

RECONHECIMENTO DE PADRÕES DE DEFEITOS DE SOLDAGEM EM SINAIS
ULTRA-SÔNICOS OBTIDOS PELA TÉCNICA TOFD UTILIZANDO REDES
NEURAS ARTIFICIAIS

Elineudo Pinho de Moura

TESE SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS
PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE
FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS
EM ENGENHARIA METALÚRGICA E DE MATERIAIS.

Aprovada por:

Prof. João Marcos Alcoforado Rebello; D.Sc.

Prof. Luiz Pereira Calôba; Dr. Ing.

Prof. Wagner Coelho de Albuquerque Pereira; D.Sc.

Dr. Carlos Alfredo Lamy; D.Sc.

Prof. Lindberg Lima Gonçalves; D. Phil.

RIO DE JANEIRO, RJ, BRASIL

JUNHO / 2003

MOURA, ELINEUDO PINHO DE.

Reconhecimento de padrões de defeitos de soldagem em sinais ultra-sônicos obtidos pela técnica TOFD utilizando redes neurais artificiais [Rio de Janeiro] 2003.

IX, 117 p. 29,7 cm (COPPE/UFRJ, D.Sc., Engenharia Metalúrgica e de Materiais, 2003)

Tese – Universidade Federal do Rio de Janeiro, COPPE

1. Ensaio não-Destrutivo.
2. TOFD.
3. Defeitos de Soldagem.
4. Transformada Wavelet.
5. Reconhecimento de Padrão.
6. Redes Neurais.

I. COPPE/UFRJ II. TÍTULO (Série)

À minha esposa, Milena, por seu apoio, compreensão e paciência,
aos meus pais e às minhas filhas.

AGRADECIMENTOS

Agradeço inicialmente a Deus e a meus Pais, a quem tudo devo.

Ao Prof. João Marcos, pela confiança em mim depositada, por seu apoio e orientação.

Aos amigos do laboratório de Ensaios Não-Destrutivos, pela companhia e toda ajuda.

Ao meu amigo Lucio Wanderley Vasconcelos pela revisão do texto da tese.

Ao CNPq pelo apoio financeiro na forma de bolsa de doutorado

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

RECONHECIMENTO DE PADRÕES DE DEFEITOS DE SOLDAGEM EM SINAIS
ULTRA-SÔNICOS OBTIDOS PELA TÉCNICA TOFD UTILIZANDO REDES
NEURAS ARTIFICIAIS

Elineudo Pinho de Moura

Junho / 2003

Orientador: João Marcos Alcoforado Rebello

Programa: Engenharia Metalúrgica e de Materiais

A técnica TOFD vem sendo cada vez mais utilizada na inspeção automática de solda. Apesar de atingir grandes velocidades de inspeção, alta confiabilidade no dimensionamento e baixa taxa de falsas indicações, a classificação de defeitos obtidos pela mesma ainda é freqüentemente questionada, pois depende principalmente do conhecimento e experiência do operador.

No presente trabalho, sinais A-scan foram capturados durante a inspeção pela técnica TOFD em juntas soldadas contendo diferentes tipos de defeitos inseridos durante o processo de soldagem. Uma outra classe de sinais foi obtida em regiões sem defeitos. Classificadores lineares e não-lineares, não-hierárquicos e hierárquicos, implementados através de uma rede neural, foram utilizados na classificação destes sinais A-scan. Avaliou-se o desempenho alcançado pelos classificadores após diferentes pré-processamentos (Cálculo da Envoltória do Sinal Retificado, Transformada de Fourier e Transformada *Wavelet*) terem sido aplicados aos sinais.

Os classificadores de padrões alcançaram bons resultados no reconhecimento de defeitos de soldagem em sinais de TOFD, principalmente para o cálculo da envoltória do sinal retificado, assim como para os sinais pré-processados pela Transformada *Wavelet*. Para estes dois tipos de pré-processamento, os resultados alcançados pelos classificadores lineares e não-lineares foram superiores a 90% tanto para dados de treinamento como de teste.

Abstract of Thesis presented to COOPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

PATTERN RECOGNITION OF WELDING DEFECTS IN TOFD SIGNALS USING
ARTIFICIAL NEURAL NETWORK

Elineudo Pinho de Moura

June / 2003

Advisor: João Marcos Alcoforado Rebello

Department: Metallurgical and Materials Engineering

TOFD technique has been widely used for automatic weld inspection. Although it reaches high speeds in the inspection, high sizing reliability and low rate of incorrect results, the classification of defects through ultrasound signals generated by this technique is still frequently questioned, because it depends mainly on the knowledge and experience of the operator.

In the present work, three kinds of defects: lack of fusion, lack of penetration and porosity, were inserted into the testing pieces during the welding process, generating patterns of defects. Another class of signal was also acquired from the region with no defect. Linear and non-linear, non-hierarchical and hierarchical classifiers, implemented by an artificial neural network, were used in the classification of these signals. The performance of classifiers was evaluated after different types of preprocessing (Full Wave Rectified Calculation, Fourier and *Wavelet* Transforms).

The classifiers reached good results in the welding defects pattern recognition of TOFD signals, mainly with full wave rectified and signals preprocessed by *Wavelet* Transform. In case of *wavelet* coefficients, the rate of success reached by linear classifiers were 99% and 93% for training and test data, respectively, reaching 99% and 96% for training and test data, respectively, by use of non-linear classifiers. In the best case, the full wave rectified of A-scans, the rate of success reached 99% for training data and 96% for test data, using linear classifier, and 100% and 98% for training and test respectively with non-linear classifiers.

ÍNDICE

1. – INTRODUÇÃO.....	1
2. – REVISÃO BIBLIOGRÁFICA.....	4
2.1. – INTRODUÇÃO	4
2.2. – PRINCÍPIO DA TÉCNICA TOFD.....	4
2.2.1. – <i>Interação da Onda com uma Descontinuidade</i>	5
2.2.2. – <i>Dimensionamento de Trincas pela Técnica TOFD</i>	8
2.2.3. – <i>Precisão e Resolução</i>	9
2.2.3.1. – Erros na Posição Lateral	10
2.2.3.2. – Erros na Determinação de Tempos.....	10
2.2.3.3. – Erros na Velocidade do Som no Material	11
2.2.3.4. – Erros na Distância Entre Transdutores	11
2.2.3.5. – Resolução Espacial	11
2.2.4. – <i>Visualização das Imagens</i>	14
2.2.5. – <i>Exemplos de A-Scan Típicos</i>	17
2.2.6. – <i>Limitações da Técnica e Considerações Finais</i>	20
2.3. – PRÉ-PROCESSAMENTO DE SINAIS	23
2.3.1. – <i>Análise de Fourier</i>	23
2.3.2. – <i>Análise Wavelet</i>	25
2.3.3. – <i>Filtro Savitzky-Golay</i>	32
2.4. – REDES NEURAIS ARTIFICIAIS.....	34
2.4.1. – <i>Introdução</i>	34
2.4.2. – <i>O Neurônio Biológico</i>	34
2.4.3. – <i>O Neurônio de Mcculloch-Pitts</i>	36
2.4.4. – <i>O Discriminador Linear</i>	40
2.4.5. – <i>Funções de Ativação</i>	41
2.4.6. – <i>Arquiteturas de Redes e Algoritmos de Treinamento</i>	43
2.4.7. – <i>Aplicações de Redes Neurais Artificiais</i>	52
2.5. – CONSIDERAÇÕES FINAIS	55
3. – MATERIAIS E MÉTODOS	56
3.1. – MATERIAIS	56
3.2. – SELEÇÃO DE SINAIS	58
3.3. – DISCRIMINADORES LINEARES NÃO-HIERÁRQUICOS E HIERÁRQUICOS	64
3.4. – CLASSIFICADORES LINEARES NÃO-HIERÁRQUICOS E HIERÁRQUICOS	67
3.5. – CLASSIFICADORES NÃO-LINEARES	70
4. – APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS.....	71
4.1. – INTRODUÇÃO	71
4.2. – CLASSIFICADORES LINEARES.....	72
4.2.1. – <i>Sinais Originais (Nenhum Pré-Processamento)</i>	72
4.2.2. – <i>Sinais Pré-Processados (Transf. Fourier e Wavelet)</i>	82
4.2.3. – <i>Sinais Pré-Processados (Envoltória do Sinal Retificado)</i>	89
4.3. – CLASSIFICADORES NÃO-LINEARES.....	98
5. – CONCLUSÕES.....	105
6. – REFERÊNCIAS.....	107

ÍNDICE DE FIGURAS

Figura 2.1 - Interação da onda com uma descontinuidade.....	6
Figura 2.2 - Arranjo típico para técnica TOFD: (1) Emissor, (2) Receptor, (a) Onda lateral, (b) Onda difratada pela ponta superior do defeito, (c) Onda difratada pela ponta inferior do defeito e (d) Eco de fundo.	7
Figura 2.3 - Modelo típico de sinal obtido (A-scan) pela técnica TOFD numa região contendo uma descontinuidade. (a) Onda lateral, (b) Onda difratada pela ponta superior do defeito, (c) Onda difratada pela ponta inferior do defeito e (d) Eco de fundo.	7
Figura 2.4 - Geometria do ensaio no modo transmissão-recepção.....	8
Figura 2.5 - Posição da trinca em relação a superfície e simétrica aos transdutores.....	12
Figura 2.6 - Resolução para TOFD.....	14
Figura 2.7 - Inspeção não paralela, com a direção de deslocamento típica (à esquerda) e o D-scan correspondente à direita. (1) Linha de referência, (2) Direção do deslocamento dos transdutores (direção xx), (3) Emissor, (4) Receptor, (5) Tempo de percurso (na direção da espessura), (6) Onda lateral, (7) Extremidade superior da descontinuidade, (8) Extremidade inferior da descontinuidade, (9) Reflexão de fundo.	15
Figura 2.8 - Imagem ultra-sônica D-scan obtida por TOFD, e o A-scan correspondente à posição selecionada pela linha horizontal presente na imagem D-scan.	16
Figura 2.9 - Comparação entre as imagens obtidas durante inspeção radiográfica e pela técnica TOFD realizadas em uma mesma região.....	17
Figura 2.10 - Imagens A-scan e D-scan típicas de uma trinca distante da superfície.	17
Figura 2.11 - Imagens A-scan e D-scan típicas de uma trinca próxima a superfície.	18
Figura 2.12 - Imagens A-scan e D-scan típicas de uma falta de penetração.	18
Figura 2.13 - Imagens A-scan e D-scan típicas de uma falta de fusão.....	18
Figura 2.14 - Imagens A-scan e D-scan típicas de uma falta de fusão entre passes.....	18
Figura 2.15 - Imagens A-scan e D-scan típicas de escória.....	19
Figura 2.16 - Imagens A-scan e D-scan típicas de uma porosidade.....	19
Figura 2.17 - Imagens A-scan e D-scan típicas de uma raiz côncava.	19
Figura 2.18 - Imagens A-scan e D-scan típicas de uma mordedura localizada na superfície oposta à superfície de inspeção.....	19
Figura 2.19 - Probabilidade de detecção pelas técnicas de END.	21
Figura 2.20 - Inspeção paralela, com a direção de deslocamento típica (à esquerda) e o B-scan correspondente à direita. (1) Linha de referência, (2) Direção do deslocamento dos Transdutores (direção yy), (3) Emissor, (4) Receptor, (5) Tempo de percurso (na direção da espessura), (6) Onda lateral, (7) Extremidade superior da descontinuidade, (8) Extremidade inferior da descontinuidade, (9) Reflexão de fundo.	22
Figura 2.21 - Transformada de Fourier.	23
Figura 2.22 - Componentes senoidais gerados pela decomposição da Transf. de Fourier.	24
Figura 2.23 - Transformada Curta de Fourier.	24
Figura 2.24 - Onda senoidal e uma Função Wavelet Daubechies 10 (db10).	25
Figura 2.25 - Componentes gerados pela decomposição da Transformada Wavelet.....	26
Figura 2.26 - Medida de correlação, C, entre a wavelet e parte do sinal.	26
Figura 2.27 - Deslocamento e medida de correlação entre a wavelet e parte do sinal.	27
Figura 2.28 - Medida de correlação, C, entre a wavelet redimensionada e parte do sinal.	27
Figura 2.29 - Correspondência entre as escalas e frequência.....	27
Figura 2.30a - Coeficientes Wavelet gerados pela correlação entre um sinal A-scan (FF25_9P04.dat) e a função wavelet gaussiana complexa de quarta ordem “cgau4”.	29
Figura 2.30b - Coeficientes Wavelet gerados pela correlação entre um sinal A-scan (FF25_9P04.dat) e a função wavelet gaussiana complexa de quarta ordem “cgau4”.	29
Figura 2.31 - Esquema dos constituintes da célula neural.	36
Figura 2.32 - Diagrama esquemático do neurônio artificial projetado por McCulloch-Pitts.	37
Figura 2.33 - Modelo de neurônio artificial.	38
Figura 2.34 - Um outro modelo de neurônio artificial.	39
Figura 2.35 - Discriminador linear separando o espaço em duas regiões em R^2	40

Figura 2.36 – Conj. de pontos a) linearmente separáveis; e b) não-linearmente separáveis.	41
Figura 2.37 - Funções de ativação mais comumente utilizadas. a) Função degrau “threshold”; b) função linear por partes; c) função logística e d) função tangente hiperbólica.	43
Figura 2.38 - Representação do erro quadrático médio em função das sinapses $w \in \mathbb{R}^2$. a) situação ideal com apenas um ponto de mínimo e convergência rápida; b) presença de mínimos locais além do mínimo global; c) infinitos pontos de mínimo e d) regiões de gradientes muito pequenos (direção w^*-w).	47
Figura 2.39 - Rede multicamada. Camada de entrada $l = 0$, duas camadas ocultas ($l = 1$ e $l = 2$) e uma camada de saída ($l = 3$)	49
Figura 2.40 - Exemplo de Superfície de Erro.	50
Figura 3.1 - Desenho esquemático da junta soldada (cotas em mm).	57
Figure 3.2 - Radiografia e D-scan obtido por TOFD de uma mesma região da solda.	58
Figura 3.3 - Sinal ultra-sônico A-scan original (canto superior esquerdo) capturado em uma região da solda contendo um defeito do tipo falta de fusão, mostrando o surgimento das ondas difratadas nas pontas superior e inferior do defeito entre a onda lateral e o eco de fundo; e os diferentes tipos de pré-processamento: Espectro de Freqüência do sinal original (canto inferior esquerdo), Transformada Wavelet Contínua (canto superior direito), Coeficientes Wavelet na escala de maior energia (canto inferior direito), Envoltória do Sinal Retificado (centro esquerdo).	60
Figura 3.4 - Sinal ultra-sônico A-scan original (canto superior esquerdo) capturado em uma região da solda contendo um defeito do tipo falta de penetração, e os diferentes pré-processamentos aplicados: Espectro de Freqüência do sinal original (canto inferior esquerdo), Transformada Wavelet Contínua (canto superior direito), Coeficientes Wavelet na escala de maior energia (canto inferior direito), Envoltória do Sinal Retificado (centro esquerdo).	61
Figura 3.5 - Sinal ultra-sônico A-scan original (canto superior esquerdo) capturado em uma região da solda contendo um defeito do tipo porosidade e os diferentes pré-processamentos aplicados: Espectro de Freqüência do sinal original (canto inferior esquerdo), Transformada Wavelet Contínua (canto superior direito), Coeficientes Wavelet na escala de maior energia (canto inferior direito), Envoltória do Sinal Retificado (centro esquerdo).	62
Figura 3.6 - Sinal ultra-sônico A-scan original (canto superior esquerdo) capturado em uma região da solda sem defeito, e os diferentes pré-processamentos aplicados: Espectro de Freqüência do sinal original (canto inferior esquerdo), Transformada Wavelet Contínua (canto superior direito), Coeficientes Wavelet na escala de maior energia (canto inferior direito), Envoltória do Sinal Retificado (centro esquerdo).	63
Figura 3.7 - As quatro classes C_j , $j = LP, ND, PO$ e LF e seus respectivos separadores não-hierárquicos S_j com as polaridades indicadas. As classes mais externas LP e ND são quase perfeitamente separadas e as mais internas PO e LF , imperfeitamente separadas.	65
Figura 3.8 - (a) e (b): Após a exclusão das entradas classificadas como LP e ND , os demais discriminadores podem assumir posições muito mais eficazes na separação das classes restantes, principalmente S_{PO} , (c), e o mesmo ocorre após a exclusão das entradas classificadas como LF (d). 66	
Figura 3.9 - Rede neural utilizada como classificador linear, mostrando padrão de saída para o primeiro neurônio vencedor. A rede como classificador pode ser adaptada tanto para o processo não-hierárquico como ao hierárquico.	67
Figura 3.10 - Algoritmo do Classificador Linear não-Hierárquico.	68
Figura 3.11 - Algoritmo do Classificador Linear Hierárquico.	69
Figura 3.12 - Rede neural utilizada como classificador não-linear, mostrando padrão de saída também para o primeiro neurônio vencedor.	70
Figura 4.1 - Sinal ultra-sônico A-scan original bastante ruidoso (canto superior esquerdo) capturado em uma região da solda dita sem defeito; e os diferentes tipos de pré-processamento: Espectro de Freqüência do sinal original (canto inferior esquerdo), Transformada Wavelet Contínua (canto superior direito), Coeficientes Wavelet na escala de maior energia (canto inferior direito), Envoltória do Sinal Retificado (centro esquerdo).	74
Figura 4.2 - Efeito dos diferentes tipos de pré-processamento dos dados de entrada no desempenho dos classificadores lineares.	97
Figura 4.3 - Classificador Hierárquico Linear versus Classificador Hierárquico não-linear no Reconhecimento de Padrão realizado na Envoltória dos Sinais Retificados.	103

1. – Introdução

Os ensaios não-destrutivos (ENDs) vêm sendo empregados para avaliar a qualidade de produtos, visando a garantia da operação segura de estruturas metálicas e equipamentos. Os ENDs têm por finalidade detectar, localizar, dimensionar e eventualmente classificar descontinuidades em materiais. Existem vários tipos de ENDs (líquidos penetrantes, partículas magnéticas, radiografia, ultra-som, correntes parasitas, etc.) e cada um possui vantagens e desvantagens, dependendo do material inspecionado, tipo de descontinuidade, meio em que se encontra o material, etc. Portanto, a escolha do método mais adequado depende da aplicação desejada. Hoje, com a concorrência cada vez mais acirrada entre as indústrias, sua utilização tem aumentado consideravelmente, haja vista o grande número de trabalhos desenvolvidos em centros de pesquisa e universidades, nesta área.

A radiografia tem sido amplamente utilizada na detecção e dimensionamento de descontinuidades em juntas soldadas de materiais metálicos. Entretanto, esta técnica dimensiona apenas o comprimento das descontinuidades, o que é insuficiente para a aplicação de uma análise de significância de defeito. Além da necessidade de revelação do filme radiográfico, que demanda tempo no informe dos resultados, os raios-X são radiação ionizante, o que representa perigo para o operador. Ao contrário do ensaio radiográfico, o ensaio ultra-sônico não requer planos especiais de segurança ou quaisquer acessórios para sua aplicação e consegue o dimensionamento completo das descontinuidades. Por estes motivos, tem-se tentado cada vez mais substituir aquela técnica pelo ultra-som.

Uma grande melhoria no ensaio de ultra-som foi obtido com o desenvolvimento da técnica ultra-sônica de tempo de percurso da onda difratada [1] (TOFD, do inglês *Time of Flight Diffraction*) que está superando as dificuldades encontradas na detecção e dimensionamento de defeitos perpendiculares à superfície da peça, fazendo incidir, no interior do material, um feixe de ultra-som inclinado em relação à superfície de inspeção [2, 3]. Até então, a detecção e dimensionamento de descontinuidades feitas por técnicas

ultra-sônicas utilizavam somente a amplitude do eco obtido e a relacionava diretamente com a dimensão da descontinuidade.

A técnica TOFD não é baseada na amplitude dos ecos, mas utiliza o tempo de percurso da onda difratada na ponta de uma descontinuidade para determinação de sua profundidade. O princípio da técnica foi demonstrado por Silk [1, 2, 4] durante a década de 70. A técnica utiliza dois transdutores, um como transmissor e outro como um receptor para cobrir o volume de material a ser inspecionado. O primeiro eco a alcançar o receptor corresponde à onda lateral. Se não há descontinuidades o segundo sinal será o eco de fundo. A importância desses dois sinais é que eles podem ser utilizados como referência para medir o tempo das outras ondas [5]. Qualquer sinal gerado pelas descontinuidades estará posicionado entre a onda superficial e o eco de fundo [5]. O modo A-scan é a forma mais típica de sinal ultra-sônico, e consiste do próprio sinal, amplitude versus tempo, que é apresentado na tela do equipamento de ultra-som [6]. A aquisição de vários sinais A-scan gravados ao longo do cordão de solda permite a formação de uma imagem D-scan, onde as amplitudes positivas e negativas são convertidas numa escala de tons de cinza.

Apesar de representar um considerável desenvolvimento, porque permite um registro gráfico da inspeção do cordão de solda, e das vantagens do ultra-som sobre o ensaio radiográfico, a técnica TOFD não fornece informações precisas sobre a classe de defeitos [7]. A classificação de defeitos baseada nos seus sinais ultra-sônicos ainda é frequentemente questionada por ser muito subjetiva, uma vez que a análise e a identificação dos tipos de defeitos dependem exclusivamente da experiência e conhecimento do operador [8].

O progresso das técnicas computacionais, principalmente o desenvolvimento das redes neurais, tem dado um grande impulso nas pesquisas de desenvolvimento de sistemas automáticos de inspeção e classificação de padrões de defeitos [9, 10, 11]. As redes neurais consistem de algoritmos que aprendem a modelar algumas funções do cérebro tais como reconhecimento de padrões, criação de associações, processamento de sinais e aprendizado com experiência ou treinamento. Embora sejam muito menos complexas

que o cérebro humano, as redes neurais têm a capacidade de processar grandes quantidades de dados em curto espaço de tempo que normalmente só poderiam ser analisadas por um especialista. O treinamento ou aprendizado da rede a partir de exemplos, tal qual o cérebro humano, é uma de suas mais importantes características [12, 13].

No presente trabalho, três tipos de defeitos: falta de fusão (FF), falta de penetração (FP) e porosidade (PO) foram inseridas nos corpos de prova durante o processo de soldagem, gerando padrões de defeitos, em chapas de aço. A posição, tipo e dimensão de cada defeito inserido são conhecidos por técnicas ultra-sônica convencional e radiográfica.

Sinais ultra-sônicos foram adquiridos durante a inspeção do cordão de solda dos corpos de prova utilizando-se a técnica TOFD. Definiu-se também uma classe de sinais de regiões sem defeitos (SD), para avaliar a capacidade destes classificadores em identificar sinais de regiões com defeitos ou regiões que não apresentam defeitos.

Diferentes tipos de pré-processamentos como a Transformada de Fourier, Transformada *Wavelet* e o Cálculo da Envoltória do sinal retificado, foram aplicadas aos sinais A-scan originais a serem posteriormente utilizados na alimentação dos classificadores lineares e não-lineares, não-hierárquicos e hierárquicos.

Este trabalho apresenta uma maneira de implementar tais classificadores através de uma rede neural, e avalia seus desempenhos no reconhecimento de padrões dos sinais A-scan de diferentes classes em função dos diferentes tipos de pré-processamentos aplicados aos sinais dos principais defeitos selecionados.

2.1. – Introdução

Este capítulo tem o objetivo de fazer uma revisão dos princípios físicos e teóricos das técnicas utilizadas no trabalho, fornecendo informações básicas necessárias ao seu entendimento. Após a revisão destes princípios físicos e teóricos, serão apresentados resultados obtidos através de uma pesquisa bibliográfica em artigos referentes a cada técnica.

Não é objetivo deste trabalho desenvolver uma nova metodologia de ensaio não-destrutivos ou processamento de sinais, tampouco criar um novo algoritmo de treinamento para redes neurais. O objetivo é utilizar estas técnicas existentes, reunidas, como uma ferramenta para o reconhecimento de padrões aplicados em END. Conseqüentemente, de forma nenhuma se pretende cobrir toda a teoria da técnica TOFD, das Redes Neurais Artificiais e do Processamento de Sinais. Até mesmo porque seria impossível fazê-lo em poucas páginas, além de fugir do principal objetivo do trabalho. Para isto, o leitor poderá consultar livros, normas e artigos existentes na literatura e citados nas referências. Na seção 2.2 serão revisados os princípios da Técnica Ultra-Sônica TOFD. Na seção 2.3, serão apresentados os diferentes tipos de pré-processamentos utilizados no sinais A-scan (Transformada de Fourier, Transformada *Wavelet* e Filtro Savitzky-Golay). Na seção 2.4, serão apresentados as Redes Neurais.

2.2. – Princípio da Técnica TOFD

Num sinal ultra-sônico, dois parâmetros podem ser utilizados no dimensionamento de descontinuidades: a amplitude do eco e/ou a sua posição (tempo). As técnicas baseadas na amplitude do sinal pressupõem que a altura do eco possa ser correlacionada com o tamanho da descontinuidade através do uso de curvas do tipo DGS, ou com a adoção de técnica de queda da amplitude do sinal (“dB drop”) [2]. A amplitude dos ecos, porém,

sofre influência de fatores que podem fornecer uma avaliação incorreta da dimensão da descontinuidade, tais como: rugosidade da superfície, orientação do defeito e sua transparência [14].

Durante a década de 70 foram propostas várias técnicas baseadas no tempo-de-percurso e suas variantes. A técnica do tempo-de-percurso da onda superficial [15], a técnica da conversão de modo da onda de Rayleigh em onda cisalhante utilizando um único transdutor [16] e o tempo de percurso da onda difratada na ponta da trinca (*“Time of Flight Diffraction”* - TOFD) [17] são algumas destas técnicas.

Entre as técnicas de tempo-de-percurso, a que teve o maior avanço no sentido de se obter aplicação na prática e normas de utilização foi a técnica TOFD. Esta técnica é relativamente recente e foi primeiramente descrita por Maurice G. Silk em 1975 [1]. Baseada no dimensionamento da altura do defeito a partir do intervalo de tempo entre a difração da onda em suas extremidades, esta técnica adequa-se ao processo de automação da inspeção, aliando rapidez [18,19,20] e confiabilidade no dimensionamento.

As técnicas baseadas no tempo-de-percurso da onda utilizam a posição dos sinais correspondentes às extremidades do defeito, ou do atraso ocorrido no sinal devido à sua existência, para dimensioná-lo. Por utilizarem o tempo-de-percurso como único parâmetro de dimensionamento, estas técnicas são pouco sensíveis às variações da amplitude do sinal [21].

2.2.1. – Interação da Onda com uma Descontinuidade

Um modelo para exemplificar a incidência de uma onda sobre uma trinca é apresentado na figura 2.1, onde quatro tipos de ondas decorrentes desta interação - Reflexão especular da onda; espalhamento da onda incidente devido à rugosidade da superfície da trinca; a difração da onda nas regiões próximas às pontas de trinca; a conversão de modo ocorrida em parte da onda difratada - podem ser observadas [2, 22].

Da interação das ondas ultra-sônicas com as extremidades das discontinuidades resulta a emissão de ondas esféricas difratadas. A detecção destas ondas difratadas torna possível estabelecer a presença de discontinuidades. A diferença no tempo de percurso dos sinais registrados é relacionado à altura da discontinuidade, ou seja, à dimensão na direção da espessura, e conseqüentemente, permite o seu dimensionamento. A amplitude do sinal não é utilizada para estimar a dimensão.

O fenômeno da conversão de modo é um fator complicador porque gera uma variedade de ecos que dificultam a distinção dos ecos difratados pelas pontas da trincas. Para evitar este tipo de problema, normalmente utilizam-se transdutores de ondas longitudinais incidentes, que por possuírem maior velocidade de propagação que as ondas transversais, chegam ao transdutor receptor bem antes dos sinais modo convertidos, não sofrendo sobreposições de outros tipos de onda e proporcionam uma identificação mais fácil dos defeitos [22]. No caso do aço, $V_l = 1,83.V_t$, onde V_l e V_t são respectivamente as velocidades longitudinal e transversal da onda [23].

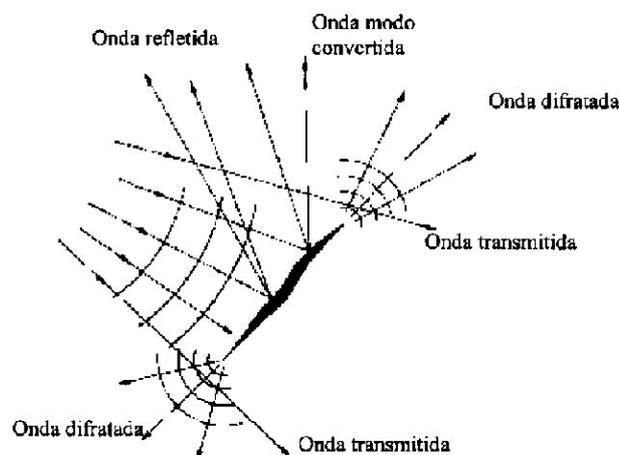


Figura 2.1 - Interação da onda com uma descontinuidade [2, 22].

A configuração convencional para a técnica TOFD utiliza dois transdutores, um emissor e um receptor, alinhados um de cada lado do cordão de solda, de tal modo que a região de interesse esteja totalmente dentro da área sonificada pelo emissor (Figura 2.2) [6].

O modo A-scan é a forma mais comum de apresentação do sinal ultra-sônico, e consiste do próprio sinal, amplitude versus tempo, que é apresentado na tela do equipamento de ultra-som. Um sinal (A-scan) típico de TOFD é apresentado na figura 2.3 [6].

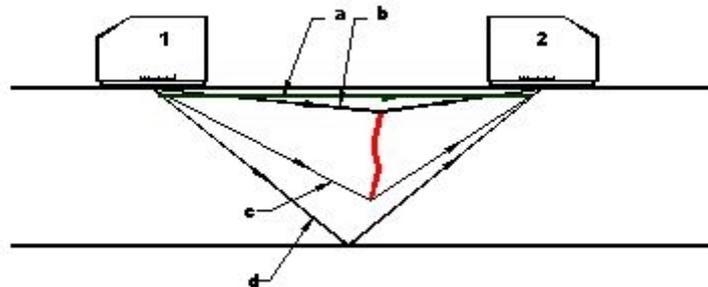


Figura 2.2 - Arranjo típico para técnica TOFD: (1) Emissor, (2) Receptor, (a) Onda lateral, (b) Onda difratada pela ponta superior do defeito, (c) Onda difratada pela ponta inferior do defeito e (d) Eco de fundo.

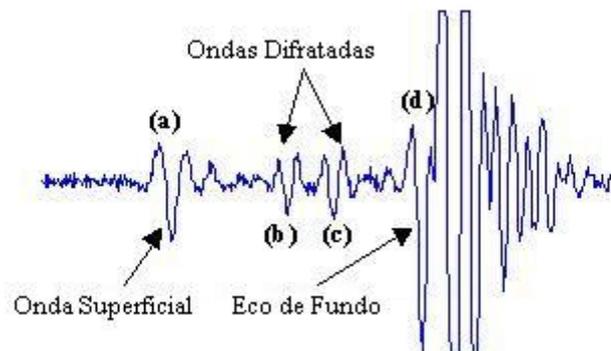


Figura 2.3 - Modelo típico de sinal obtido (A-scan) pela técnica TOFD numa região contendo uma descontinuidade. (a) Onda lateral, (b) Onda difratada pela ponta superior do defeito, (c) Onda difratada pela ponta inferior do defeito e (d) Eco de fundo.

Quatro sinais serão detectados pelo receptor. O primeiro sinal a chegar ao receptor depois da emissão do impulso acústico é, normalmente, a onda lateral que se propaga abaixo da superfície superior da peça em ensaio. Esta onda não é verdadeiramente do tipo superficial já que a sua amplitude não decai exponencialmente com a distância entre transdutores [4]. Na ausência de descontinuidades o segundo sinal a aparecer será o eco de fundo (“backwall echo”). Estes dois sinais são, normalmente, utilizados como referência para medir o tempo das outras ondas [5]. Se não se considerar conversão de

modo (onda transversal, que por ser mais lenta que a longitudinal chega após o eco de fundo), quaisquer sinais gerados pelas descontinuidades chegarão entre a onda lateral e o eco de fundo, uma vez que estas duas correspondem, respectivamente, aos percursos mais curto e mais longo entre o emissor e o receptor. Por razões idênticas, o sinal difratado na extremidade superior de uma descontinuidade chegará antes do sinal gerado na extremidade inferior. A dimensão da descontinuidade na direção da espessura pode ser calculada a partir da diferença do tempo de percurso dos dois sinais difratados.

