et al. chegam ao ponto de dizer que “redes neurais são a estatística para amadores... A maioria das redes neurais escondem a estatística do usuário.” Mesmo levando-se em consideração estas similaridades, as redes neurais apresentam outras características vantajosas. A rede neural tem uma mesma aproximação para a extração de características e para a classificação em si. Além disto, esta técnica também apresenta procedimentos mais adaptáveis para que se encontrem soluções moderadamente não lineares.

Em se tratando de redes neurais, não se tem dado tanta importância à discussão sobre as medidas de distância probabilística. Tem se tornado senso comum a grande dificuldade de se estimar as funções de densidade em espaços de características de dimensões elevadas. Outros temas que têm despertado o interesse da comunidade acadêmica são a complexidade dos procedimentos de classificação e a acuidade associada a eles. A “maldição da dimensionalidade” e o sobre-treinamento são problemas surgidos com o aumento da complexidade da classificação, mas que têm sido resolvidos com técnicas de regularização e com o desenho adequado do classificador. Os procedimentos de classificação não lineares têm se tornado mais frequentes na literatura e as redes neurais são apropriadas pra este fim. Outro senso comum atual é que não se pode resolver um problema complexo de classificação com apenas um procedimento (Jain et al., 2000).

#### 4.1.1 - Reconhecimento de Padrões em Sinais

Citaremos aqui algumas das aplicações de métodos de reconhecimento de padrão em sinais que são encontrados em literatura recente. **Chen et al. (1998)** descrevem a classificação de sinais de sonar subaquático usando redes neurais e transformadas de “Wavelet”. Neste estudo os autores utilizam o MLP e um classificador “Adaptive Kernel Classifier” para classificar os coeficientes de “wavelet” da densidade espectral de potência (PSD) dos sinais de sonar passivos.

Algo bastante similar é realizado por **Sadjadi et al. (2000)**. Neste caso minas subaquáticas são classificadas utilizando sinais acústicos refletidos. O sistema consiste de um extrator de características que utiliza “wavelet packets” em conjunto com “linear predictive coding” (LPC). Uma rede neural “backpropagation” padrão é utilizada como classificador.

No mesmo tipo de aplicação **Miao et al. (1998)** detectam e reconhecem minas terrestres utilizando seis diferentes bandas óticas variando do quase infravermelho ao quase ultra-violeta. O sistema de reconhecimento utiliza uma rede neural auto-associativa de uma camada para extrair as características. Duas outras arquiteturas de rede foram utilizadas para classificação e comparadas contra um esquema de classificação por máxima semelhança (ML).

**Bruzzone et al. (1998)** propõem uma nova rede chamada de “Structured Neural Network” (SNN) para a classificação de sinais de diferentes fontes de informação, tais como sinais de multi sensores ou sinais decritos por características calculadas em diferentes domínios. Tais redes são estruturadas em várias MLP com arquitetura hierárquica que leva em consideração as características dos sinais de entrada. Tais redes são comparadas com as tradicionais MLP e com o classificador estatístico “k-nearest neighbour”. Tais sistemas são aplicados em imagens de ressonância magnética e de sensoriamento remoto.

**Feldkamp e Puskorius (1998)** elaboraram recentemente um sistema baseado em redes neurais tipo “perceptron” de multicamadas e recorrente para resolver um conjunto de problemas, entre os quais, predição de séries temporais, filtragem não linear, e classificação de padrões temporais.

**Dos Santos (1998)** descreve a aplicação do algoritmo “Sequential Forward Search” (SFS) associado a redes neurais para classificar desgastes de fresas utilizando sinais de força durante a fresagem.

**Chen et al. (1999)** e **Wang et al. (1999)** relatam aplicação de “wavelet” e redes neurais para um sistema de classificação (extração de características). As “wavelets” são utilizadas para extrair características de sinais transientes dinâmicos e uma rede neural não supervisionada é utilizada para identificação de estados operacionais. Uma variante da teoria de ressonância adaptativa (ART) é utilizada. Chen e colaboradores descrevem o sistema de extração de característica utilizando “wavelets” enquanto Wang e colaboradores descrevem um caso estudo de um processo de trincamento numa refinaria de fluido catalítico.

Outras aplicações de métodos de reconhecimento de padrões em sinais médicos são relatadas. **Barro et al. (1999)** utilizam redes neurais adaptativas para classificar padrões de sinais de eletrocardiograma; **Park e Lee (1998)** utilizam diferentes técnicas de inteligência artificial em sinais de eletrocardiograma; e **Khalil e Duchêne (1999)** detectam e classificam múltiplos eventos em sinais estacionários (sinais eletromiográficos de útero) utilizando uma classificação auto-regressiva e de multi-escala.

#### **4.2 - Extração de Características em Reconhecimento de Padrões**

Dentre as etapas do processo de reconhecimento de padrões, a chamada extração das características pode ser considerada como a mais crítica e importante. É nesta etapa que o modelo é criado, baseado em características surgidas de uma base

de conhecimentos empíricos ou de processos interativos sobre os dados puros. Só então teremos uma representação da realidade objetiva que queremos classificar. Podemos dizer que os métodos de extração de características criam um subespaço de dimensão  $k$  do espaço característico original de dimensão  $n$ . Os métodos que têm sido mais utilizados para este fim são as transformações lineares tais como análise de componente principal (“principal component analysis”-PCA), análise fatorial, e análise discriminante linear. O melhor entre eles tem sido o PCA ou expansão de Karhunen-Loève (Jain et al., 2000).

Na técnica de PCA calculam-se os  $k$  maiores auto-vetores da matriz covariância  $n \times n$  dos padrões  $n$ -dimensionais. Através de uma transformação linear os dados são projetados nos auto-vetores com maior auto-valores e que portanto contêm maior variância. Outros métodos, como busca de projeção (“projection pursuit”) (Friedman, 1989) e análise de componentes independentes (“independent component analysis” -ICA) (Comon, 1994; Bell e Sejnowski, 1995), são mais apropriados para distribuições não-Gaussianas, já que não se apoiam em propriedades de segunda ordem dos dados.

Outros métodos de extração de características são os de análise discriminante (supervisionado), estimativa de densidade de Parzen (supervisionado), “kernel” PCA (não linear), escalamento multi-dimensional (MDL) (não linear), redes neurais auto-associativas (com as entradas sendo usadas como saídas), e finalmente as “self-organizing maps” (SOM) que ao oferecer seu mapa com conectividade espacial, pode ser interpretado como extração de características (Jain et al., 2000).

Bermejo e Cabestany (2001) propõem a utilização de uma função de custo baseada no erro marginal do algoritmo de classificação (como os vários MLP). Esta função de custo incorporaria termos de regularização para controlar a capacidade de classificação. Entre estes termos Bermejo; Cabestany sugerem a inclusão de um termo de PCA. Isto asseguraria uma maior confiança (ou margem) pra cada classe.

Outras aplicações recentes de métodos de extração de características em sinais são: **De Mori (1997)** descreve avanços recentes na extração de características e reconhecimento de voz; **Englehart (1998)** classifica sinais mioelétricos utilizando diferentes métodos de extração de características e redes neurais; **Wu et al. (1996)** utilizam redes neurais pra classificar espectros quimiometria; **Antoine et al. (1997)** caracterizam formas utilizando “wavelet transform”; **Etemad e Chellappa (1998)** utilizam seleção de base multi-escala para classificação de sinais; **Vigário et al. (2000)** utilizam ICA para classificação de sinais eletroencefalográficos; **Wahlberg e Lantz (2000)** usam diferentes métodos de agrupamento para sinais de eletroencefalograma, onde os métodos comparados são o tradicional “fuzzy cluster mean” (FCM) e o algoritmo teórico de grafos.

#### **4.3 - Propostas de Sistemas Automatizados de Diagnóstico de Defeitos em TGV de Plantas Nucleares**

A automação de diagnósticos de ECT em tubos de gerador de vapor em plantas nucleares depende em primeiro plano de um bom algoritmo classificador. Informações não implícitas no sinal, como a região do tubo em que o defeito analisado se localiza, servem para o especialista em diagnóstico (o inspetor de ECT) como elementos chave para classificar corretamente o defeito (**EPRI, 1995**). Uma tentativa no sentido de representar este conhecimento, num sistema automatizado inteligente, poderia ser resumido na organização de um algoritmo otimizado de busca e uma base organizada deste conhecimento. Outra informação muito presente na classificação tradicional, que poderia ser incluída nesta base de conhecimentos, são os canais de frequência em que foram observadas alterações significativas no sinal (suspeita de defeito) (**EPRI, 1995**). Até hoje, os sistemas que se aproximaram deste enfoque o fizeram timidamente através de sistemas de inferência “fuzzy”, focados quase que unicamente em características extraídas diretamente do sinal ou com o acréscimo de um conjunto de regras de inferência que dependiam da intervenção do

usuário do programa para sua criação (Yan e Upadhyaya, 1996; Hooper e Upadhyaya, 1998; Upadhyaya et al., 1999b).

Tanto o reconhecimento de padrões como mais especificamente, a sua classificação, são considerados atualmente dentro de um contexto maior no qual podem ser tratados como subteorias da Teoria da Decisão (Duda et al., 2001). O custo envolvido na decisão definiria como consequência imediata o grau de separação necessária entre os clusters envolvidos na decisão. No caso do tubo de gerador de vapor, este custo pode ser considerado muito elevado, já que além das questões econômicas e de segurança envolvidas na decisão de tamponamento ou não do tubo analisado, existe a questão da velocidade em que esta decisão tem que ser tomada. Todos estes fatores nos levam a credenciar o problema de classificação dos defeitos em tubos de gerador de vapor em plantas nucleares como um problema que exige um alto grau de separabilidade entre as diferentes classes. É necessário o desenho de um algoritmo que seja capaz de construir uma região limiar de decisão que minimize os custos desta decisão.

As diferentes etapas de um sistema classificador podem ser divididas em: pré-processamento, extração das características e a classificação propriamente dita. Na fase de pré-processamento elimina-se, por alguma metodologia, toda (ou o máximo possível) a informação que não é objeto de interesse no conjunto da informação digital adquirida. A simples filtragem de ruídos intrínsecos à aquisição do sinal (informação digital) é considerada como um dos aspectos do pré-processamento. Basicamente, qualquer sistema de classificação utiliza como base modelos que são construídos em cima das características extraídas deste sinal de entrada. A classificação será a capacidade de escolher o modelo que melhor corresponde ao objeto de interesse na informação de entrada. Dependendo do custo desta escolha ou o custo associado ao erro da classificação, pode-se definir a utilidade ou eficácia de uma certa característica para a tomada de decisão adequada.

A base de conhecimentos relativa ao diagnóstico de tubos de geradores de vapor utilizando ECT não é claramente definida (EPRI, 1995). Boa parte das regras

para se classificar o tipo do defeito analisado variam muito, dependendo de em qual tipo de planta nuclear o tubo analisado está inserido e portanto a geometria, da composição do tubo e da química da água que o percorre.

**Upadhyaya et al. (1993)** foram pioneiros em propor um sistema automatizado de diagnóstico que abrangesse o pré-processamento (incluindo decodificação, calibração e filtragem do sinal), a extração de características e a classificação.

Apesar do pioneirismo e ousadia de Upadhyaya e colaboradores na proposição de um sistema amplo de automação, **Brown (1985)** elabora um algoritmo classificador baseado em “template matching” (concordância com modelos) em que utiliza descritores de Fourier desenvolvidos por **Udpa e Lord (1984)** para classificar sinais de sondas diferenciais. Em seu artigo Brown consegue parametrizar características de sinais de ECT de “support plates” (hastes de suporte) que são utilizadas para separar sinais distorcidos por degradações de sinais normais. Existe um relato no mesmo ano de uma apresentação oral na Materials Evaluation (**Shindo et al., 1985**) que se sugere a utilização do microcomputador para pré-processamento e classificação dos dados, mas o relato não é específico sobre quais metodologias foram utilizadas.

Ainda em 1990, **Udpa e Udpa (1990)** apresentam pela primeira vez uma tentativa mais consistente de classificação de diferentes tipos de defeitos utilizando uma rede neural artificial. Mais especificamente, os defeitos são divididos em quatro classes: “through wall hole defect” (buraco perfurante), “axisymmetric outer crack slot” (ranhura externa assimétrica), “flat bottomed hole” (buraco raso) e “axisymmetric inner defect slot” (ranhura interna assimétrica). Em sua rede neural os autores utilizam oito descritores de Fourier como característica do sinal utilizado na entrada, usando 40 vetores-padrão para o treinamento. O conjunto-teste de dados compreendia 21 vetores. Udpa e Udpa comparam a classificação da rede neural com a de um algoritmo padrão tipo “K-means” e afirmam que a rede neural apresenta vantagens. Apesar destes resultados poderem parecer satisfatórios em uma primeira

análise, mostram-se muito distantes de uma possível aplicação em dados de campo e que pudesse ser utilizado como base para um sistema de diagnóstico automatizado.

Podemos dizer que a evolução destas propostas de automatização acompanharam o desenvolvimento e disponibilização no mercado da tecnologia dos microcomputadores com crescente capacidade de armazenamento de dados e velocidade de processamento. A possibilidade de se atingir a meta de um sistema automatizado de análise de dados de campo de ECT em plantas nucleares, passa necessariamente pela capacidade de processar e armazenar grandes quantidades de dados referentes aos milhares de tubos de um gerador de vapor. Cada tubo geralmente é submetido a testes de multifrequência, o que implica em no mínimo quatro canais de frequência de excitação onde cada um destes canais apresenta um sinal real (resistência) e um imaginário (reatância indutiva).

Observamos na década de 90 a evolução da proposta de Upadhyaya et al. em seus relatórios técnicos (Upadhyaya et al., 1993; Yan e Upadhyaya, 1996; Hooper e Upadhyaya, 1998; Upadhyaya et al., 1999b) em paralelo com outras propostas. Estes autores chamaram o sistema proposto de EDDYAI. Este sistema era baseado na detecção dos defeitos por um algoritmo detector de picos aliado a um de inferência “fuzzy” que auxiliava na detecção do defeito. O sistema “fuzzy” funciona como um classificador na medida em que utiliza regras que verificam em que canais foram detectados picos de interesse. Se fossem observados picos de interesse em um conjunto de canais de frequência simultaneamente, o sistema inferiria se é defeito ou não e qual o tipo deste defeito. No entanto, estas regras tinham que ser mudadas para cada tipo de planta e/ou tubo. As regras “fuzzy” eram construídas baseadas em informações fornecidas pelo usuário a cada tentativa de detecção e classificação dos sinais. Outros aspectos deste sistema incluíam calibração e representação dos dados e compensação do ruído (“de-nosing”). Em 1996 Yan e Upadhyaya (1996) testaram algoritmos com diferentes configurações de redes neurais “feed-forward” de três camadas, para a estimativa da profundidade do defeito. Esta tentativa baseou-se em dados de um mesmo defeito (no caso “pitting”) e usava 80 nós de entrada, 50 nós na camada intermediária e apenas um nó de saída. Os autores também utilizaram redes

neurais probabilísticas para classificar três tipos de artefatos: suporte do tubo, ferrite ou cobre. Outros algoritmos foram testados e incorporados ao sistema EDDYAI. Entre estes destacamos a utilização de número de “wavelet zero-crossings” e centro de gravidade como características utilizadas em redes neurais (Yan e Upadhyaya, 1996; Upadhyaya et al., 1999b), em sistemas de inferência “fuzzy” e em árvores de busca (Hooper e Upadhyaya, 1998; Upadhyaya et al. 1999a) para classificação de tipos de defeitos.

Dodd (1996) do Laboratório Nacional de Oak Ridge, EUA, descreve em seu relatório técnico uma tentativa de utilizar redes neurais para estimar a profundidade de defeitos utilizando os sinais de resistividade e reatância indutiva de quatro diferentes frequências diretamente na entrada da rede. A entrada da rede portanto era composta de nove nós, onde um deles funcionava como o controle de “bias” (polarização).

Outra proposta que deu sequência à anterior, foi o Programa de Integridade do Tubo de Gerador de Vapor do Laboratório Nacional de Argonne, Illinois, EUA (Diereks et al., 1997). O relatório técnico descreve uma tentativa de classificação utilizando redes neurais para prever ou estimar a profundidade do defeito utilizando tubos com defeitos fabricados e metalograficamente analisados (produzidos no PNNL – Pacific Northwest National Laboratory). A maioria dos defeitos fabricados eram externos ao tubo e simulando um defeito tipo IGA (“intragranular attack” – ataque intra-granular). No mesmo relatório técnico Diercks e colaboradores relataram tentativas de usar diferentes técnicas de ultrassom, estimando a profundidade pelo “time of flight” (tempo para a resposta). No todo, a classificação, utilizando redes neurais, se concentra somente na estimativa da profundidade do defeito e não na classificação entre os diferentes tipos de defeito.

A proposta do PNNL (Kurtz et al., 1996) relata uma tentativa de estimar o tamanho da falha por um modelo de regressão, em que se tenta estimar a POD (probabilidade de detecção) e o dimensionamento da falha.

## 5 - MAPAS DE KOHONEN (“SELF-ORGANIZING MAPS”)

### 5.1 - Redes Neurais

A história do desenvolvimento das redes neurais se confunde com a história da inteligência artificial. O fim da década de 1950 foi caracterizado pelo surgimento de programas de computador capazes de desempenhar tarefas semelhantes às humanas tentando utilizar estudos contemporâneos sobre o funcionamento do cérebro como modelos para estes novos algoritmos. Este enfoque de tentar reproduzir modelos de funcionamento do cérebro, levou à utilização do termo “inteligente” para estes algoritmos.

A conferência realizada nos Estados Unidos da América em 1956, a “Dartmouth Summer Research”, é citada por **Tsoukalas e Uhrig (1996)** como tendo sido um dos eventos que levou a “onda” de desenvolvimento destes algoritmos “inteligentes” e que inspirou **Rosenblatt (1961)** a desenvolver seu conceito de “perceptron”, uma generalização do conceito de McCulloch-Pits (**McCulloch e Pits 1943**) para o funcionamento do cérebro. O modelo abstrato de uma unidade do cérebro era baseado na teoria de que a probabilidade de que um neurônio fosse ativado dependeria dos sinais de entrada e das voltagens limites (“threshold”) no corpo do neurônio.

Uma das primeiras “máquinas de aprendizado” conhecidas continha quarenta elementos processadores e foi construída por Minsky e Dean em 1951 no Instituto de Tecnologia de Massachussets (**Tsoukalas e Uhrig, 1996**). Os elementos processadores já configuravam uma rede em que “sinapses” ajustavam seus pesos de acordo com o sucesso em desempenhar uma tarefa específica (**Tsoukalas e Uhrig, 1996**).

O desenvolvimento histórico das redes neurais pode ser encontrada em vários livros lançados na última década (Caudill e Butler, 1989; Simpson, 1990; Wasserman, 1993).

As redes neurais artificiais podem ser definidas como “um sistema de processamento de dados que consiste de um grande número de elementos processantes (neurônios artificiais) altamente interconectados numa arquitetura baseada na fisiologia do sistema nervoso central do cérebro” (Tsoukalas e Uhrig, 1996). O termo artificial se refere justamente ao caráter “imitativo” de estruturas de funcionamento do cérebro.

O princípio de funcionamento destes sistemas, o neurônio artificial, é um elemento processante de dados que apresenta características semelhantes ao seu par natural. Este neurônio artificial se constitui de uma unidade processante que, em geral, apresenta um conjunto de entradas que corresponderiam aos dendritos do neurônio biológico. Os dados que utilizam cada uma destas entradas são modificados por um peso (cuja função seria semelhante à junção sináptica biológica) que pode ser negativo ou positivo dependendo se tal entrada deve ser inibida ou amplificada respectivamente. Cada neurônio artificial em geral apresenta duas etapas de processamento dos dados. Na primeira, ocorre a soma dos dados referentes às entradas já modificadas pelos pesos resultando em um valor único, e na segunda, este valor agregado obtido passa por uma função não linear chamada de função de ativação, que gera a saída da unidade. Na figura 5.1 pode-se observar os esquemas representativos do neurônio biológico e o do neurônio artificial.




Figura 5.1 – Modelo de neurônio natural e correspondente artificial  
(Tsoukalas e Uhrig, 1996; com modificações)

A rede neural artificial é então composta de um conjunto destas unidades processantes, arranjadas em uma seqüência de camadas com conexões entre estas camadas ou unidades. Estas conexões podem ser completas, onde todos os neurônios da rede são interconectados, completa entre camadas, o que significa que cada neurônio da camada anterior é conectado com todos os outros da camada posterior, ou pode se parcial. Pode-se definir a arquitetura básica da rede neural como um grafo direto no qual cada nó  $i$  tem uma função de transferência ou de ativação  $f_i$ . O processamento de um neurônio artificial pode ser descrito como:

$$y_i = f\left(\sum_{j=1}^n w_{ij}x_j - \theta_i\right) \quad (5.1)$$

onde  $\theta_i$  é o limiar de ativação,  $x_j$  são os vetores de entrada daquele neurônio,  $w_{ij}$  são os pesos a cada uma destas entradas,  $f$  é a função de ativação citada acima e  $n$  é o número de vetores de entrada conectados.

Um arranjo típico desta arquitetura é mostrado na figura 5.2.




Figura 5.2 – Exemplo de arquitetura de rede neural artificial  
(Tsoukalas e Uhrig, 1996; modificada)

A rede ilustrada na figura 5.2 tem a arquitetura típica da chamada rede neural “feedforward” (com alimentação para frente). Esta rede recebe um vetor  $n$ -dimensional através de suas  $n$  diferentes entradas e processa este vetor através dos pesos associados à cada uma destas entradas. Cada entrada da rede associa um peso a uma componente do vetor e “distribui” esta componente pelos neurônios da camada seguinte. Se a rede for conectada plenamente, cada neurônio da segunda camada terá  $n$  entradas referentes as  $n$  componentes do vetor de entradas da segunda camada já alteradas pelo peso. Cada neurônio da segunda camada somará os valores recebidos da primeira camada e processará esta soma por uma função de ativação. Estes cálculos são propagados em série através da rede em direção da última camada. Este processo é direto e pode ser representado como uma multiplicação vetorial (não levando em conta a função de ativação):

$$Y_k = W_{ij} W_{jk} X_j = W_{ijk} X_i \quad (5.2)$$

onde  $i$ ,  $j$  e  $k$  são subíndices referentes às primeira, segunda e terceira camadas respectivamente,  $X$  é o vetor de entrada,  $W$  é a matriz de pesos referente ao conjunto de conexões entre os neurônios de diferentes camadas e  $Y$  é o vetor de saída. Este processo pode ser mais complexo à medida que as interconexões entre os neurônios fogem deste padrão, como por exemplo, existir conexão entre neurônios na mesma camada, ou realimentação (“feedback”), ou conexão de neurônios de camadas posteriores (mais próximas à saída da rede) para camadas anteriores.

As redes neurais artificiais são aptas a exercer a função de memória. Elas são capazes de funcionar como sistemas que aprendem e armazenam relações não lineares, muitas vezes implícitas, entre os vetores de entrada e a saída do sistema. Por isto, em geral são utilizadas em duas fases diferentes. A primeira fase consiste no processo de aprendizado da rede e é geralmente chamado de treinamento. Posteriormente, a rede já com o aprendizado acumulado (memorizado), através dos vetores-peso modificados na fase de treinamento, funciona como uma função de transferência não-linear entre a entrada e a saída. Nesta fase a rede tem uma resposta quase instantânea, já que vai simplesmente processar os dados de entrada através dos pesos já modificados.

O aprendizado acontece nas redes neurais através das atualizações dos pesos associados a cada conexão entre diferentes neurônios, estabelecida inicialmente. À medida em que o algoritmo progride, algumas conexões podem vir a “desaparecer” através da anulação do peso associado àquelas conexões que pouco ou nada contribuem para que a rede atinja a meta estabelecida. Outras conexões podem ser reforçadas, dependendo do problema e algoritmo de treinamento. O aprendizado da rede pode ser supervisionado ou não. No aprendizado supervisionado, a rede é treinada para fornecer a resposta desejada para um estímulo específico de entrada. No treinamento não supervisionado nenhuma informação relacionada à saída esperada do sistema, se existir, é utilizada no treinamento.

Como uma das características principais de uma rede neural artificial é a capacidade de aprendizado, a caracterização dos algoritmos que implementam este método depende fortemente das técnicas de treinamento existentes.

A categorização dos diversos modelos de redes neurais difere muito de acordo com a área de aplicação ou o tipo de análise. Uma categorização clássica divide os modelos em redes de “transferência de sinal”, redes de “transferência de estado” e redes de “aprendizado competitivo”.

As chamadas redes de transferência de sinal efetuam um mapeamento paramétrico dos sinais de entrada definido por funções de base ou funções de ativação fixas. As funções de base são ajustadas aos dados por computação algébrica ou otimização de gradiente. Estão incluídas nesta categoria as redes de propagação direta (“feedforward”), as multicamadas (MLP) (Rosenblatt, 1961), a “madaline” (Widrow e Hoff, 1960), e aquelas que utilizam o algoritmo de retropropagação do erro (Werbos, 1974; Rumelhart et al., 1986). As redes de função de base radial também podem ser incluídas nesta categoria (Kohonen, 2001).

As chamadas redes de transferência de estado apresentam valores de estado de atividade característicos destas redes. O estado inicial é definido pela informação contida pelos dados de entrada. Estas redes utilizam efeitos de relaxação e realimentação que produzem não linearidades com o objetivo de convergir para outro valor de estado característico da rede (um atrator). Dentre os modelos que podem ser incluídos nesta categoria podemos citar as redes de Hopfield (1982) e a máquina de Boltzmann (Ackley et al., 1985). Os modelos de memórias associativas bidirecionais podem ser incluídas nesta categoria.

A terceira categoria de redes neurais são as chamadas redes de aprendizado competitivo. Estas redes utilizam um mecanismo de competição entre os neurônios que as compõe, com o objetivo de determinar qual destes neurônios é o mais apropriado ou mais adaptado ao dado de entrada. Após estabelecidos os critérios para esta competição, o neurônio “vencedor” é utilizado como modelo ou centro para a

atualização dos pesos associados aos neurônios vizinhos na rede. Geralmente o processo de atualização é realizado através de interações laterais negativas ou positivas correspondentes à menor ou maior atividade desejada para o conjunto de neurônios vizinhos. Em algumas destes algoritmos apenas a célula ou neurônio “vencedor” se torna sensível ao aprendizado da entrada daquela iteração. Ao longo do processo de atualização se espera que a rede como um todo aprenda ou codifique o domínio da entrada. As redes neurais mais utilizadas nesta categoria são os chamados mapas auto-organizáveis de Kohonen (“self-organizing maps” – SOM) (Kohonen, 1982). Outro método importante nesta categoria, que surgiu a partir do SOM, é o algoritmo de aprendizado de quantização vetorial (“linear vector quantization” – LVQ) (Kohonen, 1988a; Mandami, 1977). As principais aplicações destes métodos são o reconhecimento estatístico de padrões ou classificação.

Apesar da categorização clássica apresentada, existem dilemas quanto às características específicas de uma rede neural. Um bom número de novos algoritmos de estatística matemática são publicados em jornais e conferências como métodos de rede neural artificial (Kohonen, 2001). Dentre estes, pode-se citar as redes analisadoras de componentes principais (PCA) (Kramer, 1991) e as redes de componentes independentes (ICA) (Oja, 1997; Karhunen et al., 1997).

