CONFIABILIDADE DE TÉCNICAS DE ENSAIOS NÃO DESTRUTIVOS NA INSPEÇÃO DE DUTOS UTILIZADOS NA INDÚSTRIA DO PETRÓLEO

Antonio Alves de Carvalho

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. Luís Volnei Sudati Sagrilo, D.Sc.

_____

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

_____

Prof. Cláudio Márcio do Nascimento Abreu Pereira, D.Sc.

_____

Prof. Fernando Luiz Bastian, Ph.D.

_____

Prof. Marcos Queija da Siqueira, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

JUNHO DE 2006

CARVALHO, ANTONIO ALVES DE

Confiabilidade de técnicas de ensaios não destrutivos na inspeção de dutos utilizados na indústria do petróleo [Rio de Janeiro] 2006

X, 291p. 29,7cm (COPPE/UFRJ, D.Sc., Engenharia Metalúrgica e de Materiais, 2006)

Tese - Universidade Federal do Rio de Janeiro, COPPE

1. Ensaios Não Destrutivos
2. Redes Neurais
3. Confiabilidade
4. POD

I. COPPE/UFRJ II. Título (série)

Dedico a minha esposa Glaucia,
por todo seu carinho e dedicação.

Agradecimentos

Ao professor João Marcos Alcoforado Rebello, pela orientação, apoio e disponibilidade no auxílio dos trabalhos e na resolução dos mais diversos problemas. Sua paciência e compreensão, principalmente nos momentos mais difíceis, foram fundamentais para a realização deste trabalho.

Ao professor Luís Volnei Sudati Sagrilo, pela orientação, apoio e pela atenção despendida sempre quando necessário. Sua participação e amizade foram imprescindíveis para o sucesso deste trabalho. Sagrilo, muito obrigado.

Ao Eng. e amigo Romeu Ricardo da Silva pelas sugestões que foram fornecidas e utilizadas em boa parte do estudo de redes neurais.

Ao Eng. e amigo Márcio Humberto da Silva Siqueira , pela constante disposição em ajudar quaisquer que fossem as tarefas.

A todos os colegas do LABOEND pela paciência e companheirismo no convívio diário, principalmente ao Demerson, Marcos Paulo e a Jordana pelo auxílio na parte experimental do trabalho.

Um agradecimento especial vai para o CENPES, pelo apoio irrestrito que sempre obtive daquele centro de pesquisa, principalmente do pessoal do TMEC e da DEMAN.

Aos Engenheiros Cláudio Soligo Camerini e Sérgio Damasceno Soares por disponibilizar material e pessoal qualificado para a confecção dos corpos de prova.

Ao Engenheiro Ivan Vicente Janvrot Miranda da empresa PipeWay por disponibilizar a ferramenta de pig para a realização dos ensaios experimentais.

Aos colegas do PEMM, professores, funcionários e alunos, pelo companheirismo durante todos estes anos.

Ao Eng. e amigo José Alexandre Barbosa de Farias pelo excelente apoio despendido durante a confecção dos corpos de prova.

Aos técnicos Guttemberg Coelho da Silva, Marcos Antonio da Silva e Fabiana Nazário Raphael e ao Engenheiro Carlos Henrique Francisco de Oliveira, pelo apoio dispensado na realização dos ensaios com pig.

Aos meus padrinhos Luciano e "Preta" e a todos seus familiares pela excelente amizade que obtive no Rio de Janeiro durante todos estes anos de batalha.

Aos meus familiares por todo apoio e motivação que sempre me dedicaram.

Ao CNPQ e a FAPERJ pelo apoio financeiro.

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

CONFIABILIDADE DE TÉCNICAS DE ENSAIOS NÃO DESTRUTIVOS NA INSPEÇÃO DE DUTOS UTILIZANDOS NA INDÚSTRIA DO PETRÓLEO

Antonio Alves de Carvalho

Junho / 2006

Orientadores: João Marcos Alcoforado Rebello
Luís Volnei Sudati Sagrilo

Programa: Engenharia Metalúrgica e de Materiais

Ao longo dos últimos anos várias pesquisas têm sido realizadas com o objetivo de desenvolver novas técnicas de ensaios não destrutivos, principalmente técnicas automáticas, para otimizar o ensaio e reduzir o tempo de inspeção. Por outro lado, poucos estudos foram desenvolvidos para avaliar a confiabilidade das técnicas já existentes assim como das novas técnicas desenvolvidas.