2.2.2. – Dimensionamento de Trincas pela Técnica TOFD

A figura 2.4 mostra a geometria do percurso percorrido pela onda ultra-sônica ao encontrar uma descontinuidade em um típico arranjo utilizado para inspeção, onde dois transdutores angulares são utilizados no modo transmissão-recepção [6, 14].

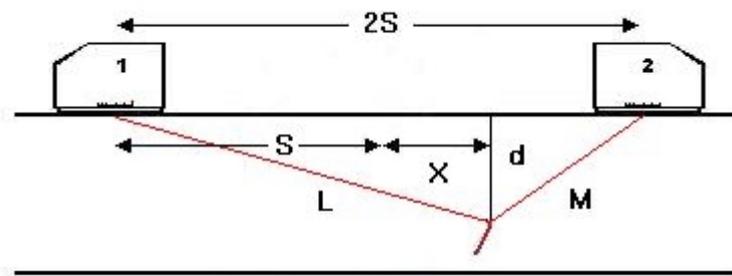


Figura 2.4 - Geometria do ensaio no modo transmissão-recepção [6,14].

$$L^2 = d^2 + (S + X)^2 \quad (2.1)$$

$$M^2 = d^2 + (S - X)^2 \quad (2.2)$$

Como os percursos (L e M) são oblíquos, a relação entre o atraso da onda difratada e a profundidade da ponta da trinca ou a espessura da peça não é linear, mas são bem definidas, desse modo não há dificuldades para se calcular a sua altura e profundidade [14]. Movimentando o par de transdutores lateralmente, sem alterar a distância $2S$ entre eles, o tempo total de atraso da onda nas pontas mudará, de acordo com a relação:

$$CT = \sqrt{d^2 + (S + X)^2} + \sqrt{d^2 + (S - X)^2} \quad (2.3)$$

onde C é a velocidade longitudinal da onda, T é o tempo de percurso da onda no material e S corresponde a metade da distância entre transdutores. Diferenciando a expressão com relação ao deslocamento lateral X , observa-se que o menor atraso ocorre quando a ponta da trinca está exatamente no ponto central entre os transdutores. A equação 2.3 fica resumida então:

$$CT = 2\sqrt{(d^2 + S^2)} \quad (2.4)$$

A expressão para a profundidade “ d ” da ponta da trinca é dada por:

$$d = \sqrt{\left(\frac{CT}{2}\right)^2 - S^2} \quad (2.5)$$

Neste caso é considerado apenas o tempo de percurso da onda no material e a distância entre os pontos de saída do feixe nos transdutores. Desconsidera-se o tempo de percurso da onda dentro dos transdutores.

Na prática, o dimensionamento dos defeitos é feito utilizando-se curvas de calibração, levantadas a partir de blocos padrões de defeitos, mas com os mesmos parâmetros do ensaio, tais como distância (2S) entre os transdutores, frequência, etc. [21, 24]

2.2.3. – Precisão e Resolução

Antes de mais nada, distinga-se precisão de resolução. Precisão é a exatidão com que a posição de um refletor ou difrator pode ser determinada, enquanto resolução é uma medida do grau de distinção entre dois difratores próximos.

É importante ter presente que a eficácia global da técnica é função de um grande número de fatores e que o erro global não será inferior ao somatório da combinação de

erros discutidos neste t3pico. A precis3o do dimensionamento pela t3cnica TOFD 3 influenciada por erros na posi3o lateral da descontinuidade (item 2.2.3.1), no tempo (item 2.2.3.2), velocidade (item 2.2.3.3), e na dist3ncia entre transdutores (item 2.2.3.4).

2.2.3.1. – Erros na Posi3o Lateral

Tal como referido na equa3o 2.4, assume-se que a posi3o lateral de uma descontinuidade est3 eqüidistante dos dois transdutores. Na realidade a descontinuidade estar3 localizada numa elipse (equa3o 2.3). O erro na profundidade (Δd) devido ao erro na posi3o lateral (ΔX) pode ser calculado a partir de [5,6]:

$$\Delta d = \frac{\sqrt{C^2 T^2 - 4S^2} \cdot \frac{\Delta X^2}{C^2 T^2}}{\sqrt{0,25 - \frac{\Delta X^2}{C^2 T^2}}} \quad (2.6)$$

2.2.3.2. – Erros na Determina3o de Tempos

O limite de precis3o na profundidade de uma descontinuidade, devido 3 imprecis3o na determina3o do tempo (ΔT), pode ser estimado a partir de [5,6]:

$$\Delta d = \frac{C \Delta t \cdot \sqrt{d^2 + S^2}}{2d} \quad (2.7)$$

onde: Δd 3 o desvio (erro) de d [5,6].

O erro na determina3o do tempo pode ser reduzido recorrendo a um pulso mais curto e/ou uma maior freqü3ncia.

2.2.3.3. – Erros na Velocidade do Som no Material

O limite de precisão no cálculo da profundidade da descontinuidade, devido a erros na velocidade do som no material (ΔC), é determinado a partir de [5,6]:

$$\Delta d = \Delta C [d^2 + S^2] - \frac{S\sqrt{d^2 + S^2}}{C.d} \quad (2.8)$$

Este erro diminui com a distância entre os transdutores. A calibração independente da velocidade por medida do atraso do eco de fundo, numa espessura conhecida, reduz drasticamente este erro [5,6].

2.2.3.4. – Erros na Distância Entre Transdutores

Erros na distância entre os transdutores (ΔS) resultarão em erros no cálculo da profundidade. O erro em profundidade (Δd) pode ser calculado a partir de [5,6]:

$$\Delta d = \frac{\Delta S [\sqrt{d^2 + S^2} - S]}{d} \quad (2.9)$$

Sob condições normais, os erros na distância entre os transdutores é a que tem maior influência na precisão global. Na difração, a eficiência máxima ocorre quando o ângulo é de 120°. Os transdutores devem ser montadas de tal forma que os eixos (imaginários) dos feixes, se interceptem àquele ângulo na profundidade à qual as profundidades são esperadas [5].

2.2.3.5. – Resolução Espacial

A definição mais simples para o termo resolução (R) é a distância mínima entre dois objetos que um sensor pode registrar distintamente. No caso, os sensores são os

transdutores ultra-sônicos. A resolução espacial (R) pode ser definida em função da profundidade e é calculada por [5,6]:

$$R = \sqrt{\frac{C^2 \cdot (T_d + T_p)^2}{4 - S^2}} - d \quad (2.10)$$

onde: T_p é a largura do pulso acústico; e,
 T_d é o tempo de percurso à profundidade d .

A resolução melhora com o aumento da profundidade e pode ser melhorada diminuindo a distância entre os transdutores ou diminuindo a largura do pulso [5,6].

Temple [25] supôs que a trinca a ser inspecionada fosse perpendicular à superfície de inspeção e situada exatamente a meia distância dos dois transdutores (como mostrado na figura 2.5).

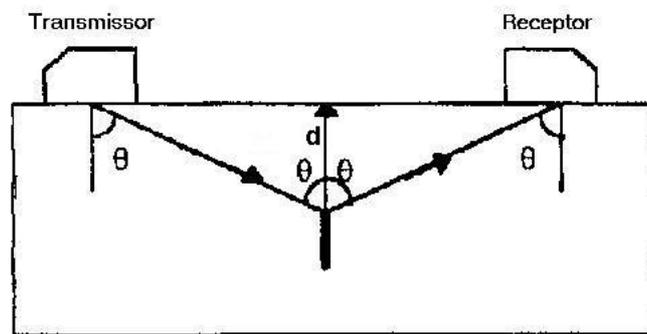


Figura 2.5 - Posição da trinca em relação a superfície e simétrica aos transdutores.

Assim, a velocidade longitudinal da onda, os percursos sônicos e os tempos de percurso das ondas difratadas pelas pontas superior e inferior seguem as relações:

$$p_s = C_l \cdot \frac{T_s}{2} \quad (2.11)$$

$$p_i = C_l \cdot \frac{T_i}{2} \quad (2.12)$$

onde: C_l é a velocidade longitudinal da onda, p_s e p_i são os percursos sônicos e T_s e T_i são os tempos de percurso das ondas difratadas pelas pontas superior e inferior, respectivamente. Desta forma, a posição das pontas superior (d_s) e inferior (d_i) do defeito é:

$$d_s = \frac{p_s}{\cos \theta} = \frac{C_{ls} \cdot T_s}{2 \cdot \cos \theta} \quad (2.13)$$

$$d_i = \frac{p_i}{\cos \theta} = \frac{C_{li} \cdot T_i}{2 \cdot \cos \theta} \quad (2.14)$$

Considerando $d_s - d_i$ a altura da trinca temos

$$d_s - d_i = \frac{C_l \cdot (T_s - T_i)}{2 \cdot \cos \theta} \quad (2.15)$$

Assim, Temple [25] determinou que a resolução da técnica na direção da espessura, ou seja, a menor distancia entre dois difratores próximos ou o menor tamanho de trinca que pode ser medido, é função do ângulo θ entre o feixe incidente e a normal à superfície, e que a resolução é limitada pela “*resolução temporal*” ($T_s - T_i$) do sistema (equação 2.16). Esta “*resolução temporal*” pode ser entendida como o menor intervalo de tempo que se pode medir no equipamento, e está associada ao comprimento do pulso.

$$\Delta d = \frac{C_l \Delta T}{2 \cdot \cos \theta} \quad (2.16)$$

Isto significa que além de contribuir para melhorar a precisão no dimensionamento, pela diminuição do erro na determinação do tempo, sistemas com pulsos estreitos e transdutores de alta frequência terão maior resolução. Um valor aceitável para a resolução temporal (ΔT) é 50 ns. Tem-se então:

$$\text{Resolução} = \frac{C_l \cdot 50 \cdot 10^{-9}}{2 \cdot \cos \theta} \quad (2.17)$$

Para uma velocidade da onda longitudinal no aço de 5,9 mm/μs.

$$\text{Resolução} = \Delta d = \frac{0,15}{\cos \theta} \text{ mm} \quad (2.18)$$

A figura 2.6 apresenta um gráfico gerado pela equação 2.18 que mostra a resolução da técnica TOFD. Pode-se observar que ângulos de incidência baixos permitem dimensionar trincas menores. A equação 2.18 fornece apenas valores teóricos para a resolução da técnica. Entretanto, determinou-se experimentalmente que transdutores de 60° são os que apresentam o melhor desempenho [21, 26].

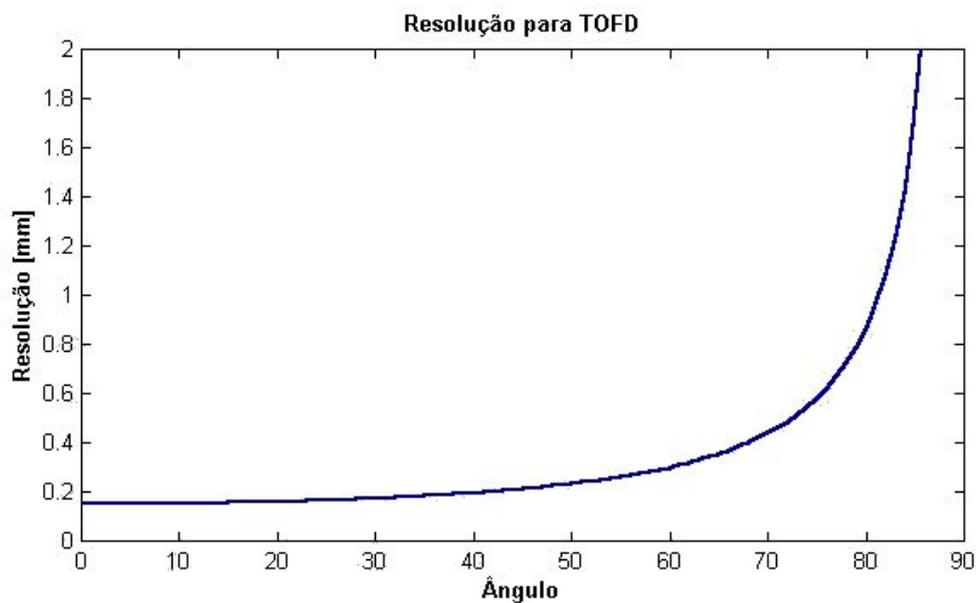


Figura 2.6 - Resolução para TOFD [25].

2.2.4. – Visualização das Imagens

A principal vantagem da técnica TOFD é a possibilidade de se fazer uma varredura automática no corpo de prova. O posicionamento automático do transdutor aliado à digitalização do sinal permite a aplicação de várias técnicas de reconstrução de imagens aplicada aos ENDs. Quando uma técnica ultra-sônica é utilizada para detectar um defeito, a informação é convencionalmente coletada e mostrada de diferentes modos: A, B, C ou D-scan, onde cada um fornece informações diferentes, os quais serão

detalhados a seguir e permitem o dimensionamento dos defeitos detectados. É possível, ainda, obter uma imagem tridimensional da região inspecionada a partir da imagem C-scan.

O modo A-scan (já apresentado anteriormente na figura 2.3) é a forma mais comum de apresentação do sinal ultra-sônico. É o próprio sinal que aparece na tela do aparelho de ultra-som. Numa varredura, um sinal A-scan é adquirido em cada posição, e a partir do processamento conjunto de todos estes sinais é que se obtém as imagens: B-scan, C-scan e D-scan. O modo D-scan, mostra uma seção longitudinal da região inspecionada, produzida pelo registro sucessivo de diversos A-scans obtidos durante o movimento perpendicular dos transdutores em relação ao feixe ultra-sônico, ou seja, longitudinal ao cordão de solda (Figura 2.7).

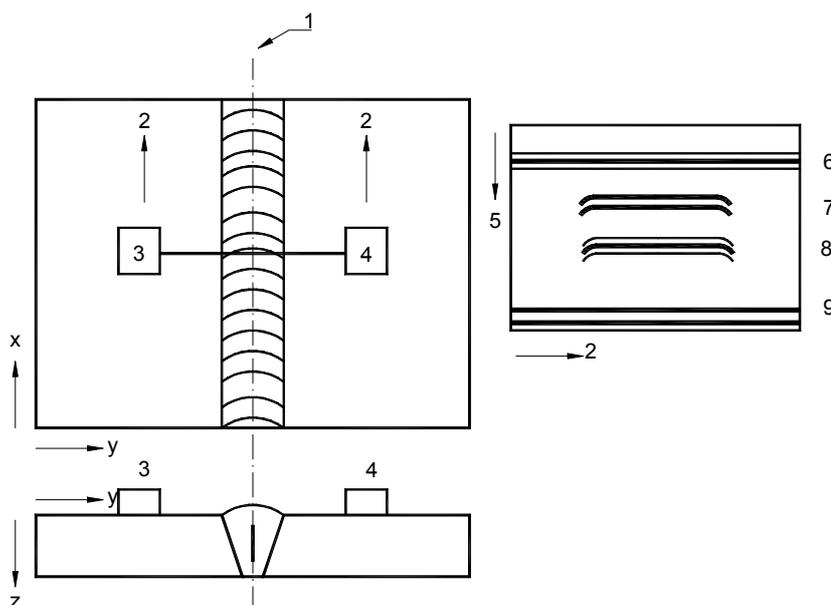


Figura 2.7 - Inspeção não paralela, com a direção de deslocamento típica (à esquerda) e o D-scan correspondente à direita. (1) Linha de referência, (2) Direção do deslocamento dos transdutores (direção xx), (3) Emissor, (4) Receptor, (5) Tempo de percurso (na direção da espessura), (6) Onda lateral, (7) Extremidade superior da descontinuidade, (8) Extremidade inferior da descontinuidade, (9) Reflexão de fundo. [5,6]

A figura 2.8 é um exemplo de imagem D-scan de uma junta soldada inspecionada por TOFD. Nela pode-se visualizar vários defeitos, juntamente com a imagem A-scan correspondente à posição da imagem D-scan selecionada pela linha horizontal.

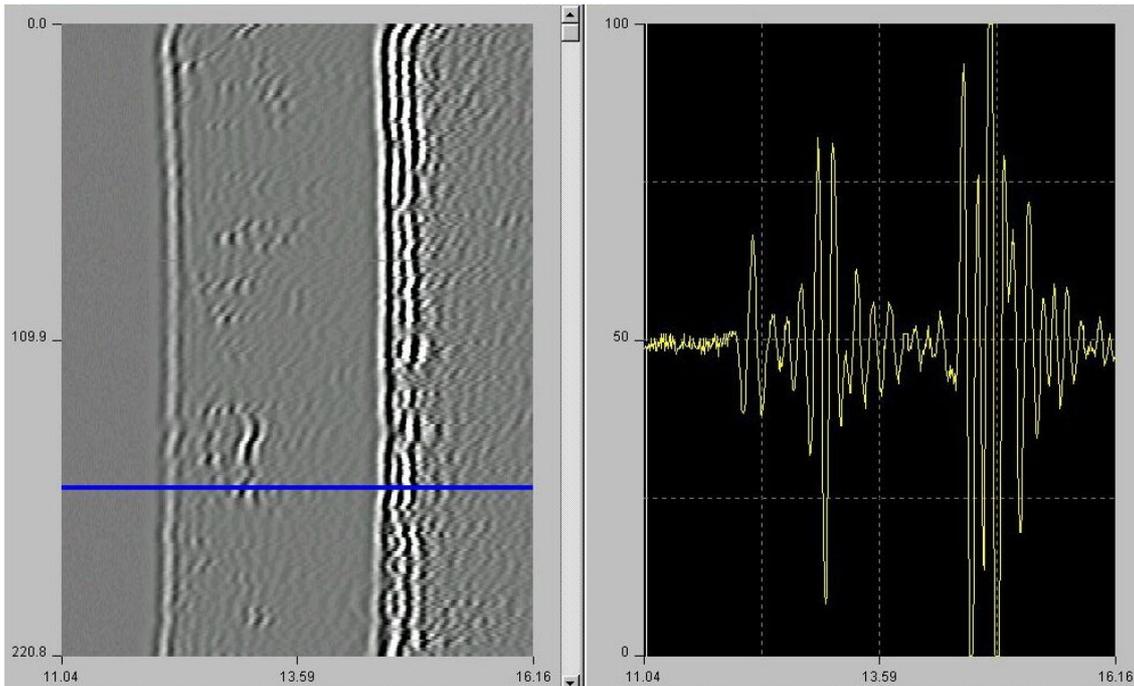


Figura 2.8 - Imagem ultra-sônica D-scan obtida por TOFD, e o A-scan correspondente à posição selecionada pela linha horizontal presente na imagem D-scan.

Na imagem D-scan, tem-se a conversão dos valores das amplitudes dos sinais A-scan em uma escala de cores ou de tons de cinza. Se, numa escala, as cores mais claras representam amplitudes menores, e as mais escuras, amplitudes maiores, diz-se que esta é uma escala positiva. Quando o inverso ocorre, tons mais claros são atribuídos a amplitudes maiores e tons mais escuros a amplitudes menores, diz-se que a escala é negativa. A adoção de uma escala de cores coerente é importante porque facilita o trabalho de interpretação dos dados e abre caminho para técnicas de processamento de imagens. Em uma escala de tons de cinza, normalmente atribui-se valor igual a zero para a cor preta, e 255 para a cor branca. Os tons de cinza variam proporcionalmente entre estes valores.

A figura 2.9 apresenta uma imagem radiográfica e uma imagem ultra-sônica D-scan obtidas a partir de uma mesma região inspecionada. Pode-se observar um mesmo defeito, do tipo falta de penetração, presente nas duas imagens.

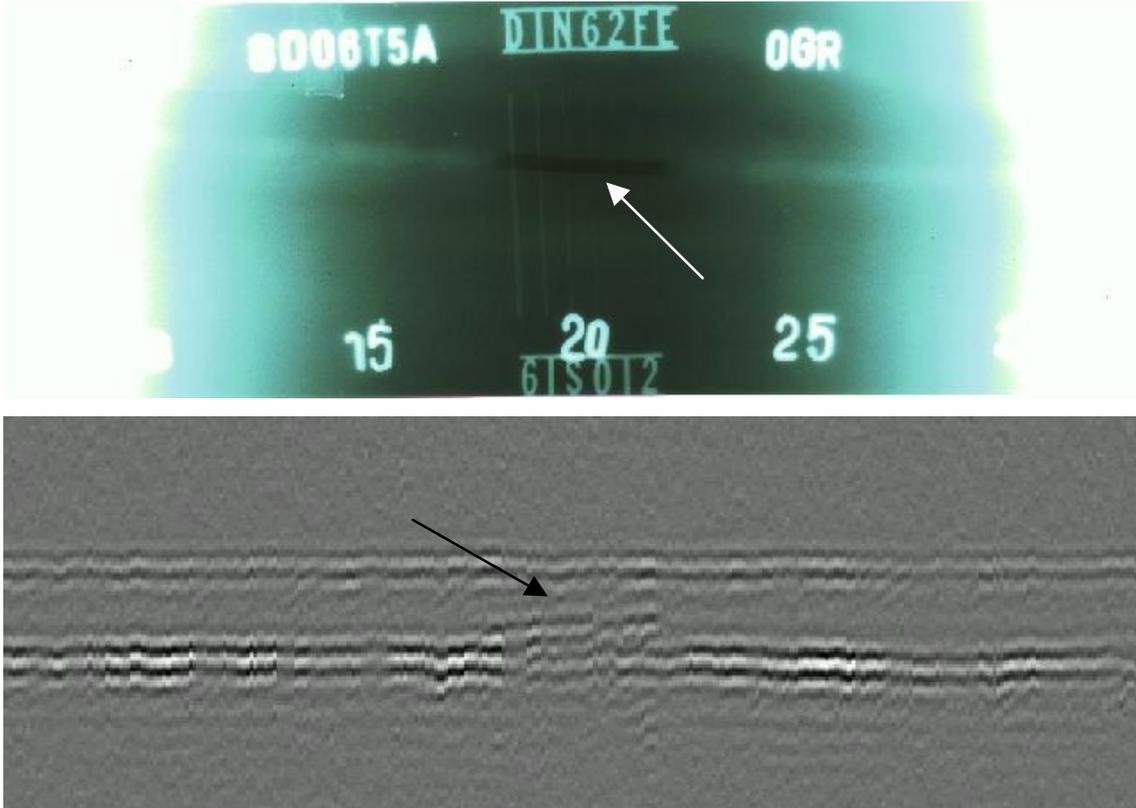


Figura 2.9 - Comparação entre as imagens obtidas durante inspeção radiográfica e pela técnica TOFD realizadas em uma mesma região.

2.2.5. – Exemplos de A-Scan Típicos

As figuras 2.10 a 2.18 apresentam exemplos de defeitos padrões presentes em juntas soldadas com suas respectivas imagens A e D-scan [6]. São as características próprias de cada tipo de defeito contidas nos sinais, que permitem sua classificação.

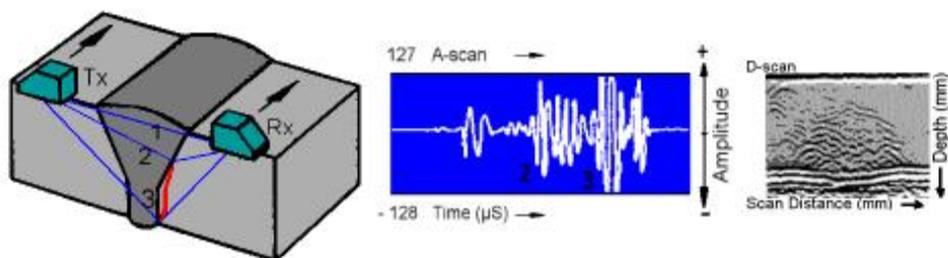


Figura 2.10 - Imagens A-scan e D-scan típicas de uma trinca distante da superfície [6].

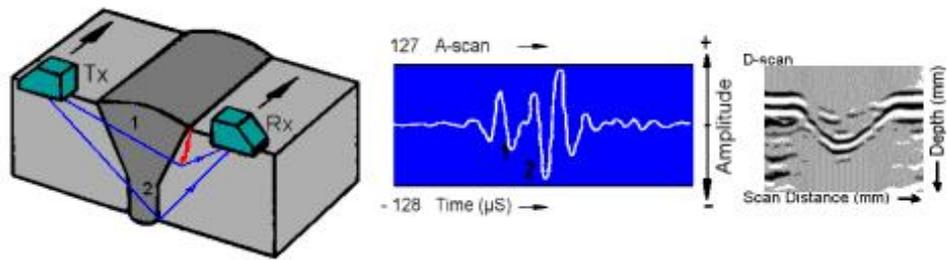


Figura 2.11 - Imagens A-scan e D-scan típicas de uma trinca próxima a superfície [6].

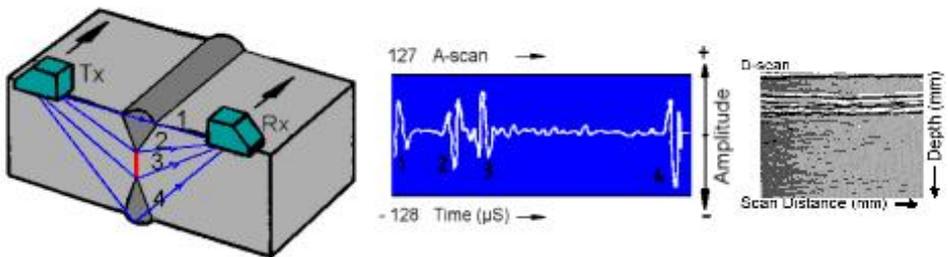


Figura 2.12 - Imagens A-scan e D-scan típicas de uma falta de penetração [6].

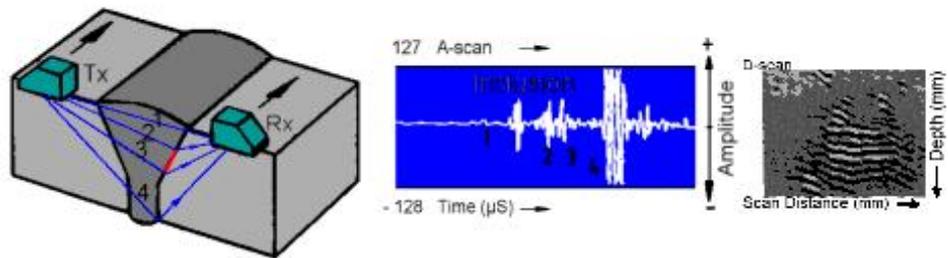


Figura 2.13 - Imagens A-scan e D-scan típicas de uma falta de fusão [6].

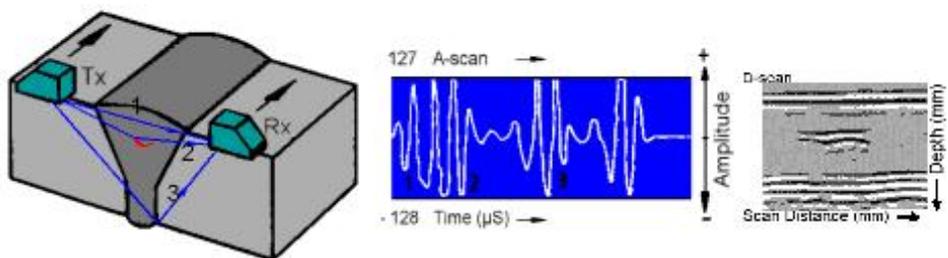


Figura 2.14 - Imagens A-scan e D-scan típicas de uma falta de fusão entre passes [6].

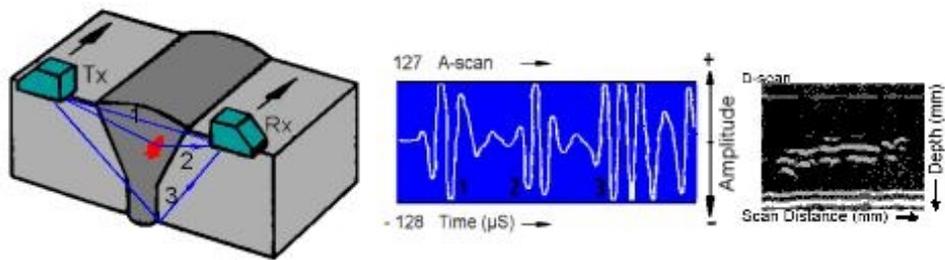


Figura 2.15 - Imagens A-scan e D-scan típicas de escória [6].

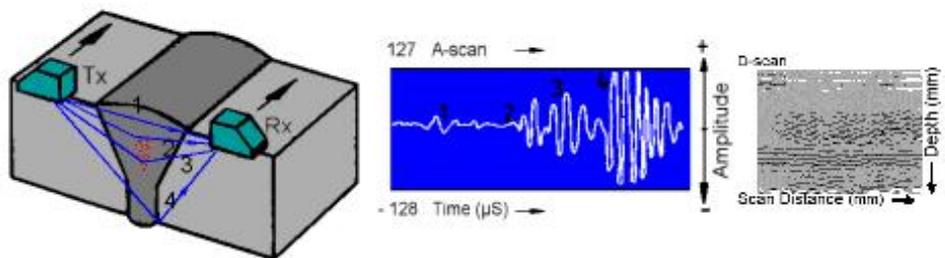


Figura 2.16 - Imagens A-scan e D-scan típicas de uma porosidade [6].

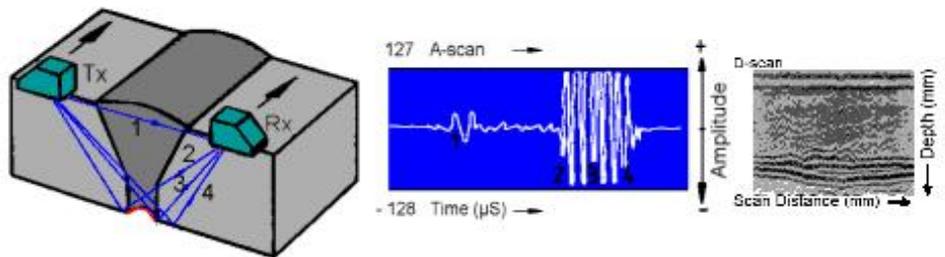


Figura 2.17 - Imagens A-scan e D-scan típicas de uma raiz côncava [6].

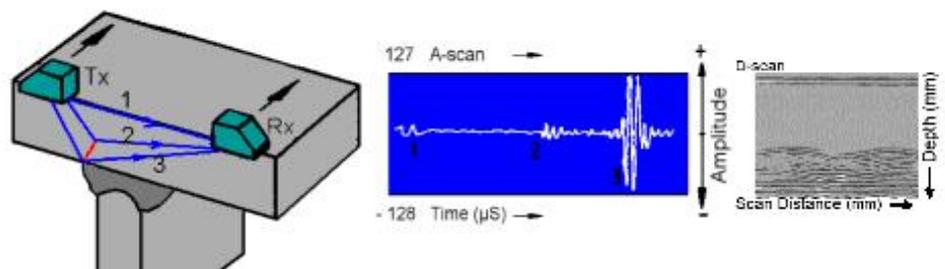


Figura 2.18 - Imagens A-scan e D-scan típicas de uma mordedura localizada na superfície oposta à superfície de inspeção [6].

Na seção MATERIAIS E MÉTODOS serão apresentados exemplos reais de sinais A-scan capturados nos corpos de prova inspecionados e utilizados como dados de entrada dos classificadores de padrão estudados.

2.2.6. – Limitações da Técnica e Considerações Finais

Embora a técnica TOFD consiga reproduzir corretamente perfis de defeitos localizados distantes da superfície de inspeção [21, 24], é incapaz de reproduzi-los quando localizados próximos a superfície de inspeção. Outras desvantagens estão na detecção de mordeduras localizadas na superfície de inspeção, e nas limitações em distinguir porosidades isoladas de ruídos emanados de heterogeneidades naturais do meio, mesmo com a utilização da média de sinais no mesmo ponto, que é eficiente na detecção de porosidades agrupadas [24].