Existem diversos tipos de arquiteturas de rede e mecanismos de treinamento. Descrições detalhadas das diversas arquiteturas, mecanismos de treinamento utilizados e desenvolvimento histórico das redes podem ser encontradas em uma variedade muito grande de livros publicados na última década, que abrangem desde a introdução aos algoritmos e idéias básicas (Tsoukalas e Uhrig, 1996; Beale e Jackson, 1990; Wasserman, 1989; Zeidenberg, 1989; Rao e Rao, 1995), até discussões mais sofisticadas da teoria envolvida nestes sistemas (Kosko, 1992; Reed e Marks II, 1998) e algumas aplicações em reconhecimento de padrão (Ripley, 1996; Bishop, 1995; Luo, 1997; Bunke e Kandel, 2000).

## 5.2 - Treinamento e Aprendizado de Redes Neurais

Historicamente, as redes neurais foram “esquecidas” pela comunidade acadêmica devido à controvérsia quanto às limitações da aplicabilidade destes algoritmos somente a espaços de solução linearmente separáveis. O desenvolvimento original foi realizado independentemente por **Parker (1972)** e por **Werbos (1974)** e o estabelecimento sistemático do algoritmo de propagação de erro por realimentação ou retropropagação (“backpropagation”) foi feito por **Rummelhart et al. (1986)**. Este algoritmo possibilitou a retomada do desenvolvimento da redes neurais artificiais. As limitações alegadas para o abandono da técnica no começo da década de 1970 se mostraram facilmente superáveis com a utilização de uma terceira camada e com a utilização do algoritmo de retropropagação. Atualmente a grande maioria das aplicações de redes neurais utilizam este algoritmo de treinamento.

O algoritmo de retropropagação do erro é baseado na chamada regra delta de Widrow-Hoff (**Widrow e Hoff, 1960**). As principais regras de aprendizado utilizadas em treinamento de redes neurais são a regra de Widrow-Hoff, a regra de **Hebb (1949)** e as regras de aprendizado competitivo. Estas regras são utilizadas por diferentes tipos de arquiteturas e aplicações.

A regra delta de Widrow-Hoff é uma minimização por decréscimos de gradiente, do erro quadrado da rede. O erro da rede é estabelecido pela diferença entre o resultado alvo (treinamento supervisionado) e o resultado obtido na saída da rede após cada iteração. A atualização dos pesos da rede pode ser definida pela relação 5.3:

$$\Delta w_i = -k \frac{\partial \varepsilon^2}{\partial w_i} \quad (5.3)$$

onde  $k$  é uma constante de proporcionalidade,  $w$  é o vetor peso, e o erro  $\varepsilon$ , é definido pela relação 5.4,

$$\varepsilon = y - \sum_{i=1}^n w_i x_i \quad (5.4)$$

onde  $y$  é a saída do neurônio e  $x$  é o vetor de entrada.

A atualização dos pesos pode ser escrita então como:

$$\Delta w_i = k 2(y - \sum_{i=1}^n w_i x_i) x_i = 2k \varepsilon x_i \quad (5.5)$$

Desta forma, a atualização dos pesos é diretamente proporcional ao erro, o que aumenta sobremaneira a velocidade de atualização e treinamento da rede. Alguns problemas comuns a redes neurais que utilizam a retropropagação do erro estão relacionados com o “aprisionamento” em soluções chamadas de mínimos locais. O mínimo local se refere à curva de minimização do erro quadrático. Esta superfície quadrática costuma apresentar vales que têm valores capazes de serem interpretados pelo algoritmo como soluções finais, apesar de existirem outras soluções com erros menores. Alguns termos foram adicionados à regra delta como paliativos deste problema. Um dos termos mais difundidos é o chamado momento, que é proporcional à atualização de pesos da iteração prévia. A equação 5.6 define uma atualização típica de retropropagação que utiliza o momento.

$$\Delta w(N+1) = -\eta \delta \Phi + \mu \Delta w(N) \quad (5.6)$$

onde  $\eta$  é a constante de aprendizado (geralmente entre 0 e 1),  $\Phi$  é o valor de ativação do neurônio,  $\delta$  é a constante de proporcionalidade entre a saída e a atualização do peso, e  $\mu$  é o momento (referente a iteração anterior).

Na prova da convergência do algoritmo de retropropagação, **Rumelhart et al. (1986)** usaram ajustes infinitesimais. Se o tamanho do passo de treinamento é muito pequeno, o tempo de treinamento é muito longo, e se o degrau é muito grande

pode ocorrer instabilidade. A escolha da constante de aprendizado adequada permite a convergência no treinamento da rede.

Outro método utilizado em retropropagação, para escapar do “mínimo local” é o chamado “simulated annealing” que utiliza regras estatísticas para a busca do mínimo global. Detalhes deste procedimento são discutidas em muitas referências (Hecht-Nielsen, 1990; Korn, 1992; Aarts e Korst, 1989).

Existem variações do método de retropropagação, como a retropropagação rápida (“fast backpropagation”) (Samad, 1988), onde um múltiplo do erro na camada  $k$  é adicionada ao valor de ativação desta camada, antes de atualizar os pesos. Outra variação foi introduzida por Fahlman (1988) utilizando um método de segunda ordem relacionado ao método de Newton para atualização dos pesos.

Um outro importante método de aprendizado, utilizado em redes neurais, é o chamado aprendizado “Hebbiano” que foi enunciado não matematicamente por Donald Hebb (1949). Este foi o primeiro sistema auto-organizável e foi definido matematicamente por Steven Grossberg (1976) através da equação 5.7.

$$w_{AB}^{novo} = w_{AB}^{velho} (1 - \alpha) + \beta x_B x_A \quad (5.7)$$

onde  $w_{AB}$  é o peso da conexão sináptica entre o neurônio A e B. O termo  $\alpha$  era definido como o termo de “esquecimento” e o termo  $\beta$  como sendo a constante de aprendizado responsável pela ativação simultânea dos neurônios A e B. O termo da direita é chamado de termo de aprendizado “Hebbiano” e se refere à ligação entre a constante de aprendizado e o produto das ativações dos dois neurônios.

Outros tipos de redes neurais utilizam variações destes métodos de treinamento como a Memórias Associativas, das quais as chamadas Redes de Hopfield têm um método de atualização característico, onde as conexões são reforçadas quando a saída do neurônio é a mesma que a entrada e são enfraquecidas quando existe discrepância entre a entrada e a saída.

O outro tipo de algoritmo de treinamento envolve o chamado aprendizado competitivo. Historicamente, o mapa auto-organizável de Kohonen é considerado o sistema auto-organizável mais simples e utiliza o aprendizado competitivo. Este sistema consiste de uma camada simples de neurônios (chamada de camada de Kohonen) que são altamente interconectados (conexões laterais) dentro da camada e fora da rede através da camada de entrada (acumuladora) que é totalmente conectada aos neurônios da camada de Kohonen através de pesos ajustáveis.

A seguir é feita uma descrição de um conjunto de algoritmos que utilizam o princípio de aprendizado competitivo. Alguns deles não são considerados necessariamente como redes neurais.

### 5.2.1 - Métodos de Aprendizado Competitivo

Atualmente, existe um grande número de modelos sendo propostos que utilizam o aprendizado competitivo. A análise estatística multivariada tem encontrado nas novas metodologias computacionais um campo para expandir e testar modelos. Neste sentido as técnicas de inteligência artificial, e especialmente as redes neurais, têm sido técnicas incorporadas a diferentes algoritmos que utilizam o aprendizado competitivo. Um objetivo comum destes algoritmos é distribuir um certo número de vetores de entrada em um possível espaço multi-dimensional. A distribuição destes vetores neste espaço deveria refletir a distribuição de probabilidade da entrada, que normalmente não pode ser conhecida explicitamente mas inferida a partir de amostras.

Baseado em Fritzke (1997) alguns dos métodos de aprendizado competitivo serão descritos brevemente com o objetivo de situar o método de Kohonen dentro da perspectiva do desenvolvimento destes algoritmos. Esta perspectiva não segue uma linha evolutiva histórica, e sim um conjunto de propriedades comuns que caracterizam estes métodos. Estas redes,  $\mathcal{A}$ , são compostas de  $N$  unidades,  $\mathcal{A} = \{c_1, c_2,$

...,  $c_n$ }, onde cada unidade tem um vetor de referência,  $w_c \in R^n$ , indicando sua posição ou “centro de campo receptivo” no espaço de entrada. Entre as unidades da rede existe um conjunto (que pode ser vazio)  $C \subset \mathcal{A} \times \mathcal{A}$ , de conexões de vizinhança que são simétricas e sem peso. Para uma unidade  $c$  define-se o conjunto  $N_c$  dos vizinhos topológicos diretos. Os sinais de entrada  $n$ -dimensionais são considerados como sendo gerados ou por uma função de distribuição de probabilidade  $p(\xi)$ ,  $\xi \in R^n$ , ou a partir de um conjunto de dados de treinamento,  $\mathcal{D} = \{\xi_1, \xi_2, \dots, \xi_M\}$ ,  $\xi_i \in R^n$ . Para um dado sinal de entrada,  $\xi$ , o vencedor  $s(\xi)$  entre as unidades de  $\mathcal{A}$  é a unidade com o vetor de referência mais próximo definido pela relação 5.8, a seguir:

$$s(\xi) = \arg \min_{c \in \mathcal{A}} \|\xi - w_c\| \quad (5.8)$$

onde  $\|\cdot\|$  define o vetor-norma Euclideano.

Um conceito de geometria computacional importante nesta descrição é a chamada região de Voronoi. Dado um conjunto de vetores,  $w_1, w_2, \dots, w_n \in R^n$ , a região de Voronoi,  $V_i$  de um vetor particular,  $w_i$ , é definida como o conjunto de pontos em  $R^n$  para o qual o vetor  $w_i$  é o vetor mais próximo (equação 5.9).

$$V_i = \{\xi \in R^n \mid i = \arg \min_{j \in \{1, \dots, N\}} \|\xi - w_j\|\} \quad (5.9)$$

A partir da suposição de que cada região de Voronoi,  $V_i$  é uma área convexa, define-se a Tecedura de Voronoi ou Tecedura de Dirichlet como a partição de  $R^n$  formada por todos os polígonos de Voronoi (figura 5.3). Este conceito é aplicável a dimensões arbitrariamente superiores (Fritzke, 1997). Outra definição conseqüente é a Triangulação de Delaunay, que é definida pela conexão de todos os pontos para os quais as regiões de Voronoi compartilham uma borda (figura 5.3). Esta triangulação tem propriedades especiais, pois é a única triangulação na qual os círculos circunscritos de cada triângulo não contêm outro ponto além dos vértices do triângulo. Omohundro (1990) demonstrou que esta triangulação é ótima para a interpolação de funções. O método de aprendizado “Hebbiano” gera um subgrafo da

triangulação de Delaunay que é limitada àquelas áreas do espaço de entrada onde se encontram os dados (Fritzke, 1997).

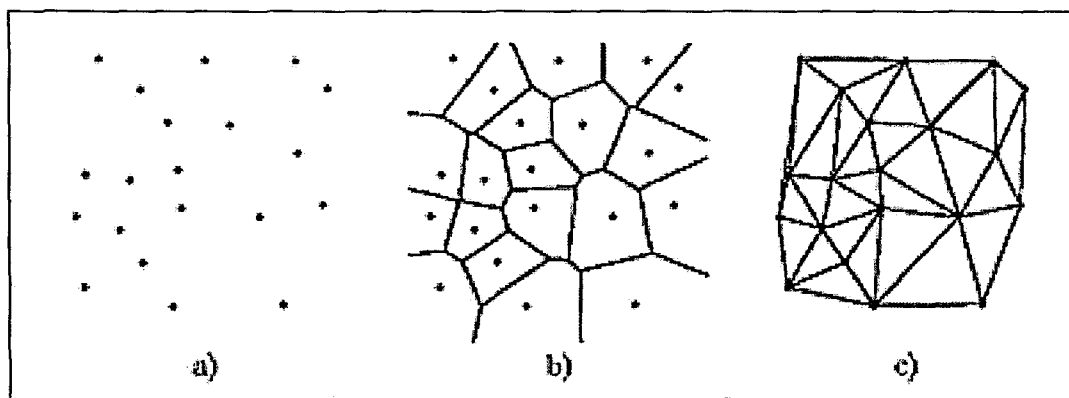


Figura 5.3 – a) conjunto de pontos em  $R^2$ ; b) tecedura de Voronoi correspondente; c) triangulação de Delaunay correspondente (Fritzke, 1997).

Ainda segundo Fritzke, os métodos de aprendizado competitivo podem ser divididos em brutos e suaves. Os métodos “brutos” seriam caracterizados pela atualização de apenas uma unidade (a vencedora) para cada sinal de entrada. Os métodos “suaves” atualizariam mais de uma unidade para cada sinal de entrada. Outra característica que divide estes métodos é a dimensionalidade fixa ou não da rede. O mapa auto-organizável de Kohonen se insere nesta última categoria.

Os principais objetivos destes algoritmos são a minimização do erro, a maximização da entropia e o mapeamento de características. Algumas variações quanto ao método de atualização deram origem a um dos algoritmos mais importantes deste tipo, chamado Aprendizado Generalizado de Lloyd (Linde et al., 1980; Forgy, 1965; Lloyd, 1957), que utiliza o treinamento em lote. Este método funciona movendo todos os vetores de referência para a média aritmética de seus conjuntos de Voronoi.

Em situações em que o conjunto de dados,  $\mathcal{D}$ , é muito grande, o método de atualização em lote se torna pouco prático. Neste caso a atualização dos vetores é feita apenas para a unidade “vencedora” utilizando uma taxa de atualização,  $\lambda$ . Se esta taxa é constante e está entre 0 e 1, o valor de cada vetor  $w_c$  representa uma média que decai exponencialmente, daqueles sinais de entrada para os quais  $c$  foi a “vencedora”. Este sistema se mantém adaptativo e é, em princípio, apto a funcionar sobre uma distribuição de sinais não estacionária  $p(\xi)$ . No entanto, esta taxa de atualização constante implica em problemas quanto à convergência (Fritzke, 1997).

Um outro método que não mantém esta taxa de atualização constante é o conhecido “k-means” (MacQueen, 1967), no qual a taxa de aprendizado é individual para cada vetor de referência. Esta taxa é dada por  $\lambda = 1/t$ , onde o parâmetro  $t$  é o número de sinais para os quais esta unidade em particular foi a vencedora até então. Neste caso, cada vetor de referência é sempre exatamente a média aritmética dos vetores de entrada para os quais  $c$  foi o “vencedor”. Portanto apesar de  $w_c(t)$  representar a média aritmética dos sinais de entrada (equação 5.10), alguns destes podem estar em regiões de Voronoi pertencentes a outras unidades de referência. A razão para isto é que cada adaptação de  $w_c$  muda as bordas da região de Voronoi  $V_c$ .

$$w_c(t) = w_c(t-1) + \lambda(t)(\xi_t^c - w_c(t-1)) = \frac{\xi_1^c + \xi_2^c + \dots + \xi_t^c}{t} \quad (5.10)$$

Este algoritmo teria um problema na convergência já que a série harmônica infinita de  $1/t$  diverge. No entanto, foi demonstrado que este algoritmo converge assintoticamente para uma configuração onde cada vetor de referência  $w_c$  é posicionado de forma que coincida com o valor esperado (E) de sua região de Voronoi,  $V_c$  (MacQueen, 1965), ou seja:

$$E(\xi | \xi) \in V_c = \int_c \xi p(\xi) d\xi \quad (5.11)$$

Outro tipo de taxa de decaimento do aprendizado foi proposta por **Ritter et al. (1991)** para mapas auto-organizáveis. Eles propuseram uma taxa de decaimento descrita por:

$$\lambda(t) = \lambda_i (\lambda_f / \lambda_i)^{t/t_{max}} \quad (5.12)$$

onde  $\lambda_i$  e  $\lambda_f$  são os valores inicial e final da taxa de aprendizado, enquanto  $t_{max}$  é o número máximo de passos de adaptação adotado.

Alguns métodos competitivos “suaves” não apresentam topologia com dimensionalidade fixa imposta sobre a rede. Um algoritmo típico é o chamado “Gás Neural” (**Martinez e Schulten, 1991**), que não tem nenhuma topologia definida. Este algoritmo ordena as unidades da rede para cada vetor de entrada de acordo com as distâncias aos vetores de referência. Algumas unidades da rede são atualizadas de acordo com o ordenamento obtido.

Outro método “suave” é o chamado Aprendizado Competitivo “Hebbiano” (**Martinez e Schulten, 1991; Martinez, 1993**). Normalmente este método é utilizado em conjunto com outros. Neste método não há mudança nos vetores de referência, o que poderia ser interpretado como uma taxa de aprendizado igual a zero. As mudanças acontecem nas bordas de vizinhança geradas entre as unidades da rede. **Martinez (1993)** provou que o grafo gerado por este algoritmo preserva a topologia num sentido geral, onde cada borda pertence à triangulação de Delaunay correspondente a um dado conjunto de vetores de referência.

Uma justaposição entre os dois métodos anteriores é chamada de Redes de Representação Topológica (**Martinez e Schulten, 1991; 1994**). Neste algoritmo, cada passo de adaptação gera uma conexão entre a unidade “vencedora” e segunda unidade mais próxima (aprendizado “Hebbiano”). Os vetores de referência são atualizados segundo o método “gás neural”, sendo utilizado um mecanismo para remover as bordas não mais válidas.

Uma mudança neste algoritmo que altera o número de unidades do mapa durante o processo de auto-organização é proposta por **Fritzke (1994a; 1995)**. Este método alia o mecanismo de crescimento de células (“growing cell structures”) (**Fritzke, 1994b**) com a geração de topologias de aprendizado “Hebbiano” de **Martinez e Schulten (1991)**. Para determinar onde inserir as novas unidades, medidas de erro local são utilizadas durante o processo de adaptação, e a inserção é feita próxima à unidade com maior acúmulos de erro.

Outros métodos sem uma dimensionalidade de rede fixa são conhecidos, como o proposto por **DeSieno (1988)**, onde “vencedores” frequentes ganham uma “consciência pesada” por ganhar tanto, e portanto, adiciona um termo de penalidade à distância ao sinal de entrada. Isto leva eventualmente, a uma situação onde cada unidade ganha aproximadamente com a mesma frequência (maximização da entropia).

Os métodos “suaves” com dimensionalidade fixa determinam previamente a dimensão  $k$  da rede a ser treinada. Uma das vantagens da rede de dimensão fixa é que ela define um mapeamento a partir do espaço de entrada  $n$ -dimensional (com  $n$  sendo arbitrariamente grande) para o espaço  $k$ -dimensional. Isto torna possível obter uma representação de baixa dimensionalidade dos dados que pode ser utilizada para propósitos de visualização.

Dentro do universo de algoritmos competitivos o mapa auto-organizável de Kohonen é o mais conhecido e aplicado. Ele apresenta dimensionalidade fixa e é “suave” (atualiza mais de uma unidade do mapa por iteração). A topologia é restrita a uma grade bi-dimensional que não muda durante a auto-organização. A distância nesta grade é utilizada para determinar o quão fortemente a unidade é atualizada quando uma unidade próxima é a “vencedora”. A medida de distância utilizada originalmente foi a chamada norma  $L_1$  (também conhecida como distância de Manhattan), dada pela seguinte expressão:

$$d_{L_1} = |x - u| + |y - v| \quad (5.13)$$

onde  $(x,y)$  e  $(u,v)$  são pontos em um plano de duas dimensões. No entanto, outras distâncias também podem ser utilizadas como a distância  $L_2$ , ou distância Euclidiana simples.

### 5.3 - Mapas auto-organizáveis de Kohonen

Os mapas auto-organizáveis, ou mapas de Kohonen (SOM) podem ser descritos como sendo redes neurais de uma única camada de neurônios com alto grau de interconexão lateral (dentro da própria camada). O termo “auto-organizável” se refere à habilidade de aprendizado não supervisionado.

Algumas aplicações de SOM em classificação de sinais são relacionadas a seguir. Uma das primeiras aplicações de algoritmos SOM para processamento e classificação de sinais foi publicada por **Kennedy e Morasso (1990)** na qual são descritas uma segmentação de imagens e um agrupamento de caracteres manuscritos. **Chiueh et al. (1994)** fazem um quantização vetorial usando SOM em imagens novamente. **Debeljak et al. (2001)** aplicam SOM para classificação de sistemas cromatográficos. Uma das aplicações em sinais de radar utilizando SOM e LPC como na extração de características foi relatado por **Sadjadi et al. (2000)**.

Estas redes utilizam inibição lateral que variam as forças de conexão entre as unidades do mapa ou da rede de modo inversamente proporcional à distância topológica entre as unidades, moderando a competição entre os neurônios. Quando um padrão de entrada é apresentado a uma camada de Kohonen, cada neurônio recebe uma cópia completa do padrão de entrada modificado pelos pesos de conexão, e a variação das respostas estabelecem uma competição que se propaga pelas conexões. O propósito da competição é determinar qual neurônio tem a resposta mais forte à entrada. Cada neurônio tenta amplificar sua saída e a saída de seus vizinhos imediatos e inibir a saída dos neurônios mais distantes.


O SOM se aproxima muito do escalamento multidimensional (estatístico). O principal objetivo do método é representar todos os pontos de espaço fonte por pontos num espaço-alvo, tal que as relações de distância e proximidade sejam preservadas ao máximo. A necessidade de se armazenar amostras é relativamente pequena, requerendo menos complexidade do que o escalamento multidimensional. O aprendizado de tais mapas de Kohonen é muito geral e pode ser aplicado a praticamente qualquer espaço fonte, espaço-alvo, e mapeamento contínuo não linear (Duda et al., 2001).

Formalmente, o SOM pode ser descrito como um mapeamento de dados não-linear, ordenado e suave sobre os elementos de uma matriz regular e de baixa dimensionalidade (Kohonen, 2001). A implementação deste mapeamento se assemelha à quantização vetorial clássica, diferindo principalmente no ordenamento que descreve a distribuição do espaço de entrada.

Supondo que o conjunto de variáveis de entrada  $\{\Lambda_i\}$  seja definível como um vetor real  $\mathbf{x} = \{\Lambda_1, \Lambda_2, \dots, \Lambda_n\}^T \in R^n$ , cada elemento na matriz SOM é também associado com um vetor real paramétrico (modelo):  $\mathbf{m}_i = \{\mu_1, \mu_2, \dots, \mu_n\}^T$ .

Considerando uma medida de distância geral  $d(\mathbf{x}, \mathbf{m}_i)$  entre  $\mathbf{x}$  e  $\mathbf{m}_i$ , pode-se definir a imagem de um vetor de entrada  $\mathbf{x}$  na matriz SOM como um elemento de matriz  $\mathbf{m}_c$  que melhor se ajusta a  $\mathbf{x}$ , ou seja, que tenha o índice  $c = \arg \min_i \{d(\mathbf{x}, \mathbf{m}_i)\}$ .

O algoritmo SOM provê novos valores para cada nó (e seus vizinhos) em cada iteração comparando cada amostra de entrada  $\mathbf{x}(t)$ , onde  $t$  é um índice inteiro, com todos os  $\mathbf{m}_i$ , otimizando a medida de distância. Foi provado que se  $\mathbf{x}(t)$  e  $\mathbf{m}_i$  são vetores Euclidianos e uma medida de distância suavizada localmente é utilizada, o processo converge (Bouton, 1992). Os nós são arranjados inicialmente em posições que obedecem a função topológica e são atualizados usando a regra de Kohonen e alguns algoritmos de atualização. Um exemplo deste arranjo topológico é mostrado na figura 5.4 com sinais do espectro da fala num mapa bi-dimensional numa rede que utiliza a topologia hexagonal para a atualização dos vetores paramétricos  $\mathbf{m}_i$ .



**Figura 5.4 - Grade hexagonal com representação dos vetores paramétrico da rede correspondentes ao espectro de fala natural (Kohonen, 2001).**

O aprendizado desta rede é realizado de forma que durante o treinamento, os nós que tenham proximidade topográfica dentro de um certo raio geométrico interagem entre si para modificarem seus pesos de acordo com a mesma entrada. Este procedimento resulta num efeito de suavização local destes vetores pesos que com a repetição do processo geram um ordenamento global do mapa. A equação 5.14 descreve este processo considerando-se os limites de convergência, onde os valores iniciais de  $m_i$  podem ser arbitrários, ou aleatórios. Os valores de  $t$  na equação são inteiros e se referem às iterações.

$$m_i(t+1) = m_i(t) + h_{ci}(t)[x(t) - m_i(t)] \quad (5.14)$$

A função  $h_{ci}(t)$  é chamada função de vizinhança e funciona como elemento suavizador dos pesos no processo de atualização durante o treinamento. Para que haja convergência do algoritmo é necessário que  $h_{ci}(t) \rightarrow 0$  quando  $t \rightarrow \infty$ . Geralmente  $h_{ci}(t) = h(\|r_c - r_i\|, t)$ , onde  $r_c \in \mathfrak{R}^2$  e  $r_i \in \mathfrak{R}^2$  são os vetores de localização dos nós  $c$  e  $i$ , respectivamente, no mapa. A forma da função  $h_{ci}$  incluindo sua largura

média acarreta o grau de suavização da “superfície elástica” a ser ajustada aos dados (Kohonen, 2001).

As funções de vizinhança mais utilizadas na literatura são a mais simples e a Gaussiana. A mais simples é definida como  $h_{ci}(t) = \alpha(t)$  em relação ao conjunto  $N_c(t)$  em torno do polo  $c$  onde  $\alpha(t)$  é associada a taxa de aprendizado (normalmente com valores entre 0 e 1) e monotonicamente decrescente no “tempo”.

A função gaussiana é descrita na equação 5.15. O valor escalar  $\alpha(t)$  é decrescente e o parâmetro  $\sigma(t)$  define a largura da distribuição correspondente ao raio de  $N_c(t)$ .

$$h_{ci}(t) = \alpha(t) \cdot \exp\left(-\frac{\|r_c - r_i\|^2}{2\sigma^2(t)}\right) \quad (5.15)$$

Segundo Kohonen (2001) o processo de seleção destes parâmetros não é muito crucial para mapas de algumas centenas de nós, a não ser a escolha do tamanho da vizinhança  $N_c(t)$ . Se esta vizinhança for muito pequena no começo do treinamento, pode não haver ordenamento global do mapa. Isto pode gerar um conjunto de falsos agrupamentos. Isto pode ser evitado pela escolha de um valor relativamente grande para o raio inicial de treinamento. Este valor grande pode ser maior que a metade do diâmetro da rede e deve diminuir linearmente com o “tempo” geralmente na chamada fase de “ajuste fino” do treinamento. No caso de mapas muito grandes, a minimização do tempo de aprendizado total pode ser crucial. No entanto, até agora estes parâmetros têm sido determinados experimentalmente (Kohonen, 2001).

Como o processo de aprendizado desta rede é estocástico, a precisão estatística do mapa depende do número de passos na fase final de convergência que pode ser razoavelmente longo. Como regra empírica, pode-se dizer que o número de passos deve ser, no mínimo, 500 vezes o número de unidades da rede (Kohonen, 2001). A desvantagem quanto à demora na convergência pode ter a contrapartida no

fato de quase não haver limitações quanto à dimensionalidade do vetor de entrada, principalmente em relação ao número de passos de iteração.

Tipicamente **Kohonen (2001)** diz utilizar até 100.000 passos para “aprendizado rápido” em sistemas de reconhecimento de voz, sendo que em algumas situações 10.000 passos são suficientes. Recomenda que se poucas amostras são disponíveis que sejam recicladas para o número desejado de passos (técnica de “bootstrap”).