BROWNE [27] argumenta que nenhuma das limitações da técnica TOFD deve ser considerada muito grave, e que a maioria pode ser resolvida ou compensada, além de ser uma técnica mais rápida e mais precisa que qualquer método substituto disponível. BROWNE [27] chega a afirmar que a técnica TOFD é mais segura e mais sensível que qualquer forma de radiografia. Outros trabalhos também afirmam que esta técnica pode, em alguns casos, substituir a radiografia convencional [3, 28, 29, 30, 31].

HECHT [32] considera que, em virtude das limitações da técnica de TOFD, não é recomendado descartar nenhum método em favor do uso do TOFD, porém, o TOFD pode ser uma grande contribuição a outros métodos de teste. HECHT [32] vê ainda a possibilidade de melhorar os resultados obtidos com TOFD por meio de processamento, como por exemplo com a utilização da Técnica de Focalização do Feixe Ultra-Sônico por Abertura Sintética (“*Synthetic Aperture Focusing Technique*” - SAFT).

Alguns trabalhos [33, 34] comparam os resultados de inspeção não-destrutiva por diferentes técnicas, como por exemplo o teste ultra-sônico e radiográfico (figura 2.19). ERHARD e EWERT [33] citam que outros métodos, como a própria radiografia, devem

ser utilizados para complementar a inspeção por TOFD, principalmente para a inspeção da região de campo próximo onde a TOFD é menos eficiente.

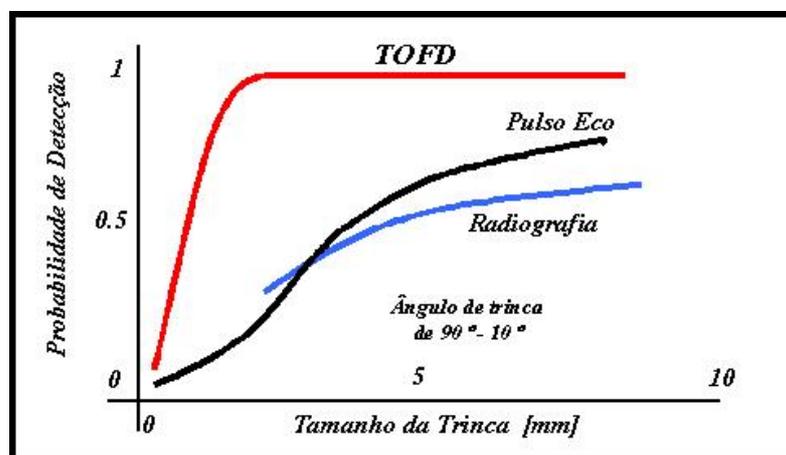


Figura 2.19 - Probabilidade de detecção pelas técnicas de END [33].

A sua utilização, contudo, depende da determinação dos fatores envolvidos na inspeção, tais como: tamanho, forma e posição do defeito; ângulo e frequência dos transdutores; espessura do material e parâmetros de varredura [5,6,21]. A probabilidade de se detectar um defeito, depende do seu tipo e da técnica não-destrutiva utilizada. Para cada tipo de defeito e técnica, o limite de detecção é baseado na interação do defeito com o método aplicado [33]. Os parâmetros dos transdutores, tais como: ângulo, frequência, dimensão e distância entre eles, devem ser escolhidos de acordo com as características do material a ser inspecionado (espessura, coeficiente de atenuação, etc.) [5, 6, 21, 23, 24].

KOMURA et al [35] obtiveram imagens B-scan de TOFD utilizando transdutores de *Phased Array*. Ele obteve bons resultados e apresenta como vantagens em utilizar transdutores de *Phased Arrey* a maior velocidade de inspeção em comparação com método ultra-sônico convencional, em função de apresentar uma imagem B-scan em tempo real sem necessidade de varredura mecânica, além da possibilidade de focalizar regiões de interesse.

A imagem B-scan, mostra uma seção transversal da região inspecionada, produzida pelo registro sucessivo de diversos A-scans obtidos durante o deslocamento paralelo dos

transdutores em relação ao feixe ultra-sônico, ou seja, transversal ao cordão de solda (Figura 2.20).

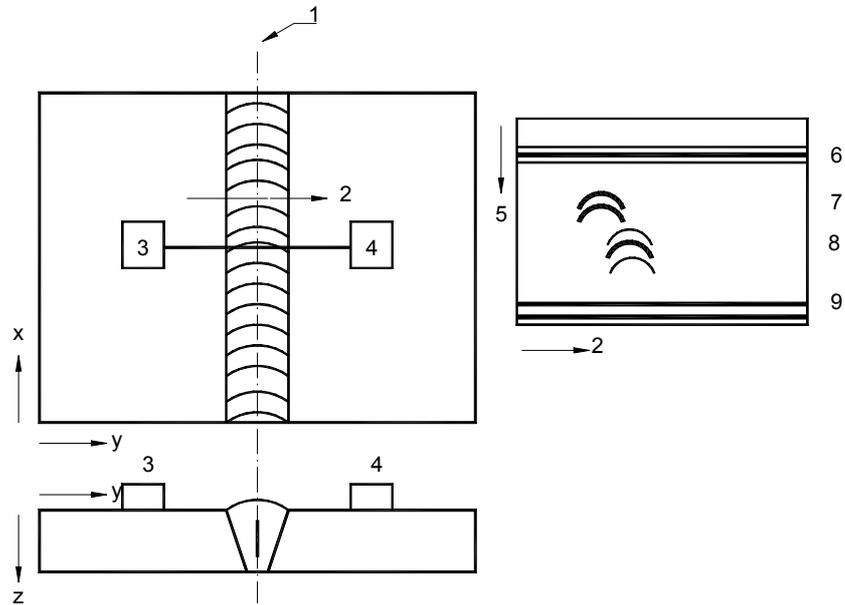


Figura 2.20 - Inspeção paralela, com a direcção de deslocamento típica (à esquerda) e o B-scan correspondente à direita. (1) Linha de referência, (2) Direcção do deslocamento dos Transdutores (direção yy), (3) Emissor, (4) Receptor, (5) Tempo de percurso (na direcção da espessura), (6) Onda lateral, (7) Extremidade superior da descontinuidade, (8) Extremidade inferior da descontinuidade, (9) Reflexão de fundo [5,6].

2.3. – Pré-Processamento de Sinais

Nesta seção, serão apresentados os diferentes tipos de pré-processamentos (Transformada de Fourier, Transformada *Wavelet* e Filtro Savitzky-Golay) aplicados aos sinais A-scan capturados durante a inspeção por TOFD nos doze corpos de prova (descritos no item 3 - MATERIAIS), e posteriormente utilizados como dados de entrada dos discriminadores lineares e não-lineares, implementados por redes neurais artificiais, que funcionarão como classificadores de padrões (ver item 2.4 - REDES NEURAIAS ARTIFICIAIS). Estes pré-processamentos foram também aplicados com o propósito de avaliar o desempenho dos classificadores quando comparados com a classificação de sinais A-scan originais, sem pré-processamento.

2.3.1. – Análise de Fourier

Existe uma grande quantidade de ferramentas disponíveis para processamento de sinais. Talvez a mais conhecida destas seja a Análise de Fourier, que consiste em decompor um sinal em suas componentes senoidais de diferentes frequências (Figura 2.21). Um outro modo de pensar na Análise de Fourier é como uma técnica matemática para transformar a visão do sinal no domínio do temporal em uma no domínio da frequência [36,37].



Figura 2.21 - Transformada de Fourier.

Matematicamente, o processo de Análise de Fourier é representado pela transformada de Fourier: $F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-j\omega t} dt$, que é o somatório no intervalo $\pm \infty$ do sinal $f(t)$ multiplicado por uma exponencial complexa. (relembrando que uma exponencial complexa pode ser decomposta em componentes senoidais reais e imaginários).

O resultado da transformada são os *coeficientes de Fourier* $F(\omega)$ que, quando multiplicado pela senoide de frequência apropriada ω , gera os componentes senoidais do sinal original. O processo está representado graficamente na figura 2.22.

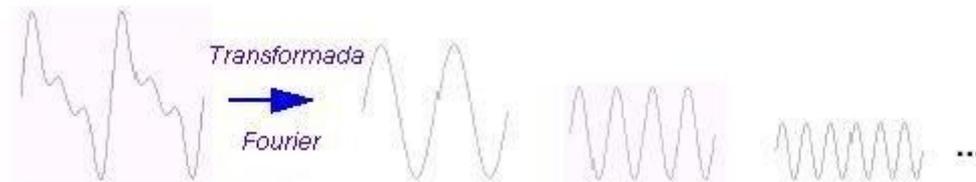


Figura 2.22 - Componentes senoidais gerados pela decomposição da Transf. de Fourier [37].

Para muitos sinais, a Análise de Fourier é extremamente útil porque o conteúdo em frequência do sinal é de grande importância. Entretanto, a Análise de Fourier tem uma séria desvantagem. Quando transformada para o domínio da frequência, a informação do tempo é perdida. Pela análise da transformada de Fourier de um sinal, é impossível dizer *quando* um evento particular aconteceu.

Se um sinal não varia muito no tempo - isto é, se é o que se chama de um *sinal estacionário* - esta desvantagem não é muito importante. Porém, a maioria dos sinais contém numerosas características transitórias ou *não-estacionárias*. Estas características são muitas vezes a parte mais importantes do sinal, e a análise de Fourier não é capaz de detectá-las. Num esforço de corrigir esta deficiência, Dennis Gabor et al [37] adaptou a transformada de Fourier para analisar somente uma pequena seção do sinal no tempo - uma técnica chamada *janelar* o sinal (Figura 2.23). A adaptação de Gabor, chamada *Short-Time Fourier Transform* (STFT), mapea um sinal numa função bidimensional de tempo e frequência.



Figura 2.23 - Transformada Curta de Fourier [37].

A STFT representa um tipo de relação entre uma visão baseada no tempo e frequência do sinal. Fornece algumas informações sobre quando e quais frequências ocorrem em um evento do sinal. Entretanto, esta informação só pode obtida com precisão limitada, dependendo também do tamanho da janela.

Enquanto a relação da SFTF entre informação de tempo e frequência pode ser útil, a desvantagem é que uma vez escolhido um tamanho para a janela de tempo, esta é a mesma para todas as frequências. Em muitos sinais é necessário variar o tamanho da janela para determinar mais precisamente tanto tempo quanto frequência.

2.3.2. – Análise *Wavelet*

A Transformada *Wavelet* foi desenvolvida especialmente para superar estas deficiências [37]. É uma técnica onde o tamanho da região processada é variável, e que permite a utilização de longos intervalos de tempo onde se quer informações sobre baixa frequência e curtos intervalos onde se quer informações das altas frequências [37, 38].

Uma *Wavelet* é uma onda de duração limitada que tem valor médio de amplitude igual a zero. Comparando uma onda senoidal, que é a base da Análise de Fourier, e uma *Wavelet* (Figura 2.24a e 2.24b), pode-se ver intuitivamente, que sinais com forma variável podem ser melhor relacionados a uma *wavelet* irregular do que com uma senoide suave.

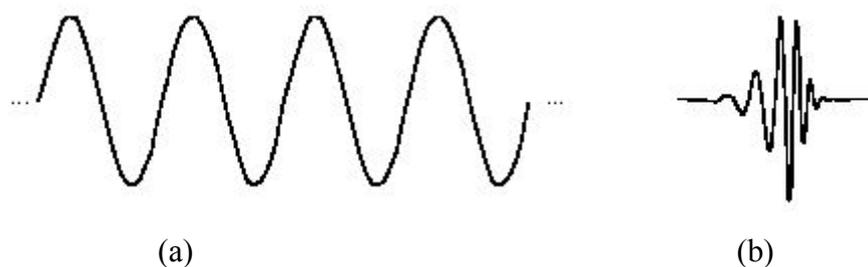


Figura 2.24 - Onda senoidal e uma Função Wavelet Daubechies 10 (db10) [37].

De modo similar à Transformada de Fourier, que consiste na decomposição de um sinal em funções senos de várias frequências, a Transformada *Wavelet* é a decomposição de

um sinal em versões de diferentes tamanhos (diferentes escalas) e posições da função *Wavelet* original (ou *onda mãe*).

A *Transformada Wavelet Contínua* (CWT) é definida como o somatório das multiplicações do sinal, $f(t)$, por versões redimensionadas e deslocadas da função base *wavelet* Ψ em todo o tempo do sinal:

$$C(\text{escala}, \text{posição}) = \int_{-\infty}^{\infty} f(t) \cdot \Psi(\text{escala}, \text{posição}, t) dt \quad (2.20)$$

O resultado da CWT é uma enorme quantidade de *Coefficientes Wavelet* C , que são funções da escala e da posição. Multiplicando cada coeficiente pela *wavelet* deslocada e redimensionada apropriada, geram-se os constituintes *wavelet* do sinal original [37].



Figura 2.25 - Componentes gerados pela decomposição da Transformada Wavelet

Uma forma prática para se obter a Transformada *Wavelet* Contínua é a seguinte.

- 1 – Uma seção no início do sinal original é comparada com a função *wavelet* escolhida.
- 2 – Calcula-se um número, C , que representa a correlação entre a *wavelet* e esta seção do sinal (Figura 2.26). Coeficientes mais altos significam maior semelhança. Os resultados dependerão da forma da função base *wavelet* escolhida.

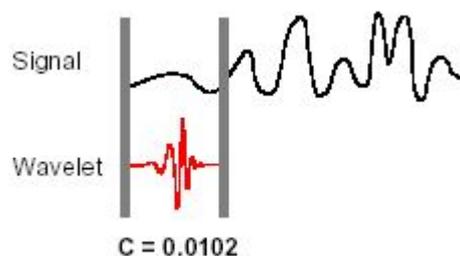


Figura 2.26 - Medida de correlação, C , entre a wavelet e parte do sinal [37].

3 - A *wavelet* é deslocada para a direita e as etapas 1 e 2 são repetidas até percorrer todo o sinal (Figura 2.27).

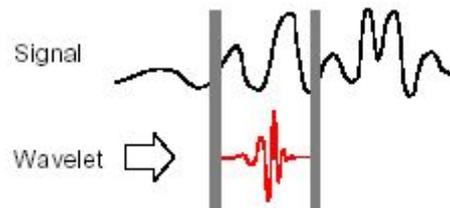


Figura 2.27 - Deslocamento e medida de correlação entre a wavelet e parte do sinal [37].

4 - A escala da *wavelet* é alterada e as etapas 1, 2 e 3 repetidas (Figura 2.28).

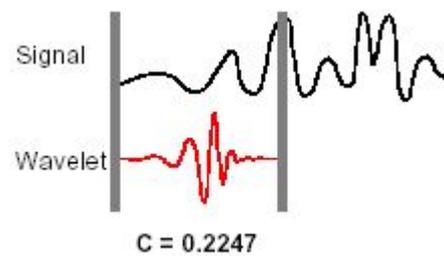


Figura 2.28 - Medida de correlação, C , entre a wavelet redimensionada e parte do sinal [37].

5 - As etapas de 1 a 4 são repetidas para todas as escalas escolhidas.

Escalas mais altas correspondem a uma *wavelet* de maior duração no tempo, assim, uma grande porção do sinal é analisada. Isto permite observar as baixas frequências e desta forma as mudanças lentas e aspectos grosseiros são medidos pelos coeficientes *Wavelets*. De modo similar, para as baixas escalas são utilizadas ondas de curta duração, o que permite observar detalhes e mudanças abruptas, isto é, observar altas frequências.



Figura 2.29 - Correspondência entre as escalas e frequência [37].

(Baixa escala $a = Wavelet$ de curta duração = mudanças rápidas = Alta frequência ω)
(Alta escala $a = Wavelet$ de longa duração = mudanças lentas = Baixa frequência ω)

Deve-se chamar atenção para o fato de que a análise *wavelet* não produz um diagrama tempo-frequência. Em lugar da frequência, o resultado da CWT é dado em escala. Pode-se, porém, relacionar a escala a uma pseudo-frequência através da equação 2.21 [37, 39].

$$F_a = \frac{\Delta F_c}{a} \quad (2.21)$$

onde: F_a é a pseudo-frequência relacionada à escala a ;

F_c é a frequência central da *wavelet* ;

Δ é a taxa de amostragem;

a é a escala.

Os coeficientes produzidos em diferentes escalas em diferentes seções do sinal constituem o resultado da correlação entre o sinal original e a *wavelet*. Da teoria de processamento de sinais, é sabido que o filtro receptor ideal para detectar sinais imersos em ruído branco é o filtro de resposta impulsiva que tem a mesma forma do sinal associado a ele, ou seja, *casado* [40, 41]. Assim, intuitivamente, poderia se imaginar que quanto maior a semelhança entre o sinal e a função *wavelet* escolhida, maior a magnitude do coeficiente. Estes coeficientes são apresentados em um gráfico no qual o eixo-X representa a posição ao longo do sinal (tempo), o eixo-Y representa a escala, e a cor em cada ponto representa a magnitude do coeficiente *Wavelet C* (Figura 2.30a). Uma representação tridimensional da figura 2.30a é apresentada na figura 2.30b.

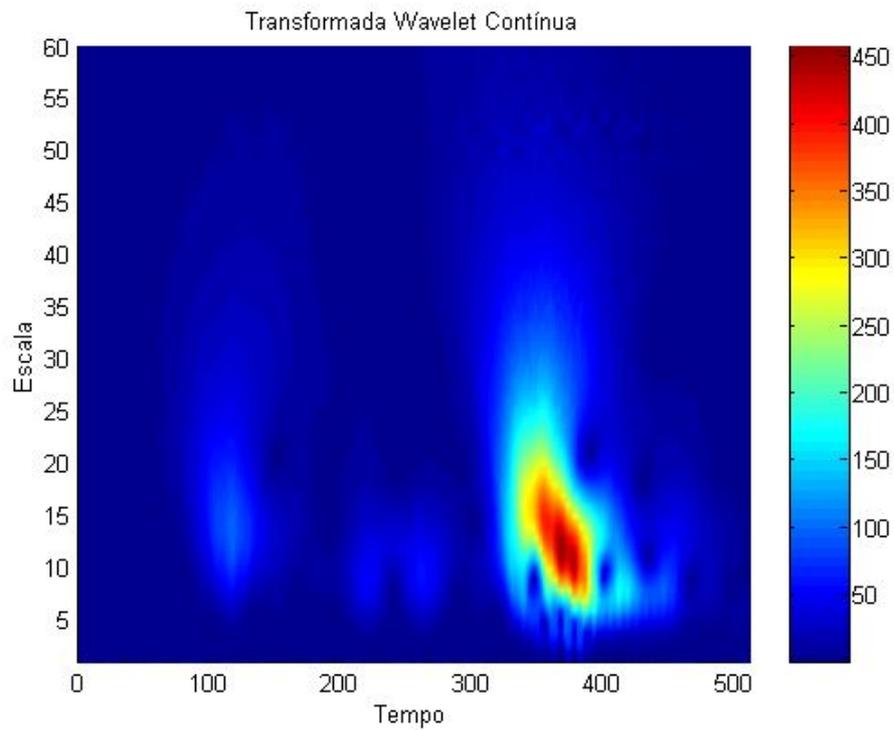


Figura 2.30a - Coeficientes Wavelet gerados pela correlação entre um sinal A-scan (FF25_9P04.dat) e a função wavelet gaussiana complexa de quarta ordem "cgau4".

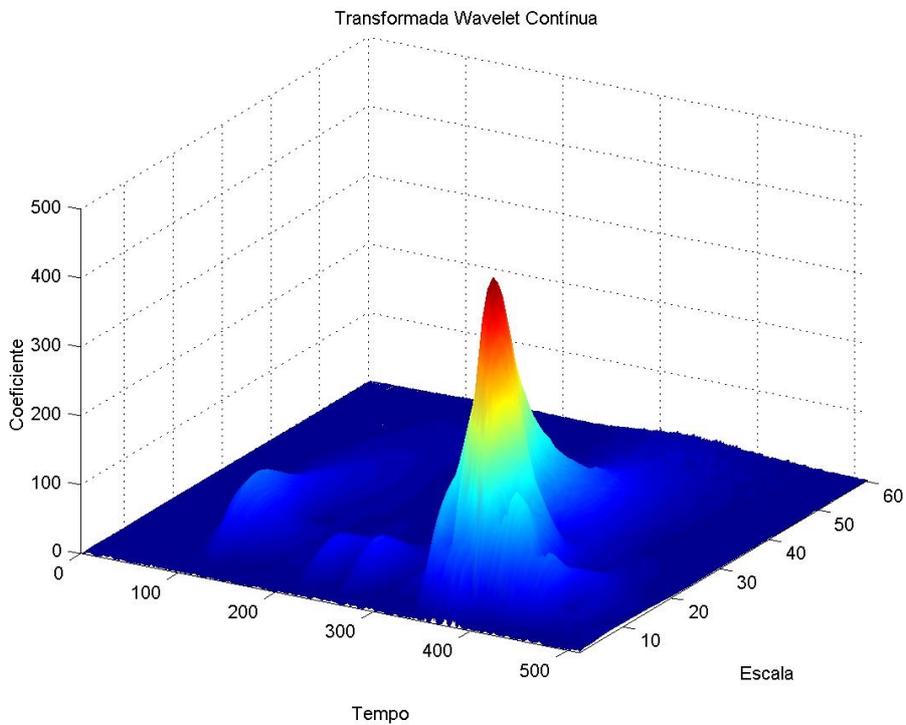


Figura 2.30b - Coeficientes Wavelet gerados pela correlação entre um sinal A-scan (FF25_9P04.dat) e a função wavelet gaussiana complexa de quarta ordem "cgau4".

A Transformada *Wavelet* tem sido muito utilizada em ensaios não-destrutivos como uma ferramenta para a eliminação de ruído [42, 43, 44, 45], na caracterização de materiais [46], e na estimativa de espaço entre espalhadores a partir de ecos ultra-sônicos [47].

Ecos ultra-sônicos de órgãos, tais como o fígado, apresentam uma pseudo-periodicidade devido aos espalhadores presentes do tecido. O espaço entre tais espalhadores tem sido proposto como uma assinatura para caracterizar tecidos. Apesar do interesse em estimar a distribuição dos espaços entre os espalhadores, os métodos presentes podem estimar somente o valor médio dos espaços dos espalhadores no tecido. TANG [47] procurando estimar a localização e o espaçamento entre cada um dos espalhadores individuais e obter a distribuição dos espaços entre os espalhadores presentes em tecidos do fígado, propôs a utilização de uma técnica baseada na decomposição *wavelet* para detectar a pseudo-periodicidade em sinais ultra-sônicos de pulso-eco. Porém, em seu trabalho [47], todos os resultados foram obtidos através de simulações em computadores.

Em materiais compósitos, a interpretação de sinais e a detecção de um possível defeito é dificultada pelo alto nível de ruído presente no sinal, gerado devido à sua natureza não-homogênea. LEGENDRE [48] propôs um processo de seleção de coeficientes *wavelet* utilizados na construção de imagens C-scan a partir da transformada *wavelet* de sinais A-scan obtidos durante a inspeção nestes materiais.

A microscopia ultra-sônica de varredura tem se mostrado uma ferramenta não-destrutiva capaz de detectar e localizar defeitos em muitos tipos de componentes. A fim de superar as dificuldades causadas pelas múltiplas reflexões e espalhamento do feixe ultra-sônico em componentes de múltiplas camadas, o que torna as imagens ultra-sônicas confusas de serem interpretadas e dificulta a determinação da natureza dos defeitos, ANGRISANI et al [49] também propôs o uso da transformada *wavelet* contínua como método de processamento dos sinais utilizados na construção de imagens de microscopia ultra-sônica de varredura em componentes eletrônicos de múltiplas camadas. ANGRISANI [49] conseguiu assim medir com maior precisão o tempo entre dois ecos ultra-sônicos sucessivos e avaliar a profundidade de defeitos.

A decomposição tempo-freqüência também foi utilizada por BETTAYEB [43] e WANG [44] para eliminar ruído e melhorar a detecção de falhas em materiais com alto coeficiente de espalhamento. Os resultados de WANG [44] mostraram que é possível detectar sinais ultra-sônicos com ruído inserido, onde o ruído presente apresentava uma relação sinal/ruído de -18dB , sem perda da precisão da medida do tempo.

Defeitos do tipo *weak bonding** ocorrem em juntas soldadas por fricção. Estes defeitos não são detectados com eficiência pelos métodos ultra-sônicos tradicionais utilizados na indústria. O sinal gerado por tais defeitos é tão fraco a ponto de ser mascarado pelo ruído de espalhadores. SHI [45] desenvolveu um algoritmo para eliminar o ruído e melhorar a detecção de defeitos, baseado na transformada *wavelet*. Os resultados de seus experimentos mostraram que o algoritmo é eficiente para aplicações práticas.

Em seu trabalho, ANGRISANI [50] associou o início e o final de ecos à saída de um filtro baseado na transformada *wavelet*. Assim, pela medida do intervalo de tempo entre os impulsos correspondentes ao início de dois ecos, foi possível medir espessuras finas em estruturas de múltiplas camadas. ANGRISANI [50] mostrou também que a transformada *wavelet* é uma poderosa ferramenta para a detecção de ecos parcialmente sobrepostos em meio ruidoso.

A escolha da função base (*wavelet*) adequada é importante para a qualidade do resultado do processamento [40, 51]. No processamento de sinais ultra-sônicos banda larga, a família de funções *wavelet* gaussiana com freqüência central igual à freqüência central do sinal recebido é a de melhor desempenho [40,52].

* Nos padrões internacionais de classificação de defeitos de soldagem, não existe um defeito classificado como *weak bonding*. Provavelmente, o autor [45] se refere a um defeito do tipo falta de fusão, que causa uma região da solda fracamente unida.

2.3.3. – Filtro Savitzky-Golay

O Filtro Savitzky-Golay (também chamado filtro de suavização polinomial ou filtro de suavização por mínimo quadrado) é tipicamente utilizados para suavizar um sinal banda larga com ruído [53, 54].

O Filtro de Alisamento Savitzky-Golay é superior à média móvel padrão, no sentido que o novo ponto, isto é, o ponto já suavizado é obtido através de uma regressão polinomial local que minimiza o erro quadrático dos dados ruidosos do intervalo, e não pela simples média dos pontos adjacentes como ocorre com o Filtro de Média Móvel padrão, que tende a eliminar uma porção importante do conteúdo de alta frequência do sinal junto com o ruído. Este método preserva certas características dos dados, tais como picos e largura do intervalo. Entretanto, ainda se observa distorção do sinal à medida que o número de pontos utilizado no intervalo aumenta [53, 54].

Em conseqüência da eficiência em preservar as componentes de alta frequência de um sinal, eles são menos bem sucedidos que filtros de média padrão na rejeição do ruído.

A idéia básica do método de Savitzky-Golay é a seguinte:

- 1 – Define-se a origem do sinal
- 2 – Define-se a largura do intervalo
- 3 – Define-se o ponto central do intervalo
- 4 – Remove-se o ponto central do conjunto de pontos do intervalo
- 5 – Ajusta-se através do método de mínimos quadrados, um polinômio de grau variável aos pontos restantes.
- 6 – Utiliza-se o polinômio para estimar o valor do ponto removido.
- 7 – Desloca-se o intervalo para o ponto seguinte do sinal original e repete-se o processo anterior.

Na prática, o cálculo da envoltória dos sinais, resultado do processo de retificação e aplicação do filtro Savitzky-Golay funciona de modo semelhante ao processo de demodulação obtido por um sistema composto por um diodo e um capacitor.

Conforme foi descrito, os filtros de suavização de ruído instrumental atuam diretamente sobre o sinal (no domínio do tempo) e não sobre as frequências que compõem tal sinal. Esta característica torna os filtros de suavização pouco seletivos, isto é, incapazes de diferenciar o que é sinal do que é ruído e, portanto, no processo de suavização de ruído uma parte da informação útil contida no sinal é simultaneamente removida. Dos filtros que atuam diretamente sobre as frequências que compõem o sinal, possibilitando a remoção seletiva de ruído, os mais populares são os filtros baseados na Transformada de Fourier, apresentada anteriormente.

2.4. – Redes Neurais Artificiais

Esta seção se propõe a descrever os principais tópicos referentes às Redes Neurais Artificiais, desde seu surgimento e propostas iniciais das Redes Neurais, até algoritmos de treinamento, aplicações e progressos nesta área.

2.4.1. – Introdução

O progresso das técnicas computacionais, principalmente o desenvolvimento das Redes Neurais Artificiais, tem dado um grande impulso às pesquisas de desenvolvimento de sistemas automáticos de inspeção e classificação de padrões de defeitos [9,10,11].

As Redes Neurais Artificiais possuem certas características exclusivas de sistemas biológicos e são implementadas através de algoritmos que tentam modelar algumas funções do cérebro. Atributos tais como, aprender através de exemplos, generalizações redundantes, reconhecimento de padrões, criação de associações, aprendizado com experiência ou treinamento [12,13] e tolerância a falhas (robustez), fazem das redes neurais artificiais uma escolha apropriada para a modelagem de sistemas não-lineares.

Embora não possam ser comparadas ao cérebro humano em complexidade, as redes neurais artificiais têm a capacidade de processar grandes quantidades de dados em curto espaço de tempo que normalmente só poderiam ser analisadas por um especialista.

2.4.2. – O Neurônio Biológico

O cérebro humano é formado por um conjunto extremamente complexo de neurônios, com aproximadamente 10 bilhões destes. Todas as funções e movimentos do organismo estão relacionados ao funcionamento destas células.

Os principais componentes dos neurônios são (Figura 2.31): os dentritos, que tem por função, receber os estímulos transmitidos pelos outros neurônios; o corpo de neurônio,

também chamado de soma, responsável por coletar e combinar informações vindas de outros neurônios; e finalmente o axônio, que é constituído de uma fibra tubular que pode alcançar até alguns metros, e é responsável por transmitir os estímulos para outras células.

O axônio ou fibra nervosa de um neurônio é um tubo filamentar delimitado pela membrana celular. Em repouso, o interior da membrana está a um potencial elétrico negativo de algumas dezenas de milivolts em relação ao exterior, sendo este designado como potencial de repouso. Esta diferença de potencial é sustentada por um processo de difusão assimétrico de íons de sódio e potássio através da membrana, processo este conhecido como bomba de sódio e potássio. Quando o potencial da membrana fica despolarizada (menos eletronegativo) o suficiente para cruzar o limiar de disparo, ocorre a formação de um potencial de ação e então rapidamente o neurônio emite um pulso que é transmitido ao longo da fibra nervosa. Ocorrido o potencial de ação, o neurônio retorna ao potencial de repouso bem mais lentamente [55].

Os neurônios estão conectados e transmitem estímulos uns aos outros através de sinapses. As sinapses são unidades estruturais e funcionais elementares compreendida entre duas membranas celulares: a membrana pré-sináptica (presente no axônio), por onde chega um estímulo proveniente de uma outra célula, e a membrana pós-sináptica, que é a do dendrito. Nesta região intersináptica, o estímulo nervoso que chega à sinapse libera substâncias chamadas neurotransmissores que se difundem através da junção sináptica entre neurônios e agem sobre um processo pós-sináptico, transferindo o estímulo à membrana dendrital. Assim, uma sinapse converte um sinal elétrico pré-sináptico em um sinal químico e então de volta em um sinal elétrico pós-sináptico.

O resultado dessa transferência é uma alteração no potencial elétrico da membrana pós-sináptica. Dependendo do tipo de neurotransmissor, a conexão sináptica será excitatória ou inibitória. Uma conexão excitatória provoca uma alteração no potencial da membrana que contribui para a formação de um impulso nervoso no axônio de saída enquanto que uma conexão inibitória age no sentido oposto.

Juntos, os neurônios formam uma grande rede chamada Rede Neural, que se estende por todo o corpo humano. Esta grande rede proporciona uma fabulosa capacidade de processamento e armazenamento de informação.

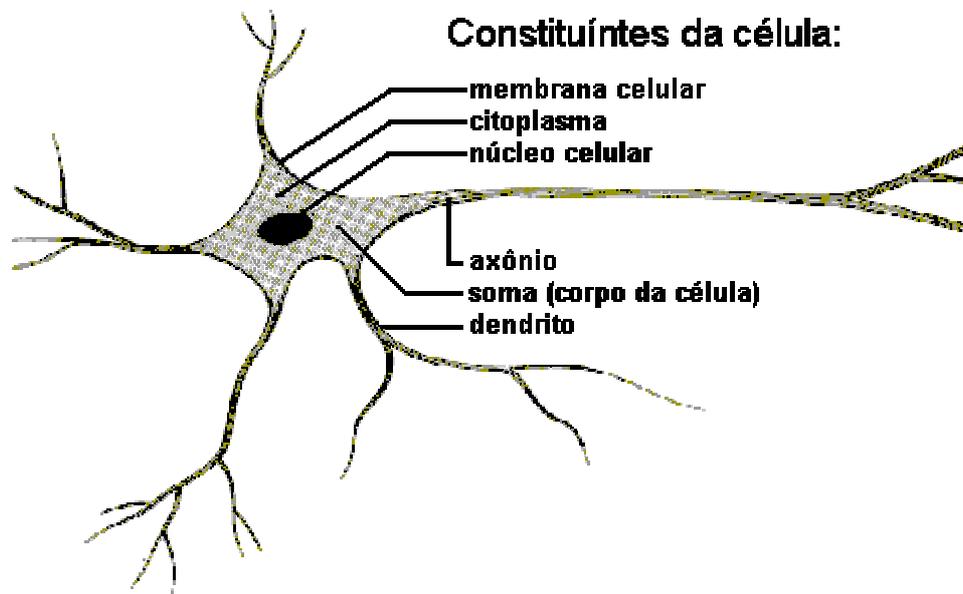


Figura 2.31 - Esquema dos constituintes da célula neural

2.4.3. – O Neurônio de Mcculloch-Pitts

As primeiras informações mencionadas sobre a neurocomputação datam de 1943, quando McCulloch e Pitts [56], baseados ou inspirados no cérebro humano desenvolveram um modelo que propõe elementos computacionais, abstraídos das propriedades fisiológicas dos neurônios biológicos e de suas conexões, introduzindo assim a referência número um, para a teoria de Redes Neurais Artificiais (doravante chamadas simplesmente de Redes Neurais).

Este modelo é bem simples quando comparado com o neurônio biológico [57, 58, 59] que possui uma imensa estrutura complexa e um grande número de detalhes, porém, o modelo integrador no neurônio de McCulloch-Pitts, é uma boa aproximação que satisfaz alguns dos modelos encontrados na neurofisiologia [58, 60].

Assim como no Neurônio Biológico, no modelo de McCulloch-Pitts tem-se vários estímulos $\vec{x} = [x_1, x_2, \dots, x_n]$ que chegam ao neurônio (Figura 2.32). Cada estímulo é multiplicado pelo seu respectivo peso sináptico pré-definido, podendo inibi-lo ($w < 0$) ou excitá-lo ($w > 0$), onde $\vec{w} = [w_1, w_2, \dots, w_n]$. Para determinar a saída do neurônio faz-se a integração sináptica, ou seja, calcula-se a soma ponderada dos estímulos com seus respectivos ganhos sinápticos que produzem um nível de atividade u . Se este nível de atividade atingir ou exceder um certo limiar (*threshold*) inicialmente fixado, a unidade torna-se ativa e produz uma determinada resposta de saída, caso contrário permanece inativo.

O neurônio de McCulloch-Pitts pode ser representado graficamente da seguinte maneira:

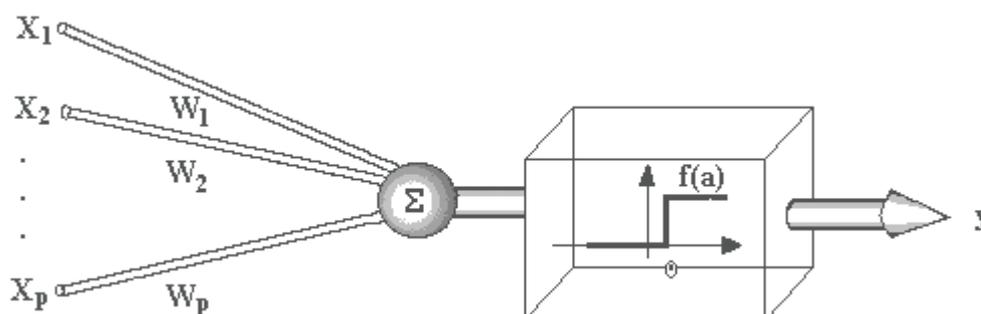


Figura 2.32 - Diagrama esquemático do neurônio artificial projetado por McCulloch-Pitts.

Matematicamente, pode-se descrever o comportamento do neurônio de McCulloch-Pitts, por meio das seguintes equações:

$$u = \sum_{j=1}^m w_j \cdot x_j = \vec{w}' \cdot \vec{x} ; e, \quad (2.22)$$

$$y = f(u) = 1, \text{ se } u \geq \theta$$

$$y = f(u) = 0, \text{ se } u < \theta$$

onde: u é o nível de atividade interna produzida pelos estímulos;

$f(u)$ é uma função de transferência degrau;

θ é o limiar (*threshold*);

o índice sobrescrito t indica a matriz transposta do vetor \bar{w} .

A maneira mais comumente adotada pelos livros para descrever o neurônio de McCulloch-Pitts, é apresentada pelo modelo neural da figura 2.33, onde um *bias* representado por b_k , é aplicado externamente. O *bias* b_k tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente. O *bias* equivale ao limiar do modelo anterior.

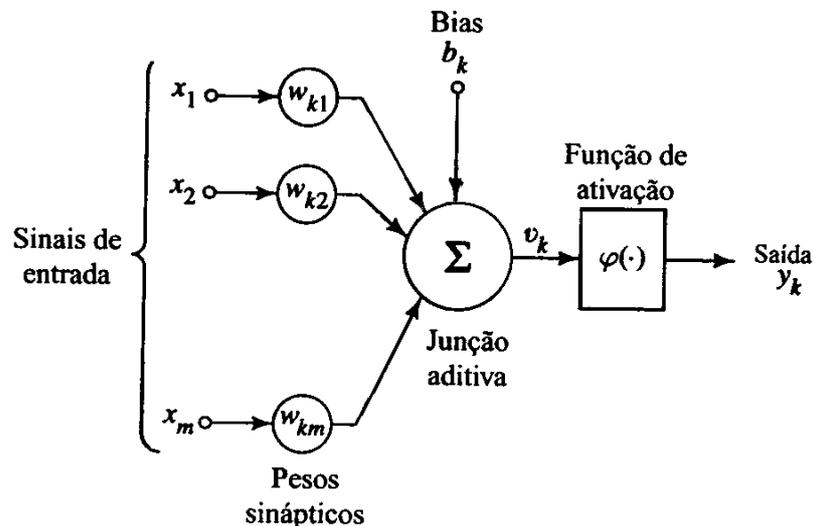


Figura 2.33 - Modelo de neurônio artificial [12].

Considerando a existência do *bias*, pode-se descrever um neurônio k escrevendo o seguinte par de equações:

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \quad (2.23)$$

$$y_k = \varphi(u_k + b_k) \quad (2.24)$$

onde x_1, x_2, \dots, x_m são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o *bias*; φ

é a função de ativação; e y_k é o sinal de saída do neurônio. O uso do *bias* b_k tem o efeito de aplicar uma transformação afim à saída u_k do combinador linear no modelo da figura 2.33, como mostrado pela equação seguinte:

$$v_k = u_k + b_k \quad (2.25)$$

O *bias* b_k é um parâmetro externo do neurônio artificial k . Pode-se considerar seu efeito de duas maneiras: (1) adicionando-se uma nova entrada fixa $x_0 = +1$ e (2) adicionando-se um novo peso sináptico igual ao *bias*, $w_{k0} = b_k$. Pode-se, portanto, reformular a combinação das equações 2.23 até 2.25 para obter a equação 2.26.

$$v_k = \sum_{j=0}^m w_{kj} \cdot x_j \quad (2.26)$$

$$y_k = \varphi(v_k) \quad (2.27)$$

Um novo modelo do neurônio da figura 2.33 pode ser representado pela figura 2.34. Embora os modelos das figuras 2.32, 2.33 e 2.34 sejam diferentes na aparência, eles são matematicamente equivalentes.

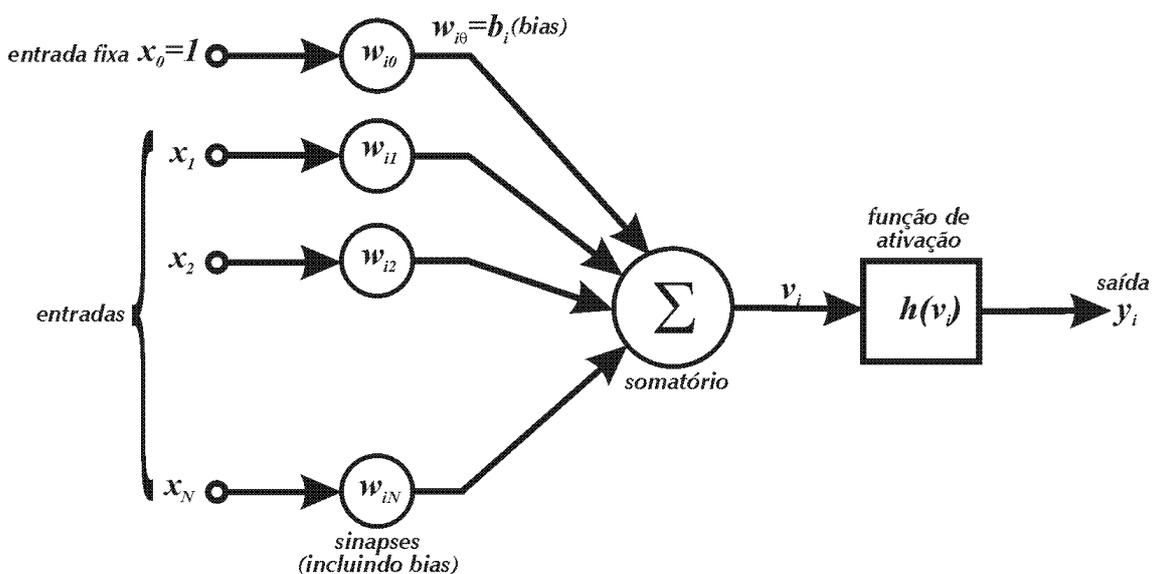


Figura 2.34 - Um outro modelo de neurônio artificial [12].

2.4.4. – O Discriminador Linear

Em vista do comportamento descrito pela equação (2.26), o neurônio de McCulloch pode ser utilizado como um caso particular de discriminador linear e funcionar como classificador de padrões ou separador de pontos.

Considere duas coleções de dados $A = [\vec{\sigma}_1, \vec{\sigma}_2, \vec{\sigma}_3, \dots, \vec{\sigma}_s]$ de s vetores n -dimensionais e $B = [\vec{\lambda}_1, \vec{\lambda}_2, \vec{\lambda}_3, \dots, \vec{\lambda}_m]$ de m vetores n -dimensionais. Para se implementar um discriminador linear que separe estas duas coleções de vetores procede-se da seguinte forma:

$$\begin{aligned} f(u) &= 1 && , \text{ se } x \in A \\ f(u) &= 0 \text{ ou } -1 && , \text{ se } x \in B \end{aligned} \quad (2.28)$$

Sendo assim, o discriminador linear separa o espaço em duas regiões. A figura abaixo ilustra a separação linear do espaço R^2 em duas regiões.

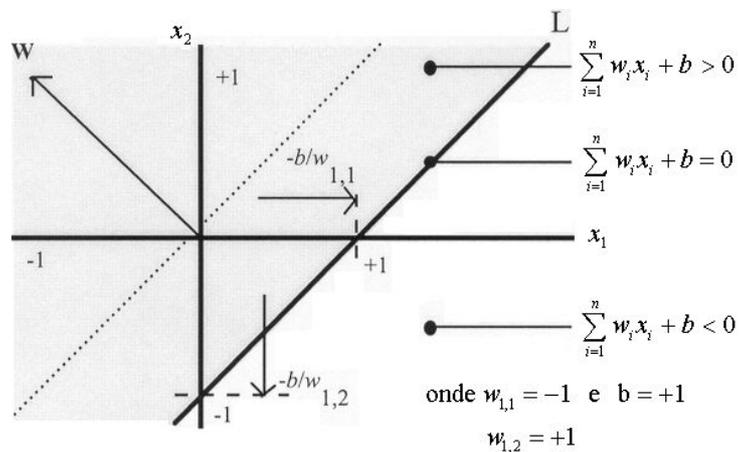


Figura 2.35 - Discriminador linear separando o espaço em duas regiões em R^2 [61].

Contudo, a separação de duas coleções de dados só é possível se os conjuntos de pontos A e B no espaço R^n sejam tais que seja possível passar um plano ou um hiperplano que separe estes conjuntos de pontos. Caso seja possível eles são ditos linearmente

separáveis (Figura 2.36a), caso contrário, não haverá nenhum discriminador linear capaz de executar esta função (Figura 2.36b) [55, 60].

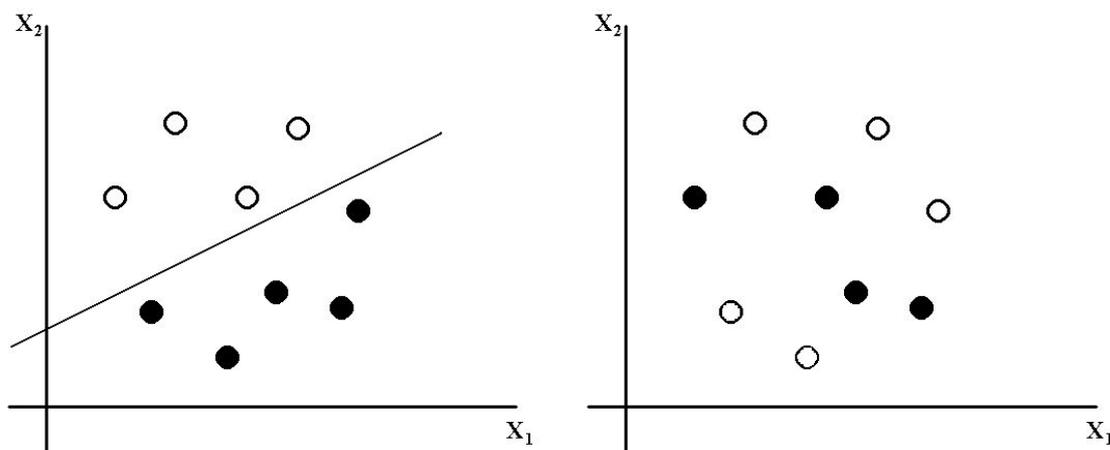


Figura 2.36 – Conj. de pontos a) linearmente separáveis; e b) não-linearmente separáveis [55].

Uma vantagem da aplicação do *bias* é que um mesmo discriminador (definido pelo vetor \vec{w}) pode ser transladado da origem pela sua utilização. A ausência do *bias* obriga o discriminador a passar pela origem, e limita bastante sua ação.

Embora o neurônio de McCulloch-Pitts tenha sido fundamental para a pesquisa e o desenvolvimento das redes artificiais atuais, não possui grande aplicação, mostrando que um neurônio sozinho não é capaz de realizar tarefas complexas (Figura 2.36b). Entretanto, a utilização de arquiteturas de rede com vários neurônios em paralelo e, por vezes, várias camadas destes, pode vir a constituir uma ferramenta poderosa [55]. Através de uma rede formada por simples neurônios de McCulloch-Pitts, é possível modelar algumas funções ou fenômenos que podem ser representados por funções lógicas [58, 60].

2.4.5. – Funções de Ativação

As funções de ativação têm por objetivo limitar a amplitude das saídas dos neurônios, tipicamente entre $[0,1]$ ou $[-1,1]$, dependendo do caso, considerando-se características como monotonicidade dentro de uma faixa, conhecida como faixa dinâmica, e saturação

fora desta. Estas funções possuem papel extremamente importante quando do tratamento de funções não-lineares.

As funções de ativação se dividem basicamente em três tipos:

Função degrau (“*threshold*”)

$$\varphi(v) = \begin{cases} 1 & , \text{ se } v \geq 0 \\ 0 \text{ ou } -1 & , \text{ se } v < 0 \end{cases} \quad (2.29)$$

Neste caso, somente a saturação é considerada (Figura 2.37a).

Função linear por partes

$$\varphi(v) = \begin{cases} 1 & , \text{ se } v \geq \frac{1}{2} \\ v & , \text{ se } \frac{1}{2} > v > -\frac{1}{2} \\ 0 \text{ ou } -1 & , \text{ se } v < -\frac{1}{2} \end{cases} \quad (2.30)$$

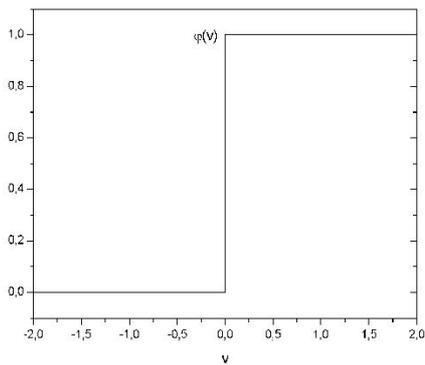
Ao contrário da função degrau, a função semi-linear é monotônica dentro de uma faixa, ocorrendo saturação fora desta (Figura 2.37b).

Função sigmóide, sendo, as mais utilizadas (Figura 2.37c e Figura 2.37d):

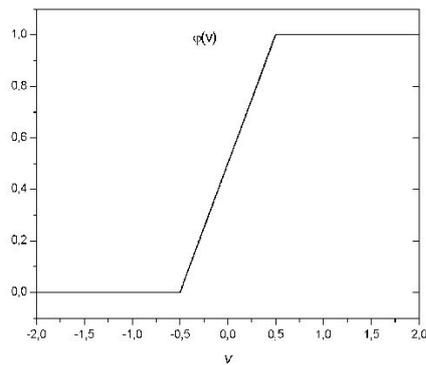
Função logística: $\varphi(v) = \frac{1}{1 + \exp(-av)}$ (2.31)

Função tangente hiperbólica: $\tanh(\beta v) = \frac{1 - e^{-2\beta v}}{1 + e^{-2\beta v}}$ (2.32)

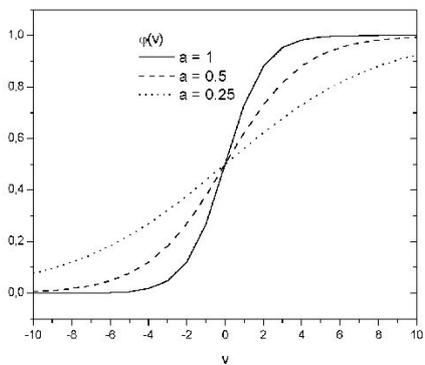
Estas funções, além de apresentarem monotonicidade sobre uma faixa e saturação fora desta, são simétricas e possuem derivadas contínuas, aspecto importante em redes neurais, sobretudo em redes multicamadas.



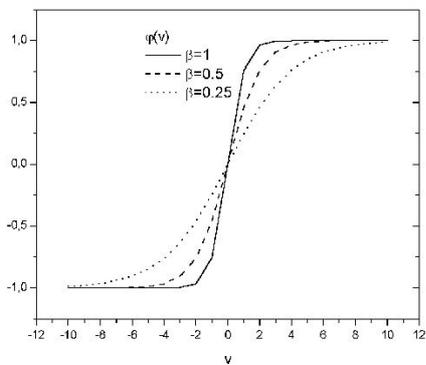
(a)



(b)



(c)



(d)

Figura 2.37 - Funções de ativação mais comumente utilizadas. a) Função degrau “threshold”; b) função linear por partes; c) função logística e d) função tangente hiperbólica [12,55].

2.4.6. – Arquiteturas de Redes e Algoritmos de Treinamento

O primeiro neurocomputador a obter sucesso (Mark I *Perceptron*) surgiu no final da década de 50, criado por Frank Rosenblatt, Charles Wightman e outros [62]. Seu interesse inicial para a criação do *Perceptron* era o reconhecimento de padrões. O *Perceptron* é uma rede de múltiplos neurônios do tipo discriminadores lineares.

O problema que Rosenblatt propôs resolver foi o seguinte: para casos simples como a implementação das funções booleanas “E” e “OU” de duas variáveis é relativamente trivial escolher os ganhos sinápticos e o valor do limiar, conforme já foi mostrado na figura 2.35 da seção 2.4.4. Porém, a implementação de uma função discriminatória arbitrária, sem a existência de algum método, beira o impossível.

Assim, por exemplo, se a função do *Perceptron* fosse reconhecer o símbolo “A”, a sua resposta deveria ser $y=1$ sempre que alguma variante deste fosse apresentado na sua entrada e $y=0$ em caso contrário. Supondo que efetivamente estas duas classes de padrões {A} e {não A} fossem linearmente separáveis, resta a questão de como escolher os ganhos de ponderação das entradas w_j e o *bias*, parâmetros que definem unicamente um discriminador linear conforme estabelecido pela expressão (equação 2.26).

Sistemas nervosos biológicos possuem capacidade de aprender uma função. Poder-se-ia portanto imaginar uma maneira de ensinar a rede artificial até que esta aprendesse a função desejada. O método de treinamento mais intuitivo possível é o treinamento supervisionado, ou seja, através de exemplos.

Hebb [63] foi o primeiro a propor uma lei de aprendizado específico para as sinapses dos neurônios. Hebb propôs que exemplos fossem apresentados à rede, isto é, para um estímulo x_l^d a saída deve ser y_l^d , onde o índice d refere-se a desejado. Os exemplos, ou pares de treinamento, são repassados até que a rede aprenda o comportamento correto, e implemente corretamente a função $y_l^d = f(x_l^d)$ para todos os $l=1, 2, \dots, L$ exemplos [55], ou seja, selecione adequadamente os valores de sinapses e *bias* através de algoritmos que minimizem os erros (diferença entre a saída obtida e a desejada).

Considere um conjunto de exemplos de treinamentos Ψ definido como

$$\Psi = \{(x_l^d, y_l^d)\}_{l=1}^N \quad (2.33)$$

Os exemplos devem então ser aplicados às entradas da rede, que ajustará seus ganhos através de um algoritmo que faça com que as saídas especificadas coincidam ou se assemelhem com os exemplos de treinamento.

Segundo o princípio de Hebb, os parâmetros w_i devem ser atualizados segundo a regra:

$$w_i^{novo} = w_i^{velho} + \Delta w_i \quad (2.34)$$

com

$$\Delta w_i = \alpha \cdot (y_i^d - y_i) \cdot x_{i,l}^d \quad (2.35)$$

onde o parâmetro α é definido como taxa de aprendizado, com as sinapses sendo alteradas em função dos erros. O limiar costuma estar incorporado à soma ponderada através do *bias*.

Sendo assim, a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação programada, onde é necessário um conjunto de regras rígidas pré-fixadas e algoritmos.

Todo o conhecimento de uma rede neural está armazenado nas sinapses, ou seja, nos pesos atribuídos às conexões entre os neurônios. Uma grande parte dos dados deve ser separado para o treinamento da rede neural, dados estes escolhidos aleatoriamente, a fim de que a rede “aprenda” as regras e não “decore” exemplos.

Após Rosenblatt, Bernard Widrow [64] desenvolveu um novo tipo de elemento de processamento de redes neurais chamado de ADALINE (*ADaptive LINear Element*) e mais tarde, sua generalização multicamadas chamado de MADALINE (múltipla ADALINE). A principal contribuição deste modelo foi um princípio de treinamento extremamente eficaz para as redes de ADALINES, que ficou conhecido com método *gradiente* ou *Regra Delta* [55].

A saída do ADALINE é um elemento y , que é uma combinação linear dos componentes do vetor de entrada $\vec{x} = [x_1, x_2, \dots, x_n]$.

$$y = \vec{w}' \cdot \vec{x} \quad (2.36)$$

Supondo uma função escolhida arbitrariamente $y = f(x_1, x_2, \dots, x_n) = f(\vec{x})$ com $f(0) = 0$, L exemplos desta função são apresentados ao ADALINE. Estes pares de entrada e saída da função constituem o conjunto de treinamento Ψ já definido pela equação 3.32. Procura-se então determinar a melhor aproximação linear possível. Isto é, encontrar um \vec{w} tal que o erro quadrático sobre todo o conjunto de observações Ψ seja minimizado. A função erro quadrático para um discriminador arbitrário pode ser dada pela equação 2.37:

$$E(w) = \sum_{l=1}^L \left(\sum_{i=1}^n w_i x_{il}^d - y_l^d \right)^2 \quad (2.37)$$

Desta forma, este dispositivo pode ser considerado um aproximador linear de funções [55]. Evidentemente, se os pontos do conjunto de treinamento estiverem relacionados linearmente, isto é, se a função $f(\vec{x})$ que se pretende aproximar é linear, então o mínimo erro quadrático será nulo. Nos demais casos, será algum valor positivo. A condição de que \vec{w} seja um ponto de mínimo é discutida por Hertz [65].

A seguir, a figura 2.38 ilustra exemplos de superfície do erro quadrático em função dos pesos sinápticos, onde $w \in \mathbb{R}^2$. A situação da figura 2.38a é a ideal, pois a função caminha rapidamente sem grande oscilação para o ponto de mínimo sem a possibilidade de estacionar em um mínimo local (figura 2.38b) ou infinitos pontos de mínimo (região de calha) (figura 2.38c) ou em regiões ou direções de gradiente muito pequeno (figura 2.38d), o que elevaria consideravelmente o tempo de treinamento.

Uma solução global pode ser obtida notando-se que a função $E(\vec{w})$ é convexa e possui um mínimo interno. A condição necessária para que \vec{w} seja um ponto de mínimo interno é de que ali o gradiente da função $E(\vec{w})$ seja nulo, conforme ilustrado para o caso de \vec{w} bidimensional na figura 2.38(a). Muitas vezes, a superfície $E(\vec{w})$ é referida como panorama da função de erro.

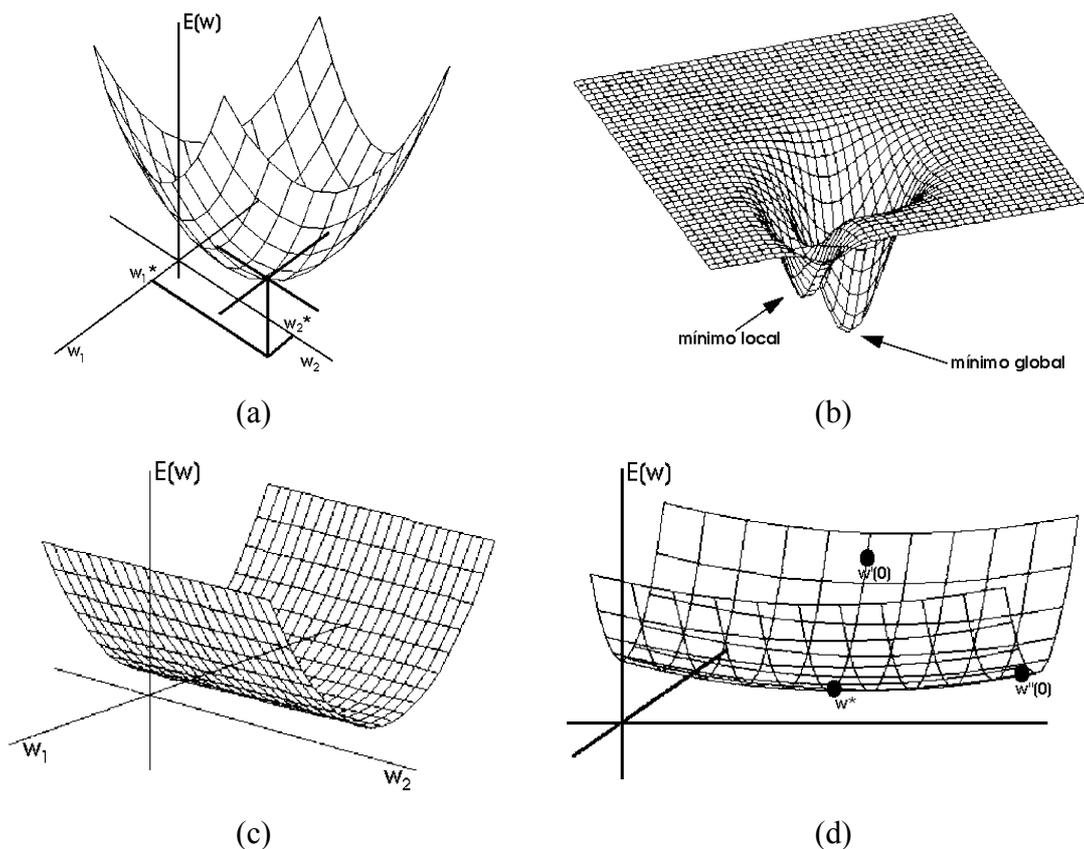


Figura 2.38 - Representação do erro quadrático médio em função das sinapses $w \in \mathbb{R}^2$. a) situação ideal com apenas um ponto de mínimo e convergência rápida; b) presença de mínimos locais além do mínimo global; c) infinitos pontos de mínimo e d) regiões de gradientes muito pequenos (direção $w^* - w$) [55].

A proposta de Widrow foi de obter o ponto de mínimo da função erro $E(w)$ através de um processo de interação local (a *Regra Delta*), utilizando um exemplo do conjunto de treinamento por vez. Esse método também é conhecido como método do *gradiente descendente*, pois partindo-se de um ponto arbitrário $\bar{w}(0)$, pode-se percorrer a superfície $E(\bar{w})$ em direção a um ponto de mínimo, bastando para isto evoluir no sentido oposto ao gradiente naquele ponto.

Isto pode ser traduzido no seguinte algoritmo iterativo para o cálculo de valores $\bar{w}(k)$ sucessivamente mais próximos do ponto de mínimo: dado $\bar{w}(k)$, obtém-se $\bar{w}(k+1)$ por:

$$w(k+1) = w(k) - \alpha \nabla(E(w(k))), \text{ ou} \quad (2.38)$$

$$w(k+1) = w(k) - \alpha \frac{d}{dw} E(w(k)) \quad (2.39)$$

onde α é o fator de aprendizagem, que está relacionado com a velocidade de convergência do processo.

Substituindo a expressão de $E(w)$, equação 2.37, na expressão anterior, obtém-se:

$$w(k+1) = w(k) + \alpha \sum_{l=1}^L (x_l^d)(\delta_l) \quad (2.40)$$

onde: $\alpha = 2 \cdot \varphi$ e $\delta_l = (y_l^d - y)$

Na expressão (2.40) observa-se que é possível atualizar os pesos sinápticos (w), após a apresentação de todo o conjunto de treinamento Ψ (uma “época”), porém, pode-se atualizar os pesos (w) a cada exemplo l [55]. Uma observação pertinente neste caso é quanto ao critério de parada da iteração, visto que o número de iterações pode tender ao infinito. Um valor de erro pré-definido, ou um número máximo de iterações, k_{\max} , podem ser utilizados como critérios de parada.

O *Perceptron* foi concebido para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico. Um único *perceptron*, ou uma combinação das saídas de alguns *perceptrons*, poderia realizar uma operação “**XOR**” (o “ou” exclusivo). Minsky e Papert [66] analisaram matematicamente o *Perceptron* e demonstraram que redes de uma camada não são capazes de solucionar problemas que não sejam linearmente separáveis. Para isto são necessárias mais conexões, as quais só existem em uma rede de *perceptrons* dispostos em camadas. Como não acreditavam na possibilidade de se construir um método de treinamento para redes com mais de uma camada, eles concluíram que as redes neurais seriam sempre suscetíveis a essa limitação.

Contudo, o desenvolvimento do algoritmo de treinamento de retropropagação do erro (*backpropagation*), por Rummerlhart, Hinton e Williams em 1986, [12,13,55,64,65,67] mostrou que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de redes neurais artificiais mais utilizado atualmente, as redes *Perceptron* Multicamadas (*Multilayer Perceptron* - MLP) (Figura 2.39) treinadas com o algoritmo *backpropagation*.