### 5.3.1 - Treinamento em Lote (“batch”)

O processo iterativo no qual um número de amostras de  $x$  é primeiro classificado nas respectivas regiões de Voronoi,  $V_i$ , e posteriormente a atualização dos  $m_i^*$  é feita iterativamente pelo algoritmo chamado “Batch Map” (**Kohonen, 1993**), supõe que todas as amostras estejam disponíveis quando o treinamento começa. Os passos deste algoritmo são as seguintes (**Kohonen, 2001**):

- 1) Para os vetores de referência iniciais, tomam-se, por exemplo, as primeiras  $K$  amostras de treinamento, onde  $K$  é o número de vetores de referência.
- 2) Para cada unidade de mapa  $i$ , coleciona-se uma lista de cópias de todas as amostras de treinamento  $x$  cujo vetor de referência mais próximo pertence à unidade  $i$ .
- 3) Toma-se para cada novo vetor de referência a média sobre a união das listas em  $N_i$ .
- 4) Repete-se a partir de 2 algumas vezes.

É relativamente fácil perceber que este algoritmo descreve o mesmo processo geral de treinamento que atualiza uma região de Voronoi por iteração. Se uma nova função de vizinhança  $h_{ci}(t)$  é utilizada, e  $\bar{x}_j$  é a média de  $x(t)$  no conjunto de Voronoi  $V_j$ , pode-se pesá-lo por um número  $n_j$  de amostras  $V_j$  e a função de vizinhança. Desta forma obtêm-se a equação:

$$m_i^* = \frac{\sum_j n_j h_{ji} \bar{x}_j}{\sum_j n_j h_{ij}} \quad (5.16)$$

A soma em  $j$  é feita para todas as unidades da SOM ou pode ser feita de forma que  $h_{ij}$  seja truncada, ou ainda a soma pode ser efetuada sobre a vizinhança  $N_i$  na qual é definida. Se não for utilizado o peso da vizinhança tem-se o seguinte:

$$m_i^* = \frac{\sum_{j \in N_i} n_j \bar{x}_j}{\sum_{j \in N_i} n_j} \quad (5.17)$$

Este algoritmo é particularmente efetivo se os valores iniciais dos vetores de referência já estão grosseiramente ordenados, mesmo que ainda não representem a distribuição das amostras. Também é importante notar que o algoritmo por lote não contém parâmetro de taxa de aprendizado e portanto não tem problemas de convergência e se direciona a valores assintoticamente mais estáveis que os valores  $m_i$  da SOM original (Kohonen, 2001).

#### 5.4 - Métodos Estatísticos de Redução de Dados e de Dimensionalidade

Nesta seção serão descritos, baseados na análise feita por Cherkassky e Mulier (1998), alguns métodos estatísticos relacionados com a metodologia utilizada

neste trabalho. A interpretação estatística dos mapas de Kohonen será apresentada dentro do contexto desta metodologia.

A obtenção da densidade de probabilidade multivariada a partir de amostras finitas é difícil de ser obtida, especialmente em problemas com dimensionalidade elevada, ou problemas em que o aumento da dimensão causa um aumento exponencial da capacidade computacional exigida para a solução (“praga da dimensionalidade”).

Se forem consideradas amostras de treinamento  $X = \{x_1, x_2, \dots, x_n\}$  num espaço de amostras  $d$ -dimensional, podemos dizer que estas têm origem em algum tipo de distribuição. O objetivo destes modelos é obter uma aproximação da distribuição (desconhecida) de forma que os valores obtidos pelos modelos sejam “próximos” (com uma “distância” bem definida) das amostras da distribuição geral. Geralmente a qualidade do modelo é estimada pela acuidade da aproximação aos dados de treinamento e não a futuras amostras.

Os modelos computacionais para estimativa de densidade baseados em máxima semelhança, como por exemplo, o Método de Maximização da Expectativa (“Expectation-Maximization”) (Dempster et al., 1977), são muito lentos, resultam em muitas soluções subótimas (mínimos locais), e dependem fortemente das condições iniciais. No entanto, em muitas aplicações práticas não existe a necessidade de estimar a densidade da dimensão superior explicitamente porque os dados multivariados em  $\mathcal{R}^d$  usualmente têm uma dimensionalidade verdadeira muito menor do que  $d$ . Portanto pode ser vantajoso mapear os dados em espaços de menor dimensionalidade antes de resolver o problema do aprendizado (Cherkassky e Mulier, 1998). Mesmo quando os dados originais são de dimensão inferior e sua distribuição é tipicamente não uniforme, é possível uma aproximação adequada para tais distribuições.

Os métodos relacionados à redução de dados são a Quantização Vetorial e o Agrupamento. O objetivo destes métodos é encontrar uma aproximação de uma dada

amostra de treinamento (com uma distribuição geral desconhecida) utilizando um pequeno número de vetores protótipo  $C = \{c_1, c_2, \dots, c_m\}$ , onde geralmente  $m \ll n$ . A Quantização Vetorial (QV) tem como objetivo minimizar um erro de aproximação bem definido (quantização) quando o número de protótipos  $m$  é fixado “a priori”. Já o agrupamento (“clustering”) tem um objetivo mais vago de encontrar agrupamentos em amostras de treinamento.

Os métodos relacionados à redução de dimensionalidade têm o objetivo de encontrar um mapeamento de um espaço amostral  $d$ -dimensional  $\mathcal{R}^d$  para algum espaço de saída  $m$ -dimensional  $\mathcal{R}^m$ , onde  $m \ll d$ . Esta relação é representada por um código de dimensão inferior  $z = G(x)$  para cada vetor de entrada  $x$ , ou seja:

$$G(x): \mathcal{R}^d \longrightarrow \mathcal{R}^m \quad (5.18)$$

Um bom mapeamento  $G$  deveria agir como um codificador de dimensão inferior da distribuição original. Em particular, deveria existir outro mapeamento “inverso” produzindo a decodificação  $x' = F(z)$  da entrada original  $x$ , assim:

$$F(z): \mathcal{R}^m \longrightarrow \mathcal{R}^d \quad (5.19)$$

Para avaliar o melhor mapeamento, uma classe de funções de aproximação podem ser definidas como  $f(x, \omega) = F(G(x))$  parametrizadas por  $\omega$  e se estabelecer uma busca de funções (nesta classe) que minimize o risco,  $R(\omega)$ , definido por:

$$R(\omega) = \int L(x, x') p(x) dx = \int L(x, f(x, \omega)) p(x) dx \quad (5.20)$$

onde  $L$  é a função de perda utilizada, sendo uma função quadrática definida por:

$$L(x, f(x, \omega)) = \|x - f(x, \omega)\| \quad (5.21)$$

onde  $\| \cdot \|$  define a norma  $L_2$ . Um exemplo de redução de dimensionalidade é a análise de componentes principais (“principal component analysis – PCA”) cuja implementação é uma projeção linear (mapeamento); isto é,  $z = G(x)$  é uma transformação linear do vetor de entrada  $x$ . A análise de PCA funciona bem em caracterização de baixa dimensão de distribuições gaussianas mas pode não ser apropriada para modelar distribuições mais gerais (Cherkassky e Mulier, 1998).

A formulação de quantização vetorial pode ser formalmente vista como um caso especial do mapeamento/codificação de dimensão inferior, onde o espaço de codificação é zero-dimensional. No entanto, os métodos QV e de codificação de dimensão inferior podem ser considerados separadamente porque lidam com problemas bem diferentes.

Tipicamente os métodos QV tentam representar uma dada amostra em um certo número  $m$  de protótipos, onde  $m$  é determinado pela taxa de transmissão de um canal. Já com os métodos de agrupamento a meta usual é a interpretação e portanto encontrar agrupamentos interessantes nos dados de treinamento, mais do que a predição de futuras amostras.

De modo similar, a codificação de dimensão inferior utiliza tipicamente uma dimensão pré-especificada do espaço a ser codificada (geralmente uni ou bidimensional) para assegurar uma boa capacidade de interpretação.

Portanto, de um modo geral, boa parte dos métodos têm a meta comum de encontrar um mapeamento minimizador de risco empírico como o definido pela equação 5.22 a seguir, ao invés do risco esperado, definido pela equação 5.20.

$$R_{emp}(\omega) = \frac{1}{n} \sum_{i=1}^n \|x_i - f(x_i, \omega)\|^2 \quad (5.22)$$

Ainda assim, em muitos casos, a minimização do risco empírico com um número pré-especificado de protótipos pode levar a boas soluções para formulação preditiva (Cherkassky e Mulier, 1998)..

Um quantizador vetorial típico particiona o espaço de entrada de vetores a ser quantizados em um número fixo de regiões disjuntas. Para cada região um vetor protótipo é encontrado. Quando um dado vetor de entrada entra no sistema, o codificador produz um índice da região onde o vetor de entrada se encontra. Este índice, chamado um símbolo do canal, pode ser transmitido por um canal binário. No decodificador, o índice é mapeado ao seu correspondente vetor de saída (também chamado centro, protótipo local, ou vetor de reprodução). A taxa de transmissão depende do número de regiões quantizadas. Dado um número de regiões, a tarefa de projetar um sistema de quantização vetorial é determinar as regiões e vetores de saída que minimizam o erro de distorção. As condições de Lloyd-Max (Lloyd, 1957; Max, 1960) estabelecem um procedimento chamado Algoritmo Generalizado de Lloyd (“Generalized Lloyd Algorithm” – GLA) para criar quantizadores vetoriais ótimos (vide seção 5.2.1 sobre os algoritmos competitivos).

#### 5.4.1 - Interpretação Estatística do SOM

Entre os métodos de redução de dimensionalidade mais importantes pode-se citar os métodos estatísticos como o PCA e o método de Curvas e Superfícies Principais (Hastie, 1984; Hastie e Stuetzle, 1989). Como já foi dito, o PCA é apropriado para modelamento de distribuições do tipo gaussiana, no entanto, uma generalização não linear mais flexível das componentes principais pode ser construída se as funções  $F$  e  $G$  (seção 5.4, equações 5.20 e 5.21) forem escolhidas do conjunto de funções contínuas.

Existem duas aproximações comumente utilizadas para construir este tipo de estimador. Uma é utilizar uma arquitetura de MLP para implementar tanto  $F$  quanto  $G$  e estimar os parâmetros via minimização do risco empírico. Esta aproximação não

leva vantagem da relação inversa entre a estrutura de  $F$  e a de  $G$ . Outra aproximação é definir  $G$  em termos de uma aproximação apropriada da inversa de  $F$ , como é feito na aproximação de curvas principais desenvolvida em estatística e sua contrapartida em redes neurais (SOM).

A noção de curvas e superfícies principais (ou manifolds) foi introduzida em estatística por Hastie and Stuetzle (Hastie, 1984; Hastie e Stuetzle, 1989) de forma a aproximar um conjunto espalhado de pontos de uma distribuição de probabilidades desconhecida. Uma curva suave não linear chamada curva principal é usada para aproximar o comportamento conjunto de duas ou mais variáveis. A curva principal é uma generalização não linear da primeira componente principal e a superfície principal (ou “manifold” principal) é uma generalização das duas primeiras componentes principais. Devido à flexibilidade e complexidade adicional de uma aproximação não linear, “manifolds” com dimensão maior que dois não são usadas tipicamente.

A curva principal (“manifold”) é uma função de valor vetorial  $F(z, \omega)$  que minimiza o risco empírico sujeito a restrições de suavidade colocadas na função  $F(z, \omega)$ . A função  $G$  é definida em termos de uma aproximação numérica ao inverso de  $F$ . Conceitualmente a curva principal é uma curva que passa através do meio dos dados.

Entre os métodos de redução de dimensionalidade que usam redes neurais, a primeira aproximação conhecida é a SOM. Este método pode ser relacionado com a aproximação das superfícies principais. No entanto, historicamente, o método SOM (como muitos outros modelos de redes neurais) foi proposto originalmente como uma explicação para o fenômeno biológico. A idéia fundamental dos mapas de características auto-organizáveis foi introduzida por Marlsburg (1973) e Grossberg (1976) para explicar a formação de mapas topológicos neurais. Mais tarde, Kohonen (1982) propôs o modelo conhecido como mapas auto-organizáveis, que tem sido aplicado com sucesso em um número de aplicações de reconhecimento de padrões e engenharia (Cherkassky e Mulier, 1998). No entanto, a relação entre SOM e outros

métodos estatísticos não era clara. Posteriormente, foi percebido que o método de Kohonen poderia ser visto como um procedimento computacional para encontrar aproximações discretas das curvas principais por meio de um mapa topológico de unidades (Ritter et al., 1992). A segunda aproximação é baseada em utilizar uma rede MLP em um modo auto supervisionado para implementar o gargalo de informação. O modo auto supervisionado ou auto-associativo de operação é utilizado apenas quando as amostras de entrada e de saída (usadas durante o treinamento) são as mesmas.

## 5.5 - Descrição do Algoritmo

Esta seção descreve o funcionamento do algoritmo utilizado nesta tese que corresponde ao treinamento “em lote” (Finlândia, 2000). Algumas tentativas foram feitas utilizando o treinamento sequencial, mas o algoritmo de lote se mostrou mais rápido, apresentando resultados melhores de classificação e com menor tempo de execução computacional.

O funcionamento da implementação do algoritmo será melhor entendido utilizando o diagrama de blocos na figura 5.5 para um exemplo de mapa de morfologia hexagonal de dimensões 9 x 6. O primeiro bloco do diagrama apresentado na figure, no canto esquerdo superior, corresponde à matriz  $C$  contendo as coordenadas das unidades numa estrutura hexagonal no plano. Para o exemplo, esta matriz teria dimensões 54 x 2. Desta forma para cada uma das 54 unidades do mapa existe um par ordenado relativo ao centro geométrico de um hexágono regular inserido numa matriz de hexágonos, e onde a distância entre estes centros é adotada como a unidade.

A partir da matriz  $C$ , gera-se uma segunda matriz ( $U_D$ ) contendo as distâncias quadradas entre as coordenadas definidas em  $C$ . Esta matriz, no exemplo, tem dimensão 54 x 54 e é simétrica, como pode ser visto na figura 5.5, e representa as distâncias quadradas entre as unidades do mapa.. Como pode ser observado nesta

figura, a diagonal desta matriz é igual a zero, pois representa a distância de cada célula a ela mesma. As segundas diagonais apresentam valores unitários que representam a distância entre os primeiros vizinhos. Desta forma, a máxima distância quadrada nesta matriz corresponde a distância entre a unidade de índice 1 e a outra na extremidade oposta da matriz com índice 54, que para este exemplo vale 73.

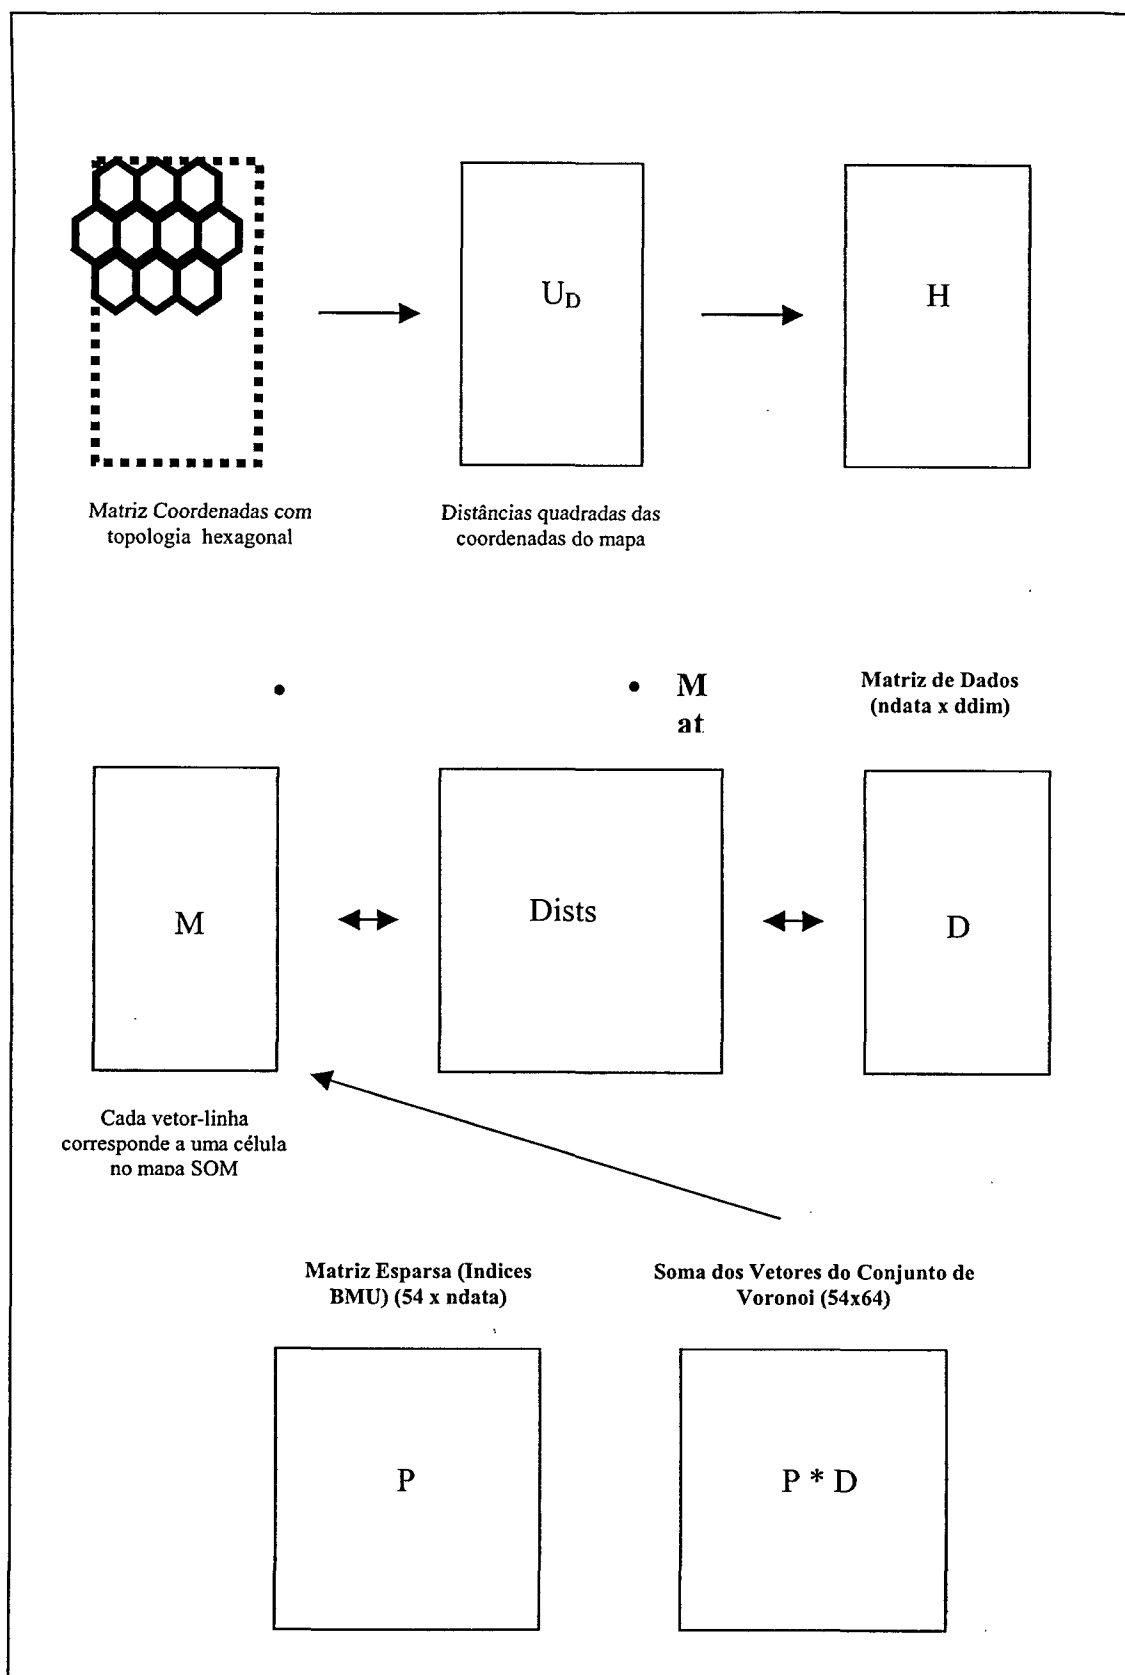


Figura 5.5 – Diagrama de blocos do algoritmo de treinamento da SOM

A partir de  $U_D$  gera-se a matriz de vizinhança de ativação ( $H$ ) que corresponde à atenuação de  $U_D$  em função do raio de atualização onde:

$$H = e^{-U_d/2r(t)} \tag{5.23}$$

onde a variável raio ( $r$ ) assume valores decrescentes à medida que o treinamento evolui.




Figura 5.6 – Matriz  $U_d$  de distâncias topológicas quadradas entre as coordenadas das células para mapa de 54 células em morfologia hexagonal.

Como pode ser visto na figura 5.6, o próximo passo é a criação da matriz  $M$  de dimensão  $54 \times ddim$ , onde  $ddim$  representa o número de dimensões dos vetores de treinamento. Cada linha, nesta matriz, corresponde ao protótipo de cada unidade do mapa, que são inicializados aleatoriamente e já na primeira iteração assumem valores que se aproximaram dos vetores de treinamento.

Cria-se então a matriz  $Dist$  a partir das distâncias quadradas entre os protótipos ( $M$ ) e os dados de treinamento  $Dists = (M-D)^2$ .

Em seguida é calculada a matriz  $P$  com valores unitários que correspondem aos índices da matriz que denotam o par unidade do mapa com o vetor de treinamento. Um valor unitário no elemento (13,5) da matriz, indica que a unidade de índice 13 é a unidade de melhor ajuste (“best match unit” – BMU) do vetor de treinamento de índice 5.

Com a matriz  $P$  pode-se calcular a soma dos valores do conjunto de Voronoi por  $P*D$ , que representa para cada célula, a soma dos vetores que a “escolheram” como BMU.

Através desta matriz atenuada e ulizando o vetor de ativação, a atualização é feita por:

$$M = \frac{H*(P*D)}{H*P} \quad (5.24)$$

Para o algoritmo sequencial, o passo de atualização acontece através de reposição de cada unidade do mapa pela média dos vetores que estão em sua vizinhança. A contribuição, ou ativação, dos vetores de dados pode ser variada de acordo com uma função de vizinhança. Esta ativação é dada pela matriz  $H$ . Para cada unidade do mapa o novo vetor peso  $m$  é dado pela seguinte equação:

$$m = \frac{\sum_{i=1}^N h_i \cdot d_i}{\sum_{i=1}^N h_i} \quad (5.25)$$

onde  $N$  é o número de células, e  $h_i$  é a ativação e  $d_i$  são os vetores de dados de treinamento.

### 5.5.1 - Som Supervisionado

Tradicionalmente a SOM é considerada como um processo não supervisionado, da mesma forma que os métodos tradicionais de clusterização. Uma pequena alteração no algoritmo foi introduzida por Kohonen com o objetivo de melhorar a classificação através da adição de alguma informação sobre a classe na fase de aprendizado. Este algoritmo levou à idéia da SOM supervisionada que foi aplicada ao reconhecimento de padrões de fala em 1984 (Kohonen et al., 1984), e que obteve segundo Kohonen (2001), resultados quase tão bons na época (1984) quanto os métodos de Quantização de Aprendizado de Vetores (“Learning Vector Quantization”) obtêm atualmente. Este princípio foi utilizado num sistema de reconhecimento de voz em 1988 (Kohonen, 1988b).

Neste algoritmo o mapa auto-organizável é treinado com a adição de  $n$  componentes ao final de cada vetor que identifica a classe correspondente daquele vetor. O número  $n$  corresponde ao número de classes existentes. As componentes adicionais com informação de classe tem formato “[0 0 0 1 0]” para um exemplo com cinco classes diferentes, onde o “um” do vetor corresponde à quarta classe. O treinamento consiste em:

- 1) iniciar randômicamente o livro-código (“codebook”);
- 2) buscar entre os vetores de dados de treinamento, para cada neurônio ou célula, o vetor de dados com menor distância ;
- 3) anexam-se aos protótipos originais do livro-código, os elementos do vetor identificador de zeros e uns.
- 4) tratando-se de algoritmo em lote, atualizam-se todos os protótipos baseados nas “unidades de melhor ajuste” (BMU). Tratando-se de algoritmo seqüencial, atualiza-se o protótipo escolhido. O livro-código é treinado com as colunas adicionais sendo incluídas na atualização;
- 5) ao fim do treinamento, o algoritmo escolhe para cada célula a etiqueta correspondente à classe correspondente à componente do vetor identificador que tiver maior valor;

6) a classificação propriamente dita ocorre após este processo, sem a utilização das “colunas identificadoras”. Procura-se para o vetor teste o protótipo com melhor ajuste. Só então a etiqueta deste protótipo é associado ao vetor teste e a classificação é efetuada.

Como pode ser visto, este algoritmo usa a informação de classe no treinamento mas ela tem uma proporção ( $n / dlen$ ) onde  $dlen$  é o comprimento dos vetores de treinamento (dados).

Uma outra forma de descrever o procedimento acima considera os vetores de entrada como compostos de duas partes  $x_a$  e  $x_c$ . A primeira parte  $x_a$  se refere aos vetores de dados ou características extraídas dos sinais de entrada. A segunda parte  $x_c$  contém vetores unitários de dimensão  $n$  onde as componentes associadas ao valor “um” se referem a cada uma das classes. Portanto os vetores de entrada se tornam vetores agregados  $x = [x_a \ x_c]$  de dimensão ( $n + dlen$ ). Estes vetores servem de entrada para a rede SOM. O termo supervisionado se refere ao fato de que a informação de classe de cada vetor  $x_a$  é utilizada no treinamento através do agregamento de  $x_c$  ao vetor de entrada. No entanto, o livro-código é atualizado e o mapa auto-organizado baseando-se no princípio da “proximidade” no espaço Euclidiano destes vetores. Isto representa que o ordenamento topológico da SOM original continua sendo feita. Esta metodologia difere neste aspecto das arquiteturas mais novas que são baseadas na LVQ (Kohonen, 2001).

## 5.6 - Algoritmo utilizado neste trabalho

Esta seção apresenta o algoritmo básico utilizado para implementar a SOM neste trabalho. O algoritmo implementa a chamada SOM supervisionada, com algumas modificações.

No algoritmo utilizado neste trabalho foi implementada uma inferência para classificação final utilizando mais de um mapa de Kohonen simultaneamente. Uma descrição desta inferência e os resultados obtidos são descritos no capítulo 7.

## 6 - EXTRAÇÃO DE CARACTERÍSTICAS DO SINAL DE ECT

O segmento do sinal é utilizado nesta tese como característica do sinal referente a uma degradação detectada. Todas as outras características utilizadas foram obtidas pela aplicação de diferentes metodologias sobre estes segmentos. Os métodos de extração de características utilizados serão descritos a seguir.

### 6.1 - Segmento do Sinal

Foram utilizados segmentos (vetores) de 32, 64 e 128 amostras em torno da IC (indicação central do defeito, ver seção 3.2). Esta indicação aponta a localização do “centro” de um sinal de ECT diagnosticado como defeito. A definição do centro do sinal está relacionada com dois parâmetros. O primeiro parâmetro é o centro “geométrico” do sinal do defeito, já que a detecção é feita quase sempre por um limite inferior de intensidade (“threshold”) e a IC se encontra, em geral, no centro da região com alteração de intensidade. O segundo parâmetro se refere à intensidade em si, pois uma parcela significativa dos sinais relativos aos defeitos apresentam algum tipo de “pico” de intensidade e este critério também é levado em conta no estabelecimento da indicação central. Como se trata quase sempre de uma análise baseada em vários sinais de frequências diferentes, a IC é definida de acordo com os critérios do inspetor de ECT utilizando estes parâmetros (IC e intensidade) em diferentes canais, inclusive os canais do sinal adquirido por sonda absoluta. Em geral, uma região afetada apresenta de 100 a 500 pontos amostrados, que correspondem, aproximadamente, nesta base de dados, a um trecho de de 3 a 15 polegadas (7,5 a 40 cm aproximadamente). Dentro da análise de segmentos de sinal no tempo, a região central do defeito, representada por 10 a 20 pontos amostrados em torno da IC, é utilizada no plano de impedância para “medir” a fase do sinal. A fase medida do sinal é o parâmetro para estimativa da profundidade do defeito.