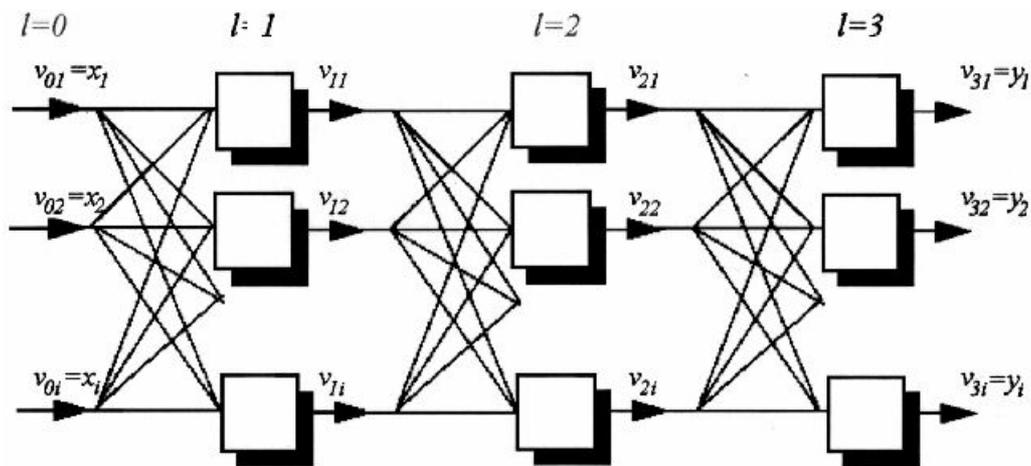


Figura 2.39 - Rede multicamada. Camada de entrada $l=0$, duas camadas ocultas ($l=1$ e $l=2$) e uma camada de saída ($l=3$) [55].

O *Multilayer Perceptron* é uma rede de múltiplas camadas de múltiplos neurônios, do tipo discriminadores lineares, ou seja, além das camadas de entrada e saída, estas contêm camadas internas ou intermediárias que são geralmente referidas como camadas ocultas. A figura 2.39 apresenta uma rede multicamada. As saídas da camada $l=0$ se conectam às entradas da camada $l=1$ e assim sucessivamente, até se formar o vetor de saída (resposta da rede) da última camada. Um vetor u_{li} refere-se à saída do i -ésimo neurônio da l -ésima camada.

Nessas redes, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa, do problema [12].

O algoritmo de *backpropagation*, também conhecido como a *Regra Delta Generalizada* [12, 13, 55, 64, 65, 67], é uma modificação do ADALINE de Widrow-Hoffe em que se considera uma função de ativação não-linear [12, 60] e as respostas assumem valores contínuos.

A regra delta padrão essencialmente implementa um gradiente descendente no quadrado da soma do erro para funções de ativação lineares. Redes sem camadas intermediárias, podem resolver problemas onde a superfície de erro tem a forma de um parabolóide com apenas um mínimo (figura 2.38a). Entretanto, a superfície do erro pode não ser tão simples, como a ilustrada na figura 2.40. Nestes casos devem ser utilizadas redes com camadas intermediárias. Ainda assim, as redes ficam sujeitas aos problemas de mínimos locais (figura 2.38b).

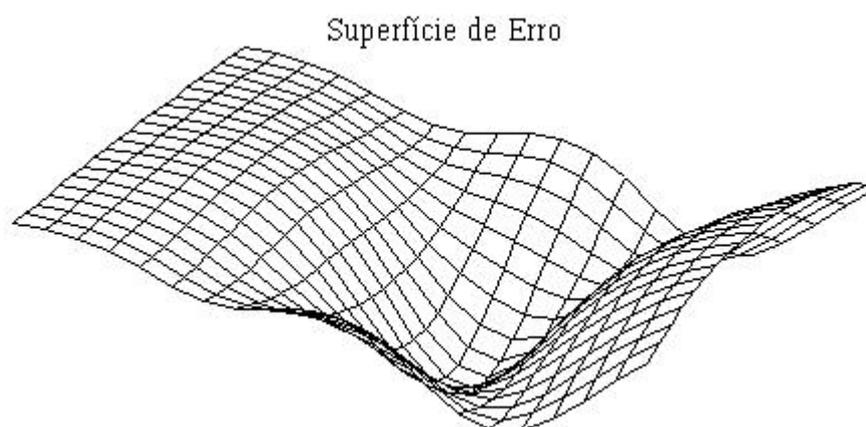


Figura 2.40 - Exemplo de Superfície de Erro.

Como provou Cybenko [68], a partir de extensões do Teorema de Kolmogoroff, são necessárias no máximo duas camadas intermediárias, com um número suficiente de neurônios por camada, para se produzir quaisquer mapeamentos. Também foi provado que apenas uma camada intermediária é suficiente para aproximar qualquer função contínua [68, 69, 70, 71, 72].

A *regra delta generalizada* funciona quando na rede são utilizados neurônios com uma função de ativação semi-linear, que é uma função diferenciável e não decrescente. Note que a função *threshold* (figura 2.37a) não se enquadra nesse requisito. Uma função de

ativação amplamente utilizada, nestes casos, é a função logística (figura 2.37c) ou tangente hiperbólica (figura 2.37d).

De uma forma similar ao algoritmo LMS (mínimo quadrado médio), o algoritmo de retropropagação aplica uma correção $\Delta w_{ji}(n)$ ao peso sináptico $w_{ji}(n)$, que é proporcional à derivada parcial $\frac{\partial E(n)}{\partial w_{ji}(n)}$, onde $E(n)$ é a energia total do erro, obtido somando-se o erro de todos os neurônios da camada de saída, os únicos neurônios “visíveis” para os quais os sinais de erro podem ser calculados diretamente. Pode-se demonstrar que a correção $\Delta w_{ji}(n)$ aplicada a $w_{ji}(n)$ é definida pela regra delta [12,13, 55, 65, 67]:

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (2.41)$$

onde η é o parâmetro da taxa de aprendizagem do algoritmo de retropropagação. O uso do sinal negativo na equação (2.41) indica a descida do gradiente no espaço de pesos (isto é, busca uma direção para a mudança de peso que reduza o valor de $E(n)$). Utilizando a regra da cadeia do cálculo, obtém-se [12]

$$\Delta w_{ji}(n) = \eta \delta_j(n) \cdot y_i(n) \quad (2.42)$$

onde o gradiente local $\delta_j(n)$ é definido por [12]

$$\delta_j(n) = -\frac{\partial E(n)}{\partial v_j(n)} = -\frac{\partial E(n)}{\partial e_j(n)} \cdot \frac{\partial e_j(n)}{\partial y_j(n)} \cdot \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n) \cdot \varphi'_j(v_j(n)) \quad (2.43)$$

O gradiente local aponta para as modificações necessárias nos pesos sinápticos. De acordo com a equação (2.43), o gradiente local $\delta_j(n)$ para o neurônio de saída j é igual ao produto do sinal de erro $e_j(n)$ correspondente para aquele neurônio pela derivada $\varphi'_j(v_j(n))$ da função de ativação associada.

Além do treinamento supervisionado, onde a própria rede modifica suas conexões (sinapses) entre os elementos (neurônios) durante a fase de aprendizado, de modo que se crie uma relação entre entradas e saídas [12,73], existe também o treinamento não-supervisionado, onde a rede modifica e/ou cria padrões a partir das entradas.

2.4.7. – Aplicações de Redes Neurais Artificiais

As redes neurais são utilizadas nas mais diversas áreas, como simuladores, controle de processos, filtros contra ruídos eletrônicos, robótica, avaliação de crédito, análise e processamento de sinais, voz e imagens, e em inúmeras outras áreas. O reconhecimento óptico de caracteres (OCR) realizado por um *scanner* é um exemplo típico de aplicação das redes neurais. Grandes grupos de investimento utilizam redes neurais para analisar o mercado financeiro em suas seleções [74,75,76,77]. Na área de reconhecimento de padrões, as redes neurais vem sendo utilizadas no processamento e classificação dos mais variados tipos de sinais [78, 79, 80]. Os tipos mais utilizados são as redes “*backpropagation*”.

A extração das características do sinal representa uma etapa importante na sua classificação utilizando aproximadores de reconhecimento de padrão [78, 81]. Várias características tem sido propostas.

HAZARIKA [82] trabalhou com redes neurais artificiais para a classificação de eletroencefalogramas. As redes neurais foram utilizadas juntamente com a Transformada *Wavelet* Discreta, aplicada para a determinação de coeficientes *wavelet*, e utilizados para a extração das características dos eletroencefalogramas. Em seu estudo, HAZARIKA selecionou três diferentes tipos de eletroencefalograma, cada um obtido em pacientes diagnosticados como normais, com esquizofrenia e com desordem compulsiva obsessiva. A arquitetura da rede utilizada por HAZARIKA foi uma rede de múltipla camada alimentada adiante (*feedforward*) e treinada com algoritmo retro-propagação de erro (*backpropagation*). HAZARIKA reporta que obteve um índice de 66% e 71% de eletroencefalogramas corretamente classificados para as classes normal e com esquizofrenia, respectivamente.

A extração de parâmetros é mais comumente utilizada em outro tipo de sinal biomédico temporal, o eletrocardiograma (ECG). Inúmeros parâmetros são propostos para a caracterização de eletrocardiogramas, por exemplo, as ondas P, Q, R, S, etc. Esta medida reduz drasticamente a dimensão do conjunto de entrada a ser processado pela rede. STERNICKEL [83] trabalhou com redes neurais artificiais para o reconhecimento automático da onda P e do complexo QRS (essenciais para a detecção de anomalias cardíacas) em eletrocardiograma. Novamente, no trabalho de STERNICKEL, as características dos sinais foram extraídas pela aplicação da Transformada *Wavelet* Discreta. Assim, por meio do uso conjunto da Transformada *Wavelet* Discreta e de uma rede neural de múltipla camada treinada com algoritmo retro-propagação de erro, 99,9% e 92,0% das ondas P foram corretamente classificadas, quando pré-processadas pelas funções bases (*wavelet*) do tipo Coiflet 6 e Daubechies 12, respectivamente. O resultado encontrado por STERNICKEL demonstra também que os mesmos dependem da escolha correta da função base (*wavelet*) utilizada. STERNICKEL afirma que o melhor desempenho da função Coiflet 6 deve-se ao fato sua estrutura adapta-se melhor ao padrão da onda P. Em particular, sua pesquisa contribui para resolver problemas da detecção automática da onda P em eletrocardiogramas.

Deve-se chamar a atenção para o fato de que em sinais de ECG, cada uma destas ondas (P, Q, R, S) ocorrem em tempos distintos e tem duração bem diferentes e definidas. Conseqüentemente, cada uma delas possui componentes em freqüência diferentes. Isto as torna mais fáceis de separá-las no diagrama tempo-freqüência.

O reconhecimento e a classificação de padrões a partir de parâmetros extraídos de sinais, utilizando redes neurais, tem sido aplicados na caracterização de transdutores ultra-sônicos e também em sinais obtidos durante inspeções não-destrutivas realizadas por diferentes métodos (correntes parasitas [84], emissão acústica [85], ultra-som pulso-eco [9, 86]). Uma vez extraídas as características, um número reduzido de parâmetros conterà informações para a classificação do defeito.

SONG e SHIN [84] utilizaram redes neurais na caracterização e classificação de defeitos a partir de parâmetros extraídos de sinais de corrente parasitas simulados. Em

testes iniciais com dados simulados, o sistema apresentou uma precisão de 91% na determinação do tipo de defeito.

PHILIPPIDIS [85] utilizou redes neurais para a caracterização de danos presentes na interface matriz/matriz ou fibra/matriz (resultantes do processo térmico de fabricação) de compósitos carbono/carbono, a partir de parâmetros extraídos de sinais capturados durante inspeção de emissão acústica em compósitos carbono/carbono.

MASNATA e SUNSERI [9] utilizaram uma rede neural artificial multicamada treinada com algoritmo *backpropagation*, para o reconhecimento de padrão em parâmetros extraídos de defeitos distribuídos em três classes (trinca, inclusão de escória e porosidade). Foi alcançado um percentual médio de 99,7% de acerto. MASNATA e SUNSERI afirmam que a interação entre a onda sônica e o meio de propagação (contornos de grão e heterogeneidades do material) produz variação aleatória da onda ultra-sônica, e não são parâmetros significantes na classificação de defeito, mas reportam que o percentual de acerto caiu para 99,3% no caso de ruído presente.

O bom desempenho apresentado nos exemplos acima pelas redes neurais, demonstra o alto potencial para sua aplicação em sistemas automáticos de caracterização de defeitos.

Apesar de haver diversas aplicações de redes neurais no reconhecimento de padrões e classificação de sinais obtidos por diversas técnicas não-destrutivas na literatura técnica, como já apresentado acima, não chegou ao conhecimento do autor a existência de quaisquer trabalhos relacionados à utilização de redes neurais artificiais no reconhecimento de padrões e classificação de defeitos em sinais ultra-sônicos obtidos especificamente pela técnica TOFD.

2.5. – Considerações Finais

Foram apresentados na revisão teórica e bibliográfica os princípios físicos necessários ao entendimento de cada uma das técnicas utilizadas neste trabalho, bem como os resultados de trabalhos encontrados na literatura, onde cada uma das técnicas tem sido ou foram aplicadas. Pode-se então apresentar os materiais, equipamentos e metodologia utilizada neste trabalho.

O trabalho encontra justificativa na necessidade de automatizar todas as etapas da inspeção ultra-sônica por TOFD, e de maximizar o índice de acerto na identificação de defeitos através da utilização de ferramentas computacionais para pré-processamento de sinais e reconhecimento de padrões, tal como as redes neurais artificiais, que melhoram a confiabilidade da classificação de defeitos detectados por esta técnica.

3. – Materiais e Métodos

3.1. – Materiais

Inspeções com a técnica TOFD foram realizadas em doze corpos de prova, confeccionados em chapas de aço AISI 1020 com 20mm de espessura, 300mm de comprimento, chanfro em V com 50° de inclinação, distância de aproximadamente 2mm na raiz e soldados por processo eletrodo revestido (Figura 3.1). Diferentes tipos de defeitos, como falta de fusão (FF), falta de penetração (FP) e porosidades (PO) foram inseridos nos corpos de prova durante o processo de soldagem, gerando padrões de defeitos. A posição, o tipo e a dimensão de cada um dos defeitos inseridos são conhecidos através de ensaio ultra-sônico convencional e radiográfico.

Um sistema de inspeção composto por um veículo (Robô), responsável por transportar os transdutores ultra-sônicos e garantir o melhor contato possível entre os transdutores e a região a ser inspecionada, foi projetado munido de rodas magnéticas que lhe permite inspecionar dutos, chapas e estruturas ferromagnéticas em geral, em todas as posições, inclusive sobre-cabeça [87, 88].

Os transdutores são do tipo normal de onda longitudinal, marca KRAUTKRAMER, 0,25 pol/6 mm de diâmetro, modelo MSW/QC/PC, com frequência central de 5 MHz. Para a obtenção de ondas longitudinais nos ângulos desejados foram utilizados um par de sapatas para ondas longitudinais com ângulo de incidência de 60° no aço.

O aparelho de ultra-som convencional de fabricação KARL DEUTSCH, modelo ECHOGRAPH 1080 conectado a uma placa conversora A/D Gagescope CS - Lite, fabricada pela Gage Applied - Sciences.

O robô e o aparelho de ultra-som estão conectados a um microcomputador controlado por um programa desenvolvido pelo Laboratório de Ensaios não-Destrutivos - LABOEND, de nome comercial US-TOFD, que é responsável pelo controle da posição

do transdutores e armazenagem dos sinais A-scan, cada um contendo 512 pontos, capturados pelo aparelho de ultra-som, a uma taxa de amostragem de 100MHz, durante o deslocamento lateral do par de transdutores (a cada 1 mm) ao longo da solda, e que serão posteriormente utilizados na construção das imagens ultra-sônicas (D-scan).

Características das 12 juntas soldadas inspecionadas:

Juntas de topo em placas de aço

Metal de base: aço AISI 1020

Espessura: 20 mm.

Comprimento: 300 mm.

Processo de soldagem: Passe de raiz: Eletrodo Revestido

Enchimento: Eletrodo Revestido

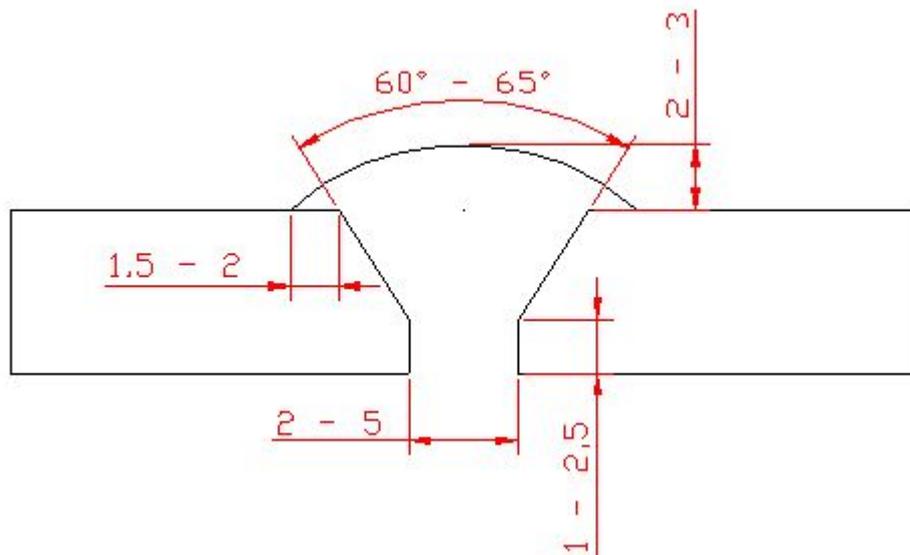


Figura 3.1 - Desenho esquemático da junta soldada (cotas em mm).

A figura 3.2 reúne, para efeito de comparação, imagens obtidas durante inspeções radiográfica e ultra-sônica por TOFD em uma mesma região de solda em aço. A imagem radiográfica digitalizada não sofreu qualquer processamento de imagem. Pode-se visualizar que os mesmos defeitos estão presentes em ambas as imagens.

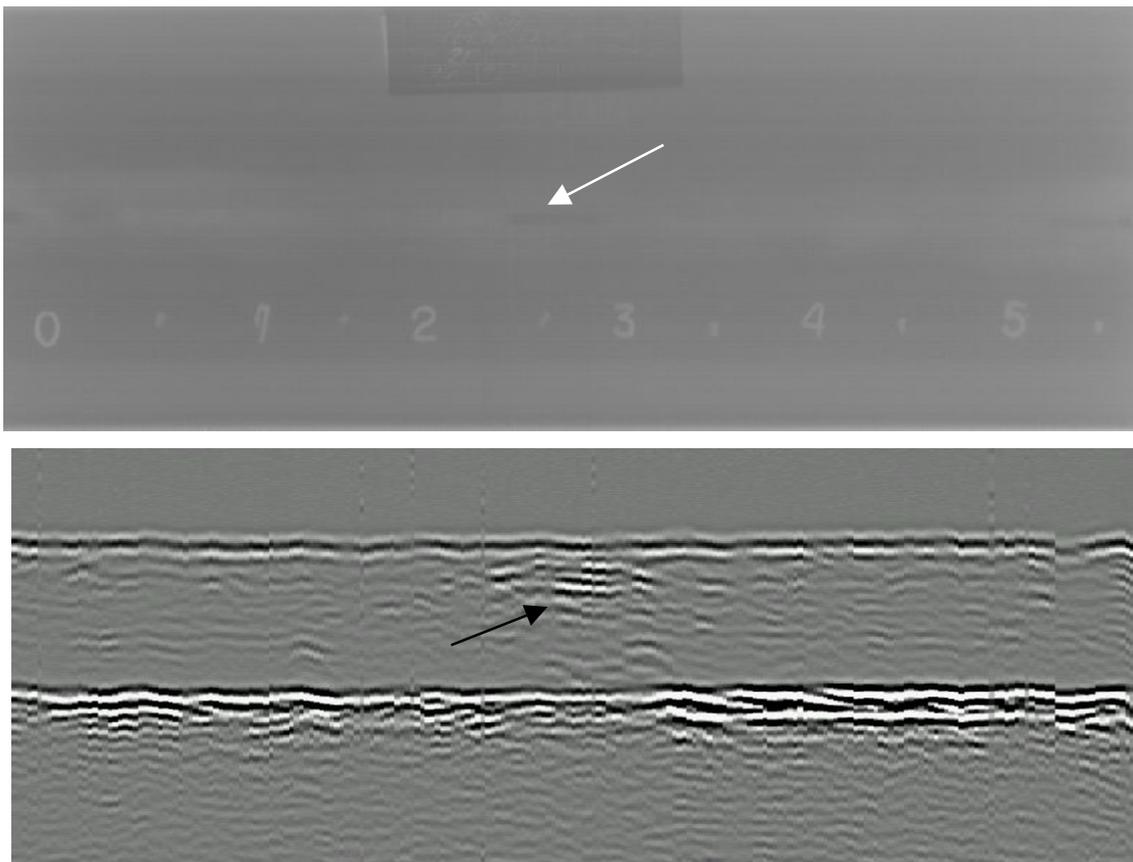


Figure 3.2 - Radiografia e D-scan obtido por TOFD de uma mesma região da solda.

3.2. – Seleção de Sinais

Através das imagens D-scan obtidas após a inspeção ultra-sônica por TOFD dos doze corpos de prova, e utilizando o resultado das radiografias como gabarito, um total de 240 sinais (A-scan), igualmente divididos entre cada uma das quatro classes - falta de fusão (FF), falta de penetração (FP), porosidade (PO) e uma classe de sinal que não apresenta defeitos (SD) - foram selecionados para os diferentes métodos de pré-processamento e classificação por redes neurais. Dos 60 sinais selecionados para cada classe, 40 foram utilizados durante a etapa de treinamento da rede e 20 sinais foram reservados para testar a capacidade do classificador em identificar sinais não apresentados durante o processo de treinamento.

Com o propósito de avaliar o desempenho dos classificadores, as entradas apresentadas à rede neural foram pré-processadas por diferentes métodos (Transformada de Fourier,

Transformada *Wavelet* e Filtro Savitzky-Golay). Neste trabalho, o Filtro Savitzky-Golay foi utilizado para obter a Envoltória dos Sinais ultra-sônicos retificados.

Em consequência do número de pontos dos A-scans (512 pontos) e das características de cada pré-processamento, o espectro de frequência proveniente da Transformada de Fourier, e que será utilizado como a entrada da rede neural, é representada por um vetor \bar{x} de dimensão 256 (um sinal com 256 pontos), ou geometricamente, por um ponto no espaço de dimensão 256, chamado espaço de entrada. No caso da Transformada *Wavelet* e do cálculo da envoltória do sinal retificado, resultado da aplicação do Filtro Savitzky-Golay, o vetor \bar{x} tem dimensão 512.

A escolha de uma função *wavelet* adequada é importante para a qualidade dos resultados do processamento [40, 51]. A fim de escolher qual função *wavelet* seria utilizada durante o pré-processamento, testes iniciais foram realizados com diversas destas funções. A função *wavelet* que apresentou os melhores resultados foi a gaussiana complexa de quarta ordem “cgau4”. Este resultado está coerente com os encontrados por ABBATE e ZHANG [40,52]. Eles reportam que, no processamento de sinais ultra-sônicos banda larga, a família de funções *wavelet* gaussiana é a de melhor desempenho [40,52].

As figuras 3.3, 3.4, 3.5 e 3.6 são exemplos típicos de sinais A-scan capturados nos corpos de prova inspecionados neste trabalho e utilizados como dados de entrada dos classificadores de padrão estudados. Além dos sinais A-scan originais (canto superior esquerdo), as figuras apresentam o resultado dos diferentes pré-processamentos aplicados: espectro de frequência (canto inferior esquerdo), coeficientes *wavelet* na escala de maior energia (canto inferior direito) da Transformada *Wavelet* Contínua (canto superior direito) e Cálculo da Envoltória do sinal Retificado (centro esquerdo).

Pode-se perceber na figura 3.3 (um sinal A-scan típico de uma falta de fusão) a presença das ondas difratadas pelas pontas superior e inferior do defeito entre a onda lateral e o eco de fundo. No caso da falta de penetração, figura 3.4, percebe-se o surgimento do eco refletido pela ponta da falta de penetração e a queda de amplitude do eco de fundo

resultado da perda de energia sônica causada pela difração na ponta da falta de penetração. Na figura 3.5 vê-se o surgimento do eco difratado por uma porosidade. O sinal obtido em regiões da solda sem defeito, figura 3.6, é o mais simples entre as classes, contendo apenas os sinais de referência (onda lateral ou superficial e eco de fundo). É a partir destas características que os classificadores podem fazer o reconhecimento de padrão de cada classe.

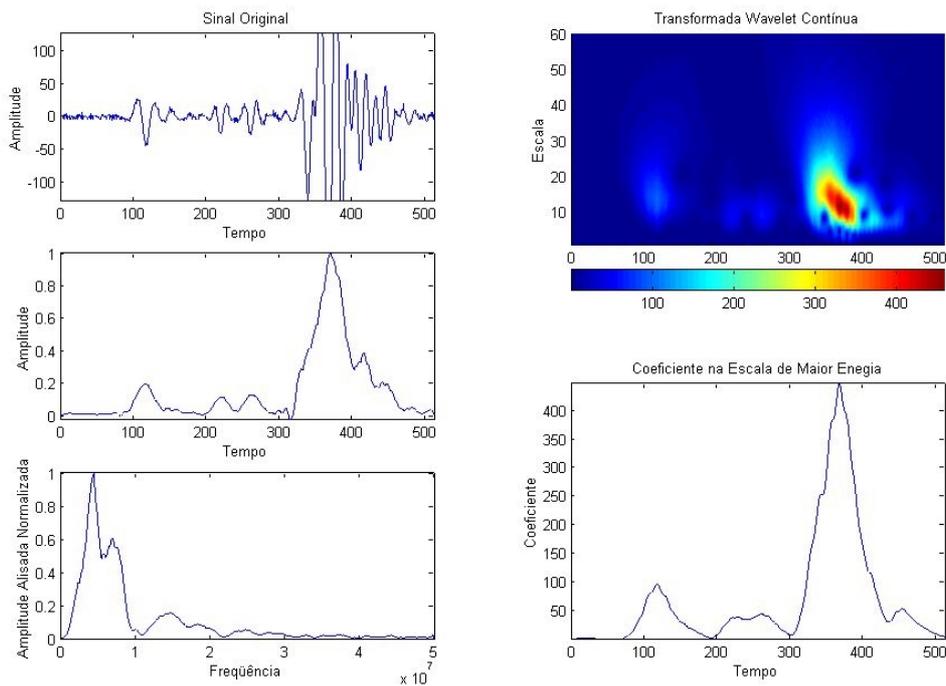


Figura 3.3 - Sinal ultra-sônico A-scan original (canto superior esquerdo) capturado em uma região da solda contendo um defeito do tipo falta de fusão, mostrando o surgimento das ondas difratadas nas pontas superior e inferior do defeito entre a onda lateral e o eco de fundo; e os diferentes tipos de pré-processamento: Espectro de Frequência do sinal original (canto inferior esquerdo), Transformada Wavelet Contínua (canto superior direito), Coeficientes Wavelet na escala de maior energia (canto inferior direito), Envoltória do Sinal Retificado (centro esquerdo).

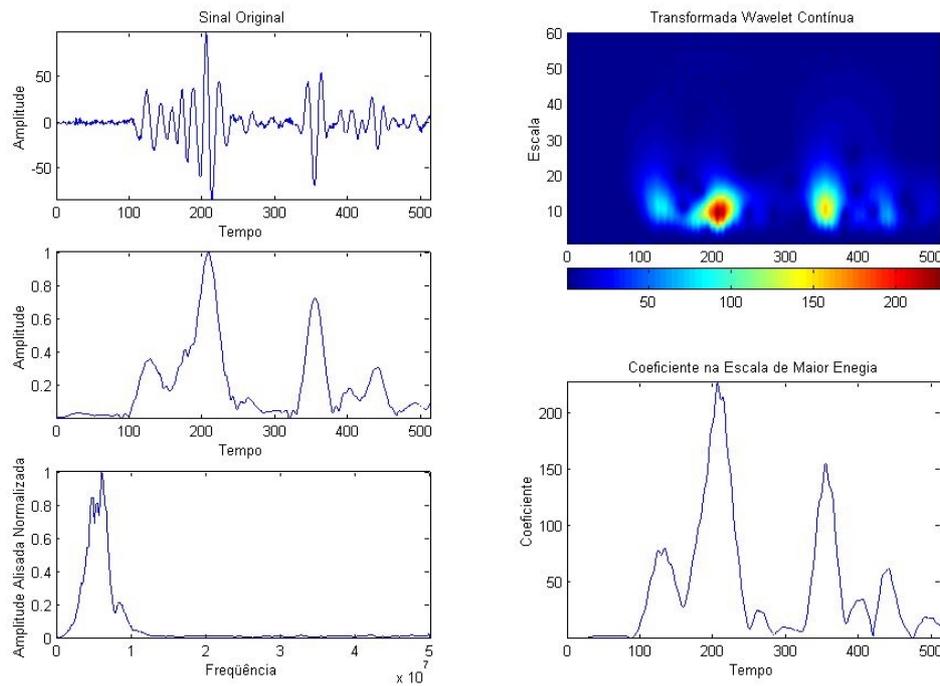


Figura 3.4 - Sinal ultra-sônico A-scan original (canto superior esquerdo) capturado em uma região da solda contendo um defeito do tipo falta de penetração, e os diferentes pré-processamentos aplicados: Espectro de Frequência do sinal original (canto inferior esquerdo), Transformada Wavelet Contínua (canto superior direito), Coeficientes Wavelet na escala de maior energia (canto inferior direito), Envoltória do Sinal Retificado (centro esquerdo).

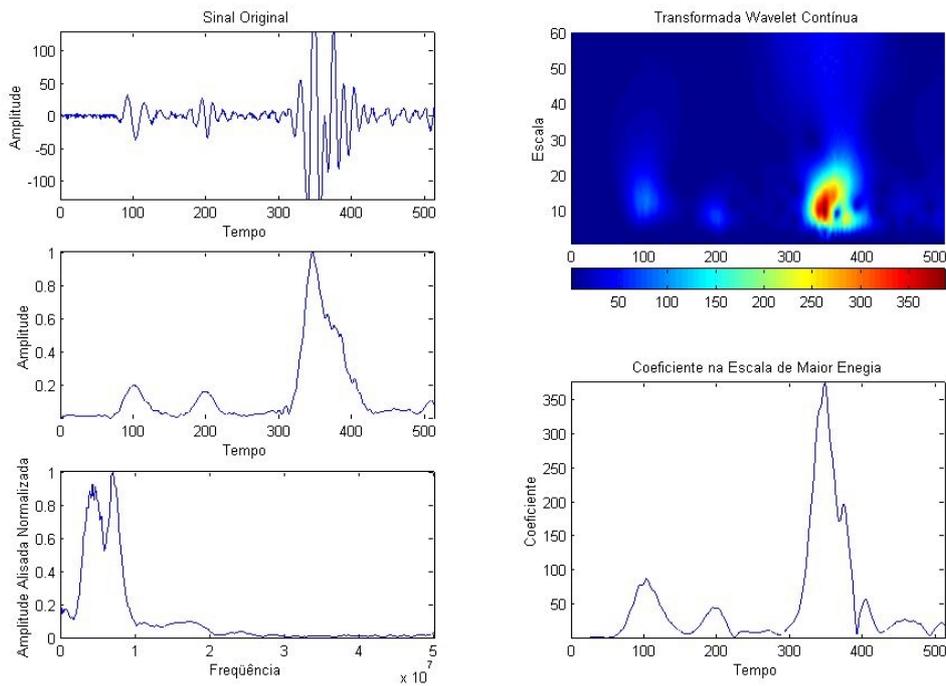


Figura 3.5 - Sinal ultra-sônico A-scan original (canto superior esquerdo) capturado em uma região da solda contendo um defeito do tipo porosidade e os diferentes pré-processamentos aplicados: Espectro de Freqüência do sinal original (canto inferior esquerdo), Transformada Wavelet Contínua (canto superior direito), Coeficientes Wavelet na escala de maior energia (canto inferior direito), Envoltória do Sinal Retificado (centro esquerdo).

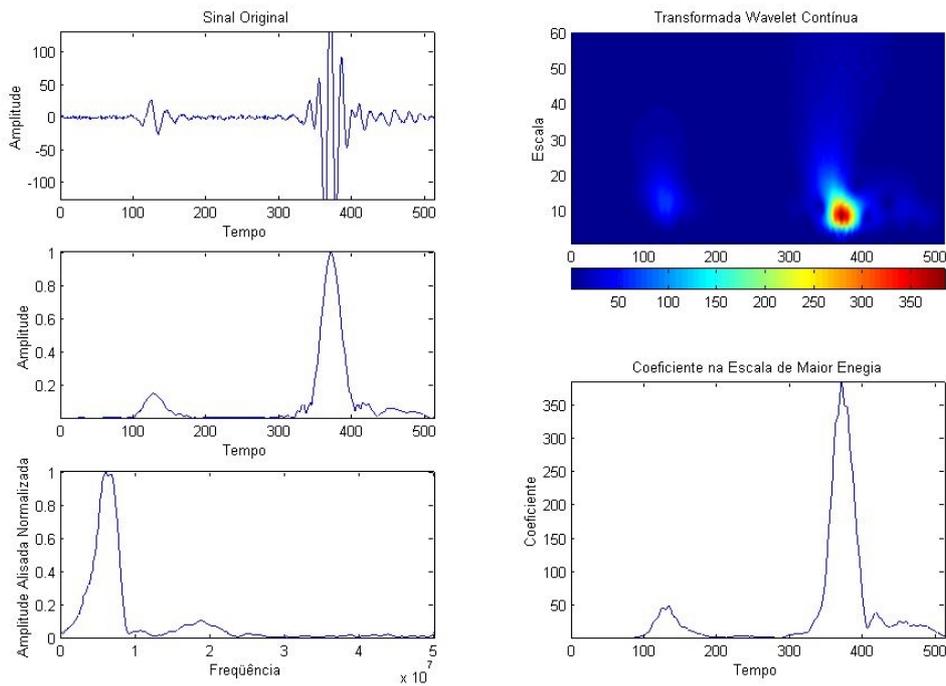


Figura 3.6 - Sinal ultra-sônico A-scan original (canto superior esquerdo) capturado em uma região da solda sem defeito, e os diferentes pré-processamentos aplicados: Espectro de Frequência do sinal original (canto inferior esquerdo), Transformada Wavelet Contínua (canto superior direito), Coeficientes Wavelet na escala de maior energia (canto inferior direito), Envoltória do Sinal Retificado (centro esquerdo).

3.3. – Discriminadores Lineares Não-Hierárquicos e Hierárquicos

Os discriminadores lineares, apresentados na revisão bibliográfica sobre redes neurais (item 2.4), foram utilizados na construção dos separadores das quatro classes de sinais A-scan obtidos pela técnica TOFD. Cada classe C_j tem seu próprio discriminador, definido por \vec{w}_j e b_j , e que separa a entrada desta classe das demais, através de uma inequação de primeira ordem, apresentada pelas seguintes equações:

$$\vec{x} \in C_j \Leftrightarrow u_j > 0 \quad (3.1)$$

onde

$$u_j = \sum_{i=1}^{512} w_{ji} x_i + b_j = \vec{w}_j^t \vec{x} + b_j \quad (3.2)$$

No domínio da entrada o separador da classe C_j , isto é, o lugar geométrico dos pontos que satisfazem $u_j = 0$, é um plano perpendicular ao vetor \vec{w}_j e distante da origem $\frac{-b_j}{|\vec{w}_j|}$, distância tomada no sentido de \vec{w}_j . Usualmente normaliza-se $|\vec{w}_j| = 1$, ajustando-se o valor de b_j de modo a não alterar a inequação (3.1). Neste caso, u_j mede a distância da entrada \vec{x} ao separador, e normalmente é uma medida da probabilidade de acerto da classificação para aquela entrada específica [12, 81]. Os discriminadores lineares ótimos são aqueles que maximizam a probabilidade de acerto da classificação.

A visualização geométrica dos separadores em nosso caso é impossível devido à dimensão do espaço de entrada (512), mas em um espaço de dimensão 2, pode ser facilmente realizada. Considere a figura 3.7, onde o sombreado mostra o domínio das entradas de classes hipotéticas C_j e seus respectivos planos separadores S_j (que neste caso são representados por retas). Cada separador S_j divide o espaço de entrada em dois semi-espacos (neste caso dois semiplanos), um onde $u_j > 0$ e outro onde $u_j < 0$. Entradas que pertencem a classe C_j e que são corretamente classificadas são representadas por

pontos no semiplano onde u_j é positivo. Note que existem regiões que se situam no semi-espço positivo de dois ou mais separadores: uma entrada nesta região será alocada em duas ou mais classes. Por outro lado, podem existir regiões que situam-se no semi-espço negativo de todos os separadores: uma entrada nesta região não será alocada em nenhuma classe. Nesta situação, pode-se usar o fato de que u_j é a medida da probabilidade de uma entrada pertencer à classe C_j e “desempatar” o resultado, tomando a classe com o maior u_j , a mais provável de conter a entrada, como sendo a resposta.

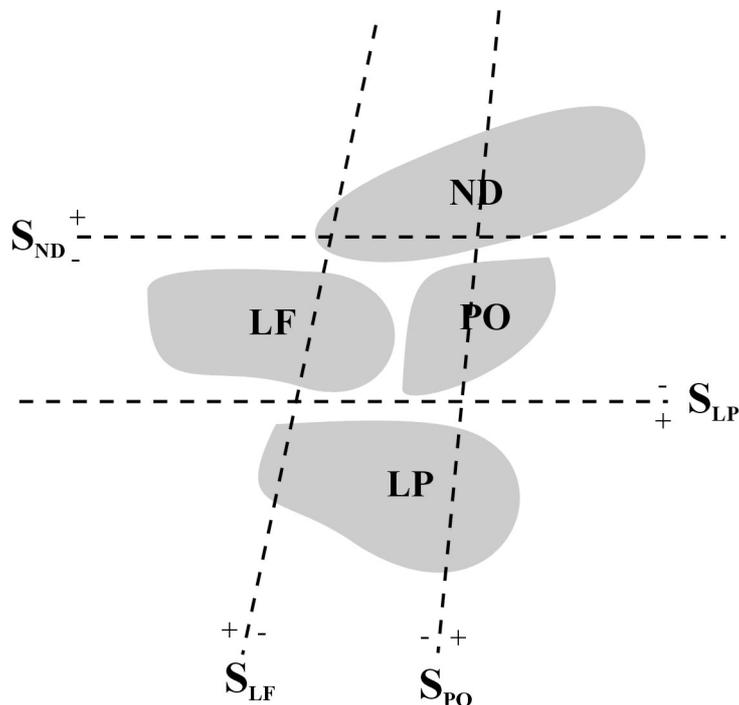


Figura 3.7 - As quatro classes C_j , $j = LP, ND, PO$ e LF e seus respectivos separadores não-hierárquicos S_j com as polaridades indicadas. As classes mais externas LP e ND são quase perfeitamente separadas e as mais internas PO e LF , imperfeitamente separadas.

Note-se também claramente que as classes mais “externas” são separáveis mais facilmente, enquanto que as “internas” são dificilmente separáveis (Figura 3.7). Mas, se estas classes “externas” forem removidas, outras classes anteriormente “internas” tornam-se “externas”, e podem agora ser facilmente separáveis (Figura 3.8). Isto conduz ao conceito de classificação hierárquica, onde inicialmente são classificadas as classes “externas”, ou seja, aquelas com alto grau de acerto, e somente após as “internas” [89].

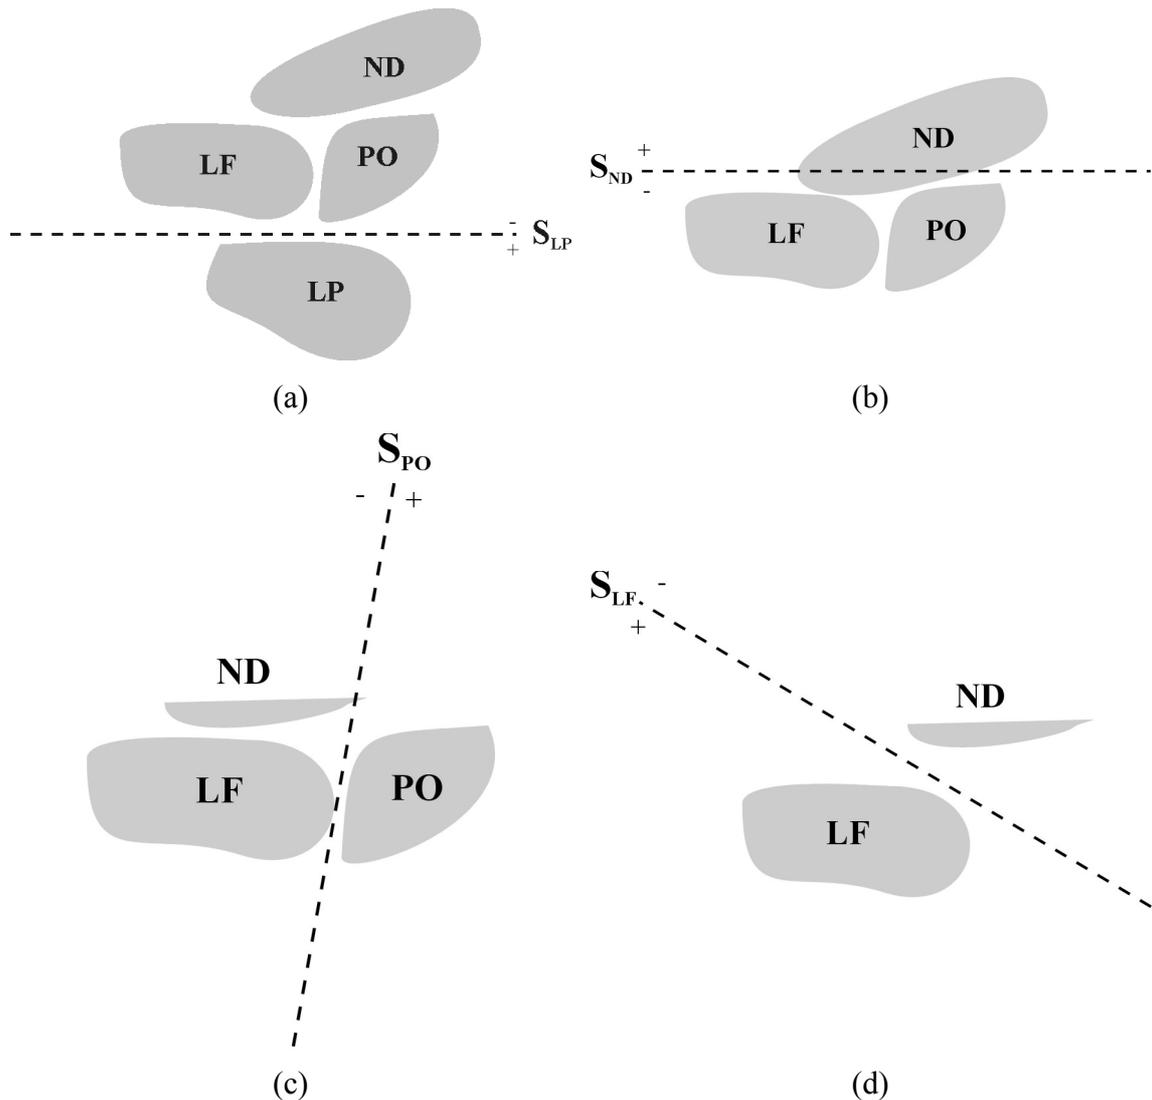


Figura 3.8 - (a) e (b): Após a exclusão das entradas classificadas como LP e ND, os demais discriminadores podem assumir posições muito mais eficazes na separação das classes restantes, principalmente S_{PO} , (c), e o mesmo ocorre após a exclusão das entradas classificadas como LF (d).

Como pode ser notado através da figura 3.8b, existe uma pequena região da classe ND que não é corretamente discriminada pelo separador S_{ND} , situando-se no semi-espaço negativo. Neste caso, este conjunto de sinais referentes à classe ND que não é retirado do sistema, e o discriminador da classe PO é encontrado não somente para separar PO de LF, como também deste conjunto de sinais pertencentes à classe ND (Figura 3.8c).

É importante ressaltar que estas figuras são ilustrações simplificadas do método de obtenção dos discriminadores não-hierárquicos e hierárquicos, servindo apenas para mostrar o princípio de funcionamento destes discriminadores, não representando

fielmente a condição encontrada para os sinais utilizados neste trabalho. Para mostrar, ao menos parcialmente, a condição real para os sinais utilizados, seria necessário abordar os conceitos de Componentes Principais de Discriminação (CPD) [12], e se fugiria ao objetivo proposto: avaliar os índices de acerto e erro destes tipos de discriminadores/classificadores para as classes estudadas.

3.4. – Classificadores Lineares Não-Hierárquicos e Hierárquicos

Neste trabalho, um discriminador deve ser determinado para classificar cada uma das classes. Isso é obtido através de uma rede neural com um neurônio de saída para cada classe, ou seja, foi utilizado neste trabalho um total de quatro neurônios na camada de saída, independente da presença ou não de camada oculta. Esses discriminadores ótimos são determinados pelo ajuste dos pesos sinápticos durante o treinamento, baseado num padrão de saída, por um algoritmo de treinamento *backpropagation*. Um exemplo de padrão de saída utilizado durante o treinamento da rede supervisionada é apresentado na figura 3.9 mostrando o primeiro neurônio como vencedor.

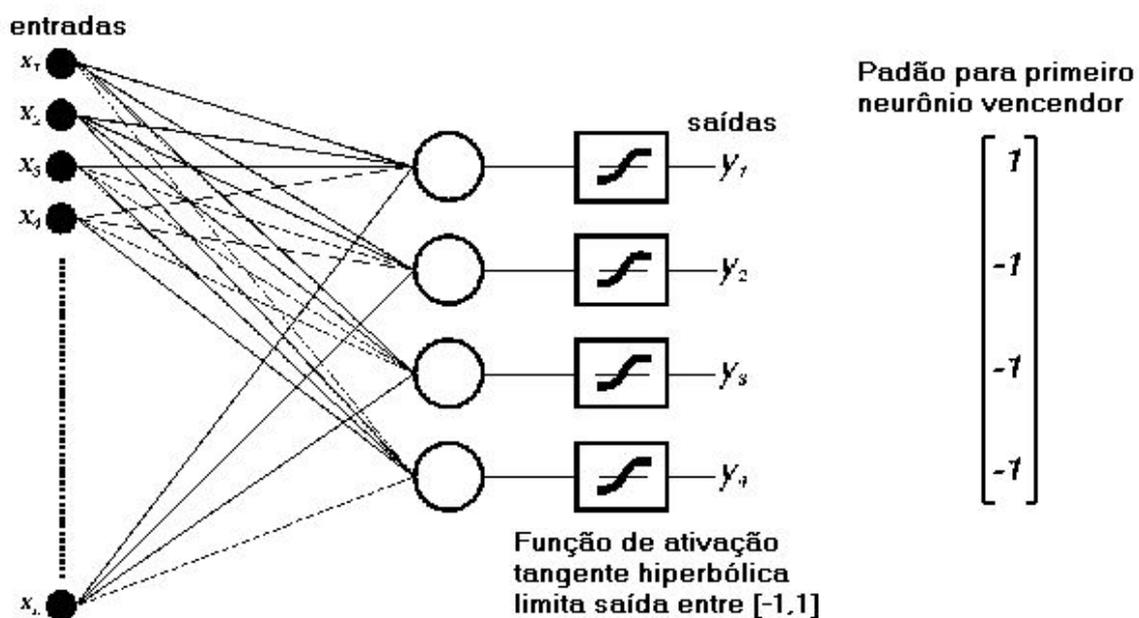


Figura 3.9 - Rede neural utilizada como classificador linear, mostrando padrão de saída para o primeiro neurônio vencedor. A rede como classificador pode ser adaptada tanto para o processo não-hierárquico como ao hierárquico.

Os algoritmos dos classificadores são construídos após a obtenção dos discriminadores de cada classe. O fluxograma do classificador não-hierárquico é mostrado na figura 3.10. Os vetores entrada são multiplicados pelos vetores \vec{w}_j de cada classe e somado ao bias b_j correspondente, gerando u_j . O resultado desta operação que for maior que zero corresponde à classe selecionada. Nesta situação, tem-se a possibilidade de nenhuma classe ser indicada (quando todas as saídas forem negativas), ou ocorrer mais de uma indicação (mais de uma saída ser maior que zero). Neste caso, pode-se usar um critério de reclassificação ou “desempate”, no qual o maior valor de u_j indica a classe. Para ambos os casos (sem reclassificação e com reclassificação), construíram-se as tabelas de confusão de defeito, acertos e erros com base nos resultados obtidos.

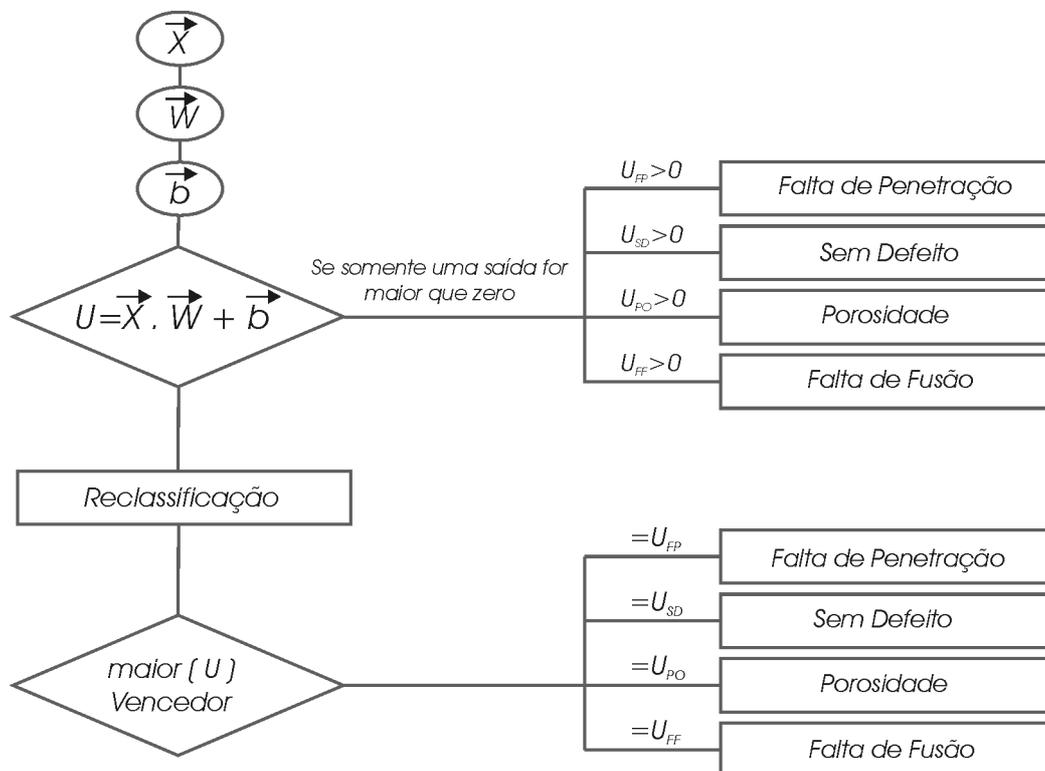


Figura 3.10 - Algoritmo do Classificador Linear não-Hierárquico.

Ao contrário do classificador não-hierárquico, o classificador hierárquico funciona classificando primeiro as classes mais facilmente separáveis. O algoritmo deste classificador é mostrado na figura 3.11 [89]. Verificou-se o desempenho de forma similar ao não-hierárquico. Os algoritmos do classificador não-hierárquico e hierárquico

são comparados na seção 4 – APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS, em termos de percentual de acerto.

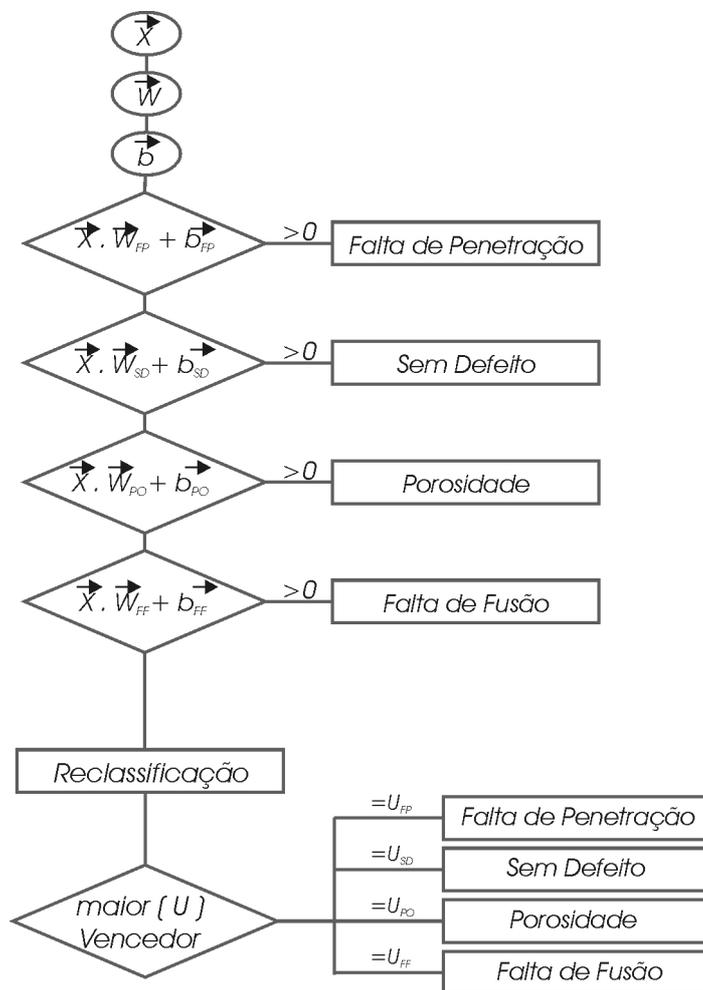


Figura 3.11 - Algoritmo do Classificador Linear Hierárquico.

3.5. – Classificadores Não-Lineares

Adicionando-se uma ou mais camadas ocultas, a rede torna-se capaz de aprender tarefas complexas e de extrair estatísticas de ordem elevada [12]. Os classificadores obtidos a partir de uma rede neural de múltiplas camadas, podem separar padrões não-linearmente separáveis. Vários trabalhos [68, 69, 70, 71, 72] demonstram que uma rede neural de múltiplas camadas alimentada adiante (*Feed Forward*), com uma única camada de neurônios ocultos, utilizando funções de ativação do tipo sigmoide, é suficiente e capaz de aproximar qualquer função não-linear contínua.

Para este tipo de classificadores (não-lineares), a arquitetura da rede neural artificial utilizada foi do tipo múltipla camada, com uma única camada oculta, totalmente conectada, com alimentação adiante (*Feed-Forward*) treinada com algoritmo de retro-propagação de erro (*backpropagation*) (Figura 3.12).

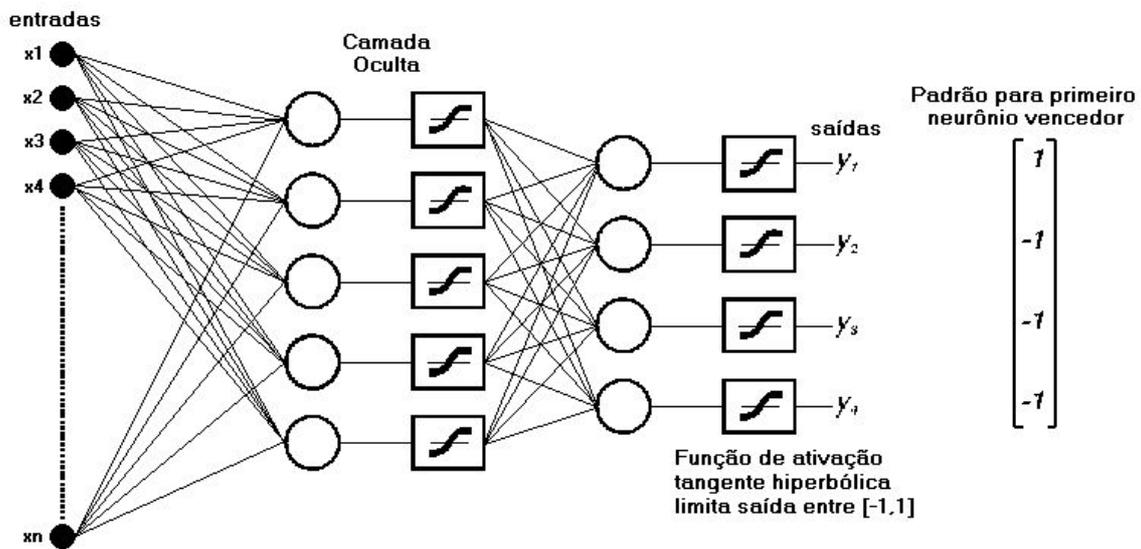


Figura 3.12 - Rede neural utilizada como classificador não-linear, mostrando padrão de saída também para o primeiro neurônio vencedor.

4. – Apresentação e Discussão dos Resultados

4.1. – Introdução

Os resultados deste trabalho estão separados quanto: à aplicação ou não de pré-processamento nos sinais A-scan (Sinal Original sem pré-processamento, Amplitudes do Espectro de Frequência, Coeficientes *Wavelet*, Envoltória do Sinal Retificado); à finalidade dos sinais (Dados de Treinamento ou Teste); a presença ou não de critério de desempate (Sem ou Com Reclassificação); presença ou não de hierarquia na separação das classes (Sem ou Com Hierarquia); e quanto a linearidade do discriminador (Linear ou não-linear).

Os primeiros resultados apresentados são os obtidos pelos classificadores lineares utilizando tanto algoritmos de separação não-hierárquica quanto hierárquica, no reconhecimento de padrão em dados de treinamento e teste, sem e com reclassificação nos sinais originais. Em seguida, utilizando este mesmo padrão de apresentação dos resultados alcançados a partir dos sinais originais, são apresentados os resultados obtidos com sinais originais pré-processados de modo a possibilitar uma avaliação do desempenho dos classificadores na separação de classes, em função dos diferentes métodos de pré-processamento e das diferentes características dos classificadores.

Ressalta-se que os dados de teste servem para avaliar o desempenho do classificador para dados que não foram utilizados durante o treinamento, garantindo a generalização. A ordem de separação das classes (hierarquia) foi escolhida baseada no resultado do treinamento do processo não-hierárquico. A primeira classe é a que apresenta a melhor taxa de acerto na identificação e a última classe é a que apresenta a pior taxa.

4.2. – Classificadores Lineares

4.2.1. – Sinais Originais (Nenhum Pré-Processamento)

Inicialmente, serão apresentados os resultados obtidos com os dados de treinamento e de teste pelo *classificador linear não-hierárquico*. Neste tipo de classificador, cada classe deve ser discriminada de todas as demais, independentemente de ser ou não linearmente separável. As tabelas 1 e 2 são resultados obtidos com os dados de treinamento, enquanto as tabelas 3 e 4 são resultados obtidos com os dados de teste.

A primeira coluna de todas as tabelas de “confusão, acertos e erros”, traz os sinais A-scan divididos nas classes a que pertencem. Como se tem um neurônio por classe, as quatro colunas seguintes indicam a porcentagem dos sinais de cada classe que foi classificada por cada um dos neurônios. Assim, na intercessão entre a linha de uma dada classe com a coluna de um neurônio da mesma classe (células hachuradas), tem-se o percentual de sinais pertencentes a uma classe que foi corretamente classificada pelo neurônio responsável por separar aquela classe. O percentual de sinais não classificados por nenhum dos neurônios é apresentado na coluna “nenhuma”. Um mesmo sinal, que tenha sido classificado por mais de um neurônio, aparece na coluna denominada “mais de uma”. Nas tabelas de confusão, acertos e erros que apresentam resultados com reclassificação, estas duas últimas colunas (Nenhuma e Mais de uma) não existem, pois o sinal é obrigado a pertencer a uma classe. As colunas seguintes (“Acerto”, “Erros” e “Sem Classificação”) resumem os resultados apresentados nas primeiras colunas. Assim como as colunas “Nenhuma” e “Mais de Uma”, durante a reclassificação, os sinais “Sem Classificação” são obrigados a pertencer a alguma classe, e por isso não aparecem nas tabelas de resultado com reclassificação.

Pode ser observado pelas tabelas 2 e 4, que o resultado geral para os dados de treinamento (85%) é superior ao resultado geral para os dados de teste (71,25%). Isso é justificado porque é mais fácil classificar um sinal que foi fornecido à rede durante o processo de treinamento. A tabela 1 mostra os resultados encontrados para o classificador linear não-hierárquico sem critério de desempate na saída. A tabela 1

também apresenta os valores percentuais para quando nenhuma classe foi identificada ou houve mais de uma classe ativada. Pela tabela 1, observa-se que o defeito falta de penetração (FP) é o de melhor desempenho (95%), indicando ser esta classe mais facilmente separável das demais. Este resultado deve-se ao fato de que a posição do pico de fundo é sensivelmente modificada por este tipo de defeito. O resultado encontrado para a classe sem defeito foi o segundo melhor (87,5%), seguido do defeito porosidade (82,5%). O pior desempenho obtido foi para a classe falta de fusão (75%). Esta constatação condiz com o fato de que a classe FF é caracterizada por dois picos, que podem não estar muito evidentes no sinal, sendo portanto de classificação mais difícil. Poderia-se supor que a classe de sinais sem defeitos fosse a mais facilmente separável, uma vez que é o mais simples dos sinais, no entanto, pôde-se verificar que isso não ocorreu. O que pode ter sido uma consequência do ruído presente nos sinais, que provavelmente tenha sido confundido com defeito.

Na tabela 2, são mostrados os percentuais de desempenho do classificador com o critério de desempate baseado no maior valor de saída dos sinais não classificados ou classificados mais de uma vez. Embora fosse esperado um melhor desempenho para esse processo, essa melhoria não foi comprovada para os sinais de treinamento, e estes foram reclassificados erroneamente, obtendo-se na tabela 2 os mesmos resultados obtidos na tabela 1. No entanto, mais adiante, será interessante observar que a melhoria é obtida para os dados de teste (tabelas 3 e 4).

A partir da tabela 1, também pode-se observar que durante o processo mais conservador (sem critério de desempate na saída) não houve confusão entre classes, ou seja, nenhum dos neurônios confundiu sinais de uma classe com a sua. No entanto, durante a reclassificação (tabela 2) o sinal é forçado a pertencer a uma classe. Uma hipótese para tentar explicar a confusão entre classes durante a reclassificação é apresentada a seguir.

A figura 4.1 é um bom exemplo de sinal A-scan capturado e apresentado à rede como de uma região da solda dita sem defeito. Entretanto, a seta sobre a figura está indicando a presença do que pode ser um defeito ou uma região do sinal com alto nível de ruído.

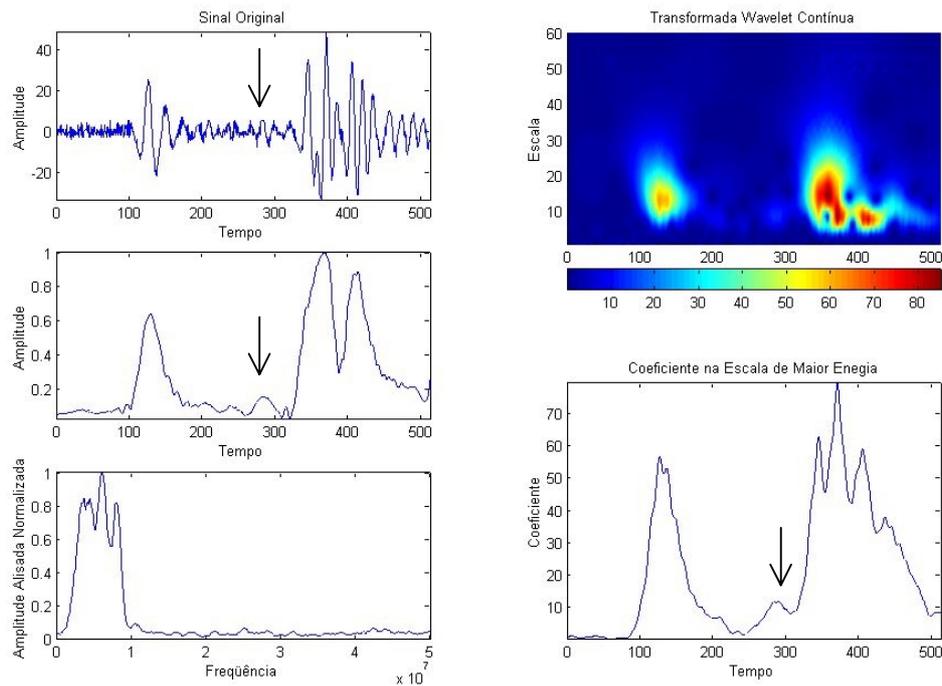


Figura 4.1 - Sinal ultra-sônico A-scan original bastante ruidoso (canto superior esquerdo) capturado em uma região da solda dita sem defeito; e os diferentes tipos de pré-processamento: Espectro de Freqüência do sinal original (canto inferior esquerdo), Transformada Wavelet Contínua (canto superior direito), Coeficientes Wavelet na escala de maior energia (canto inferior direito), Envoltória do Sinal Retificado (centro esquerdo).