A utilização de segmentos com diferente número de pontos como “característica” a ser utilizada pelo sistema de classificação de defeitos desta tese,

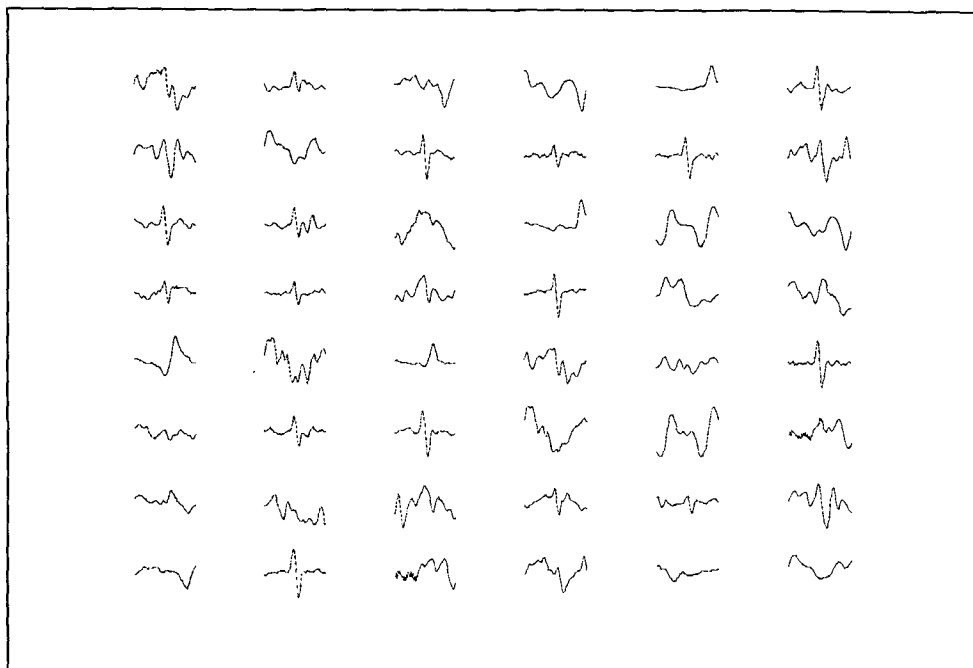
implica na busca de diferentes padrões presentes nestes sinais. Segmentos maiores podem implicar na inclusão de outros eventos adjacentes ao sinal do defeito. Como pode ser visto nas figuras 3.4, 3.5 e 3.6, as degradações ocorrem preferencialmente em regiões do gerador de vapor próximas aos suportes e à base de tubos, que causam alterações significativas nos sinais de ECT. Desta forma o segmento de 128 pontos está no limite superior para não inclusão dos sinais de eventos não “desejáveis”. O segmento de 32 pontos representa uma aproximação do centro do defeito que poderia, a princípio, apresentar características importantes para a classificação.

A figura 3.12 apresenta um segmento de sinal típico com 128 pontos referente a uma degradação de perfuração (PIT). Como pode ser visto, existe a presença de um sinal de suporte ao lado direito da IC. Este sinal do TSP não aparece num segmento de 64 pontos (figura 3.13) do mesmo sinal. Outro recurso descrito para “subtrair” o evento indesejado é o método de mixagem entre canais como descrito na seção 3.3.


A seguir, estão representados nas figuras 6.1 até 6.15, em três figuras para cada tipo de degradação, os gráficos dos vetores característicos com segmentos de 64 pontos de todos os sinais de ECT (real, imaginário e suas representações no plano de impedância) utilizados como base de treinamento e teste para o sistema de classificação de defeitos. Os segmentos se referem, na ordem, aos sinais de ECT relativos aos defeitos ISC, PIT, WEA, THI, e IMP. Neste conjunto de figuras, estão exibidos todos os vetores característicos utilizados para treinamento e teste dos mapas de Kohonen. Este conjunto se compõe de sinais de dois canais diferenciais de diferentes frequências de excitação para cada defeito. Optou-se pela utilização dos dois canais de maior frequência de excitação pelo fato de serem os mais utilizados nos procedimentos de detecção recomendados no PDD. Isto perfaz um total de 48 vetores para cada defeito ou 240 vetores no total. Maiores detalhes do critério de seleção dos dados podem ser vistos no capítulo 3, seção 3.2.

Um critério extremamente importante, adotado na tese, é a normalização dos vetores pelo máximo do módulo no plano complexo, o que torna o processo de

classificação independente da intensidade do sinal. Este critério foi adotado pelo interesse na busca de padrões na forma do sinal. O critério intensidade poderia mascarar semelhanças entre vetores com intensidade muito diferentes.



**Figura 6.1 – Segmentos de 64 pontos do sinal real relativos à degradação ISC.**



**Figura 6.2 – Segmentos de 64 pontos do sinal imaginário relativos à degradação ISC.**

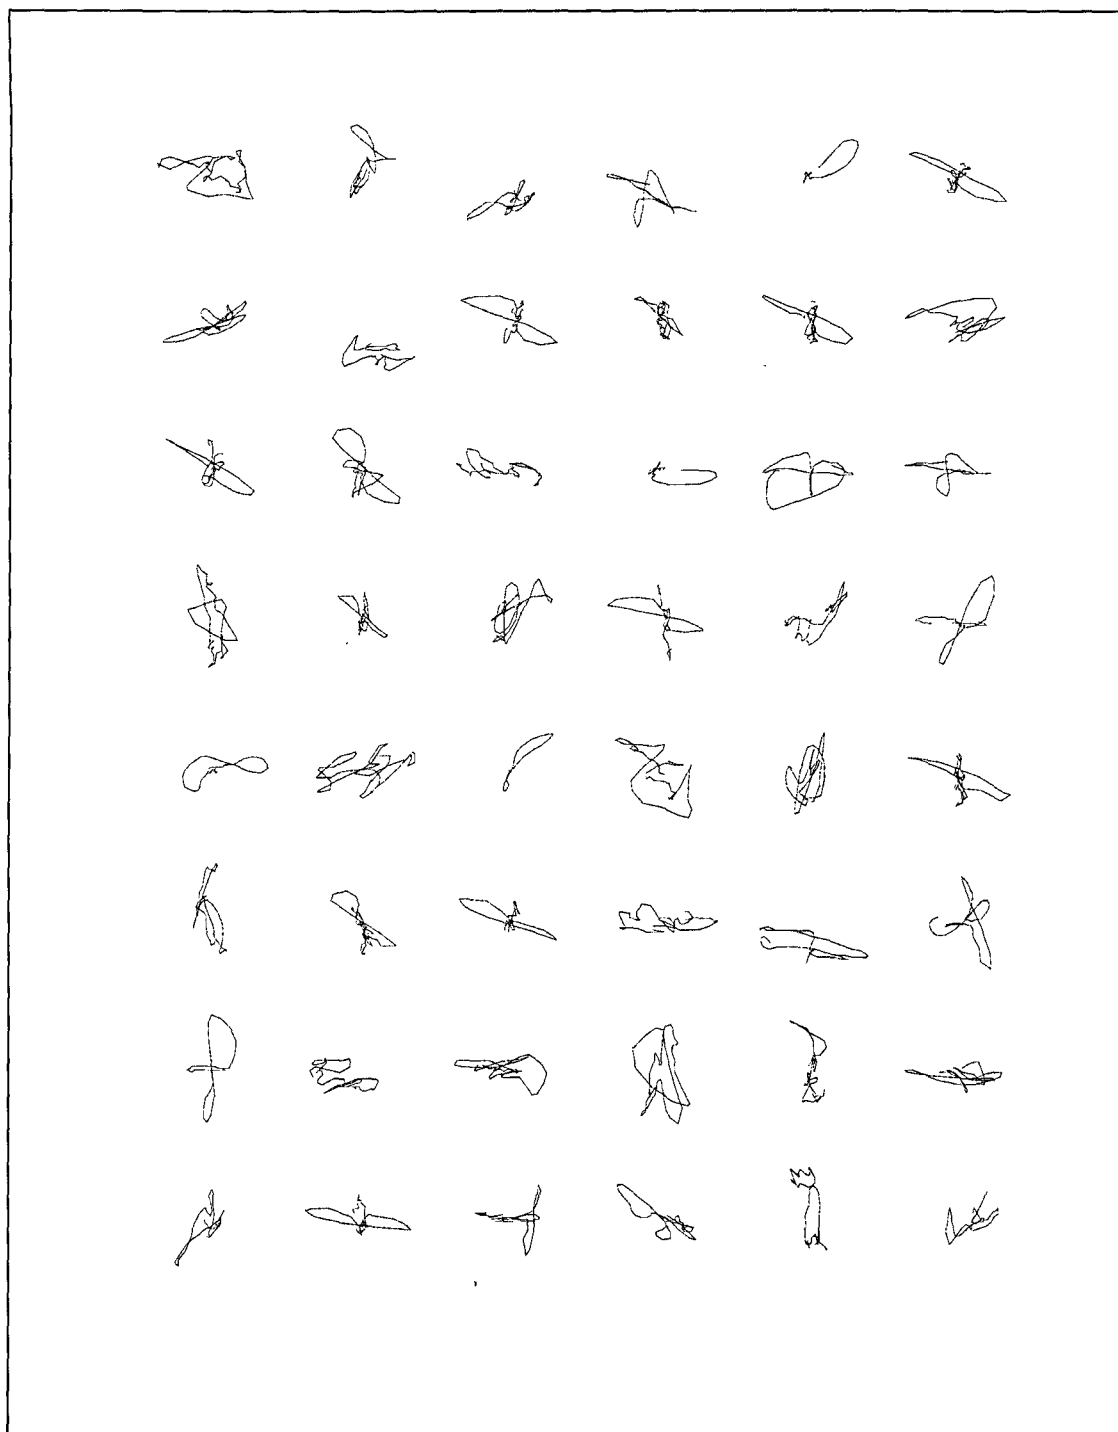




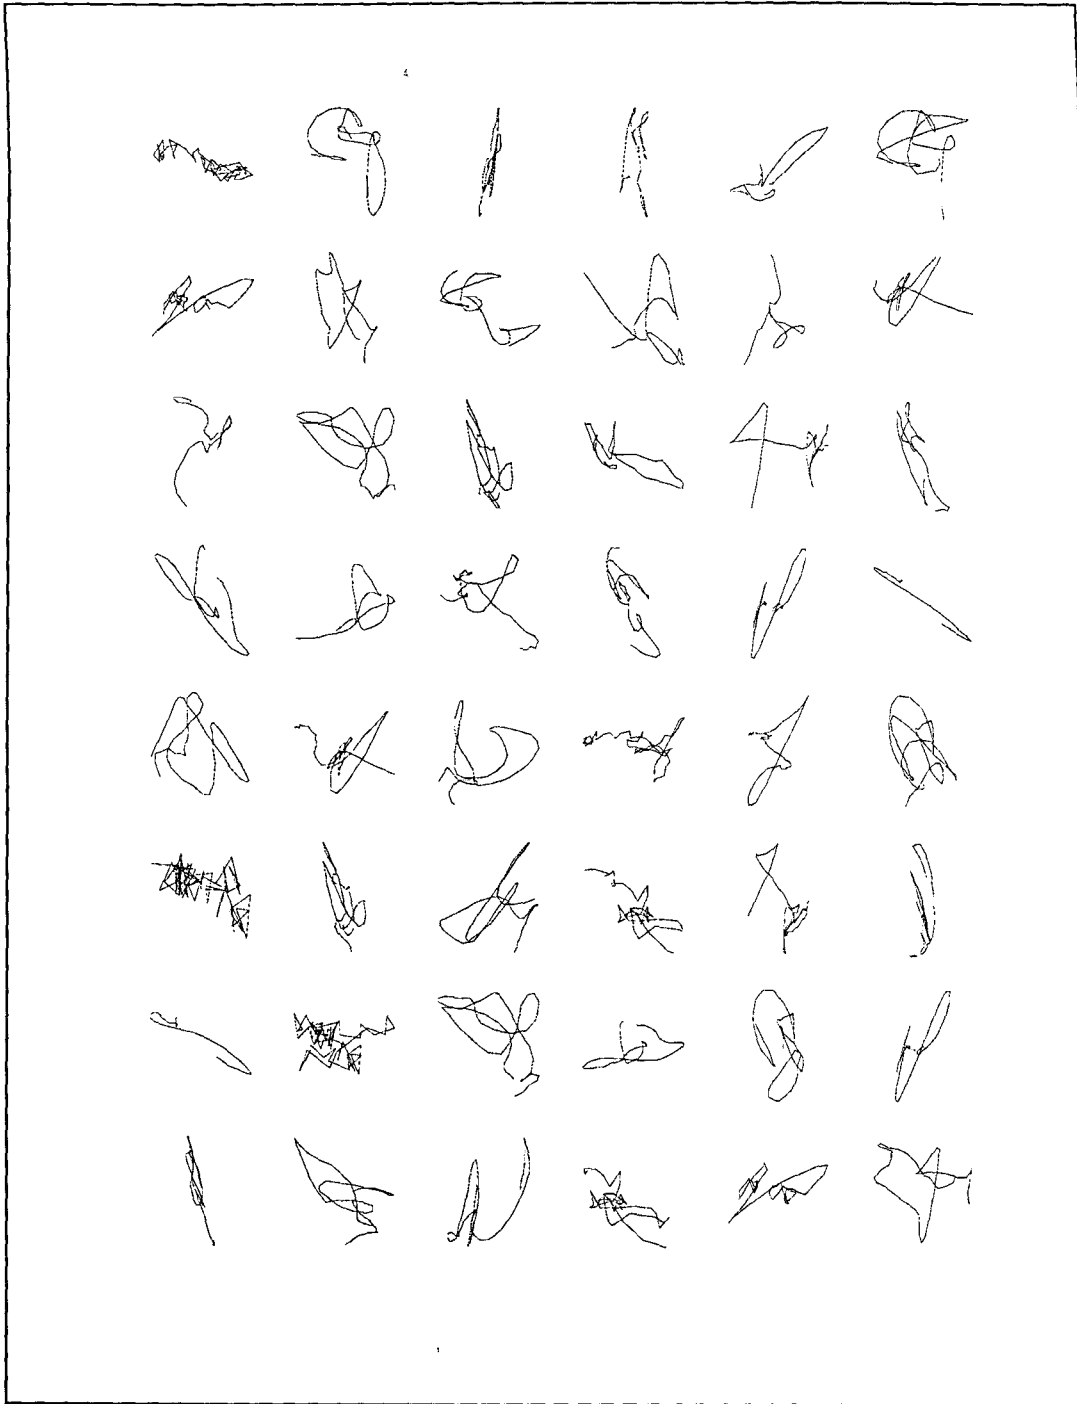
Figura 6.3 – Segmentos de 64 pontos relativos à degradação ISC no plano de impedância.



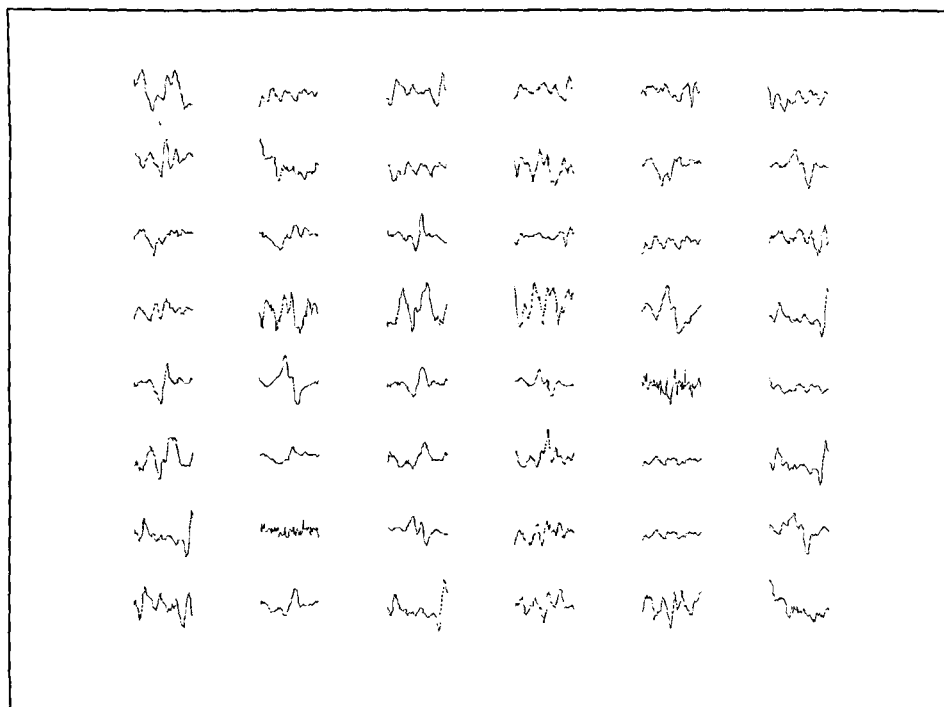
**Figura 6.4 – Segmentos de 64 pontos do sinal real relativos à degradação PIT.**




**Figura 6.5 – Segmentos de 64 pontos do sinal imaginário relativos à degradação PIT**



**Figura 6.6 – Segmentos de 64 pontos relativos à degradação PIT no plano de impedância.**



**Figura 6.7 – Segmentos de 64 pontos do sinal real relativos à degradação WEA.**



**Figura 6.8 – Segmentos de 64 pontos do sinal imaginário relativos à degradação WEA**

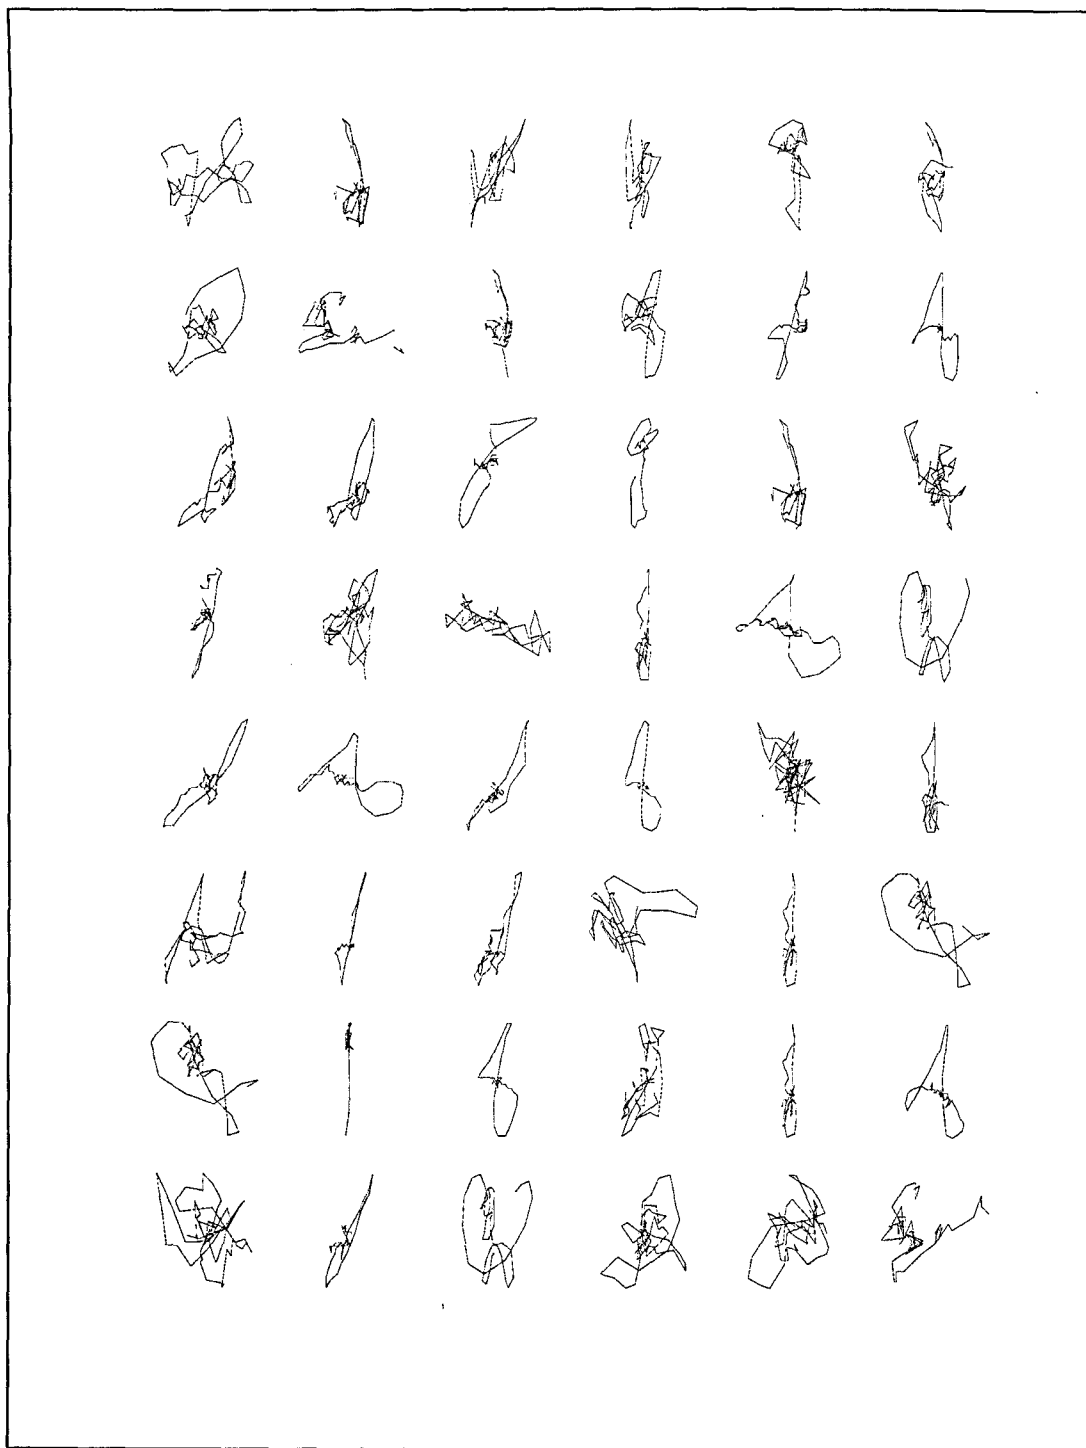




Figura 6.9 – Segmentos de 64 pontos relativos à degradação WEA no plano de impedância.



**Figura 6.10 – Segmentos de 64 pontos do sinal real relativos à degradação THI.**



**Figura 6.11 – Segmentos de 64 pontos do sinal imaginário relativos à degradação THI.**

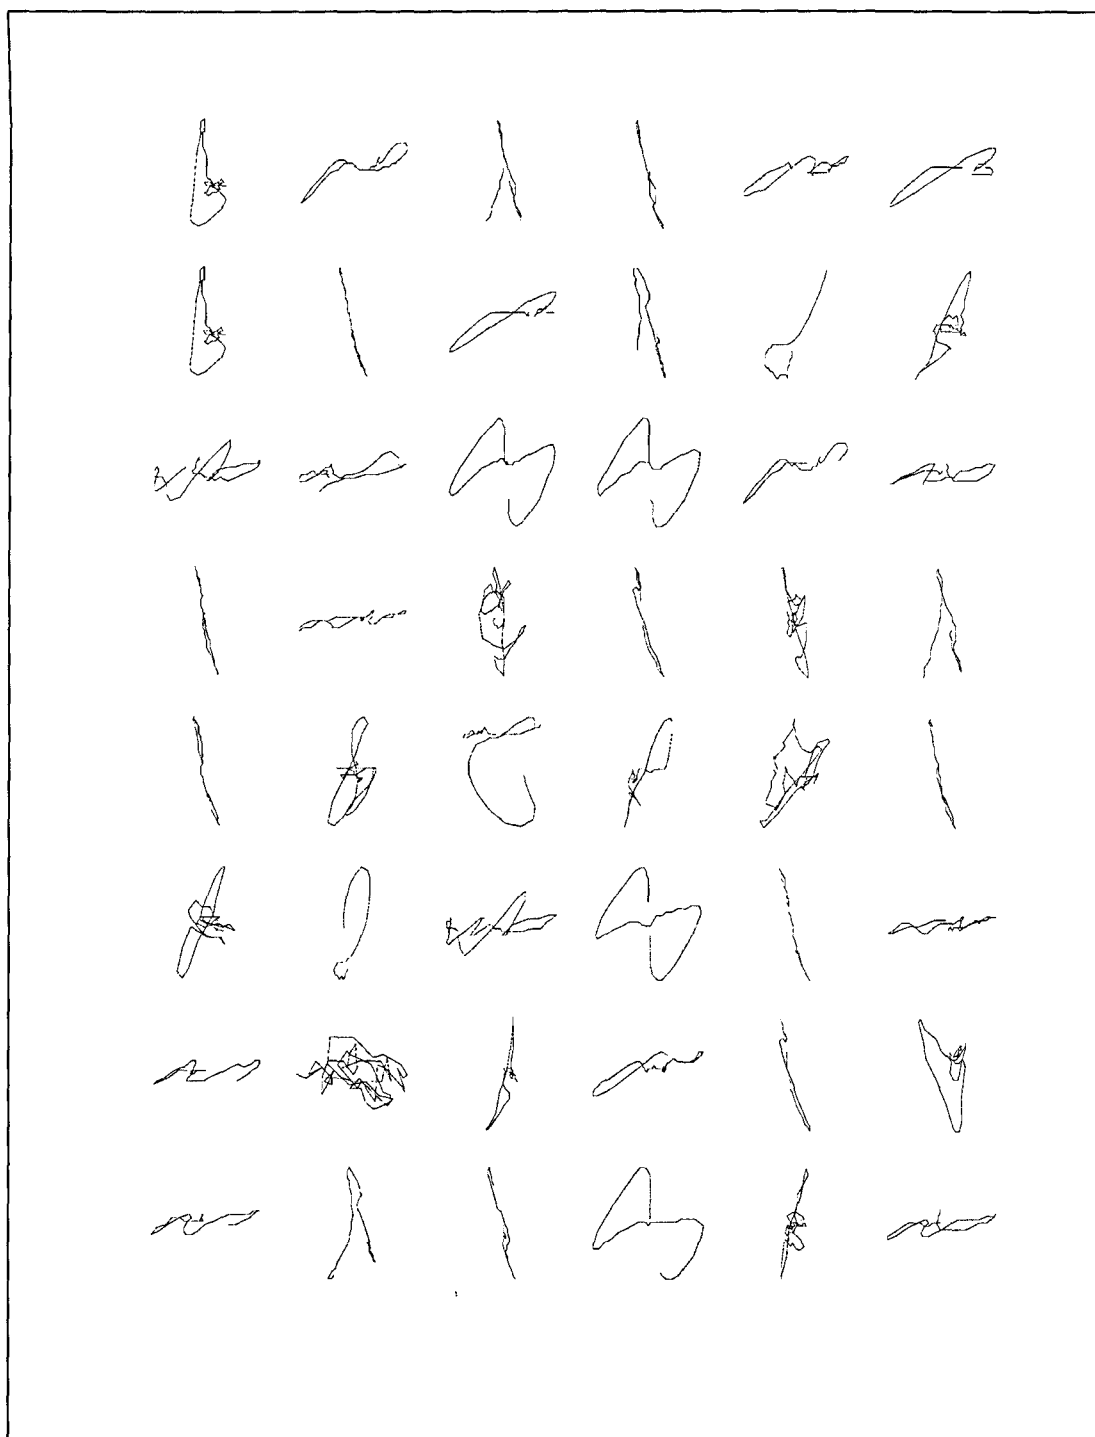




Figura 6.12 – Segmentos de 64 pontos relativos à degradação THI no plano de impedância.