É possível que estes sinais realmente pertençam às classes reclassificadas pela rede, e o erro tenha ocorrido durante a classificação realizada pelo operador. Além desta hipótese, este erro também pode está relacionado à baixa relação sinal/ruído, picos característicos da classe pouco destacados, ou mesmo à posição relativa entre as diferentes classes, etc. Esse questionamento motiva ainda mais a realização deste trabalho, mostrando que isso pode ocorrer no processo convencional de inspeção, devido a dificuldade de classificação de defeitos obtidos pela técnica TOFD.

A tabela 1 também resume o desempenho destes classificadores em termos de percentual global de observações corretamente classificadas, erros e saídas sem classificação (todas as saídas de rede negativas ou mais de uma positiva). Primeiro para o caso sem critério de desempate na saída e posteriormente com classificação pelo maior valor (tabela 2). Desta forma foi possível chegar ao desempenho geral deste tipo

de algoritmo de classificação. O percentual encontrado foi de 85% de acerto, um resultado razoável considerando que foi utilizado um classificador linear.

As tabelas 3 e 4 apresentam os resultados para os dados de teste, mostrando, como mencionado anteriormente, que o desempenho deste (71,25%) é inferior aos resultados de treinamento (85%). No entanto, pode-se perceber uma coerência com os resultados de treinamento, sendo a classe FP mais facilmente separável (90%) e a classe FF mais dificilmente separável (55%).

Pôde-se também notar pelas tabelas 3 e 4 que ocorreu uma melhoria com a reclassificação para os dados de teste (total de acerto de 63,75% sem reclassificação contra 71,25% com reclassificação), embora o processo de reclassificação não tenha melhorado o desempenho dos classificadores para os sinais de treinamento.

Tabela 1 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Não-Hierárquico

Sinais Originais – Dados de Treinamento – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais de Uma	Acertos	Erros	Sem classif.
	FF	FP	PO	SD					
FF	75	0	0	0	25	0	75	0	25
FP	0	95	0	0	5	0	95	0	5
PO	0	0	82,5	0	17,5	0	82,5	0	17,5
SD	0	0	0	87,5	12,5	0	87,5	0	12,5
Total							85	0	15

Tabela 2 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Não-Hierárquico

Sinais Originais – Dados de Treinamento – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	75	10	2,5	12,5	75	25
FP	0	95	2,5	2,5	95	5
PO	2,5	5	82,5	10	82,5	17,5
SD	0	5	7,5	87,5	87,5	12,5
Total					85	15

Tabela 3 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Não-Hierárquico

Sinais Originais – Dados de Teste – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais de Uma	Acertos	Erros	Sem classif.
	FF	FP	PO	SD					
FF	55	0	0	0	35	10	55	10	35
FP	0	80	0	0	10	10	80	10	10
PO	5	0	65	5	25	0	65	10	25
SD	0	0	5	55	30	10	55	15	30
Total							63,75	11,25	25

Tabela 4 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Não-Hierárquico

Sinais Originais – Dados de Teste – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	55	15	25	5	55	45
FP	5	90	0	5	90	10
PO	10	0	70	20	70	30
SD	0	10	20	70	70	30
Total					71,25	28,75

Após a separação não-hierárquica, uma ordem de separação das classes (hierarquia de separação) foi escolhida com base nos resultados do treinamento do processo não-hierárquico (tabela 1 e 2). Iniciando-se com a classe que apresentou melhor índice de acerto até a classe que apresentou o pior índice.

A tabela 5 apresenta os primeiros resultados encontrados para o classificador hierárquico. O desempenho deste classificador mostrou-se melhor que a do classificador não-hierárquico (tabela 1), mesmo no critério mais exigente (classificação apenas quando somente uma saída for maior do que zero, ou seja, sem reclassificação). Os índices de 100% de acerto para FF e PO comprovam serem as duas classes linearmente discrimináveis das demais. Outra observação importante em relação ao índice de 100% de acerto para as classes FF e PO é que estas superaram até mesmo às classes SD e FP, mais facilmente separáveis no processo não-hierárquico. Isso pode ser explicado em teoria pelo fato de que com a retirada das classes mais externas, a classificação das classes mais internas torna-se mais fácil (figura 3.8). Durante a etapa de reclassificação, os sinais de treinamento foram erroneamente reclassificados e os resultados conseguidos com critério de desempate na saída da rede, mostrados na tabela 6, são os mesmos que no caso anterior, tabela 5, não havendo aumento do percentual de acerto, mas, novamente, houve uma pequena melhoria no índice global de acerto no processo de reclassificação dos sinais de teste. Isso pode ser observado quando se compara as tabelas 7 e 8.

Comparando o classificador não-hierárquico (tabelas 1 a 4) com o hierárquico (tabelas 5 a 8), fica evidente que os resultados deste último são melhores, principalmente em relação às classes FF e PO. As tabelas 5 e 6 representam os resultados gerais deste tipo de classificador para os dados de treinamento. O índice de 96,25% de acerto da tabela 6 é consideravelmente maior do que os 85% da tabela 2, aumentando também dos 71,25% da tabela 4 para 78,75% da tabela 8 para os dados de teste. Este resultado pode ser considerado bastante bom considerando que foi utilizado um critério de discriminação linear para classificação dos defeitos.

Tabela 5 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Sinais Originais – Dados de Treinamento – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais de Uma	Acertos	Erros	Sem classif.
	FF	FP	PO	SD					
FF	100	0	0	0	0	0	100	0	0
FP	0	95	0	0	5	0	95	0	5
PO	0	0	100	0	0	0	100	0	0
SD	0	0	0	90	10	0	90	0	10
Total							96,25	0	3,75

Tabela 6 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Sinais Originais – Dados de Treinamento – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	100	0	0	0	100	0
FP	0	95	2,5	2,5	95	5
PO	0	0	100	0	100	0
SD	5	2,5	2,5	90	90	10
Total					96,25	3,75

Tabela 7 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Sinais Originais – Dados de Teste – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais de Uma	Acertos	Erros	Sem classif.
	FF	FP	PO	SD					
FF	75	0	20	5	0	0	75	25	0
FP	10	90	0	0	0	0	90	10	0
PO	5	5	80	5	5	0	80	15	5
SD	0	5	20	65	10	0	65	25	10
Total							77,5	18,75	3,75

Tabela 8 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Sinais Originais – Dados de Teste – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	75	0	20	5	75	25
FP	10	90	0	0	90	10
PO	5	5	85	5	85	15
SD	0	5	30	65	65	35
Total					78,75	21,25

Analisando os erros ocorridos durante a reclassificação mostrados nas tabelas 2, 4, 6 e 8, pode-se verificar que nenhuma das classes estudadas foi sistematicamente confundida com outra classe.

Tabela 9 - Resumo dos resultados obtidos por Classificador Linear no reconhecimento de padrão em Sinais Originais.

	Não-Hierárquico		Hierárquico	
	Treinamento	Teste	Treinamento	Teste
Nº de Sinais	160 Sinais	80 Sinais	160 Sinais	80 Sinais
Acertos	85%	71,3%	96,25%	78,75%
Reclassificados	0%	7,5%	0%	1,25%
Erros	15%	28,75%	3,75%	21,25%

Como já explicado anteriormente, para a obtenção dos resultados apresentados até aqui, os sinais processados pelo classificador durante o treinamento e teste foram os sinais originais de inspeção, ou seja, com nenhum tipo de pré-processamento, como por exemplo, filtros passa-baixa, ou outras técnicas de remoção de ruído, etc.

O percentual global de observações corretamente classificadas, apresentados em todas as tabelas de resumo deste trabalho (tabelas 9, 23 e 32), e utilizado para avaliar o desempenho dos classificadores, foi calculado já considerando os acertos obtidos com a reclassificação. As tabelas de resumo também apresentam o percentual de erros e o percentual de acerto reclassificado separadamente.

4.2.2. – Sinais Pré-Processados (Transf. Fourier e *Wavelet*)

Na tentativa de melhorar o desempenho dos classificadores, os sinais A-scan originais foram pré-processados antes de serem novamente apresentados à rede como dados de entrada. Isto permitiu também avaliar a influência de cada pré-processamento aplicado. Entre as ferramentas disponíveis para o processamento de sinais, a Transformada de Fourier é a mais conhecida. Desta forma, o primeiro tipo de pré-processamento utilizado neste trabalho consistiu do cálculo do espectro de frequência de cada um dos 240 sinais através da aplicação da Transformada de Fourier [36, 37]. Os demais pré-processamentos são a Transformada *Wavelet* [37] e o cálculo da envoltória do sinal através da aplicação do filtro digital Savitzky-Golay [53, 54] no sinal original retificado. Após cada pré-processamento, a mesma metodologia utilizada durante a classificação linear dos sinais originais (tabelas 1 a 8) foram repetidas.

Pode-se observar a partir dos resultados apresentados até o momento (obtidos com sinais originais), e publicados em trabalhos recentes [90,91], que os classificadores hierárquicos normalmente apresentam um melhor desempenho que classificadores não-hierárquicos e o critério de reclassificação melhora os resultados obtidos. Por este critério, a maior saída do classificador é utilizada como critério de desempate. Por esta razão, para os espectros de frequência e coeficientes *wavelet* utilizados como dados de entrada, serão mostrados somente os resultados de treinamento e teste obtidos pelos classificadores *hierárquicos com reclassificação*.

As tabelas seguintes mostram a taxa de acerto para dados de treinamento e teste das quatro classes de A-scan. As tabelas 10 e 11 apresentam os resultados obtidos quando as amplitudes do espectro de frequência foram utilizados para alimentar os classificadores. As tabelas 12 e 13 apresentam os resultados obtidos quando foram utilizados os coeficientes *wavelet* tomados na escala de maior energia do diagrama tempo-escala.

Como esperado, é possível verificar a partir das tabelas 10 e 12, que o desempenho global deste tipo de algoritmo para a classificação dos dados de treinamento (superior a 78% para as amplitude do espectro de frequência e 99% para os coeficientes *wavelet*) é

superior ao desempenho global para classificação dos dados de teste (72,5% e 92,5%) visto na tabela 11 e 13 respectivamente.

Quando as amplitudes do espectro de frequência dos dados de treinamento são fornecidas à rede (tabela 10) observou-se que a classe “falta de penetração” tem o melhor desempenho (85%) seguida pela classe “porosidade” (82,5%). Como as piores classes são “sem defeito” (72,5%) e “falta de fusão” (72,5%) com a mesma taxa de acerto.

Observou-se uma mudança na taxa de acerto e na hierarquia de separação das classes dos sinais originais (FP; SD; PO; FF), sinais pré-processados pela Análise de Fourier (PO; FP; FF; SD) e sinais pré-processados pela Análise *Wavelet* (SD; FF; PO; FP). Isto pode ser visto pela comparação das tabelas 10 e 11.

Poderia-se supor que a classe “sem defeito” fosse a mais facilmente separável por ser o sinal mais simples, mas isto não foi confirmado. Uma hipótese para explicar este fato é que o ruído presente no sinal tenha sido confundido com um defeito. Em segundo lugar, observou-se que nenhuma das classes de defeitos tem um espectro de frequência bem definido. Além disso, todas as classes apresentam uma grande dispersão no espectro.

Particularmente, a classe “falta de penetração” apresentou o melhor desempenho (85%) na tabela 10 e taxa máxima de acerto (100%) nas tabelas 12 e 13 apresentando um alto nível de separação. Este resultado confirma a boa taxa de acerto da classe “falta de penetração” obtida anteriormente [90] na classificação de sinais no domínio do tempo.

Deve-se ressaltar que, como esperado, há uma influência do tipo de pré-processamento na taxa de sucesso. Pode-se ver claramente que os resultados obtidos com os coeficientes *wavelet* (superior a 99% e 92,5% como mostrado na tabela 12 e 13) são consideravelmente melhores que os obtidos com as amplitudes dos espectros de frequência, tanto no treinamento como no teste (superior a 78% e 72,5% como mostrado na tabela 10 e 11).

O pior desempenho do classificador alimentado com as amplitudes dos espectro de frequência dos sinais A-scan, quando comparados ao desempenho obtido com os coeficientes *wavelet* pode ser explicado por várias razões. Primeiramente, toda a informação de tempo é perdida durante a transformação do sinal para o domínio da frequência pela Transformada de Fourier, e é impossível dizer quando um evento particular aconteceu. Isto é importante na análise de sinais *não-estacionários* [37] e em particular para sinais obtidos pela técnica TOFD, que utiliza o tempo-de-percurso das ondas difratadas como único parâmetro de dimensionamento, e é pouco sensível às variações da amplitude do sinal [21]. Para a Transformada *Wavelet* esta perda de informação do tempo não ocorre. Em segundo lugar, durante a análise de frequência dos sinais A-scan, observou-se que nenhuma das classes de defeito tem um espectro de frequência bem definido e característico de cada classe. Ao contrário, todas as classes apresentaram uma grande dispersão no espectro.

Outra observação importante sobre a influência do tipo de pré-processamento são as taxas de acerto de 100% alcançadas pelas classes “falta de fusão” e “sem defeito” (Tabela 12). Isto garante a eficiência da Transformada *Wavelet* como um método de pré-processamento e que as três classes são linearmente separáveis uma das outras.

Deve-se chamar a atenção da elevada eficiência alcançada no reconhecimento de padrão de defeitos em sinais de TOFD pré-processados pela Transformada *Wavelet*. Este resultado pode ser considerado muito bom, levando-se em conta que o critério de classificação utilizado na classificação dos defeitos foi o linear.

Analisando os erros durante a reclassificação para todas as tabelas já apresentadas, pode-se observar que nenhuma classe estudada foi sistematicamente confundida por outra.

Tabela 10 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Amplitude do Espectro - Dados de Treinamento - Com Critério de Reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	72,5	5	10	12,5	72,5	27,5
FP	0	85	5	10	85	15
PO	0	2,5	82,5	15	82,5	17,5
SD	5	0	22,5	72,5	72,5	27,5
Total					78,125	21,875

Tabela 11 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Amplitude do Espectro - Dados de Teste - Com Critério de Reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	80	0	15	5	80	20
FP	0	75	10	15	75	25
PO	5	20	65	10	65	35
SD	0	5	25	70	70	30
Total					72,5	27,5

Tabela 12 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Coefficientes *Wavelet* - Dados de Treinamento - Com Critério de Reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	100	0	0	0	100	0
FP	0	100	0	0	100	0
PO	0	0	97,5	2,5	97,5	2,5
SD	0	0	0	100	100	0
Total					99,375	0,625

Tabela 13 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Coefficientes *Wavelet* - Dados de Teste - Com Critério de Reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	100	0	0	0	100	0
FP	0	100	0	0	100	0
PO	0	5	80	15	80	20
SD	10	0	0	90	90	10
Total					92,5	7,5

A seguir, a tabela 14 mostra qual a escala de maior energia, ou seja, a escala que contém os coeficientes de maior magnitude de cada um dos 160 sinais A-scan utilizados durante o treinamento. Para os sinais pré-processados pela Transformada *Wavelet*, somente os coeficientes da escala de maior energia foram utilizados como espaço de entrada. A tabela 14 mostra também a pseudo-frequência relacionada a cada uma das escalas de maior energia do diagrama CWT. Esta pseudo-frequência foi calculada através da equação 2.21 (item 2.3.2 - ANÁLISE WAVELET). Novamente, pode-se observar que nenhuma das classes possui uma escala (pseudo-frequência) de maior energia característica, e que a faixa de dispersão da escala escolhida é praticamente a mesma para todas as classes.

Ainda assim, como já foi apresentado, o índice de acerto alcançado no reconhecimento de padrão a partir dos coeficientes *wavelet* foram muito bons. A explicação, já dada para os resultados da Transformada de Fourier, deve estar no fato de que, a informação de tempo (importante na análise de sinais não-estacionários [37] e em particular na análise de sinais obtidos pela técnica TOFD, que utiliza o tempo-de-percurso das ondas difratadas como único parâmetro de dimensionamento [21]), não foi perdida durante a Transformada *Wavelet* como ocorre durante a transformação do sinal para o domínio da frequência pela Transformada de Fourier.

Tabela 14 – Escala de maior energia do diagrama CWT e pseudo-frequência associada.

Falta de Fusão			Falta de Penetração			Porosidade			Sem Defeito		
Sinal	Esc.	Freq. [MHz]	Sinal	Esc.	Freq. [MHz]	Sinal	Esc.	Freq. [MHz]	Sinal	Esc.	Freq. [MHz]
1	12	4,17	41	14	3,57	81	8	6,25	121	13	3,85
2	12	4,17	42	13	3,85	82	9	5,56	122	13	3,85
3	14	3,57	43	13	3,85	83	8	6,25	123	13	3,85
4	11	4,55	44	12	4,17	84	8	6,25	124	14	3,57
5	9	5,56	45	13	3,85	85	8	6,25	125	14	3,57
6	8	6,25	46	12	4,17	86	9	5,56	126	13	3,85
7	9	5,56	47	11	4,55	87	8	6,25	127	14	3,57
8	11	4,55	48	9	5,56	88	8	6,25	128	13	3,85
9	11	4,55	49	9	5,56	89	11	4,55	129	13	3,85
10	9	5,56	50	10	5,00	90	12	4,17	130	10	5,00
11	11	4,55	51	10	5,00	91	12	4,17	131	14	3,57
12	11	4,55	52	9	5,56	92	13	3,85	132	14	3,57
13	10	5,00	53	10	5,00	93	13	3,85	133	8	6,25
14	9	5,56	54	11	4,55	94	8	6,25	134	8	6,25
15	10	5,00	55	11	4,55	95	10	5,00	135	8	6,25
16	13	3,85	56	12	4,17	96	11	4,55	136	9	5,56
17	13	3,85	57	11	4,55	97	9	5,56	137	15	3,33
18	14	3,57	58	11	4,55	98	11	4,55	138	8	6,25
19	13	3,85	59	11	4,55	99	8	6,25	139	10	5,00
20	12	4,17	60	11	4,55	100	12	4,17	140	12	4,17
21	13	3,85	61	11	4,55	101	10	5,00	141	14	3,57
22	14	3,57	62	14	3,57	102	12	4,17	142	8	6,25
23	13	3,85	63	14	3,57	103	12	4,17	143	9	5,56
24	9	5,56	64	9	5,56	104	12	4,17	144	9	5,56
25	14	3,57	65	10	5,00	105	10	5,00	145	11	4,55
26	13	3,85	66	9	5,56	106	13	3,85	146	11	4,55
27	12	4,17	67	9	5,56	107	10	5,00	147	11	4,55
28	13	3,85	68	12	4,17	108	11	4,55	148	9	5,56
29	15	3,33	69	11	4,55	109	12	4,17	149	9	5,56
30	14	3,57	70	14	3,57	110	10	5,00	150	14	3,57
31	9	5,56	71	14	3,57	111	9	5,56	151	15	3,33
32	13	3,85	72	12	4,17	112	10	5,00	152	8	6,25
33	13	3,85	73	13	3,85	113	9	5,56	153	14	3,57
34	13	3,85	74	13	3,85	114	9	5,56	154	14	3,57
35	14	3,57	75	13	3,85	115	9	5,56	155	9	5,56
36	13	3,85	76	12	4,17	116	9	5,56	156	11	4,55
37	13	3,85	77	13	3,85	117	9	5,56	157	13	3,85
38	14	3,57	78	13	3,85	118	10	5,00	158	14	3,57
39	13	3,85	79	12	4,17	119	14	3,57	159	14	3,57
40	14	3,57	80	13	3,85	120	13	3,85	160	12	4,17

4.2.3. – Sinais Pré-Processados (Envoltória do Sinal Retificado)

Como feito na seção anterior (item 4.2.2 – SINAIS PRÉ-PROCESSADOS: TRANSFORMADA DE FOURIER E *WAVELET*), no presente item procura-se avaliar a influência do pré-processamento no desempenho da rede neural. Nesta seção utilizaremos um outro tipo de pré-processamento que consiste do cálculo da envoltória de cada um dos 240 sinais, através da aplicação do filtro digital Savitzky-Golay [53,54] após a retificação dos sinais ultra-sônicos originais. Após este pré-processamento, a mesma metodologia utilizada durante a classificação linear dos sinais originais (tabelas 1 a 8) foi repetida. É interessante notar que várias características observadas durante a análise de resultados da classificação linear dos sinais originais (tabelas 1 a 8) foram também observadas na classificação linear da envoltória (tabelas 15 a 22).

Antes da utilização do Filtro Savitzky-Golay, dois parâmetros devem ser escolhidos: a ordem do polinômio e o tamanho da janela do filtro. A escolha desses parâmetros deve respeitar algumas regras, como por exemplo: (1) a ordem do polinômio deve ser um número inteiro, (2) o tamanho da janela deve ser um número inteiro e ímpar e (3) a ordem do polinômio deve ser menor que o tamanho da janela escolhida. Para os sinais A-scan estudados, cada um com 512 pontos e capturados a uma taxa de amostragem de 100 MHz, os valores de tamanho de janela e ordem do polinômio que apresentaram bons resultados foram 61 e 5, respectivamente.

As tabelas 15 a 22 também resumem o desempenho destes classificadores em termos de percentual global de observações corretamente classificadas, erros e saídas sem classificação (todas as saídas de rede negativas ou mais de uma positiva). Desta forma foi possível chegar ao desempenho global de cada algoritmo de classificação, primeiro sem o critério de desempate na saída e posteriormente com critério de desempate na saída.

Na tabela 15, observa-se que o defeito falta de penetração (FP) é novamente o de melhor desempenho (97,5%), indicando ser realmente esta a classe mais facilmente separável das demais. A explicação, já dada na seção anterior, é que a posição do pico

de fundo é sensivelmente modificada por este tipo de defeito. Embora a classe FP continue sendo a mais facilmente separável, houve alteração na ordem de separação das demais classes. O cálculo da envoltória parece ter realçado os picos característicos dos defeitos da classe FF, que teve um grande aumento no índice de acerto quando comparado com a utilização dos sinais originais, onde apresentou o pior desempenho. A classe SD mostrou mais uma vez, não ser a mais facilmente separável, como era esperado. Provavelmente em consequência do ruído presente nos sinais, como já mostrado pela figura 4.1, com um exemplo de sinal A-scan capturado em uma região dita sem defeitos. Na figura 4.1, percebe-se a presença de ruído e que provavelmente foi confundido com defeito.

O resultados gerais para os dados de treinamento (90,625% e 99,375% - tabela 15 e 19 respectivamente), são superiores aos resultados gerais para os dados de teste (72,5% e 96,25% - tabela 17 e 21 respectivamente). A justificativa, já apresentada na seção anterior para este fato, é que é mais fácil classificar um sinal que foi fornecido à rede durante o processo de treinamento.

Nota-se também que a reclassificação, baseada em um critério de desempate na saída, contribuiu para uma melhoria no índice de acerto do classificador não-hierárquico. O percentual de acerto do classificador não-hierárquico cresceu de 90,625% para 94,375% durante o treinamento (tabelas 15 e 16) e de 72,5% para 83,75% durante o teste (tabelas 17 e 18). Embora a reclassificação tenha melhorado bastante o percentual de acerto do classificador não-hierárquico, não houve melhoria para o processo hierárquico, que manteve o percentual de 99,375% durante o treinamento e 96,25% durante o teste, independente de haver ou não reclassificação.

Apesar da reclassificação não ter melhorado o percentual de acerto dos classificadores hierárquicos, pela simples comparação de seus resultados, fica mais uma vez evidente que os resultados do classificador hierárquico são melhores que dos não-hierárquicos. Elevando o índice de acerto dos dados de treinamento de 94,375% (tabela 16) para 99,375% (tabela 20), e também dos 83,75% da tabela 18 para 96,25% da tabela 22 para os dados de teste.

A tabela 19 apresenta os primeiros resultados encontrados para o classificador hierárquico. Novamente, o desempenho deste classificador hierárquico mostrou-se melhor que a do classificador não-hierárquico, mesmo no critério mais exigente (classificação apenas quando somente uma saída for maior do que zero, ou seja, sem reclassificação). Os índices de 100% de acerto para FF, PO e SD comprovam serem três classes linearmente discrimináveis das demais. Outra observação importante em relação ao índice de 100% de acerto para as classes FF, PO e SD é que estas superaram até mesmo às classes FP, mais facilmente separável no processo não-hierárquico. Isso pode ser explicado, em teoria, pelo fato de que, com a retirada das classes mais externas, a classificação das classes mais internas torna-se mais fácil (figura 3.8). Durante a etapa de reclassificação, os sinais de treinamento foram erroneamente reclassificados e os resultados conseguidos com critério de desempate na saída da rede, mostrados na tabela 20 e 22, são os mesmos que no caso anterior (tabela 19 e 21), não havendo aumento do percentual de acerto.

Assim como para os sinais originais, a ordem de separação das classes (hierarquia de separação) também foi escolhida com base nos resultados do processo não-hierárquico (tabela 15 e 17). Iniciando-se com a classe que apresentou melhor índice de acerto até a classe que apresentou o pior índice.

O que mais chama a atenção nos resultados encontrados a partir da envoltória dos sinais retificados, é a maior eficiência alcançada após este pré-processamento bastante simples, com custo computacional muito menor que o cálculo dos coeficientes *wavelet*. Deve-se chamar atenção para a semelhança entre a envoltória do sinal retificado e os coeficientes *wavelet* tomados na escala de maior energia do diagrama tempo-escala da Transformada *Wavelet* Contínua (centro esquerdo e canto inferior direito, respectivamente, das figuras 3.3, 3.4, 3.5, 3.6 e 4.1).

Este resultado pode ser considerado muito bom levando-se em conta que um critério de classificação linear foi utilizado na classificação dos defeitos.

Tabela 15 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Não-Hierárquico

Envoltória dos sinais – Dados de Treinamento – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais De Uma	Acertos	Erros	Sem classif.	
	FF	FP	PO	SD						
FF	95	0	0	0	2,5	2,5	95	2,5	2,5	
FP	0	97,5	0	0	2,5	0	97,5	0	2,5	
PO	0	0	80	0	20	0	80	0	20	
SD	0	0	0	90	0	10	90	10	0	
Total							90,625	3,125	6,25	

Tabela 16 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Não-Hierárquico

Envoltória dos Sinais – Dados de Treinamento – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	100	0	0	0	100	0
FP	0	97,5	2,5	0	97,5	2,5
PO	12,5	0	82,5	5	82,5	17,5
SD	0	0	2,5	97,5	97,5	2,5
Total					94,375	5,625

Tabela 17 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Não-Hierárquico

Envoltória dos Sinais – Dados de Teste – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais de Uma	Acertos	Erros	Sem classif.	
	FF	FP	PO	SD						
FF	65	0	0	0	25	10	65	10	25	
FP	0	90	0	0	5	5	90	5	5	
PO	0	0	60	1	25	10	60	15	25	
SD	0	0	0	75	0	25	75	25	0	
Total							72,5	13,75	13,75	

Tabela 18 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Não-Hierárquico

Envoltória dos Sinais – Dados de Teste – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	80	10	10	0	80	20
FP	0	95	5	0	95	5
PO	15	0	75	10	75	25
SD	0	0	15	85	85	15
Total					83,75	16,25

Tabela 19 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Envoltória dos Sinais – Dados de Treinamento – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais De Uma	Acertos	Erros	Sem classif.
	FF	FP	PO	SD					
FF	100	0	0	0	0	0	100	0	0
FP	0	97,5	0	0	2,5	0	97,5	0	2,5
PO	0	0	100	0	0	0	100	0	0
SD	0	0	0	100	0	0	100	0	0
Total							99,375	0	0,625

Tabela 20 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Envoltória dos Sinais – Dados de Treinamento – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	100	0	0	0	100	0
FP	0	97,5	2,5	0	97,5	2,5
PO	0	0	100	0	100	0
SD	0	0	0	100	100	0
Total					99,375	0,625

Tabela 21 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Envoltória dos Sinais – Dados de Teste – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais de Uma	Acertos	Erros	Sem classif.
	FF	FP	PO	SD					
FF	100	0	0	0	0	0	100	0	0
FP	0	95	5	0	0	0	95	5	0
PO	0	0	90	10	0	0	90	10	0
SD	0	0	0	100	0	0	100	0	0
Total							96,25	3,75	0

Tabela 22 - Tabela de Confusão, Acertos e Erros (%)

Classificador Linear Hierárquico

Envoltória dos Sinais – Dados de Teste – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	100	0	0	0	100	0
FP	0	95	5	0	95	5
PO	0	0	90	10	90	10
SD	0	0	0	100	100	0
Total					96,25	3,75

É importante notar que existe uma coerência entre os resultados encontrados durante a classificação linear dos sinais originais (tabelas 1 a 8) e observados na classificação linear dos sinais pré-processados (tabelas 10 a 13 e 15 a 22).

A tabela 23 reúne todos os resultados obtidos com a utilização da envoltória dos sinais retificados para alimentar a rede neural. Pôde-se verificar uma considerável melhoria em todas as etapas realizadas, ou seja, sem ou com hierarquia, sem ou com reclassificação, para os sinais de treinamento e de teste. Isso justifica-se pelo fato de que o pré-processamento destacou certas informações relevantes contidas no sinal, características de cada classe, e provavelmente eliminou as informações irrelevantes que pudessem dificultar a classificação.

Tabela 23 - Resumo dos resultados obtidos por Classificador Linear no reconhecimento de padrão na Envoltória dos Sinais Retificados.

	Não-Hierárquico		Hierárquico	
	Treinamento	Teste	Treinamento	Teste
Nº de Sinais	160 Sinais	80 Sinais	160 Sinais	80 Sinais
Acertos	94,38%	83,75%	99,375%	96,25%
Reclassificados	3,75%	11,25%	0%	0%
Erros	5,625%	16,25%	0,625%	3,75%

Deve-se lembrar que o percentual global de observações corretamente classificadas, apresentados em todas as tabelas de resumo deste trabalho (tabelas 9, 23 e 32), foi calculado já considerando os acertos obtidos com a reclassificação.

A figura 4.2 compara os resultados obtidos quando o classificador linear é alimentado com o sinal original [90,91] e com o sinal A-scan após cada um dos diferentes métodos de pré-processamento. Verificou-se uma taxa de acerto inferior alcançada pelo classificador alimentado com as amplitudes do espectro de frequência comparado ao alimentado com os sinais originais. Pode-se ver também que há uma melhoria dos resultados obtidos pelo coeficientes *wavelet* dos sinais, quando comparados com os sinais originais. Isto deve-se ao fato do pré-processamento ter revelado informações

importantes no sinal que é característico da classe e, provavelmente ter eliminado informações irrelevantes que poderiam confundir sua classificação.

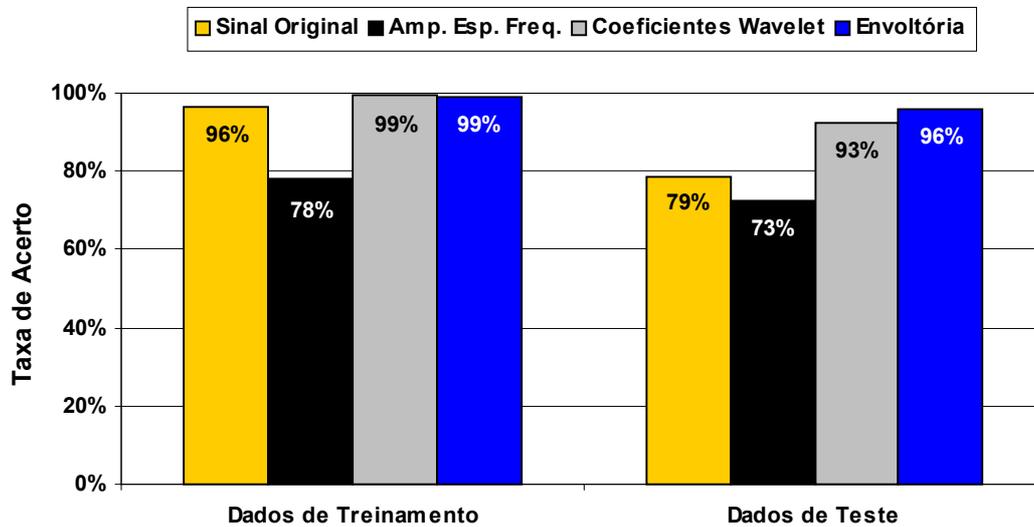


Figura 4.2 - Efeito dos diferentes tipos de pré-processamento dos dados de entrada no desempenho dos classificadores lineares.