**Figura 6.13 – Segmentos de 64 pontos do sinal real relativos à degradação IMP.**



**Figura 6.14 – Segmentos de 64 pontos do sinal imaginário relativos à degradação IMP.**


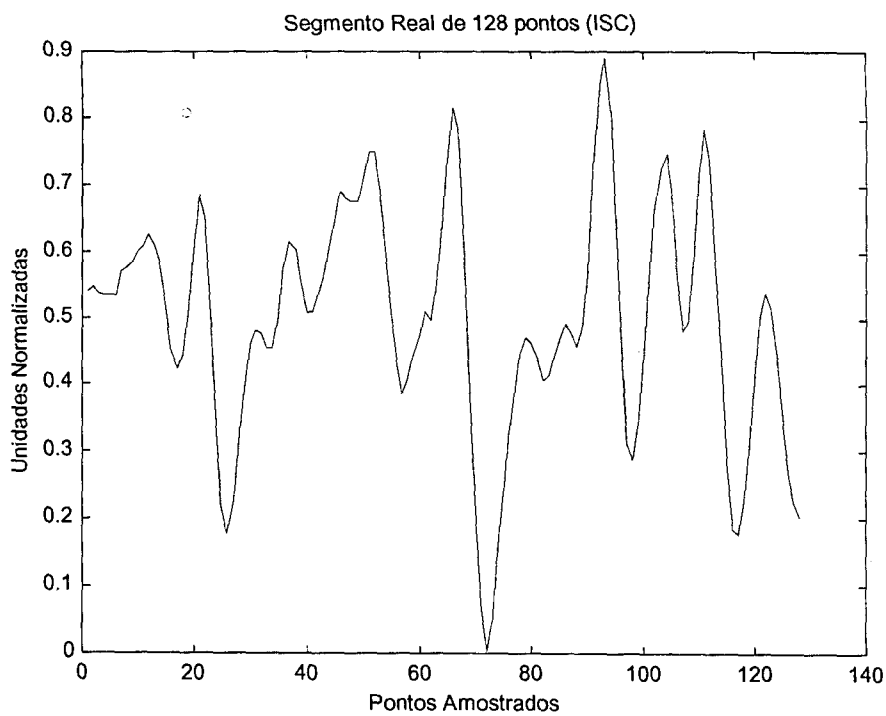
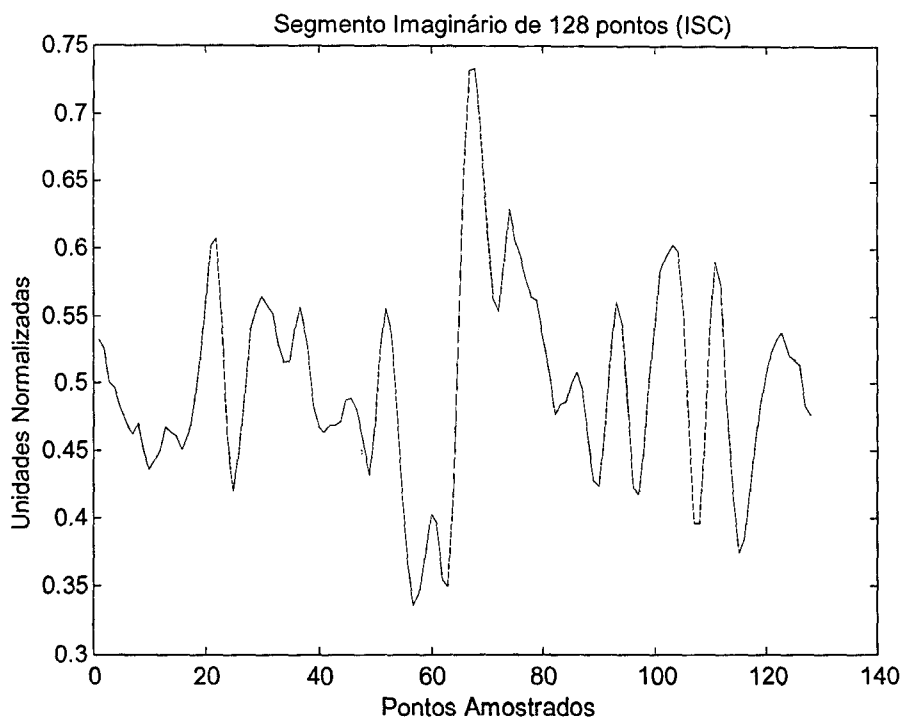


Figura 6.15 – Segmentos de 64 pontos relativos à degradação IMP no plano de impedância.



(a)



(b)

Figura 6.16 – Segmentos de 128 pontos de sinal real (a) e imaginário (b), correspondentes à uma indicação de degradação tipo ISC.

## 6.2 - Módulo

O módulo do sinal de ECT é uma característica já utilizada em trabalhos anteriores ( Upadhyaya et al., 1993; Yan e Upadhyaya, 1996; Hooper et al., 1997; 1998) para caracterização e classificação dos defeitos em tipos e profundidade. Esta característica representa uma medida da intensidade do segmento do sinal. O módulo é definido pelo vetor  $C$  que define a figura de Lissajous formada no plano da impedância pelo sinal de ECT (figura 6.17) da região afetada pela degradação.




Figura 6.17 – Vetor que define o módulo do sinal de ECT no plano de impedância.

O módulo é definido como:

$$M = \|C\| = \sqrt{R^2 + X_L^2} \quad (6.1)$$

onde  $M$  é o módulo,  $R$  é o valor da resistência e  $X_L$  é a reatância indutiva.

No sistema de classificação desta tese, o vetor característico de módulo é um vetor de 32, 64 ou 128 pontos que se referem a aplicação da equação 6.1 para cada

um dos pontos do segmento selecionado. Portanto o vetor característico de módulo representa a variação da intensidade do sinal na região de degradação detectada.




Figura 6.18 – Vetor módulo com 128 pontos referente a uma indicação de degradação ISC.

### 6.3 - Fase

Esta característica é a mais utilizada durante a inspeção para estimativa da profundidade do defeito. Os valores são extraídos da figura de Lissajous formada no plano de impedância pelo sinal de ECT (figura 6.19) na região afetada pelo defeito. Tal medida considera que o sinal tenha sido calibrado de acordo com a norma ASME, onde para 100% de profundidade do defeito deve haver um ângulo de fase de  $40^\circ$ , como descrito na seção 2.3.2 e mostrado na figura 2.8. A fase  $\phi$  é definida como:

$$\phi = \tan^{-1}\left(\frac{X_t}{R}\right) \quad (6.2)$$

O vetor fase característico é obtido pela equação 6.2 para cada um dos pontos do segmento selecionado (32, 64 ou 128 pontos amostrados). Um vetor fase característico é mostrado na figura 6.19.




Figura 6.19 – Vetor fase característico com 128 pontos referente a indicação de degradação ISC.

Esta característica, a princípio, representa a variação da profundidade do defeito na região selecionada. Observa-se que este parâmetro é utilizado pela norma para estimativa da profundidade da degradação. Para esta tese, a fase do sinal é investigada quanto ao conteúdo implícito de características referentes à cada tipo de defeito. Tanto o módulo quanto a fase do sinal contêm informações quanto à morfologia da figura de Lissajous, historicamente utilizada para o diagnóstico pelo inspetor de ECT.

## 6.4 - Número de Cruzamentos com o Zero da Transformada de “Wavelet”

A transformada de “wavelet” tem se tornado uma ferramenta para processamento de sinais muito utilizada nos últimos anos (Strang e Nguyen, 1997; Smith e Barnwell, 1986). Uma de suas vantagens é a sua sensibilidade a pontos singulares, tendo se mostrado promissora na medição de regularidade de um sinal.

O método que usa o número de cruzamentos com o zero da transformada de “wavelet” (“wavelet zero-crossings” – WZC) foi desenvolvido por Mallat (1991) para caracterizar sinais transientes. Mallat mostrou que para uma classe particular de funções geradoras (“wavelets”), os cruzamentos como o zero da transformada de Wavelet provêm as localizações dos pontos de variação brusca do sinal em diferentes escalas de frequência. Ele também definiu uma representação utilizando os cruzamentos com o zero da transformada de Wavelet do sinal, que é bem adaptada para a resolução de problemas de reconhecimento de padrões (Mallat, 1991).

Esta característica foi utilizada por Upadhyaya et al. (1999b) para estabelecer um sistema de inferência fuzzy para classificar tipos de defeitos baseados nas discontinuidades detectadas em um conjunto de sinais.

### 6.4.1 - Transformada de “Wavelet”

A transformada de “Wavelet” é uma operação linear que decompõe o sinal em componentes de diferentes escalas. Esta transformada é baseada na convolução do sinal com um filtro de dilatação (“dilation”). Uma onda de “wavelet” é uma função  $\Psi(x) \in L^2$ , onde  $L^2$  denota o espaço de Hilbert (Young, 1988), tal que:

$$\int_{-\infty}^{+\infty} \psi(x) dx = 0$$

(6.5)

A dilatação por um fator de escala  $s$  é denotada por:

$$\psi_s(x) = \frac{1}{s} \psi\left(\frac{x}{s}\right) \quad (6.6)$$

A transformada de “wavelet” de uma função  $f(x)$  numa escala  $s$  e posição  $x$  é dada pelo produto de convolução:

$$W_s^\psi(x) = f(x) * \psi_s(x) \quad (6.7)$$

Foi mostrado por **Grossmann e Morlet (1984)** que esta transformada satisfaz uma equação de conservação de energia e que  $f(x)$  pode ser reconstruída a partir de sua transformada de “wavelet”. Quando a escala  $s$  diminui, o suporte da dilatação  $\psi_s(x)$  diminui de forma que  $W_s(x)$  é sensível a detalhes mais finos. A escala  $s$  caracteriza o tamanho e regularidade das características do sinal extraídos pela transformada de “wavelet”.

A transformada de “wavelet” depende de dois parâmetros  $s$  e  $x$  que variam continuamente sobre o conjunto dos números reais. Para aplicações práticas estes parâmetros devem ser discretizados. Para uma classe particular de funções geradoras (“wavelets”), o parâmetro de escala pode ser amostrado da seqüência diádica  $(2^j)_{j \in \mathbb{Z}}$  (onde  $\mathbb{Z}$  é o conjunto dos inteiros), sem que haja modificações das propriedades gerais da transformada. A transformada de “wavelet” na escala  $2^j$  é dada por:

$$W_{2^j}^\psi(x) = f(x) * \psi_{2^j}(x) \quad (6.8)$$

Para cada escala  $2^j$ , a função  $W_{2^j}(x)$  é contínua, já que é igual à convolução de duas funções em  $L^2$  (Mallat, 1991). A transformada de Fourier de  $W_{2^j}(x)$  é:

$$W_{2^j}^\Psi(\omega) = F(\omega)\Psi(2^j\omega) \quad (6.9)$$

Se a condição:

$$\sum_{\omega=-\infty}^{+\infty} |\Psi(2^j\omega)| = 1 \quad (6.10)$$

for satisfeita, então a “wavelet”  $\Psi(x)$  é chamada diádica e  $f(x)$  pode ser reconstruída a partir da seguinte somatória:

$$f(x) = \sum_{j=-\infty}^{+\infty} W_{2^j}(x) * \psi_{2^j}(x) \quad (6.11)$$

Desta forma, a transformação é calculada através de convoluções. Na medida em que o comprimento finito dos sinais causa distorções, é necessária uma suavização ou simetrização do sinal antes da transformação para evitar problemas.

#### 6.4.2 - Método do Número de Cruzamentos com o Zero da Transformada de “Wavelet”

Mallat (1991) mostra que para certa classe de funções de “wavelet” pode-se criar uma representação do sinal (baseada no número de cruzamentos da transformada de “wavelet” com o zero) que aponta os pontos de variação brusca do sinal para diferentes escalas. Para esta classe de funções “wavelets”, define-se uma função de suavização  $\theta_s(x)$  que seja duas vezes diferenciável e as seguintes “wavelets”:

$$\psi(x) = \frac{d}{dx} \theta_s(x) \quad (6.12)$$

$$\lambda(x) = \frac{d^2}{dx^2} \theta_s(x) \quad (6.13)$$

Mallat mostra que para estas “wavelets”, a transformada de um sinal é proporcional (pelo fator de escala  $s$ ) à primeira derivada do sinal suavizado por  $\theta_s(x)$ , se a “wavelet” é a primeira derivada do sinal suavizado. Da mesma forma a transformada de “wavelet” do sinal é proporcional (pelo fator de escala  $s^2$ ) à segunda derivada do sinal suavizado por  $\theta_s(x)$  se a “wavelet” utilizada é a segunda derivada do sinal suavizado. As equações 6.14 e 6.15 (Mallat, 1991) mostram este comportamento das transformadas.

$$W_s^\psi(x) = f(x) * \left( s \frac{d}{dx} \theta_s(x) \right) = s \frac{d}{dx} (f(x) * \theta_s(x)) \quad (6.14)$$

$$W_s^\lambda(x) = f(x) * \left( s^2 \frac{d^2}{dx^2} \theta_s(x) \right) = s^2 \frac{d^2}{dx^2} (f(x) * \theta_s(x)) \quad (6.15)$$

O extremo local de  $W_s^\psi(x)$  corresponde ao cruzamento em zero de  $W_s^\lambda(x)$  e à inflexão dos pontos de  $f(x) * \theta_s(x)$ . Assim, as discontinuidades no sinal podem ser detectadas pelos “zeros” da transformada que utiliza a “wavelet” oriunda da segunda derivada. Deste modo, a detecção de discontinuidades pode ser feita pela comparação de transformadas em diferentes escalas  $s$ . Pode-se então caracterizar a regularidade do sinal pelo número de discontinuidades detectadas por esta transformada (Upadhyaya et al., 1999b). As localizações dos cruzamentos com o zero da transformada de “wavelet” podem gerar uma representação do sinal que caracteriza o sinal pelo seu número de inflexões em diferentes escalas.

Mallat (1991) propõe uma representação integrando a transformada de “wavelet” entre cada dois pontos consecutivos de cruzamentos com o zero  $z_{n-1}$  e  $z_n$ :


$$c_n = \int_{z_{n-1}}^{z_n} W_{2^j}^\psi(x) dx \quad (6.16)$$

Os pontos singulares relevantes se propagam de uma escala para outra, ou seja, os máximos e cruzamentos em zero aparecem tanto na escala  $s = 2^j$  quanto na  $s = 2^{j+1}$ . As amplitudes de máximo local em diferentes escalas têm relação com o tipo de descontinuidade (Upadhyaya et al., 1999b). Pode-se dizer que se uma descontinuidade tem uma singularidade maior do que o ruído de fundo então é possível separar o ruído da parte útil do sinal já que a amplitude da parte útil decresce mais lentamente do que o ruído à medida em que a escala aumenta.


A implementação desta representação baseia-se em quatro passos básicos (Upadhyaya et al., 1999b):

- 1) Utilização de um operador de simetria nos dois extremos do sinal para evitar distorção de borda;
- 2) Aplicação da transformada de “wavelet” com várias escalas;
- 3) Determinação dos pontos de cruzamento com o zero da transformada;
- 4) Cálculo das integrais entre cada dois pontos adjacentes de cruzamento com o zero.

Nas figuras 6.20 e 6.21 apresentamos um vetor característico típico obtido pela aplicação desta metodologia. Os vetores característicos foram obtidos para o terceiro nível de decomposição (correspondente a uma filtragem das componentes de alta frequência do sinal).



**Figura 6.20 – Vetor característico utilizando a representação de WZC de um segmento real de 128 pontos de sinal de ECT correspondente à uma indicação de degradação tipo ISC.**



**Figura 6.21 – Vetor característico utilizando a representação de WZC de um segmento imaginário de 128 pontos de sinal de ECT correspondente à uma indicação de degradação tipo ISC.**

## 6.5 - Codificação Preditiva Linear (LPC)


A codificação preditiva linear (LPC) é uma técnica de análise de sinal comumente aplicada em situações de reconhecimento de voz (**Rabiner e Schafer, 1978**). O princípio básico desta análise é que uma amostra do sinal pode ser aproximada como uma combinação linear de amostras passadas. Pela minimização da soma das diferenças quadradas (dentro de um intervalo finito) entre as amostras do sinal e as preditas linearmente, um conjunto único de coeficientes preditores pode ser determinado. Esta técnica tem sido utilizada como forma de extração de características para reconhecimento de padrões em sinais (**Azimi-Sadjadi et al., 2000**) e compressão de imagens (**Wade, 1993**).

Um modelo preditivo de auto-regressão de um sinal em tempo discreto  $x(k)$  tem a forma:


$$x(k) = \sum_{i=1}^n a_i x(k-i) + w(k) \quad (6.17)$$

onde  $k$  é um índice para tempo ou sequência dos sinais,  $a_i$  são os parâmetros do modelo e  $w(k)$  é um ruído branco. Os parâmetros do modelo de ordem  $n$ , são calculados usando as técnicas de mínimos quadrados. Uma descrição mais aprofundada sobre a teoria da LPC é encontrada em importante revisão (**Makhoul, 1975**) e textos de processamento de sinais de voz (**Rabiner e Schafer, 1978**).

Neste trabalho, para codificar um segmento de indicação de defeito, foram utilizados um número de coeficientes proporcionais ao tamanho do segmento (25% do tamanho do segmento) que apresentaram um erro de predição abaixo de 16 %. Definiu-se o erro de predição como a proporção entre o erro quadrático médio do vetor predito e o erro máximo. O erro máximo foi tomado como a distância quadrática média do vetor ao eixo zero. Todos estes valores foram calculados para os vetores já normalizados. A figura 6.22 mostra um vetor característico obtido por este método para um sinal correspondente a uma degradação tipo ISC.



(a)



(b)

**Figura 6.22 – Vetores característicos obtidos pela aplicação da codificação linear preditiva (LPC) com 30 coeficientes a segmento de 128 pontos de um sinal de ECT correspondente a uma indicação de degradação tipo ISC. (a) real (b) imaginário.**

## 7 - INFERÊNCIA E CLASSIFICAÇÃO FINAL

### 7.1 - Aspectos Gerais sobre o Sistema de Inferência e Classificação de Defeitos

O sistema de classificação utilizado nesta tese é baseado na montagem de vetores característicos compostos por uma ou mais características básicas dos sinais de degradação. A inferência do tipo de defeito é feita utilizando diferentes mapas de Kohonen relativos às características escolhidas. Esta escolha é feita baseada no grau de acerto na classificação obtido pelos mapas individualmente. Este grau de acerto serve como parâmetro de comparação da importância de cada característica para a caracterização do tipo de defeito.

A princípio, a rede de Kohonen é um algoritmo não supervisionado. O algoritmo utilizado nesta tese utiliza um grau “suave” de supervisão como está descrito na seção 5.5.1. Este algoritmo adiciona elementos com informação do tipo de defeito aos vetores-protótipo a serem treinados. Ao fim do treinamento, cada protótipo é associado com uma etiqueta de tipo, com base nos valores atingidos pelos elementos adicionados. Os elementos adicionados antes do treinamento são retirados do vetor-protótipo e o mapa de Kohonen treinado e pré-classificado, apresenta um conjunto de protótipos para cada tipo de defeito, arranjados espacialmente no mapa em agrupamentos. Cada agrupamento tem vetores “próximos” no espaço Euclidiano de dimensão  $n$ , onde  $n$  é o número de componentes do vetor-característico utilizado no mapa. Os mapas de cada característica pode ser utilizado para classificação individualmente.

Cada agrupamento de protótipos corresponde a um tipo de defeito e correspondem, em seu conjunto, a uma representação do conhecimento implícito na base de dados referente ao tipo de defeito. É importante ressaltar, que a obtenção destes mapas de Kohonen para cada característica, representa um dos núcleos da proposta desta tese. Estes mapas em si, já funcionam como repositórios do conhecimento para uma classificação posterior. Esta forma de representação do conhecimento se assemelha à obtida por qualquer rede neural de retropropagação, no

entanto, estes mapas possibilitam a visualização da base de dados de forma organizada. Este fato permite com que o especialista humano possa facilmente checar os mapas de protótipos (“codebooks”) e conferir a informação existente.

Foram implementados dois conjuntos de algoritmos para o funcionamento do sistema de classificação. O primeiro para treinamento dos diferentes mapas de Kohonen referentes às características selecionadas e o segundo para classificação utilizando os mapas obtidos na primeira etapa.

## 7.2 - Etapa de Treinamento do Sistema de Classificação

O algoritmo para treinamento dos mapas de Kohonen para a classificação dos defeitos de ECT está representado nas figuras 7.1 e 7.2. Os passos representados nesta figuras se referem aos utilizados para treinamento dos mapas relativos a cada característica.

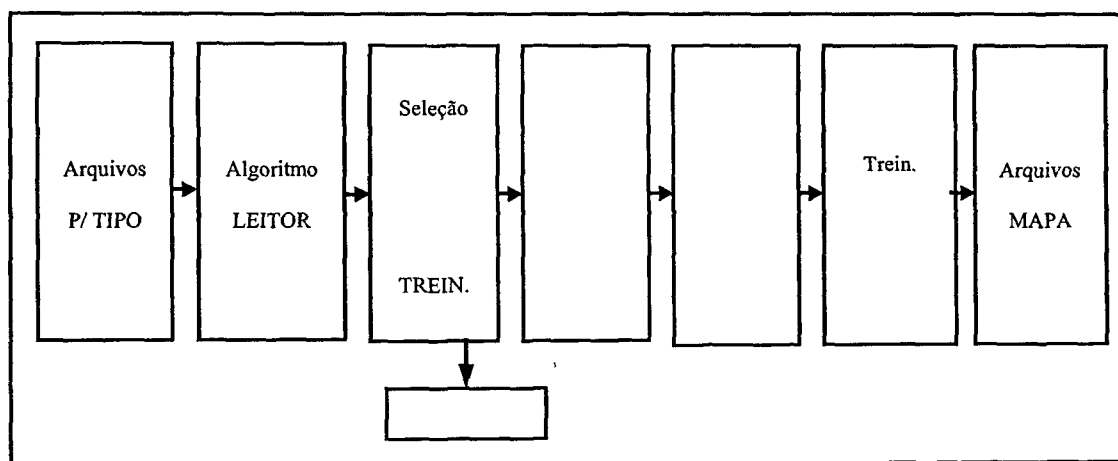


Figura 7.1 - Diagrama de blocos das etapas de treinamento.

Como pode ser visto na figura 7.1, nesta etapa de treinamento os dados são carregados e divididos em dois conjuntos, o conjunto para treinamento e outro para teste. A escolha dos dados para participarem da fase de treinamento é feita de forma

randômica mantendo a proporção de igualdade entre o número de vetores para cada tipo de degradação. Uma segunda fase do algoritmo se refere ao treinamento dos mapas de acordo com os parâmetros e dados selecionados e lidos. A terceira fase do sistema de inferência se refere à montagem de estruturas de matrizes contendo os mapas treinados e os parâmetros obtidos pelo treinamento para cada mapa. A figura 7.2 resume os passos da etapa de treinamento utilizado nesta tese. Após a escolha do tamanho do segmento de sinal a ser utilizado como base para treinamento do mapa, e selecionados aleatoriamente da base de dados, estes vetores funcionam como modelo para o treinamento dos diferentes mapas de acordo com os parâmetros escolhidos no passo 5. A escolha destes parâmetros está descrita na seção 7.2.

#### ALGORITMO DE TREINAMENTO DO SOM

- 1- Seleção do tamanho dos vetores de dados a serem utilizado (32, 64 ou 128).
- 2- Seleção de quais mapas característicos serão treinados .
- 3- Seleção da proporção entre os tamanhos do conjunto treino e conjunto teste.
- 4- Leitura dos dados de treinamento randomicamente escolhidos de acordo com os passos 1 a 3.
- 5- Escolha dos parâmetros de treinamento em lote (“batch”): tamanho do mapa, número de passos da fase grosseira (“rough”) de treinamento, número de passos da fase fina (“finetune”) de treinamento.
- 6- Treinamento dos diferentes mapas e montagem de estrutura composta das matrizes de dados, das matrizes-código treinadas, das matrizes ordenadas das etiquetas associadas a cada célula pelo treinamento.

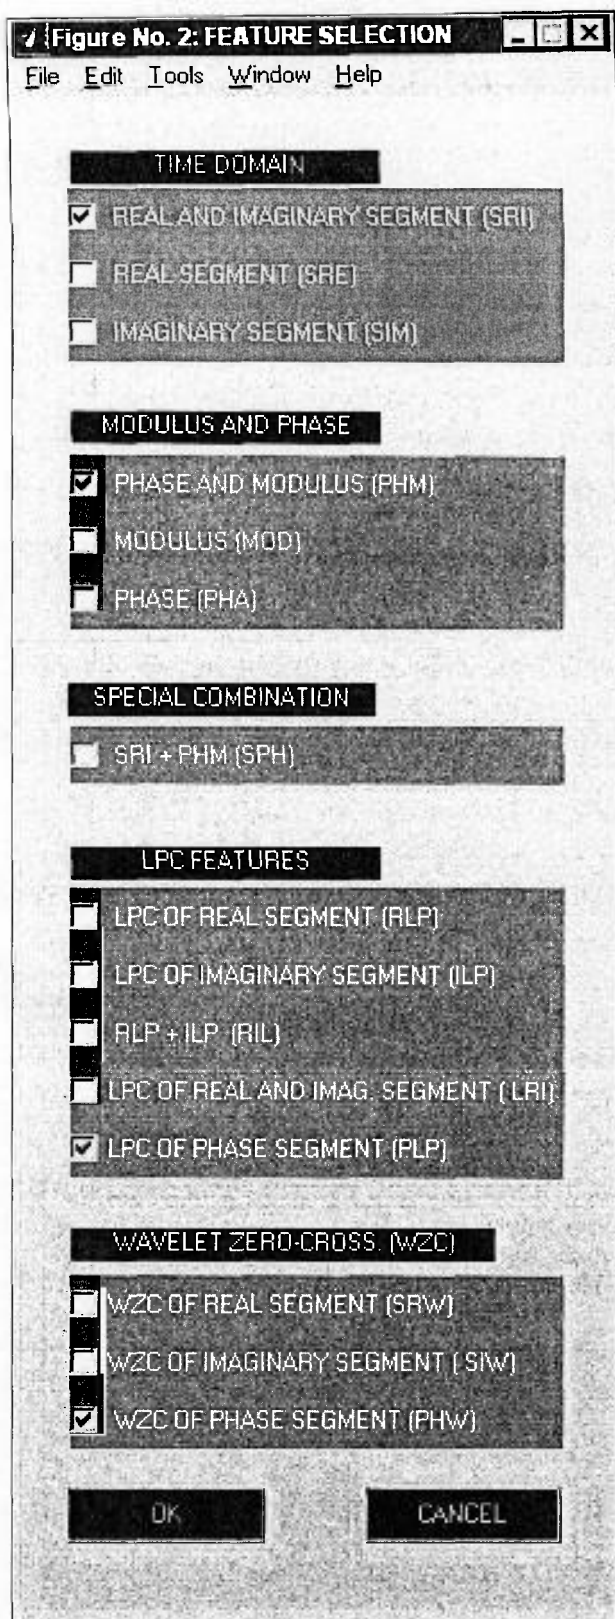
**Figura 7.2 - Diagrama de blocos das etapas de treinamento.**

Nesta etapa de treinamento o principal objetivo é a criação de arquivos que contenham todas as matrizes características e as informações relativas ao treinamento. Isto é obtido através de um algoritmo para montagem de estruturas contendo as matrizes, as etiquetas associadas à cada tipo de defeito, os parâmetros escolhidos para o treinamento e os parâmetros obtidos pelo treinamento da rede.

Através da interface gráfica, mostrada nas figuras 7.3 e 7.4, é possível selecionar os dados de acordo com os critérios descritos na seção 3.2 (“Montagem dos Conjuntos de Treinamento”) ao ser pressionado o botão “Carregar Modelos”. Este processo se refere ao bloco “algoritmo leitor” descrito na figura 7.1. Também é possível se optar entre a leitura de segmentos de 32, 64 ou 128 pontos (passo 1 da figura 7.2).



**Figura 7.3 - Interface gráfica para sistema de classificação de defeitos em ECT.**



**Figura 7.4 - Interface gráfica que permite a seleção dos mapas de Kohonen característicos a serem utilizados na classificação final.**

A escolha dos vetores de treinamento pode ser feita pressionando-se o botão “Seleção Cjto. Treino” como mostrado na figura 7.3. Este valor pode variar de zero a um. Foram utilizados dois valores nesta tese: treinamento com 50% do número total de sinais disponíveis e 67% do total dos sinais disponíveis (tabelas 7.1 e 7.2). Este algoritmo de seleção do conjunto de treinamento implementa uma seleção entre os vetores de entrada fazendo uma amostragem randômica entre os sinais. Esta amostragem, apesar de aleatória, tem como limitante a manutenção da mesma proporção de vetores referentes a cada tipo de defeito. Os índices dos vetores “escolhidos” são guardados em uma variável global e salvos em um arquivo que pode ser utilizado posteriormente pelo algoritmo de teste. Desta forma a cada treinamento um novo conjunto de dados escolhidos aleatoriamente é utilizado, e arquivado, tornando possível o teste do mapa quanto à sua eficiência na classificação.

Os parâmetros de treinamento utilizados foram escolhidos de acordo com três índices obtidos no processo. O primeiro índice é o chamado erro de quantização  $q_e$ . Este índice mede a distância euclideana média entre todos os vetores de treinamento e os protótipos das respectivas BMU (“best match unit”). O valor de  $q_e$  é atualizado para cada iteração. Para o algoritmo de treinamento em lote utilizado (seção 5.5), a atualização ocorre para as BMU e as unidades vizinhas incluídas no raio de atualização que gera a distribuição (em geral gaussiana) da ativação. Este raio começa maior na fase de treinamento inicial, chamada de “bruta”, e é reajustado para valores decrescentemente menores na fase de ajuste “fino”.

O erro de quantização é o principal índice de qualidade do treinamento do mapa, e, muitas vezes, se o número de unidades do mapa não é suficientemente grande para representar a distribuição dos dados, pode-se chegar à um erro final de treinamento relativamente elevado, mesmo com um tempo longo de treinamento.

A proporção entre o número de unidades no mapa de Kohonen e a quantidade de vetores-treinamento é chamada por **Kohonen (2001)** de  $m_{pd}$ , sendo definido por:

$$m_{pd} = \frac{m_{units}}{d_{len}} \quad (7.1)$$

onde  $m_{units}$  é o número de unidades no mapa, e  $d_{len}$  é a quantidade de vetores de treinamento.

Ainda Kohonen recomenda a escolha do número de unidades para o mapa baseado na seguinte relação heurística:


$$m_{units\_ini} = 5d_{len}^{0,54321} \quad (7.2)$$

e define os tamanhos típicos para os mapas. Ele define um mapa “pequeno” como contendo  $m_{units\_ini}/4$  células, e um mapa “grande” aquele contendo  $4 m_{units\_ini}$ .


Neste trabalho são utilizados mapas de tamanho “grande”, como sugerido por **Kohonen (2001)**, e mais dois tamanhos maiores que se mostraram mais apropriados para o treinamento. Assim é definido um tamanho “gigante” equivalente a  $12 m_{units\_ini}$  e outro “super gigante” equivalente a  $16 m_{units\_ini}$ . Estes tamanhos foram definidos porque permitiram o treinamento simultâneo dos vários mapas característicos, sem exigir a necessidade de intervenção do usuário na seleção do tamanho de cada mapa, o que aumenta em muito o tempo de execução do treinamento. Nota-se que a possibilidade de manter fixo o tamanho dos mapas para os diferentes SOM treinados pode tornar o treinamento menos eficaz e bem mais lento, já que certos mapas característicos utilizam vetores bem maiores do que outros, e portanto exigem mapas maiores para que se obtenha erros de quantização razoáveis (entre 0 e 0,5).

Nas primeiras iterações o  $q_e$  apresentou valores em torno de quatro. Deve-se observar que os vetores característicos também são normalizados para valores entre

zero e um (ver capítulo 6). A figura 7.5 apresenta dois gráficos típicos da variação do erro de quantização com o número de iterações.



(a)



(b)

**Figura 7.5 - Comportamento típico do erro de quantização (QE) durante treinamento em lote de mapa de Kohonen com 19 x 12 unidades e vetores de dimensão 256 (SRI de 128 pontos). (a) treinamento em fase "bruta"; (b) treinamento em fase "fina".**

O número de iterações recomendadas (Kohonen, 2001) para mapas típicos é  $50m_{pd}$ , sendo  $10 m_{pd}$  para a fase de treinamento “bruta” (raios maiores) e  $40 m_{pd}$  para a fase “fina” (raios menores) do treinamento. Um valor característico de um  $m_{pd}$  para um mapa com  $32 \times 19$  unidades treinando metade dos dados de treinamento (120 vetores) gira em torno de 5, portanto o número total de iterações deve ser de 250. Um treinamento “curto” é definido como  $50/4 m_{pd}$ , o que para o exemplo acima representa 62 passos. E um treinamento “longo” é definido como  $50*4*m_{pd}$  o que equivale a 1000 iterações para o exemplo citado. Como pode ser visto na figura 7.5, o erro de quantização para um mapa referente à esta tese com tamanho  $19 \times 12$  com vetores de 256 unidades, só consegue alcançar o valor de 1,07 após 900 iterações. Isto pode ser explicado pela distribuição não uniforme dos dados de entrada.

Os raios de atualização são decrescentes com o treinamento e os parâmetros raio inicial e final são definidos empiricamente. Kohonen (2001) recomenda a utilização de uma área de atualização inicial que ocupe até a metade da área de todo o mapa. Este procedimento é adotado nesta tese e, assim, o raio inicial é admitido como sendo a quarta parte do número de unidades do maior lado da matriz SOM. A topografia do mapa é hexagonal, e portanto, as distâncias topográficas são iguais em qualquer direção e o raio final para a definição da ativação é o valor unitário, ou seja, a distância dos “primeiros vizinhos”.

O segundo índice utilizado para escolha dos parâmetros de treinamento é o chamado erro topográfico ( $t_e$ ). O erro topográfico é definido como a razão entre o número de vetores de treinamento para os quais a primeira e a segunda melhores unidades do mapa (BMU) não sejam vizinhas, e o número total de vetores de treinamento. Este erro indica a preservação da distribuição topográfica do mapa, onde um erro pequeno indica a organização dos protótipos de acordo com a distribuição encontrada nos dados.


O terceiro índice utilizado para a escolha dos parâmetros de treinamento foi o próprio erro de classificação definido na equação 7.3 na seção 7.3.

Através da otimização do tamanho do tamanho do *SOM* a partir dos três indicadores ( $q_e$ ,  $t_e$  e erro de classificação) concluiu-se que o tamanho do *SOM* era importante para o erro de classificação. Desta forma, alguns mapas de tamanho “super” ( $16m_{unifs\_ini}$ ) foram treinados com um tempo “longo” ( $200m_{pd}$ ) para controle do parâmetro  $q_e$ . O  $q_e$  obtido nestes mapas de controle foram utilizados como parâmetros de qualidade para obtenção de mapas com menor tempo de treinamento (menos passos). Os mapas treinados com vetores de 256 elementos tiveram o tamanho definido em torno de 30 x 20 e o número ótimo de iterações utilizado para o treinamento na fase “bruta” foi 20, e para a fase “fina”, 100. O controle do tamanho do mapa para obtenção de tamanhos mínimos obedeceu o critério de menor erro de classificação final como definido na equação 7.3 da seção 7.3. Os erros de quantização para estes mapas otimizados variou entre 0,01 a 0,5 e o erro topográfico ficou entre 0 e 0,02.

### 7.3 - Etapa de Classificação de Defeitos

A última etapa de classificação infere o tipo dos vetores de teste baseada na comparação com os protótipos obtidos para os diferentes mapas característicos treinados na fase anterior com os vetores selecionados para o treinamento.

Os vetores de cada característica são obtidos pela aplicação dos métodos são comparados com o respectivo mapa, e para cada mapa, uma unidade é escolhida por “semelhança” ou “distância Euclideana” entre os vetores e os protótipos de cada unidade. Cada unidade do mapa escolhida (BMU), tem uma etiqueta de tipo associada a ela pela pré-classificação feita no treinamento. Assim, para cada mapa, obtém-se uma classificação do sinal. Na inferência múltipla o tipo com maior frequência de escolha entre os mapas “vence” a decisão final de classificação. Com isto, aumenta-se a precisão do diagnóstico em relação ao obtido por mapas individuais. Desta forma, cada mapa fornece um diagnóstico ao sistema e uma decisão final é feita. Os passos do procedimento de classificação são apresentados na figura 7.6.



**Figura 7.6- Algoritmo de inferência múltipla utilizado na classificação.**

O segundo conjunto de algoritmos implementados realizam a classificação propriamente dita, partindo de um conjunto de vetores de teste, e das estruturas contendo os mapas treinados no primeiro bloco. O diagrama apresentado na figura 7.7 mostra a sequência de etapas para o teste dos mapas utilizando o conjunto de vetores de teste. A leitura do conjunto de teste é feita com base nos índices salvos em arquivo na etapa de treinamento daquele conjunto. O mesmo algoritmo pode ser utilizado para testar sinais que não pertençam à base de dados utilizada. Neste caso os índices não são utilizados.

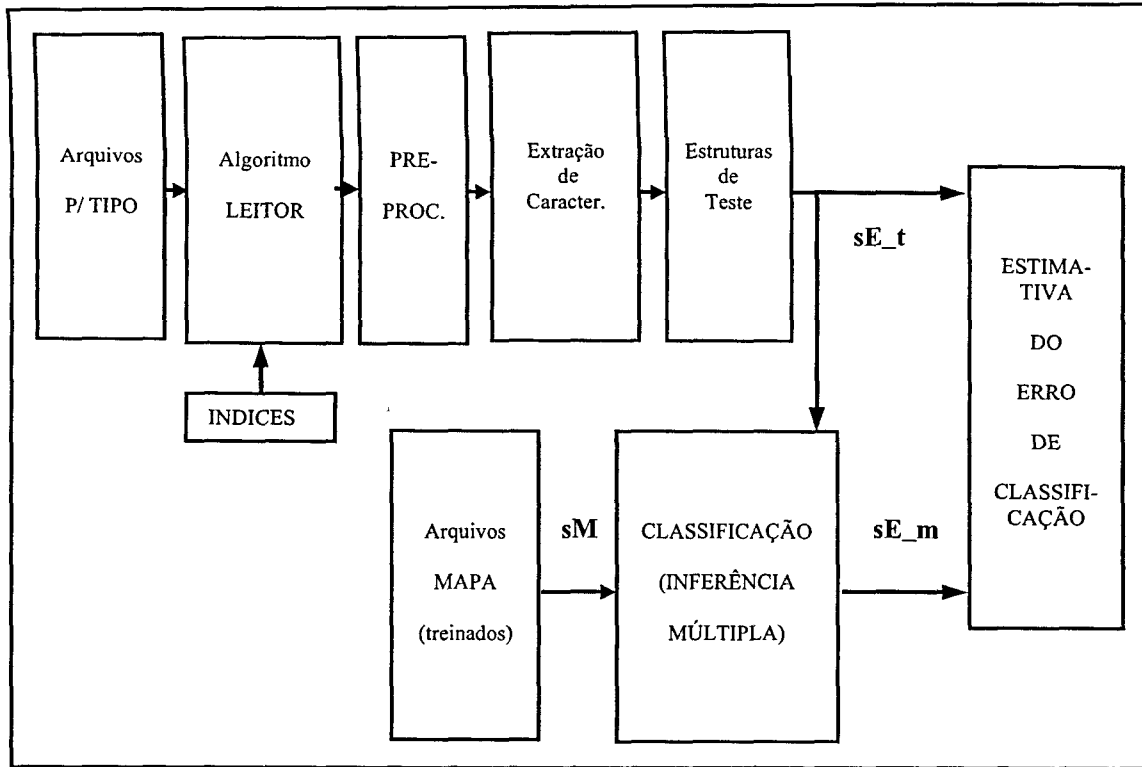


Figura 7.7 - Diagrama de blocos das etapas de teste.

Após a seleção do arquivo com os mapas treinados, o bloco de algoritmos cria duas estruturas para serem comparadas no final. A primeira estrutura  $sE_t$  (figura 7.7) contém os vetores de teste após terem sofrido a ação do módulo de pré-processamento (normalização) e extração das características relativas aos mapas treinados. A segunda estrutura  $sE_m$  é montada a partir da classificação com inferência múltipla, através da comparação entre os diversos mapas obtidos e os vetores-teste. Esta estrutura final contém os vetores de teste e as etiquetas atribuídas à cada um deles. Finalmente a estimativa de erro é obtida pela comparação entre  $sE_m$  e  $sE_t$ , e obtendo-se o erro baseado na equação:

$$\epsilon = \frac{n_e}{n_t} \quad (7.1)$$

onde  $\epsilon$  é o erro de classificação,  $n_e$  é o número de vetores-teste erroneamente classificados, e  $n_t$  é o número total de vetores-teste. Conseqüentemente o índice de acerto utilizado na tese é definido como  $\phi = (1-\epsilon)$ .

O critério de “desempate” utilizado na inferência múltipla para a decisão final quanto ao tipo de defeito foi baseado nos mapas característicos que se apresentaram mais precisos. O “desempate” é necessário nas situações em que o mesmo número de mapas atribuem a um vetor-teste, diferentes classificações.

### 7.3.1 - Resultados de Classificação e Mapas Característicos Obtidos

Nesta seção, são apresentados os resultados de classificação dos defeitos utilizando-se os mapas de Kohonen com supervisão “suave” e com a inferência múltipla.

Os resultados de classificação utilizando dos mapas de características individuais são mostrados nas tabelas 7.1 e 7.2. Os resultados são apresentados através do índice de acerto em termos percentuais. Cada resultado de índice de acerto apresentado, representa uma média obtida com dez testes diferentes. Cada teste representa uma nova amostragem (aleatória) da base de dados e um novo treinamento. Desta forma, são apresentados os índices de acerto médio com uma margem de erro equivalente a um desvio padrão dos resultados obtidos com a repetição da amostragem e treinamento.

Foram feitos testes utilizando-se segmentos do sinal de diferentes tamanhos (32, 64 e 128 amostras). Os vetores característicos relacionados nas tabelas 7.1 e 7.2 foram construídos utilizando-se estes segmentos do sinal, e os resultados são mostrados para cada um destes vetores característicos. Pode-se observar nas tabelas 7.1 e 7.2 a presença de vetores simples (utilizando apenas uma característica), e vetores compostos, como o SRI (real e imaginário), o PHM (fase e módulo), o LRI

(coeficientes de LPC de um vetor SRI) e o WRI (cruzamentos com o zero da representação de “wavelet” de um vetor SRI).

Foram utilizados dois tamanhos de conjuntos de treinamento para o sistema, um, utiliza 50% dos dados para treinamento que são apresentados na tabela 7.1. A tabela 7.2 apresenta os resultados para um conjunto de treinamento de dois terços da base de dados.

Tabela 7.1 – Índices de acerto para os diferentes mapas de Kohonen obtidos para as diferentes características do sinal de ECT com 50% da base para treinamento.

Vetores Característicos da SOM (1/2:1/2)		Índices de Acertos para Classificação p/ 5 Defeitos			
		Símbolo	128 pts	64 pts	32 pts
Domínio do Tempo					
Segmento Real		SRE	(72,0 ± 5,0)	(75,4 ± 3,5)	(73,3 ± 2,5)
Segmento Imaginário		SIM	(70,3 ± 4,5)	(71,2 ± 5,0)	(69,4 ± 3,5)
Segmento Re + Imag.		SRI	(76,0 ± 4,5)	(77,5 ± 2,5)	(78,3 ± 5,0)
Plano de Impedância					
Fase		PHA	(71,2 ± 3,5)	(72,5 ± 2,5)	(65,4 ± 3,5)
Módulo		MOD	(70,2 ± 4,5)	(71,5 ± 3,5)	(70,7 ± 4,0)
Fase + Módulo		PHM	(77,4 ± 5,0)	(76,5 ± 4,0)	(74,3 ± 5,0)
Código Linear Preditivo					
LPC de Semento Real		RLP	(51,2 ± 4,0)	(47,2 ± 3,0)	(45,4 ± 3,5)
LPC de Segmento Imagin.		ILP	(52,3 ± 3,5)	(46,4 ± 2,5)	(42,5 ± 4,0)
RLP + ILP		RIL	(53,2 ± 3,0)	(50,4 ± 4,0)	(48,0 ± 5,0)
LPC (SRI)		LRI	(61,6 ± 5,0)	(56,7 ± 5,0)	(55,4 ± 5,0)
LPC (FASE)		PLP	(63,3 ± 4,0)	(54,2 ± 3,0)	(53,2 ± 2,0)
Zeros da "Wavelet"					
WZC ( REAL )		SRW	(51,4 ± 4,5)	(43,2 ± 4,0)	(38,4 ± 6,2)
WZC ( IMAGINÁRIO)		SIW	(55,3 ± 5,0)	(45,4 ± 6,5)	(40,3 ± 5,0)
WZC ( FASE )		PHW	(53,4 ± 5,0)	(46,4 ± 6,0)	(37,2 ± 4,0)
WZC ( SRI)		WRI	(58,5 ± 5,0)	(56,4 ± 6,0)	(46,2 ± 4,0)

Tabela 7.2 – Índices de acerto para os diferentes mapas de Kohonen obtidos para as diferentes características do sinal de ECT com 66,7% da base para treinamento.

Vetores Característicos da SOM (2/3:1/3)		Índices de Acertos para Classificação de Segmentos			
		Símbolo	128 pts.	64 pts.	32 pts.
Domínio do Tempo					
Segmento Real		SRE	(75,2 ± 4,5)	(76,3 ± 2,5)	(75,3 ± 4,5)
Segmento Imaginário		SIM	(71,7 ± 3,5)	(75,7 ± 3,5)	(73,2 ± 3,5)
Segmento Re + Imag.		SRI	(81,8 ± 4,0)	(81,9 ± 4,5)	(80,4 ± 4,5)
Plano de Impedância					
Fase		PHA	(73,2 ± 3,0)	(74,3 ± 3,5)	(72,2 ± 4,5)
Módulo		MOD	(72,5 ± 4,0)	(73,8 ± 4,5)	(73,5 ± 4,0)
Fase + Módulo		PHM	(80,7 ± 5,0)	(80,9 ± 5,0)	(77,9 ± 5,0)
Código Linear Preditivo					
LPC de Semento Real		RLP	(57,4 ± 4,0)	(53,2 ± 2,5)	(52,5 ± 4,0)
LPC de Segmento Imagin.		ILP	(56,7 ± 4,0)	(54,5 ± 3,5)	(53,2 ± 3,5)
RLP + ILP		RIL	(57,2 ± 3,5)	(59,3 ± 5,0)	(55,2 ± 4,5)
LPC (SRI)		LRI	(65,3 ± 4,5)	(63,7 ± 4,5)	(63,7 ± 4,0)
LPC (FASE)		PLP	(68,7 ± 3,5)	(57,4 ± 3,5)	(53,5 ± 4,0)
Zeros da "Wavelet"					
WZC ( REAL )		SRW	(53,9 ± 4,5)	(45,8 ± 4,5)	(37,7 ± 6,0)
WZC ( IMAGINÁRIO)		SIW	(54,7 ± 3,0)	(44,7 ± 3,5)	(40,5 ± 4,0)
WZC ( FASE )		PHW	(53,0 ± 4,0)	(45,7 ± 5,0)	(35,4 ± 5,5)
WZC (SRI)		WRI	(56,0 ± 4,0)	(53,4 ± 4,5)	(44,2 ± 4,0)

**Tabela 7.3 – Índices de acerto para inferência utilizando múltiplos mapas de Kohonen obtidos para as diferentes características do sinal de ECT.**

Inferência Múltipla (SRI + SRE + SPH + PHM + SRW)	Índice de Acerto		
	128 pts	64 pts	32 pts
Treino / Teste (1/2 : 1/2)	85,3 ± 4,5	83,7 ± 5,0	80,5 ± 5,0
Treino / Teste (2/3 : 1/3)	88,2 ± 3,5	87,5 ± 4,0	83,7 ± 4,5

**Tabela 7.4 – Índices de acerto para inferência utilizando múltiplos mapas de Kohonen obtidos para as diferentes características do sinal de ECT.**

Inferência Múltipla (15 vetores característicos)	Índice de Acerto		
	128 pts	64 pts	32 pts
Treino / Teste (1/2 : 1/2)	62,3 ± 5,5	60,4 ± 5,0	56,5 ± 5,5
Treino / Teste (2/3 : 1/3)	65,2 ± 4,5	62,5 ± 4,0	57,4 ± 6,5

Observa-se que os melhores resultados de classificação obtidos pelos mapas característicos individuais foram obtidos pelos vetores SRI e PHM, que representam a informação contida diretamente pelos segmentos de vetores real e imaginário.

Observa-se também que os resultados de classificação obtidos para os vetores característicos de LPC (“linear predictive coding”) e WZC (“walet zero-crossings”) são inferiores em torno de 15% aos obtidos pelos vetores de segmento do sinal.

O índice de acerto, em geral, melhora de dois a 5% com o aumento do conjunto de treinamento de 50% para 66.7%.

Os vetores característicos que utilizam WZC, mostraram-se mais “sensíveis” à utilização de segmentos menores (32 pontos amostrados), tendo um decréscimo significativo no índice de acerto em comparação com o segmento de 64 pontos amostrados. Deve-se notar que esta mesma sensibilidade ao tamanho do vetor característico não foi observada para os vetores característicos de segmentos vetoriais. Este resultado indica que é possível caracterizar o sinal para classificação utilizando apenas um segmento de 32 pontos amostrados.

Os resultados de inferência múltipla são resumidos em duas tabelas, a 7.3 e 7.4. Estas tabelas representam a melhor e a pior combinação, em termos de resultados, para a inferência múltipla. Observa-se que a utilização de muitas características na inferência múltipla (mais do que 7 características) prejudica o desempenho da inferência múltipla (tabela 7.4). Isto é atribuído ao fato da decisão final de classificação ser erroneamente influenciada por mapas individuais com índices de acerto ruim. A utilização, na inferência múltipla, de mapas treinados com cinco vetores característicos de melhor resultado individual, resulta em um aumento no índice de acerto em torno de 5%.

A seguir, são apresentados os mapas de Kohonen e as respectivas representações do livro de códigos. O livro de códigos contém os protótipos treinados para aqueles mapas. Nas figuras 7.8, 7.9 e 7.10 são apresentadas diferentes representações de um mapa de Kohonen que obteve 92% de índice de acerto de classificação utilizando, para treinamento, dois terços (160 amostras) da base de dados. Este mapa se refere aos vetores característicos SRI de 128 elementos

formados pela concatenação dos segmentos de sinal real e imaginário de ECT (cada um com 64 elementos) e um treinamento de 1000 passos (em lote).

A figura 7.8 apresenta as assinaturas (representação no plano de impedância) dos protótipos treinados de cada unidade do mapa SRI. A figura 7.9 mostra a classificação feita sobre este mapa na fase de treinamento. Observa-se que forma-se dois pequenos agrupamentos relativos às degradações PIT e IMP que se localizam topograficamente distantes, no mapa, aos agrupamentos principais relativos a estes defeitos. Isto mostra que alguns destes sinais (30% no caso do IMP e 10% no caso de PIT) apresentam características que se assemelham com características de outros tipos de defeitos.

Uma das vantagens do mapa de Kohonen é a possibilidade de visualização do livro de códigos. A figura 7.10 mostra a sobreposição da representação do livro código sobre o mapa de Kohonen (classificado). Desta forma, pode-se visualizar, de uma forma ordenada por distância euclideana, quais as figuras de Lissajous são características para cada defeito. Deve-se ressaltar que este mapa apresenta quatro vezes mais unidades ( e portanto protótipos) do que o número de amostras utilizadas para o treinamento, obtendo-se portanto um mapeamento organizado de protótipos representativos da base de dados.

As figura 7.11, 7.12 e 7.13 mostram respectivamente os protótipos, o mapa de Kohonen classificado e a sobreposição dos protótipos com o mapa do vetor característico LRI. Este vetor é formado pelos coeficientes de LPC de um vetor SRI (Real concatenado com Imaginário). O mapa de Kohonen (30 x 26) foi treinado com segmentos de 32 coeficientes de LPC de segmentos de sinais de ECT (real e imaginário concatenados). Este mapa obteve índice de acerto de classificação de 65%.

As figura 7.14, 7.15 e 7.16 mostram respectivamente os protótipos, o mapa de Kohonen classificado e a sobreposição dos protótipos com o mapa do vetor característico WRI. Este vetor é formado pela representação de “wavelet zero-

crossings” de um vetor SRI (Real concatenado com Imaginário). O livro de códigos tem 672 unidades para um mapa 32x21. Os vetores protótipos WRI de 128 elementos foram treinados com 120 amostras (1/2) do número total de vetores da base de dados utilizada. O mapa obteve índice de acerto de classificação de 55%.

As figuras 7.17, 7. 18, 7.19, 7.20 e 7.21 apresentam um conjunto de protótipos obtidos pelo mapa de SRI citado acima (com 92% de índice de acerto na classificação com 2/3 dos dados para o treinamento). Estes vetores exibem assinaturas representativas de cada um dos tipos de defeito correspondentemente classificados.




Figura 7.8 – Representação no plano de impedância do livro-código com 32x24 (768) unidades, contendo vetores-protótipos SRI de 128 elementos treinados com 160 amostras (2/3) do número total de vetores da base de dados utilizada.




Figura 7.9 – Mapa de Kohonen (32 x 24) treinado com segmentos de 128 pontos de sinais de ECT (real e imaginário concatenados). Os códigos ISC, PIT, THI, WEA e IMP se referem aos diferentes tipos de degradação treinados.




Figura 7.10 - Representação aproximada do livro código dos vetores SRI sobrepostos ao mapa classificado obtido com índice de acerto de classificação de 92%. Cada cor representa um uma classificação do tipo de defeito como indicado no mapa da figura 7.2. (marron – ISC, verde – THI, amarelo – WEA , verde claro – PIT e azul – IMP).




Figura 7.11 – Representação dos do livro-código com 30x26 (780) unidades, contendo vetores-dos protótipos LRI , treinados com 160 amostras (2/3) do número total de vetores da base de dados utilizada.




Figura 7.12 – Mapa de Kohonen (30 x 26) treinado com segmentos de 32 coeficientes de LPCdesegmentos de sinais de ECT (real e imaginário concatenados). Os códigosISC,PIT, THI, WEA e IMP se referem aos diferentes tipos de degradação treinados.




Figura 7.13 - Representação aproximada do livro código dos vetores LRI sobrepostos ao mapa classificado obtido com índice de acerto de classificação de 65%. Cada cor representa um uma classificação do tipo de defeito como indicado no mapa da figura 7.2. (marron – ISC, verde – THI, amarelo – WEA, verde claro – PIT e azul – IMP).




Figura 7.14 – Representação dos do livro-código com 32x21 (672) unidades, contendo vetores-dos protótipos WRI de 128 elementos, treinados com 120 amostras (1/2) do número total de vetores da base de dados utilizada.