4.3. – Classificadores Não-Lineares

Após a utilização dos diferentes algoritmos de classificação linear (sem reclassificação, com reclassificação, não-hierárquico, hierárquico) e dos diferentes pré-processamentos, determinou-se que o cálculo da Envoltória do Sinal Retificado pela aplicação do filtro Savitzky-Golay foi o que rendeu os melhores resultados entre os pré-processamentos. Nesta seção são apresentados os resultados do reconhecimento de padrão de defeitos em sinais A-scan pré-processados pelo filtro Savitzky-Golay, obtidos por classificadores não-lineares. Estes novos resultados (tabelas 24 a 31) estão coerentes com os anteriores (tabelas 1 a 22), quanto a superioridade dos resultados alcançados por algoritmos com reclassificação, hierarquia e em dados de treinamento.

A partir das tabelas 24, 25, 28 e 29, pode-se ver que todos os dados de treinamento foram corretamente classificados, alcançando 100% de acerto, até mesmo quando nenhuma hierarquia de separação (tabelas 24 e 25) ou critério de desempate da saída do classificador (tabela 24 e 28) são utilizados. Para os dados de teste a eficiência do *classificador não-linear não-hierárquico* cai um pouco, mas mantém o índice máximo de acerto (100%) em pelo menos uma classe, chegando a alcançar 95% de índice global de acerto. Para o *classificador não-linear hierárquico*, duas classes mantiveram o índice máximo de acerto (100%), alcançando, no final, um índice global de 97,5% de acerto.

Deve-se chamar a atenção para o relativo pequeno conjunto de treinamento e teste, onde um único erro por classe chega a 5% de erro (um erro em vinte dados de teste) e significa 1,25% de erro no índice global (1 erro / 80 dados de teste). Um universo maior de dados de treinamento (maior que 40) e teste (maior que 20) poderá produzir um melhor treinamento, ou seja, um discriminador com maior capacidade de generalização. Essa medida, pode ser eficiente também para evitar que a rede decore os exemplos em lugar de aprendê-los. A isto, chama-se, “excesso de treinamento” (*overtraining*).

Fica evidente que os discriminadores não-lineares são capazes de reconhecer e separar melhor os sinais que os discriminadores lineares.

Tabela 24 - Tabela de Confusão, Acertos e Erros (%)

Classificador Não-Linear Não-Hierárquico

Envoltória dos Sinais – Dados de Treinamento – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais de Uma	Acertos	Erros	Sem Classif.
	FF	FP	PO	SD					
FF	100	0	0	0	0	0	100	0	0
FP	0	100	0	0	0	0	100	0	0
PO	0	0	100	0	0	0	100	0	0
SD	0	0	0	100	0	0	100	0	0
Total							100	0	0

Tabela 25 - Tabela de Confusão, Acertos e Erros (%)

Classificador Não-Linear Não-Hierárquico

Envoltória dos Sinais – Dados de Treinamento – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	100	0	0	0	100	0
FP	0	100	0	0	100	0
PO	0	0	100	0	100	0
SD	0	0	0	100	100	0
Total					100	0

Tabela 26 – Tabela de Confusão, Acertos e Erros (%)

Classificador Não-Linear Não-Hierárquico

Envoltória dos Sinais – Dados de Teste – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais de Uma	Acertos	Erros	Sem Classif.
	FF	FP	PO	SD					
FF	85	0	0	0	15	0	85	0	15
FP	0	95	0	0	0	5	95	5	0
PO	0	0	80	10	10	0	80	10	10
SD	0	0	0	95	0	5	95	5	0
Total							88,75	5	6,25

Tabela 27 – Tabela de Confusão, Acertos e Erros (%)

Classificador Não-Linear Não-Hierárquico

Envoltória dos Sinais – Dados de Teste – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	95	0	0	5	95	5
FP	0	95	5	0	95	5
PO	0	0	90	10	90	10
SD	0	0	0	100	100	0
Total					95	5

Tabela 28 – Tabela de Confusão, Acertos e Erros (%)

Classificador Não-Linear Hierárquico

Envoltória dos Sinais – Dados de Treinamento – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais de Uma	Acertos	Erros	Sem Classif.
	FF	FP	PO	SD					
FF	100	0	0	0	0	0	100	0	0
FP	0	100	0	0	0	0	100	0	0
PO	0	0	100	0	0	0	100	0	0
SD	0	0	0	100	0	0	100	0	0
Total							100	0	0

Tabela 29 – Tabela de Confusão, Acertos e Erros (%)

Classificador Não-Linear Hierárquico

Envoltória dos Sinais – Dados de Treinamento – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	100	0	0	0	100	0
FP	0	100	0	0	100	0
PO	0	0	100	0	100	0
SD	0	0	0	100	100	0
Total					100	0

Tabela 30 – Tabela de Confusão, Acertos e Erros (%)

Classificador Não-Linear Hierárquico

Envoltória dos Sinais – Dados de Teste – Sem reclassificação

Classe do Sinal	Neurônio Vencedor				Nenhuma	Mais de Uma	Acertos	Erros	Sem Classif.
	FF	FP	PO	SD					
FF	100	0	0	0	0	0	100	0	0
FP	0	100	0	0	0	0	100	0	0
PO	0	0	95	5	0	0	95	5	0
SD	0	0	5	95	0	0	95	5	0
Total							97,5	2,5	0

Tabela 31 – Tabela de Confusão, Acertos e Erros (%)

Classificador Não-Linear Hierárquico

Envoltória dos Sinais – Dados de Teste – Com reclassificação

Classe do Sinal	Neurônio Vencedor				Acertos	Erros
	FF	FP	PO	SD		
FF	100	0	0	0	100	0
FP	0	100	0	0	100	0
PO	0	0	95	5	95	5
SD	0	0	5	95	95	5
Total					97,5	2,5

Deve-se lembrar que o percentual global de observações corretamente classificadas, apresentados em todas as tabelas de resumo deste trabalho (tabelas 9, 23 e 32), foi calculado já considerando-se os acertos obtidos com a reclassificação.

Tabela 32: Resumo dos resultados obtidos por Classificador não-linear no reconhecimento de padrão na Envoltória dos Sinais Retificados.

	Não-Hierárquico		Hierárquico	
	Treinamento	Teste	Treinamento	Teste
N° de Sinais	160 Sinais	80 Sinais	160 Sinais	80 Sinais
Acertos	100 %	95 %	100 %	97,5 %
Reclassificados	0 %	6,25 %	0 %	0 %
Erros	0 %	5 %	0 %	2,5 %

Abaixo, a figura 4.3 compara os melhores resultados encontrado com classificadores lineares hierárquicos *versus* classificadores não-lineares hierárquicos, no reconhecimento de padrões da Envoltória de Sinais Retificados (pré-processamento que apresentou o melhor resultado).

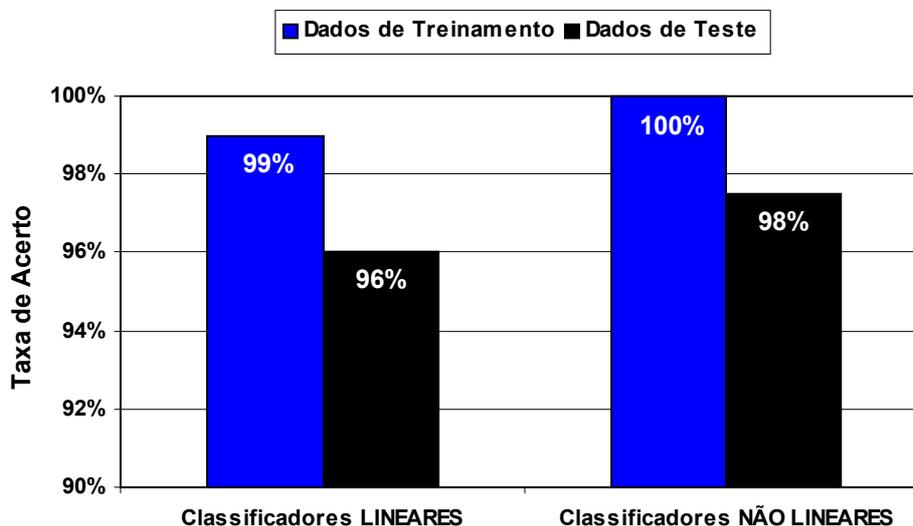


Figura 4.3 - Classificador Hierárquico Linear versus Classificador Hierárquico não-linear no Reconhecimento de Padrão realizado na Envoltória dos Sinais Retificados.

Apesar de haver diversas aplicações de redes neurais no reconhecimento de padrões e classificação de sinais obtidos por diversas técnicas não-destrutivas na literatura técnica, a originalidade deste trabalho reside no fato que nenhum outro trabalho utilizando redes neurais para classificar defeitos de soldagem em sinais ultra-sônicos obtidos especificamente pela técnica TOFD, foi encontrado na literatura. Consequentemente, infelizmente, os resultados obtidos não puderam ser comparados a resultados de outros autores pela ausência de publicações neste campo de pesquisa: Classificação de defeitos de soldagem de sinais obtidos pela técnica TOFD, utilizando classificadores lineares e não-lineares.

SILVA [89,93] utilizou redes neurais para classificar defeitos de soldagem a partir de parâmetros extraídos de padrões radiográficos do IIW (*International Institute of Welding*). As classes estudadas por SILVA foram Falta de Penetração, Porosidade, Mordedura, Inclusão de Escória. O índice de sucesso na classificação alcançado por SILVA utilizando classificadores lineares chegou a 85% e próximo a 100% com classificadores não-lineares.

VEIGA et al [92] utilizou redes neurais supervisionadas para o reconhecimento de padrões de defeitos em sinais ultra-sônicos de pulso-eco retificados. Duas classes de defeitos foram estudadas (Falta de Penetração e Porosidade). Uma terceira classe de sinais (Sem Defeito) também foi utilizada. VEIGA reporta que obteve um índice de acerto de 100% durante o treinamento e 73,3% para dados de teste.

Também não foi possível comparar com os resultados alcançados por inspetores, uma vez que os órgãos responsáveis pela qualificação e certificação de pessoal em ensaios não-destrutivos não divulgam seus dados.

5. – Conclusões

Primeiramente, o estudo revelou que os sinais ultra-sônicos A-scan das classes de defeitos estudadas e obtidos pela técnica TOFD, são linearmente separáveis. Os classificadores lineares de padrões implementados por uma rede neural artificial, mostraram-se bastante eficientes no reconhecimento das quatro classes de defeitos estudadas neste trabalho.

Um segunda observação importante, é quanto à pequena diferença entre os índices de acerto dos dados de teste e dos dados de treinamento. O que confirma a capacidade dos classificadores estudados na identificação de sinais desconhecido.

Outra observação é que o critério de classificação por hierarquia otimizou o desempenho em relação à classificação não-hierárquica. Além disso, o pré-processamento dos sinais originais, especialmente a aplicação do Filtro Savitzky-Golay, utilizado para o cálculo da envoltória, e a aplicação da Transformada *Wavelet*, utilizada para o cálculo dos coeficientes *wavelet*, facilitou ainda mais a utilização desses classificadores, melhorando consideravelmente o desempenho da classificação.

No caso dos coeficientes *wavelet*, o índice de acerto no reconhecimento das classes alcançado pelos classificadores lineares chegou a 99% para os dados de treinamento, e 93% para os dados de teste. Para os classificadores não-lineares, os índices foram de 99% e 96% para os dados de treinamento e teste, respectivamente. Com a envoltória dos sinais retificados, o índice de acerto alcançado chegou a 99% para dados de treinamento, e 96% para os dados de teste, utilizando classificadores lineares, e 100% e 98% para os dados de treinamento e teste, respectivamente, com classificadores não-lineares. Como era esperado, a utilização de classificadores não-lineares, foi capaz de melhorar o reconhecimento de padrão e a separação das classes estudadas.

O que mais chama a atenção nos resultados encontrados a partir da envoltória dos sinais retificados, é a boa eficiência alcançada após este pré-processamento bastante simples, com custo computacional muito menor que o cálculo dos coeficientes *wavelet*.

Apesar de outros tipos de defeitos tipo trinca, mordedura, inclusão de escória, etc., não terem sido estudados neste trabalho, o mesmo procedimento poderá ser utilizado na sua classificação.

De um modo geral, os resultados obtidos são muito promissores e podem dar contribuições relevantes no desenvolvimento de um sistema automático de detecção e classificação de defeitos de soldagem inspecionados pela técnica TOFD.

6. – Referências

- [1] Silk, M.G., Lidington, B.H., “*Defect sizing using an Ultrasonic Time Delay Approach*”, British Journal of NDT, pp. 33-36, March, 1975.
- [2] Silk, M. G., “*Sizing Crack-like Defect by Ultrasonic Means*”, In Research Techniques in Nondestructive Testing, vol. 3, Academic Press, pp. 51 - 79, 1977.
- [3] Raad, J. A., Dijkstra, F. H., “*Mechanized Ultrasonic Testing on Girth Welds During Pipeline Construction*”, Materials Evaluation, vol. 55, N° 8, pp. 890 - 895, ago 1997.
- [4] Silk, M.G., “*The Transfer of Ultrasonic Energy in the Diffraction Technique for Crack Sizing*”, Ultrasonics, pp. 113-120, May, 1979.
- [5] Pré norma Europeia - NP ENV583-6, “*Técnica do Tempo de Percurso difractado como método para a detecção e dimensionamento de descontinuidades*”.
- [6] British Standard BS7706, “*Guide to Calibration and Setting-up of Ultrasonic Time of Flight Diffraction (TOFD) Technique for Defect Detection, Location and Sizing of Flaws*”, British Standard Institution, 1993.
- [7] Scheerder, A. A. A., “*Equipment Condition Monitoring using TOFD - Experiences at DSM*”, 15th WCNDT Roma 2000
<http://www.ndt.net/article/wcndt00/papers/idn070/idn070.htm>
- [8] Camerini, C.S., “*A Avaliação dos Métodos de Identificação e Dimensionamento de Descontinuidades em Juntas Soldadas Utilizando a Inspeção por Ultra-Som*”, Tese de Mestrado, Universidade Federal do Rio de Janeiro, COPPE/UFRJ. Rio de Janeiro, Março 1982.

- [9] Masnata, A., Sunseri, M., “*Neural Network Classification of Flaws Detected by Ultrasonic Means*”, NDT & E International, Vol. 29, N°2, pp. 87-93, 1996.
- [10] Siqueira, M. H. S., “*Long Distances Inspection Using Ultrasonic Guided Waves and Artificial Intelligence*”, D.Sc. Thesis, Department of Metallurgical and Materials Engineering, COPPE/UFRJ, Brasil, 2002.
- [11] Margrave, F. W., Rigas, K., Bradley, D. A., Barrowcliffe, P., “*The Use of Neural Networks in Ultrasonic Flaw Detection*”, Measurement, 25, pp. 143-154, 1999.
- [12] Haykin S., Neural Networks, “*A Comprehensive Foundation*”, Macmillian College Publishing. Inc., 1994.
- [13] Wasserman, P. D., “*Neural Computing Theory and Practice*”, New York, Van Nostrand Reinhold, 1989.
- [14] Silk, M. G., “*Changes in Ultrasonic Defect Location and Sizing*”, In NDT International, vol. 20, N° 1, pp. 9 - 14, February, 1987.
- [15] Cook, D., “*Crack Depth Measurement with Surface Waves*”, British Acoustical Society, Spring Meeting, University of Loughborough, Ultrasonic in Industry Session, 5th -7th April, 1972.
- [16] Hudgell, R.J., Morgan, L.L., Lumb, R.F., “*Non-Destructive Measurement of the Depth of Surface-Breaking Cracks using Ultrasonic Rayleigh Waves*”, British Journal of NDT, pp. 144-149, September, 1974.
- [17] Silk, M.G., Lidington, B.H., “*An Investigation of the Potential of the Use of Scattered Ultrasound in the Determination of Crack Depth*”, Artigo da Non-Destructive Testing Center, Materials Physics Division, U.K.A.E.A. Research Group, Atomic Energy Research Establishment, Harwell, AERE-R 7649, 1974 HL. 74/202 (C14)

[18] INSIGHT, Vol. 38, N°8, August 1996, S.549

[19] INSIGHT, Vol. 37, N°8, August 1995, S.581

[20] INSIGHT, Vol. 38, N°6, June 1996, S.391

[21] Silva, I. C., “*Avaliação da Técnica do Tempo de Percurso da Onda Difrata no Dimensionamento de Descontinuidades*”, Tese de Mestrado, Universidade Federal do Rio de Janeiro, março 1999.

[22] Silk, M.G., “*New Approaches to Crack Sizing by Ultrasonics - Recent Developments in Non-Destructive Testing*”, Seminar Papers, Abington, Cambridge, 4-6, Oct. 1976, Published by the Welding Institute, Paper 5, pp. 40-45, 1978.

[23] ASM Handbook, “*Nondestructive evaluation and quality control*”, vol. 17, 1993, pp. 406-431.

[24] Silva, S.G., “*Técnica Ultra-Sônica do Tempo de Percurso da Onda Difrata na Detecção e Dimensionamento de Descontinuidades em Cordões de Solda de Aço*”, Tese de Mestrado, Universidade Federal do Rio de Janeiro, COPPE/UFRJ, Rio de Janeiro, Dezembro 2000.

[25] Temple, J.A.G., “*Time of Flight Inspection: Theory*”, Nuclear Energy, vol. 22, n° 5, pp. 335-348, Oct, 1983.

[26] Temple, J.A.G., “*Predicted Ultrasonic Responser for Pulse-Echo Inspections*”, British Journal of NDT, pp. 145 - 154, May, 1986.

[27] Browne, B., “*Time of Flight Diffraction, Its Limitations - Actual & Perceived*”, NDTnet, September 1997, vol. 2, N° 9,
<http://www.ndt.net/article/tofd/browne/browner.htm>.

[28] Raad, J. A., Dijkstra, F. H., “*Why Develop Acceptance Criteria for Pipeline Girth Weld Defects?*”, European-American Workshop Determination of Reliability and Validation Methods of NDE, Berlin, Jun, 1997 (Extraído de NDTnet, vol. 3, N° 4, April 1998, <http://www.ndt.net/article/0498/dijkstra/dijkstra.htm>).

[29] Verkooijeen, J., “*TOFD Used to Replace Radiography*”, Insight - Nondestructive testing and Condition Monitoring, vol. 38, N ° 1, pp. 31 - 36, Jan, 1996.

[30] Trimborn, N., “*The Performance of the Time of Flight Diffraction (TOFD) Technique in Various International Round Robin Trials and the Continuing Research Work Underway*”, 7th European Conference on NDT, Copenhagen, vol. 2, pp. 1231 - 1235.

[31] Richteer, R. M., Quadrado, F. E., “*END na Construção do Gasoduto Bolívia-Brasil (GASBOL)*”, XVII Congresso Nacional de Ensaios Não-Destrutivos, São Paulo, pp. 29 - 40, Agosto 1998.

[32] Hecht, A., “*Time of Flight Diffraction Technique (TOFD) - An Ultrasonic Testing Method for all Applications*”, NDT.net, September 1997, vol. 2, N° 09, <http://www.ndt.net/article/tofd/hecht/hecht.htm>.

[33] Erhard, A., Ewert, U., “*The TOFD Method - Between Radiography and Ultrasonic in Weld Testing*”, NDTnet, September 1999, vol. 4, N° 9, <http://www.ndt.net/article/v04n09/erhard/erhard.htm>.

[34] Munns, I. J., Georgiou, T. W. I., Abington, U. K., “*Ultrasonic and Radiographic NDT of Butt Fusion Welds in Polyethylene Pipe*”, NDTnet - April 1996, vol. 1, N° 04, <http://www.ndt.net/article/twi/twi.htm>, Paper presented at Plastic Pipes IX Heriot-Watt University Edinburgh, Scotland, UK, 18-21, September, 1995.

- [35] Komura, I., Hirasawa, T., Nagai, S., Takabayashi, J., Nasure, K., “*Crack Detection and Sizing Technique by Ultrasonic and Eletromagnetic Methods*”, Nuclear Engineering and Desing 206, pp. 351-362, 2001.
- [36] Lathi, B. P., “*Communication Systems*”, John Wiley & Sons, 1968.
- [37] Michel Misiti; Yves Misiti; Georges Oppenheim; Jean-Michel Poggi, “*Wavelet Toolbox for Use with MATLAB*”, User’s Guide, Version 1, 1996, The MathWorks Inc.
- [38] Graps, A.L., “*An Introduction to Wavelets*”, IEEE Computational Sciences and Engineering, Volume 2, Number 2, 1995, pp 50-61.
- [39] Nogueira, C.L., “*Análise Ultra-Sônica da Distribuição dos Agregados no Concreto Através de Wavelets*”, XXI Congresso Nacional de Ensaaios Não-Destrutivos, Salvador, Agosto 2002.
- [40] Zhang, G.M., Hou, C.G., Wang, Y.W., Zhang, S.Y., “*Optimal Frequency-to-bandwidth ratio of Wavlet in Ultrasonic non-destructive Evaluation*”, Ultrasonic, 39, pp. 13-17, 2001.
- [41] Schwartz, M., “*Transmissão de informação, modulação e ruído*”, Guanabara Dois, 1979.
- [42] Chen, J., Shi, Y., Shi, S., “*Noise Analysis of Digital Ultrasonic Nondestructive Evaluation System*”, International Journal of Pressure Vessels and Piping, 76, pp. 619-630, 1999.
- [43] Bettayeb, F., Rachedi, T., Rezzak, K., “*Ultrasonic Signal Analysis by the Wavelet Tranform*”, 8th ECNDT, Barcelona, 2002.

- [44] Zhang, G., Zhang, S., Wang, Y., “*Application of Adaptive Time-Frequency Decomposition in Ultrasonic NDE of Highly-Scattering Materials*”, *Ultrasonics*, 38, pp.961-964, 2000.
- [45] Chen, Y.J., Shi, Y.W., Zhang, X.P., “*Detection of Weak Bonding in Friction Welds by Ultrasound*”, *Ultrasonics* 36, pp. 141-146, 1998.
- [46] Qi, G., “*Wavelet-Based AE Characterization of Composite Materials*”, *NDT&E International* 33, pp. 133-144, 2000.
- [47] Tang, X., Abeyratne, U.R., “*Wavelet Transforms in Estimating Scatterer Spacing From Ultrasound Echoes*”, *Ultrasonics* 38, pp. 688-692, 2000.
- [48] Legendre, S., Goyette, J., Massicotte, D., “*Ultrasonic NDE of Composite Material Structures Using Wavelet Coefficients*”, *NDT & E International*, 34, pp. 31-37, 2001.
- [49] Angrisani, L., Bechou, L., Dallet, D., Daponte, P., Ousten, Y., “*Detection and Location of Defects in Electronic Devices by Means of Scanning Ultrasonic Microscopy and the Wavelet Transform*”, *Measurement*, 31, pp.77-91, 2002.
- [50] Angrisani, L., Daponte, P., “*Thin Thickness Measurements by Means of a Wavelet Transform-based Method*”, *Measurement*, 20, pp. 227-242, 1997.
- [51] Sternickel, K., “*Automatic Pattern Recognition in ECG Time Series*”, *Computer Methods and Programs in Biomedicine*, 68, pp. 109-115, 2002.
- [52] Abbate, A., Koay, J., Frankel, J., Schroeder, S.C., Das, P., “*Signal Detection and Noise Suppression Using a Wavelet Transform Signal Processor: Application to Ultrasonic Flaw detection*”, *IEEE Trans. Ultrason. Ferroelect. Freq. Contr.*, 14, pp. 14-25, 1997.

- [53] “*Signal Processing Toolbox for Use With MATLAB*”, User’s Guide, Version 4, 1999, The MathWorks Inc.
- [54] Sophocles, J. O., “*Introduction to Signal Processing*”, Prentice-Hall, 1999.
- [55] Kovács, Z.L., “*Redes Neurais Artificiais: Fundamentos e Aplicações*”, 2º edição, Edição Acadêmica, São Paulo, 1996.
- [56] McCulloch, W., Pitts, W., “*A Logical Calculus of the Ideas Immanente in Nervous Activity*”, Bulletin of Mathematical Biophysics, 1943.
- [57] Schmidt, R. F. “*Neurofisiologia*”, 40 ed., Editora Pedagógica e Universitária.
- [58] Anderson, A. J. “*An Introduction to Neural Networks*”, (The MIT Press, 1995).
- [59] Weiss, T. F. “*Cellular Biophysics - Electrical Properties*”, (The MIT Press, Massachusetts, 1996).
- [60] Fausett, L. “*Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*”, (Englewood Cliffs, NJ: Prentice-Hall Intern. 1994).
- [61] Howard Demuth, Mark Beale, “*Neural Network Toolbox for Use with MATLAB*”, User’s Guide, Version 3, 1998, The MathWorks Inc.
- [62] Rosenblatt, F., “*The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain*”, Psychological Review, vol. 65, pp. 386-408.
- [63] Hebb, D., “*The Organization of Behavior*”, Wiley, New York, 1949
- [64] Widrow, B., “*Generalization and Information Storage in Networks of Adaline Neurons*”, Self-Organizing Systems, pp. 435-461, Washington, DC, Spartan Books, 1962.

- [65] Hertz, J., Krogh, A., Palmer, R.G., *“Introduction to the Theory of Neural Computation”*. Addison-Wesley Publishing Company, 1991.
- [66] Minsky, M.L., Papert, S.A., *“Perceptrons”*, Cambridge, MA: MIT Press, 1969
- [67] Kosko, B., *“Neural Networks and Fuzzy Systems - A Dynamical Systems Approach to Machine Intelligence”*, Prentice Hall International Editions, New Jersey, 1992.
- [68] Cybenko, G., *“Approximation by Superpositions of a Sigmoidal Function”*, Mathematics of Control, Signals and Systems, 2, pp.303-314, 1989.
- [69] Hornik, K., Stinchcombe, M., White, H., *“Multilayer Feedforward Network are Universal Approximators”*, Neural Networks 2 (5) 356-366, 1989.
- [70] Hecht-Nielsen, R., *“Kolmogorov's Mapping Neural Network Existence Theorem”*, In: International Conference on Neural Networks, vol 3, IEEE, pp. 11-14, Washington DC, 1989.
- [71]. Hush, D. R. and Horne, B. G., *“Progress in Supervised Neural Networks”*, IEEE Signal Processing Mag., 10, pp. 8-39, 1993,.
- [72] Funahashi, K.-I., *“On the Approximate Realization of Continuous Mappings by Neural Networks”*, Neural Netw. 2 (3), pp.183-192, 1989.
- [73] Adriano Almeida, Eric v. K. Hill. *“Neural Network Detection of Fatigue Crack Growth in Riveted Joints Using Acoustic Emission”*, Materials Evaluation, pp.76-82, January 1995.
- [74] Dasgupta, C.G., Dispensa, G.S., Ghose, S., *“Comparing the Predictive Performance of a Neural Network Model With Some Traditional Market Response*

Models”, International Journal of Forecasting, Volume 10, Issue 2, pp 235-244, September 1994.

[75] Badiru, A.B., Sieger, D.B., “*Neural Network as a Simulation Metamodel in Economic Analysis of Risky Projects*”, European Journal of Operational Research, Volume 105, Issue 1, pp. 130-142, February 1998.

[76] Indro, D.C., Jiang, C.X., Patuwo, B.E., Zhang, G.P., “*Predicting Mutual Fund Performance Using Artificial Neural Networks*”, Omega, Volume 27, Issue 3, pp. 373-380, June 1999.

[77] Quah, T.S., Srinivasan, B., “*Improving Returns on Stock Investment Through Neural Network Selection*”, Expert Systems with Applications, Volume 17, Issue 4, pp. 295-301, November 1999.

[78] Maglaveras, N., Stamkopoulos, T., Diamantaras, K., Pappas, C., Strintzis, M., “*ECG Pattern Recognition and Classification Using Non-Linear Transformations and Neural Networks: A Review*”, International Journal of Medical Informatics, 52, pp. 191-208, 1998.

[79] Lavine, B.K., Davidson, C.E., Moores, A.J., “*Genetic Algorithms for Spectral Pattern Recognition*”, Vibrational Spectroscopy, 28, pp. 83-95, 2002.

[80] Bruzzone, L., Roli, F., Serpico, S.B., “*Structured Neural Networks for Signal Classification*”, Signal Processing, 64, pp. 271-290, 1998.

[81] Bishop, C. M., “*Neural Networks for Pattern Recognition*”, Oxford University Press, 1995.

[82] Hazarika, N., Chen, J.Z., Tsoi, A.C., Sergejew, A., “*Classification of ECG Signals Using the Wavelet Transform*”, Signal Processing, 59, pp. 61-72, 1997.

- [83] Sternickel, K., “*Automatic Pattern Recognition in ECG Time Series*”, Computer Methods and Programs in Biomedicine, 68, pp. 109-115, 2002.
- [84] Song, S.J., Shin, Y.K., “*Eddy Current Flaw Characterization in Tubes by Neural Networks and Finite Element Modelling*”, NDT&E International, 33, pp.233-243, 2000.
- [85] Philippidis, T.P., Nikolaidis, V.N., Anastassopoulos, A.A., “*Damage Characterization of Carbon/Carbon Laminates Using Neural Network Techniques on AE Signals*”, NDT&E International, vol. 31, pp. 329-340, 1998.
- [86] Bettayeb, F., Bendartaoui, H., Raouraou, B., “*The Ultrasonic Testing Reliability by the Artificial Intelligence Techniques*”, 8th ECNDT, Barcelona, 2002.
- [87] Catunda, C.E.G., “*Veículo de Ensaio com Rodas Magnéticas*”, Projeto Final do Curso de Engenharia Mecânica, UFRJ, Brasil, Abril 2002.
- [88] Catunda, C.E.G., Rebello, J.M.A., Silva, I.C., Carvalho, A.A., Moura, E.P., “*Desenvolvimento de um Veículo de Ensaio com Rodas Magnéticas*”, In: 6^a Conferência sobre Tecnologia de Equipamentos, Salvador - Bahia, Agosto 2002.
- [89] Silva, R.R., Siqueira, M.H.S., Calôba, L.P., et al, “*Radiographics Pattern Recognition of Welding Defects Using Linear Classifiers*”, INSIGHT, pp. 669-674, Vol. 43, N°10, October, 2001.
- [90] Moura, E. P., Carvalho, A. A., Silva, R. R., Siqueira, M. H. S., Calôba, L. P., Rebello, J. M. A., “*Welding Defect Pattern Recognition In TOFD Signals Using Linear Classifiers*”, Submetido para publicação no Journal of Nondestructive Evaluation.
- [91] Moura, E. P., Silva, R. R., Siqueira, M. H. S., Rebello, J. M. A., “*Pattern Recognition of Welding Defects in Preprocessed TOFD Signal Using Linear Classifiers*”, Submetido para publicação no Journal of Nondestructive Evaluation.

[92] Veiga, J.L.B.C., Carvalho, A.A., Silva, I.C., Rebello, J.M.A., “Automação da Análise do Ensaio Ultra-Sônico Pulso-Eco Utilizando Redes Neurais Artificiais”, In: 3ª PANNDT - Conferência Pan-Americana de Ensaaios Não Destrutivos, Rio de Janeiro, Brasil, Junho, 2003.

[93] Silva, R.R., Calôba, L.P., Siqueira, M.H.S., Rebello, J.M.A., “Patterns Nonlinear Classifiers of Weld Defects in Industrial Radiographies”, In: 3ª PANNDT - Conferência Pan-Americana de Ensaaios Não Destrutivos, Rio de Janeiro, Brasil, Junho, 2003.