Figura 7.15 – Mapa de Kohonen (32 x 21) treinado com segmentos de 128 pontos de coeficientes de WZC de sinais de ECT (real e imaginário concatenados). Os códigos ISC, PIT, THI, WEA e IMP se referem aos diferentes tipos de degradação treinados.


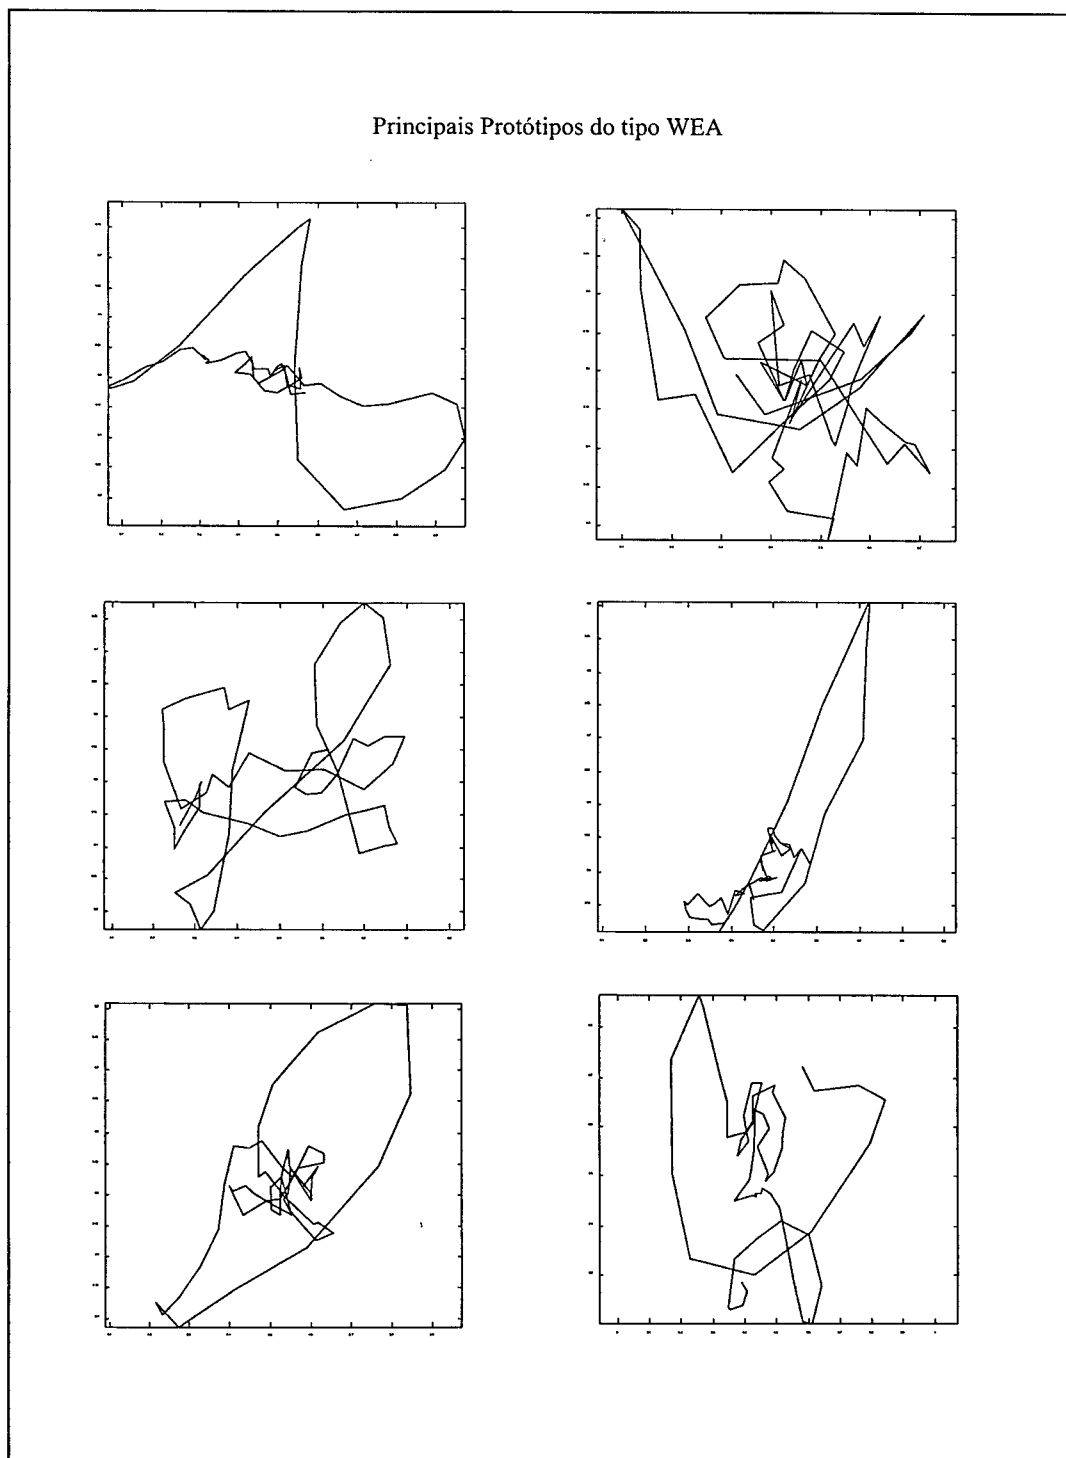
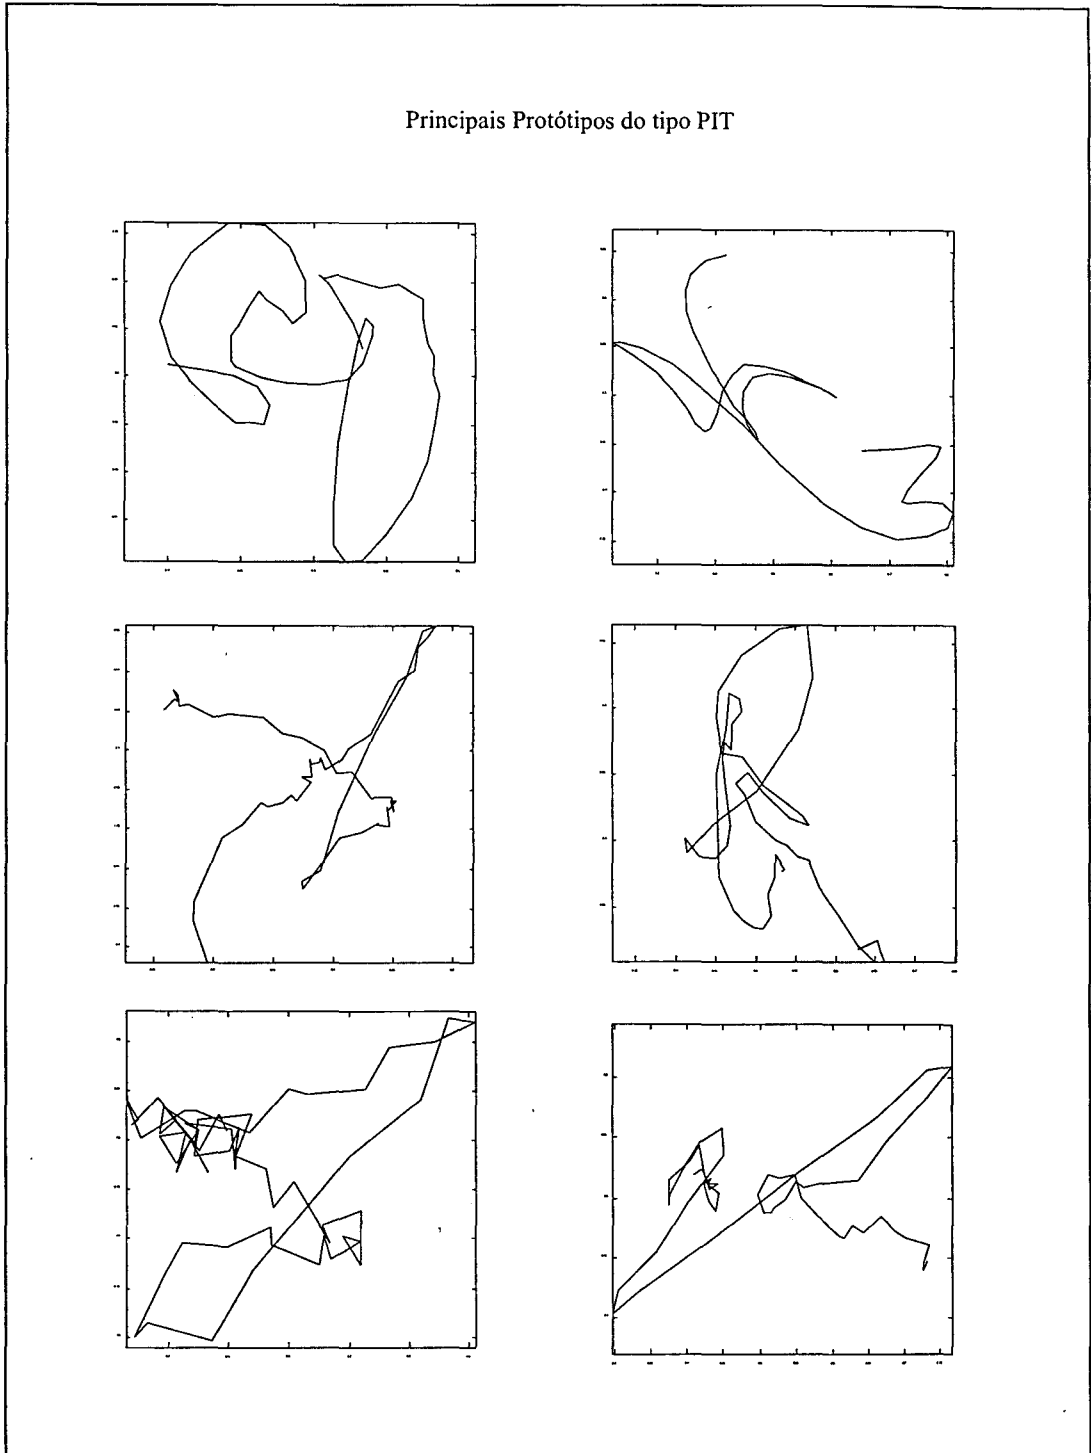


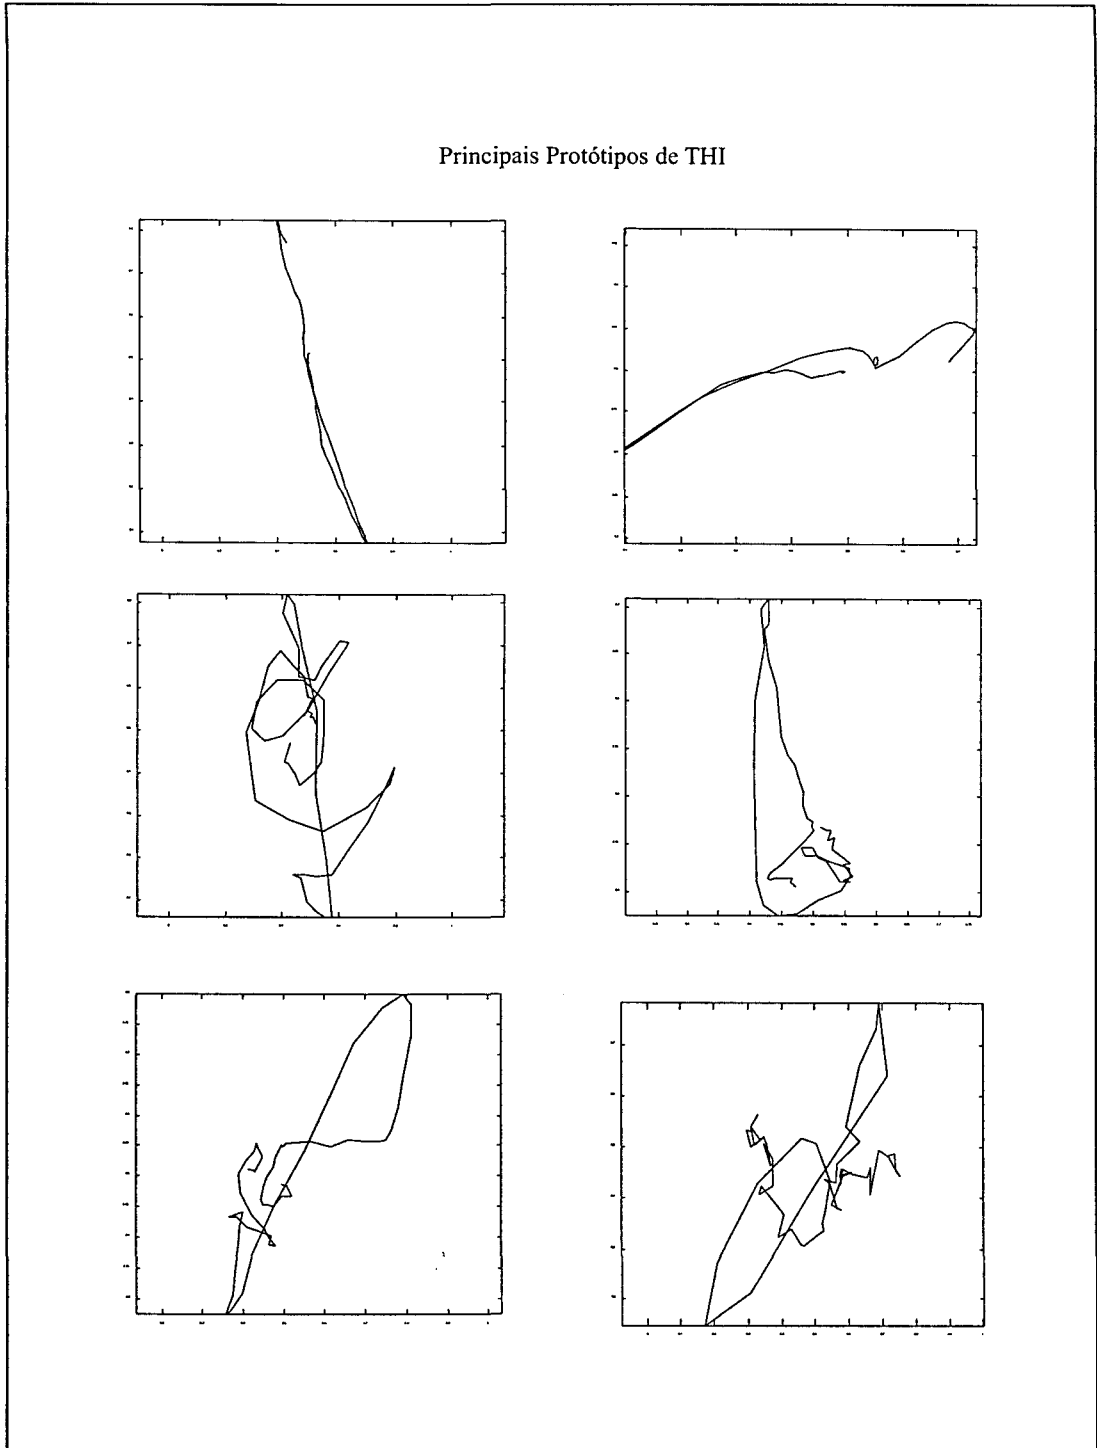
Figura 7.16 - Representação aproximada do livro código dos vetores WRI sobrepostos ao mapa classificado obtido com índice de acerto de classificação de 55%. Cada cor representa um uma classificação do tipo de defeito como indicado no mapa da figura 7.2. (marron – ISC, verde – THI, amarelo – WEA , verde claro – PIT e azul – IMP).



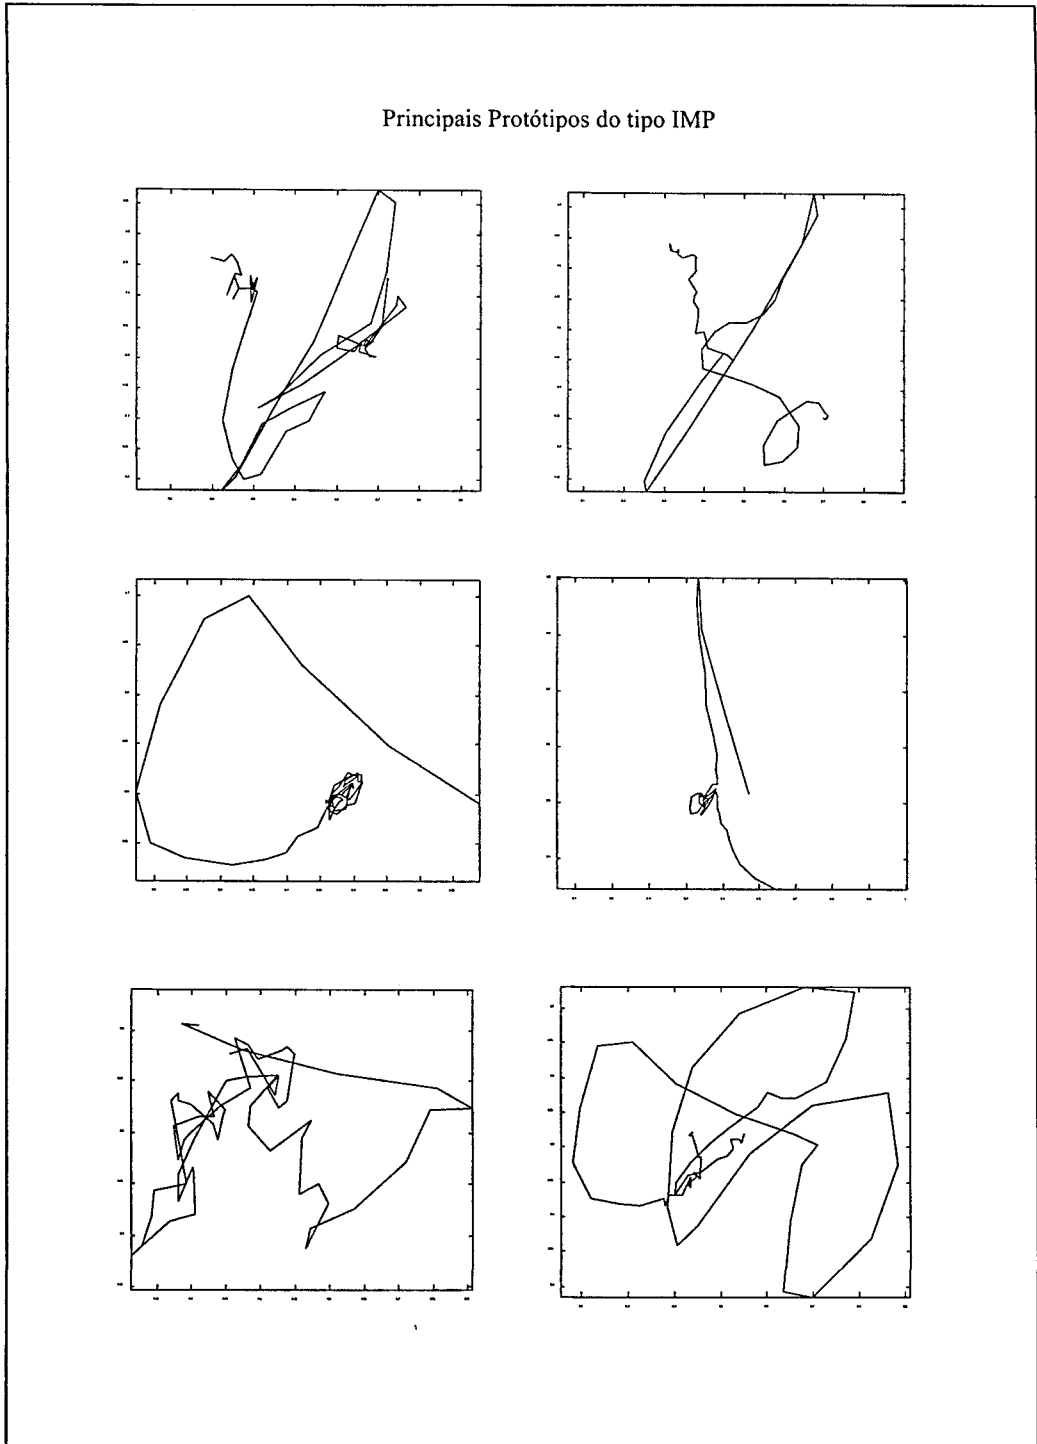
**Figure 7.17 – Principais protótipos classificados como tipo WEA, representados no plano da impedância.**



**Figura 7.18 – Principais protótipos classificados como tipo PIT, representados no plano da impedância.**




**Figura 7.19 – Principais protótipos classificados como tipo THI, representados no plano da impedância.**



**Figura 7.20 – Principais protótipos classificados como IMP, representados no plano da impedância.**

## Principais Protótipos do tipo ISC



**Figura 7.21 – Principais protótipos classificados como ISC, representados no plano da impedância.**

## 8 - CONCLUSÕES

Foi desenvolvida uma metodologia para classificar defeitos em tubos de gerador de vapor de plantas nucleares utilizando sinais do teste de correntes parasitas. Até então, o diagnóstico do tipo de defeito esteve baseado em informações não intrínsecas ao sinal, como a localização do defeito no tubo, o tipo de planta em questão, a presença da indicação no sinal de canais de frequência de excitação específicos, e outras.

O resultado obtido na classificação entre cinco tipos de defeito é um índice médio de acerto de 85% para o sistema de inferência múltipla. Este sistema utiliza diferentes mapas de Kohonen treinados individualmente com diferentes vetores característicos do sinal de ECT para fazer a inferência final quanto ao tipo de defeito.

Os resultados obtidos na classificação dos mapas treinados com vetores característicos individuais mostram que o segmento do sinal e sua representação no tempo são mais importantes para a identificação do sinal do que as características extraídas por “wavelet zero-crossing” e codificação preditiva linear. Isto pode ser atribuído ao fato de que o segmento do sinal de ECT (adquirido nas inspeções regulares das tubulações de gerador de vapor) que representa o trecho do tubo degradado, apresenta poucos pontos amostrados. Desta forma, tanto os coeficientes de LPC como a representação de “wavelet zero-crossing” não conseguem caracterizar eficientemente o sinal correspondente à cada tipo de degradação. No entanto, a utilização destas características funciona como mais um elemento classificador na inferência múltipla e contribue para a melhora dos índices de acerto de classificação em relação aos resultados obtidos com mapas individuais.

Foi utilizada uma base de dados organizada e direcionada ao treinamento de inspetores de ECT no diagnóstico e reconhecimento de defeitos em tubos de gerador de vapor de plantas nucleares. Esta base, apesar de relativamente pequena, contendo 120 defeitos, parece ser bastante representativa. Foram utilizados sinais de defeitos em diferentes localizações no tubo, visando uma maior representatividade dos

defeitos encontrados em tubos das plantas nucleares que utilizam geradores de vapor com tubos de aço Inconel 600. Portanto, pode-se esperar que os resultados obtidos nesta tese possam se estender para sinais obtidos de outras plantas e de outros sinais não pertencentes a esta base, já que também foram incluídos nesta tese, dados relativos a diferentes plantas nucleares, inclusive com diferentes arquiteturas.

A metodologia se mostrou robusta o suficiente para incluir na entrada do sistema classificador, dados que foram segmentados utilizando como parâmetro somente a indicação do centro da região degradada. O desempenho na classificação obtido com segmentos de apenas 32 pontos amostrados, confirma a robustez deste procedimento (principalmente utilizando-se os segmentos dos sinais como vetor característico) e a sua aplicabilidade para testes em plantas nucleares. A normalização (entre 0 e 1) pelo máximo do módulo do vetor de impedância utilizada como critério de pré-processamento, também contribui para demonstrar a robustez da metodologia, mesmo que possa ter reduzido os índices de acerto obtidos para a classificação dos tipos de defeito.

Foram obtidos mapas representativos de cada tipo de defeito, a partir dos quais é possível estimar as “assinaturas” mais importantes para cada tipo de defeito.

Desta maneira, o método desenvolvido além de ser promissor como classificador, favorece a visualização da distribuição dos vetores característicos através dos mapas de Kohonen e se aplica de forma precisa ao estágio em que se encontra o conhecimento sobre a relação entre os sinais de ECT e os tipos de defeito que são diagnosticados pelos especialistas (inspetores).

## **8.1 - Contribuições da tese**

As contribuições desta tese podem ser descrita de acordo com os seguintes itens:

- 1) A utilização inédita de mapas de Kohonen para classificar sinais de ECT. Este tipo de rede neural já havia sido aplicado anteriormente com sucesso no reconhecimento de padrões em voz.
- 2) Novo método de classificação de sinais utilizando inferência múltipla. A utilização de diferentes mapas de Kohonen relativos às diferentes características é uma contribuição inédita deste trabalho. A inferência múltipla obteve resultados superiores àqueles utilizando a inferência simples para cada mapa. Mesmo quando houve redundância, ou seja, quando um dos mapas de Kohonen utilizados representava característica não linearmente independente do outro também utilizado na inferência múltipla, houve melhora nos índices de acerto na classificação.
- 3) Obtenção de conjunto de protótipos de sinais relativos à cada defeito. Isto inclui os protótipos dos sinais e os protótipos das características associadas. Estes protótipos principais, após testados na classificação, e o estudo desenvolvido nesta tese, evidenciam a existência de mais de uma forma de figura de Lissajous (assinatura) característica para cada sinal.
- 4) Estudo inédito no Brasil quanto à investigação de qualquer relação entre os sinais de ECT e os defeitos de tubos de gerador de vapor em plantas nucleares. A própria descrição do problema e estudo sistemático destes sinais ainda não foi explorada de nenhuma forma no país.
- 5) Comparação da classificação entre vetores de diferentes tamanhos para caracterizar e classificar os diferentes tipos de defeitos de ECT.
- 6) Utilização de uma novo vetor característico para este tipo de sinal e comprovação de sua importância na classificação dos defeitos de tubos de gerador de vapor. Este vetor característico foi chamado nesta tese de SRI (sinal real e imaginário) e foi criado pela concatenação dos dois vetores real e imaginário em um só. Este vetor característico mostra-se importante, por permitir a utilização de técnicas de

processamento, detecção e classificação destes sinais utilizando técnicas mais simplificadas, com menor dimensionalidade.

## 8.2 - Sugestões e Perspectivas para Trabalhos Futuros

Esta tese abre um conjunto variado de opções para futuros trabalhos, tanto na aplicação específica da qual tratou, como em muitas outras aplicações. A metodologia em si, permite um estudo sistemático e parametrizado (pelo resultado da classificação) da importância de diferentes características de um sinal digital, para caracterizar um determinado padrão ou classe concomitantemente com a visualização dos vetores protótipos de cada característica.

Assim, como sugestões para trabalhos futuros pode-se citar:

- 1) O desenvolvimento de um sistema de detecção por “template matching” (ajuste de padrão) dos defeitos de ECT apresentados, utilizando “modelos” ou conjunto de “protótipos” desenvolvidos nesta tese. Atualmente a detecção automática utilizada nas plantas nucleares só é feita por limite de intensidade do sinal (“tresholding”).
- 2) Validação da metodologia desenvolvida nesta tese pela aplicação à uma base de dados maior, com a possível criação de mapas validados, que seriam repositórios do conhecimento relativo a cada tipo de defeito. Desta forma estes mapas validados, funcionariam como um banco de dados para um diagnóstico automatizado e auxílio ao inspetor de ECT.
- 3) Um estudo sistemático de comparação entre os protótipos obtidos a partir de sinais de ECT de tubos em geradores de vapor em usinas nucleares com sinais de ECT obtidos em laboratório, em condições controladas e com defeitos usinados de forma a extrair característica intrínsecas somente ao defeito.

- 4) Fusão da metodologia proposta nesta tese com metodologias anteriores para classificação, tais como sistemas de inferência nebulosa que utilizem informações relativas à localização do defeito e outras comumente utilizadas pelo especialista para o diagnóstico. Esta fusão entre as duas metodologias, deve aumentar de forma significativa os índices de acerto na classificação.
- 5) Desenvolvimento de parâmetros para a automação do uso de algoritmos de filtragem (tipo “de-noising”) para defeitos em ECT. Este estudo se faz necessário para que não se percam características importantes do sinal pela filtragem de informações contidas no suposto “ruído”. O sucesso na classificação pode ser um parâmetro importante neste desenvolvimento, ao mesmo tempo, melhorar de forma significativa o sucesso da classificação automática.
- 6) Aplicação da metodologia desta tese (inferência com múltiplas características) para outros tipos de sinais característicos de defeitos ou padrões a serem reconhecidos e classificados, como em reconhecimento de voz ou em aplicações médicas: sinais de eletroencefalograma, sinais de ressonância magnética nuclear, principalmente a funcional (“functional magnetic resonance imaging”).
- 7) A otimização do algoritmo de inferência múltipla desenvolvido nesta tese (utilizando o SOM com supervisão suave) através da introdução de outros parâmetros para a inferência entre os diferentes mapas, como por exemplo, a distância do vetor testado aos primeiros vizinhos da rede. O sistema atual utilizou só o número de decisões dos mapas individuais para a decisão final.

## LISTA DE REFERÊNCIAS

AARTS, E.; KORST, J. **Simulated annealing and boltzmann machines**, New York: John Wiley & Sons, 1989.

ACKLEY, D.H.; HINTON, G.E.; SEJNOWSKI, T.J. A learning algorithm for Boltzmann machines. **Cognitive Science**, v.9, p.147-169, 1985.

ALENCAR, D.A. **SIMPAR: Sistema de simulação de testes de tubos por correntes parasitas**. Belo Horizonte, 1995. 144p. Dissertação (Mestrado) - Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte.

AMERICAN SOCIETY OF MECHANICS ENGINEERS (ASME). Section V, Article 8; **Boiler and pressure vessel code**. New York, 1992. p. 127-133.

ANDERSON, J.; PELLIONISZ, A.; ROSENFELD, E. **Neurocomputing 2: Directions for Research**. Cambridge Massachusetts, MIT Press, 1990.

ANTOINE, J.P.; BARACHE, D.; CESAR JR., R.M.; et al. Shape characterization with the wavelet transform. **Signal Processing**, v.62, p.265-290, 1997.

AZIMI-SADJADI, M.R.; YAO, D.; HUANG Q.; et al. Underwater target classification using wavelet packets and neural networks. **IEEE Transactions on Neural Networks**, v.11, n.3, p.784-794, May 2000.

BAJCSY, R.; KOVACIC, S. Multiresolution elastic matching. **Computer Vision Graphics Image Processing**, v.46, p.1-21, 1989.

BEALE R.; JACKSON, T. **Neural computing: an introduction**. New York: Adam Hilger, 1990.

BELL, A.; SEJNOWSKI, T. An information-maximization approach to blind separation. **Neural Computation**, v.7, p.1004-1034, 1995.

BERMEJO, S.; CABESTANY, J. Oriented principal component analysis for large margin classifiers. **Neural Networks**, 2001. /no prelo/

BISHOP, C.M. **Neural networks for pattern recognition**. New York: Oxford University Press, 1995.

BOUTON, C.; PAGÈS. Self-organization and convergence of the one-dimensional Kohonen algorithm with non uniformly distributed stimuli. **Laboratoire de Probabilités**, Université Paris VI, Paris, 1992.

BRAY, D.E.; MCBRIDE, D. **Nondestructive testing techniques**. New York: John Wiley & Sons, 1992. 753p.

BROWN, S.D. Template matching – an approach for the machine sorting of eddy current data. **Materials Evaluation**, v.43, p.1553-1565, Nov. 1985.

BRUZZONE, L.; ROLI, F.; SERPICO, S.B. Structured neural networks for signal classification. **Signal Processing**, v.64, p.271-290, 1998.

BUNKE, H.; KANDEL, A. **Neuro-fuzzy pattern recognition**. Singapore: World Scientific, 2000.

CAUDILL, M.; BUTLER, C. **Naturally Intelligent Systems**, Cambridge:MIT Press, 1989.

CHEN, B.H.; WANG, X.Z.; YANG, S.H.; et al. Application of wavelets and neural networks to diagnostic system development, 1, feature extraction. **Computers and Chemical Engineering**, v.23, p.899-906, 1999.

CHEN, C.H.; LEE, J.D.; LIN, M.C. Classification of underwater signals using wavelet transforms and neural networks **Mathematical Computing Modeling**, v.27, n.2, p.47-60, 1998.

CHIUEH, T.D.; TANG, T.T.; CHEN, L.G. Vector quantization using tree-structured self-organizing feature maps. **IEEE Journals on Selected Areas in Communications**, v.12, n.9, p.1594-1599, Dec. 1994.

COMON, P. Independent Component Analysis, a New Concept? **Signal Processing**, v.36, n.3, p.287-314, 1994.

ESTADOS UNIDOS DA AMÉRICA. CONVAIR DIVISION OF GENERAL DYNAMICS CORPORATION. Classroom training handbook. **Nondestructive testing – eddy current testing**. San Diego, California: 1967. 61p.

DAUBECHIES, I. The wavelet transform: A method of time-frequency localization. In: **Advances in Spectral Analysis**, Editado por Haykin, S. New York: Prentice-Hall, 1990.

DE MORI, R. **Recent advances in feature extraction and acoustic modeling for automatic speech recognition**. Munich, Germany, 1997. Invited Expert Summary IEEE. International Conference on Acoustics, Speech and Signal Processing (ICASSP). Disponível em: <<http://www.lia.univ-avignon.fr/publications/>>. Acesso em: 9 jun. 2000.

DEBELJAK, Z.; STRAPAC, M.; MEDIC-SARIĆ, M. Application of self-organization maps for the classification of chromatographic systems and prediction of values of chromatographic quantities. **Journal of Chromatography A**, v.925, p.31-40, 2001.

DEMPSTER, A.P.; LAIRD, N.M.; RUBIN, D.B. Maximum likelihood from incomplete data via the EM algorithm (with discussion). **Journal of Royal Statistical Society**, v.39, p.1-38, 1977.

DESIENO, D. Adding a conscience to competitive learning. In: IEEE International Conference on Neural Networks, San Diego, 1988. **Proceedings ...**, New York, 1988. v.1, p.117-124.

DEVROYE, L. Automatic pattern recognition: a study of the probability of error. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.10, n.4, p.530-543, 1988.

DEVROYE, L.; GYORFI L.; LUGOSI G. **A probabilistic theory of pattern recognition**. Berlin: Springer-Verlag, 1996.

DIEREKS, D.R.; BAKHTIARI, S.; CHOPRA, O.K.; et al. **Steam generator tube integrity program**. Semiannual report August 1995 – May 1996, NUREG/CR-6511, ANL-96/17, v. 1, USA, April 1997.

DODD, C.V. **Data analysis for steam generator tubing samples**. Report for US. Nuclear Regulatory Commission, NUREG/CR-6455, ORNL/TM-13206, July 1996.

DONOHU, L. D. De-noising by soft-thresholding. **IEEE Transactions on Information Theory**, v.41, n.3, May 1995.

DOS SANTOS, M. T. **Estudo do monitoramento do desgaste de fresas de topo baseado no emprego de sensores**. São Paulo, 1998. 178p. Tese (Doutorado) - Escola Politécnica, Universidade de São Paulo.

DUDA, R.O.; HART P.E.; STORK, D.G. **Pattern Classification**. 2.ed. New York: John Wiley & Sons, 2001. 654p.

ENGLEHART, K. **Signal representation for classification of the transient myoelectric signal**. New Brunswick, Canada, Oct. 1998. 150p. Tese (Doutorado) - University of New Brunswick, Canada. Disponível em: [www.ee.unb.ca/kengleha/publicat.htm](http://www.ee.unb.ca/kengleha/publicat.htm). Acesso em: 14 Maio 2001.

EPRI - Electric Power Research Institute. **Steam generator eddy current data analysis performance demonstration: review material**. Palo Alto, California: Oct. 1995.

ETEMAD, K.; CHELLAPPA, R. Separability-based multiscale basis selection and feature extraction for signal and image classification. **IEEE Transactions on Image Processing**, v.7, n.10, p.1453-1465, Oct. 1998.

FAHLMAN, S.E. Faster-learning variations of back propagation: an empirical study. In: Connectionist Models Summer School, San Mateo, 1988. **Proceedings...** San Mateo: Morgan Kaufmann, 1990. p.534-542.

FELDKAMP, L.A.; PUSKORIUS, G.V. A signal processing framework based on dynamic neural networks with application to problems in adaptation, filtering and classification. **Proceedings of the IEEE**, v.86, n.11, p.2259-2277, Nov. 1998.

FERNANDEZ E.A.; PRESEDO J.; BARRO S. An ECG ischemic detection system based on self-organizing maps and a sigmoid function pre-processing stage artificial intelligence in medicine. In: Joint European Conference on Artificial Intelligence in Medicine and Medical Decision Making. **Proceedings...**, Springer Verlag, 1999. v.1620, p.207-216.

FINLÂNDIA. Laboratory of Computer and Information Science. **SOM Toolbox version 2**. Finland, Feb. 2000. Disponível em: <http://www.cis.hut.fi/projects/somtoolbox/>. Acesso em: 15 Mar. 2001

FORGY, E.W. Cluster analysis of multivariate data: efficiency vs interpretability of classifications. **Biometrics**, v.21, p.768-769, 1965.

FRIEDMAN, J. H. Regularized discriminant analysis. **Journal of American Statistical Association**, v.84, p.165-175, 1989.

FRITZKE, B. Fast learning with incremental RBF networks. **Neural Processing Letters**, v.1 (1), p.2-5, 1994a.

FRITZKE, B. Growing cell structures – a self-organizing network for unsupervised and supervise learning. **Neural Networks**, v.7 (9), p. 1441-1460, 1994b.

FRITZKE, B. **A growing neural gas network learns topologies**. In: Tesauro G.; Toruetzky, D.S, Leen T.K. *Advances in Neural Information Processing Systems*. Cambridge, MIT Press, 1995.

FRITZKE, B. *Some Competitive Learning Methods*. Institute for Neural Computation Ruhr-Universität Bochum, 1997. Disponível na internet no endereço: <http://www.neuroinformatik.ruhr-uni-bochum.de>. Acesso em: 03 Abril de 2002.

FU, K.S. **Syntactic pattern recognition and applications**. Englewood Cliffs, N.J.: Prentice Hall, 1982.

FU, K.S. A step towards unification of syntactic and statistical pattern recognition. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.5, n.2, p.200-205, Mar. 1983.

GRENANDER, U. **General Pattern Theory**. Oxford University Press, 1993.

GROSSBERG, S. Adaptive pattern classification and universal recording, I: Parallel development and coding of neural feature detectors. **Biological Cybernetics**, v.23, p.121-134, 1976.

GROSSMANN, A.; MORLET, J. Decomposition of Hardy functions into square integrable wavelets of constant shape. **SIAM Journal of Mathematics**, v.15, p.723-736, 1984.

HASTIE, T. **Principal curves and surfaces**. Technical Report 11, Department of Statistics, Stanford University, 1984.

HASTIE, T.; STUETZLE, W. Principal curves. **JASA**, v.84, p.502-516, 1989.

HEBB, D. **Organization of Behavior**, New York: John Wiley, 1949.

HECHT-NIELSEN, R. **Neurocomputing**, Reading: Addison-Wesley, 1990.

HINES J.W. **MATLAB Supplement to fuzzy and neural approaches in engineering**. New York: York: John Wiley & Sons, 1997.

HOOPER, W.C.; DASILVA, D., UPADHYAYA, B.R. **Eddy current test data analysis for steam generator tubing diagnosis**. Annual Report of Nuclear Engineering Department of the University of Tennessee – Knoxville, Tennessee. Prepared for the Electric Power Research Institute (EPRI), Palo Alto, California, Jan. 1997.

HOOPER, W.C.; UPADHYAYA, B.R. **An automated diagnostics system for eddy current data analysis of steam generator tubing**. Annual Report of Nuclear Engineering Department of the University of Tennessee – Knoxville, Tennessee. Prepared for the Electric Power Research Institute (EPRI), Palo Alto, California, Jan. 1998.

HOPFIELD, J.J. Neurons with graded response have collective computational properties like those of two-state neurons. **Proceedings of the National Academy of Sciences ( USA)**, v.79, p.2554-2558, 1982.

HUGHES, D.E. Induction-balance and experimental researches therewith. **Philosophical Magazine**, v.8, p.50-56, 1879.

IAEA (INTERNATIONAL ATOMIC ENERGY AGENCY). **Assessment and management of agency of major nuclear power plant components important to safety: steam generators**. TECDOC – 981. Vienna, Nov. 1997.

JAIN, A.K.; DUIN, R.P.W.; MAO, J. Statistical pattern recognition: a review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.22, n.1, p.4-37, Jan. 2000.

KANG, S.J.; MOON, J.C.; CHOI, D.H.; et al. A distributed and intelligent system approach for the automatic inspection of steam-generator tubes in nuclear power plants. **IEEE Transactions on Nuclear Science**, v.45, n.3, p.1713-1722, 1998.

KARHUNEN, J.; OJA, E.; WANG, L.; et al. A class of neural networks of independent component analysis. **IEEE Transactions on Neural Networks**, v.8, n.3, p.486-504, 1997.

KENNEDY, J.; MORASSO, P. Application of self-organizing networks to signal processing. **Lecture Notes on Computer Science**, n.412, p.225-232, 1990.

KHALIL, M.; DUCHÊNE, J. Detection and classification of multiple events in piecewise stationary signals: comparison between autoregressive and multiscale approaches. **Signal Processing**, v.75, p.239-251, 1999.

KOHOENEN, T. Clustering, taxonomy, and topological maps of patterns. In: 6<sup>th</sup> International Conference on Pattern Recognition, Munich, 1982. **Proceedings... Munich, 1982**. p.114-128.

KOHONEN, T. An Introduction to neural computing. *Neural Networks*, v.1, p.3-16, 1988a.

KOHONEN, T. The “neural phonetic typewriter”. *Computer*, v.21, n.3, p.11-22, 1988b.

KOHONEN, T. Things you haven't heard about the self-organizing maps. In: *International Conference on Neural Networks*, Piscataway, 1993. **Proceedings ...** Piscataway, 1993. p.1147-1156.

KOHONEN, T. **Self-organizing maps**. 3.ed. Springer-Verlag Berlin Heidelberg New York, 2001. 501p.

KOHONEN, T.; MÄKISARA, K.; SARAMÄKI, T. Phonotopic Maps – insightful representation of phonological features for speech recognition. In: *7<sup>th</sup> International Conference on Pattern Recognition*, 1984. **Proceedings ...** Los Alamitos, 1984. p.182-185.

KORN, G.A. **Neural Network Experiments on Personal Computers and Workstations**. Cambridge: MIT Press, 1992.

KOSKO, B. **Neural networks and Fuzzy Systems, a dynamical systems approach to machine intelligence**. Prentice-Hall International Inc, 1992.

KRAMER, M.A. Nonlinear principal component analysis using autoassociative neural networks. *AIChE Journal*, v.37, p.233-243, 1991.

KREUTZBRUCK, M.V.; TRÖLL, J.; MÜCK, M.; et al. Experiments on Eddy Current NDE with HTS rf SQUIDS. In: *Applied Superconductivity Conference. Proceedings...*, 1996.

KURTZ, R.J.; HEASLER, P.J.; ANDERSON, C.M. **Performance demonstration tests for eddy current inspection of steam generator tubing.** Pacific Northwest National Laboratory, prepared for U.S. Nuclear Regulatory Commission, NUREG/CR-6227, PNLL-9433, USA, May 1996.

LINDE, Y.; BUZO, A.; GRAY, R.M. An algorithm for vector quantizer design. **IEEE Transactions on Communications**, v.28, p.84-95, 1980.

LLOYD, S.P. Least squares quantization in PCM's. **Bell Telephone Laboratories Paper.** New Jersey: Murray Hill, 1957.

LUO, F.L.; UNBEHAUEN R. **Applied Neural Networks for Signal Processing.** New York: Cambridge University Press, 1997.

MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: Fifth Berkeley Symposium on Mathematical Statistics and Probability, Berkeley, 1967. **Proceedings ...** University of California Press, 1967. p.281-297.

MALLAT, S. A theory for multiresolution signal decomposition: the wavelet representation. **IEEE Pattern Anal. and Machine Intelligence**, v.11, n.7, p.674-693, 1989a.

MALLAT, S. Multifrequency channel decompositions of images and wavelet models. **IEEE Transactions on Acoustic Speech Signal Processing**, v.37, n.12, p.2091-2110, 1989b.

MALLAT, S. Zero-crossings of a wavelet transform. **IEEE Transactions on Information Theory**, v.37, n.4, 1991.

MANDAMI, E.H. Application of fuzzy logic to approximate reasoning using linguistic synthesis. **IEEE Transactions on Computers**, v. 12, p. 1182-1191, 1977.

MARKHOUL, J. Linear predictions: a tutorial review. **Proceedings of IEEE**, v.63, n.4, 1975.

MARLSBURG, C. Self-organization of orientation sensitive cells in the striate cortex. **Kybernetic**, v.14, p.85-100, 1973.

MARTINEZ, T.M. Competitive Hebbian learning rule forms perfectly topology preserving maps. In: International Conference on Artificial Neural Networks, Amsterdam, 1993. **Proceedings ... Springer**, 1993. p.427-434.

MARTINEZ, T.M.; SCHULTEN, K.J. A "neural-gas" network learns topologies. In: Artificial Neural Networks, editado por: Kohonen, T; Mäkisara K; Simula O; Kangas, J, p. 397-402, North-Holland, Amsterdam, 1991.

MARTINEZ, T.M.; SCHULTEN, K.J. Topology representing networks. **Neural Networks**, v.7, p.507-522, 1994.

MAX, J. Quantizing for minimum distortion. **IRE Transactions on Information Theory**, v.IT-6, p.7-12, 1960.

MCCULLOCH, W.S.; PITTS, W. A logical calculus of ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v.5, p.115-133, 1943.

MCMASTER, R.C. **Nondestructive Testing Handbook**. Edited for the American Society for Nondestructive Testing. New York: Ronald Press, 1959. v.1 and 2.

MCMASTER, R.C. The history, present status, and future development of eddy current tests. In: Workshop on Eddy Current Nondestructive Testing, November 3-4, 1977, Maryland. **Proceedings...** Maryland, 1981. p.1-32.

MESQUITA, R.N.; CABRAL, E.L.L.; UPADHYAYA, B.R. Classification of steam generator tube defects using linear predictive coding and a self-organizing neural network. In: MARCON, Gatlinburg 2001. **MARCON 2001**. 1 CD-ROM.

MEYER, Y. **Wavelets and Operators**. New York: Cambridge University, 1992 (primeira edição em lingual inglesa); **Ondelettes et Operateurs**. Paris: Hermann, 1988.

MIAO, X.; AZIMI-SADJADI, M.R.; TIAN, B.; et al. Detection of mines and mine like targets using principal component and neural-networks methods. **IEEE Transactions on Neural Networks**, v.9, n.3, p.454-463, May 1998.

OJA, E. The nonlinear PCA learning rule in independent component analysis. **Neurocomputing**, v.17, n.1, p.25-45, 1997.

OMOHUNDRO, S.M. The Delaunay triangulation and function learning. International Computer Science Institute, TR-90-001, Berkeley, 1990.

PARK, S.H.; LEE, S.P. EMG pattern recognition based on artificial intelligence techniques. **IEEE Transactions on Rehabilitation Engineering**, v.6, n.4, p.400-405, Dec. 1998.

PARKER, D. **Learning Logic, Invention Report**, S81-64, file 1, Office of Technology Licensing, Palo Alto: Standford University, 1972.

PICARD, R. **Affective Computing**. MIT Press, 1997.

RABINER, L.R.; SCHAFER, R.W. **Digital processing of speech signals**. New Jersey: Prentice-Hall, 1978.

RAJESH, S.N.; UDPA, L; UDPA S.S. Numerical model based approach for estimating probability of detection in NDE applications. **IEEE Transactions on Magnetics**, v.29, n.2, p.1857-1860, Mar. 1993.

RAO, V.B.; RAO, V.R. **C++ Neural Networks & Fuzzy Logic**. New York:MIS Press, 1995.

REED, R.D.; MARKS II, R.J. **Neural Smithing – supervised learning in feedforward artificial neural networks**. Massachusetts: MIT Press, 1999.

REIFMAN, J. Survey of artificial intelligence methods for detection and identification of component faults in nuclear power plants. **Nuclear Technology**, v.119, n.1, p.76-97, 1997.

RIPLEY, B. **Statistical aspects of neural networks**. Networks on Chaos: Statistical and Probabilistic Aspects. U. Bornndorff-Nielsen, J. Jensen, and W. Kendal, eds., Chapman and Hall, 1993.

RIPLEY, B. Pattern recognition and neural networks. Cambridge, Mass.: Cambridge University Press, 1996.

RITTER, H.J.; MARTINEZ, T.M.; SCHULTEN, K.J. **Neuornale Netze**. Addison-Wesley, München, 1991.

RITTER, H.J.; MARTINEZ, T.M.; SCHULTEN, K.J. **Neural Computation and Self-Organization Maps: An Introduction**. Massachussets: Addison-Wesley, 1992.

ROSENBLATT, F. **Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms**. Washington DC: Spartan Books, 1961.

RUMELHART, D.E.; HINTON, G.R.; WILLIAMS, R.J. **Learning internal representations by error propagation**. In: *Parallel Distributed Processing*, editado por Rumelhart, D.E.; McClelland, J.L. Cambridge: MIT Press, 1986.

SADJADI, M.R.A.; YAO, D.; HUANG Q.; et al. Underwater target classification using wavelet packets and neural networks. **IEEE Transactions on Neural Networks**, v.11, n.3, p.784-794, May 2000.

SAMAD, T. **Backpropagation is significantly faster if the expected value of the source unit is used for update**. In: *International Network Society Conference Abstracts*, 1988.

SHINDO, Y.; YOSHIE, S.; MARIMOTO, M. Quantitative system for evaluating eddy current testing of heat exchanger tubing. **Materials Evaluation**, v.43, p. 1299, Sept. 1985.

SIMPSON P.K. **Artificial neural systems**. New York: Pergamon Press, 1989.

SMITH, M.J.; BARNWELL, T.P. Exact reconstruction techniques for tree-structured subband coders. **IEEE Transactions on Acoustic Speech Signal Processing**, v.34, 1986.

STOLTE J., UDPA L; LORD W. Multifrequency eddy current testing of steam generator tubes using optimal affine transformation. In: D.O. Thompson; D.E. Chimenti. **Review of Progress in Quantitative Nondestructive Evaluation**. New York, Plenum Press, 1982. v.7A, p.821-830.

STRANG, G.; NGUYEN, T. **Wavelets and Filter Banks**. USA: Wellesley-Cambridge, 1997.

SWORD, C.K.; SIMAAN M. Estimation of mixing parameters for cancellation of discretized eddy current signals using time and frequency domain techniques. **Journal of Nondestructive Evaluation**, v.5, n.1, 1985.

TEGOPOULOS, J.A.; KRIEZIS, E.E. **Eddy currents in linear conducting media**. Netherlands: Elsevier, 1985. v.16. (Elsevier Series in Studies in Electrical and Electronic Engineering).

TSOUKALAS, L.H.; UHRIG, R.E. **Fuzzy and neural approaches in engineering**. New York: John Wiley & Sons, 1996.

UDPA, S.S.; LORD, W. A Fourier descriptor classification scheme for differential probe signals. **Materials Evaluation**, v.42, n.9, p. 1136-1141, 1984.

UDPA, L.; UDPA, S.S. Eddy current defect characterization using neural networks. **Materials Evaluation**, v.48, n.3, p. 342-347, 1990.

UPADHYAYA, B.R.; YAN, W., BERKAN, R.C. **Hybrid digital signal processing and neural networks for automated diagnostics using NDE method**. Annual Report of Nuclear Engineering Department of the University of Tennessee – Knoxville, Tennessee. Prepared for the U.S. Nuclear Regulatory Commission Office Of Nuclear Regulatory Research, Nov. 1993.

UPADHYAYA, B.R.; YAN, W.; BEHRAVESH, M.M.; et al. Development of a diagnostic system for eddy current data analysis using applied artificial intelligence methods. **Nuclear Engineering and Design**, v.193 p.1-11, 1999a.

UPADHYAYA, B.R.; ERBAY, A.S.; HÁZI, G.; et al. **Eddy current test data analysis for steam generator tubing diagnosis using artificial intelligence methods**. Annual Report of Nuclear Engineering Department of the University of Tennessee – Knoxville, Tennessee. Prepared for the Electric Research Institute (EPRI), Palo Alto, California, Feb. 1999b.

VIGÁRIO, R.; SARELA, J.; JOUSMAKI, V.; et al. Independent component approach to the analysis of EEG and MEG recordings. **IEEE Transactions on Biomedical Engineering**, v.47, n. 5, May 2000.

WADE, M.A. Numerical study of linear predictive coding for the compression of gray scale images. Knoxville, TN, Dec. 1993. Tese (Mestrado) - University of Tennessee, Knoxville.

WAHLBERG P.; LANTZ, G. Methods for robust clustering of epileptic EEG Spikes. **IEEE Transactions on Biomedical Engineering**, v.47, n.7, p.857-868, July 2000.

WANG, X.Z.; CHEN, B.H.; YANG, S.H.; et al. Application of wavelets and neural networks to diagnostic system development, 2, integrated framework and its application. **Computers and Chemical Engineering**, v.23, p.945-954, 1999.

WASSERMAN, P.D. **Neural computing – theory and practice**. New York: Van Nostrand Reinhold, 1989.

WASSERMAN, P.D. **Advanced methods in neural computing**. New York: Van Nostrand Reinhold, 1993.

WATANABE, S. **Pattern recognition: human and mechanical**. New York: John Wiley & Sons, 1985.

WEHRMEISTER, A.E. Eddy current examination in the nuclear industry. In: Workshop on Eddy Current Nondestructive Testing, Maryland, Nov., 1977. **Proceedings...** Maryland, 1981. p.49-55.

WERBOS, P. J. **Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences.** Boston, 1974. Tese (Doutorado) - Harvard University, USA.

WIDROW, B.; HOFF, M.E. Adaptive switching circuits. In: ANDERSON J.A.; ROSENFELD E. **IRE Convention Record.** New York, 1960. p.96-104. (Reimpresso em: **Neurocomputing.** Cambridge: MIT Press, 1988).

WITKIN, A. Scale space filtering. In: International Joint Conference in Artificial Intelligence. **Proceedings ...**, 1983.

WU, W.; WALCZAK, B.; MASSART, D.L.; et al. Artificial neural networks in classification of NIR spectral data: design of the training set. **Chemometrics and Intelligent Laboratory Systems**, v.33, p.35-46, 1996.

YAN, W.; UPADHYAYA, B.R. **Development of an automated diagnostics system for eddy current analysis using applied artificial intelligence techniques.** Annual Report of Nuclear Engineering Department of the University of Tennessee – Knoxville, Tennessee. Prepared for the Electric Power Research Institute (EPRI), Palo Alto, California, Feb. 1996.

YOUNG, N. **An Introduction to Hilbert Space.** New York: Cambridge University Press, 1988.

ZEIDENBERG, M. **Neural networks in artificial intelligence.** London: Ellis Horwood Limited, 1990.

ZETEC, INC. **Manual do usuário do MIZ-30.** Estados Unidos. Disponível em: <<http://www.zetec.com.br>>. Acesso em: 20 mar. 2002.