Este trabalho de tese tem por objetivo avaliar a confiabilidade de técnicas de ensaios não destrutivos utilizadas na inspeção de dutos. Para tanto foram aplicadas as técnicas de MFL (do inglês “magnetic flux leakage”) via pig instrumentado e as técnicas ultra-sônicas pulso-eco manual e automatizada e TOFD (do inglês “time of flight diffraction”) também automatizada. A técnica de MFL foi avaliada utilizando redes neurais artificiais no reconhecimento de padrões de sinais de defeito, enquanto a técnica de ultra-som foi avaliada utilizando curvas POD (do inglês “probability of detection”).

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

RELIABILITY OF NONDESTRUCTIVE TEST TECHNIQUES
IN THE INSPECTION OF PIPELINES USED IN THE OIL INDUSTRY

Antonio Alves de Carvalho

June / 2006

Advisors: João Marcos Alcoforado Rebello
Luís Volnei Sudati Sagrilo

Department: Metallurgical and Materials Engineering

Over the last years various researches have been carried out aiming to develop new techniques in nondestructive tests, mainly automatic techniques, to optimize the tests and reduce inspection time. On the other hand few studies have been developed to evaluate the reliability of the techniques either already in existence or the new techniques recently developed.

The work of this thesis aims to evaluate the reliability of nondestructive test techniques for the inspection of pipelines. Therefore the MLF (Magnetic Flux Leakage) technique with intelligent pig, the ultrasonic pulse-echo techniques both manual and automatic and the automatic TOFD (Time of Flight Diffraction) technique were considered. The MFL technique was evaluated using artificial neural networks for patterns recognition of defect signal, while the ultrasonic techniques were evaluated using POD (Probability of Detection) curves.

ÍNDICE

CAPÍTULO I – INTRODUÇÃO 1

CAPÍTULO II – REVISÃO BIBLIOGRAFICA 8
II.1. Pig 8
II.2. Campo Magnético de Fuga ou Magnetic Flux Leakage – MFL 16
II.2.1. Magnetização 19
II.2.2. Sensores 24
II.2.3. Registro e análise das descontinuidades 26
II.2.4. Sistema de potência 27
II.2.5. Visualização dos dados 27
II.3. Ensaio por ultra-som 30
II.3.1. Características e geometria do campo sônico 31
II.3.2. Interação da onda com uma descontinuidade 36
II.3.3. Realização do ensaio ultra-sônico 37
II.3.4. Resultado da inspeção 38
II.3.5. Ensaio ultra-sônico pulso-eco 43
II.3.6. Técnica do tempo de percurso da onda difratada – TOFD 45
II.4. Redes neurais artificiais 50
II.4.1. Modelo de um neurônio artificial 51
II.4.2. Arquitetura da rede neural artificial 54
II.4.3. Conhecimento 56
II.4.4. Processo de treinamento e aprendizagem 57
II.4.5. Perceptrons 59
II.4.6. Algoritmo de retropropagação do erro 61
II.5. Processamento de sinais 62
II.5.1. Análise de Fourier 62
II.5.2. Análise wavelet 64
II.5.2.1. Escala 67
II.5.2.2. Translação 67
II.5.2.3. Remoção de ruído 71

II.5.3. Filtro média móvel 72
II.5.4. Filtro Savitzky-Golay 72
II.6. Confiabilidade dos ensaios não destrutivos 75
II.7. Considerações finais 83

CAPÍTULO III – MATERIAIS E MÉTODOS 84
III.1. Introdução 84
III.2. Ensaios de MFL 84
III.2.1. Corpos de prova para ensaio de MFL 84
III.2.2. Inspeção dos corpos de prova com pig de MFL 87
III.2.3. Reconhecimento de padrões de sinais de MFL 90
III.2.4. Componentes principais de discriminação não linear 91
III.3. Ensaios de ultra-som 94
III.3.1. Corpos de prova para ensaios de ultra-som 94
III.3.2. Inspeção dos corpos de prova por ultra-som 97
III.3.2.1. Inspeção manual 97
III.3.2.2. Inspeção automatizada 98
III.4. Desenvolvimento de curva POD 102
III.5. Curva ROC 106

CAPÍTULO IV – RESULTADOS E DISCUSSÕES 109
IV.1. Detecção e classificação de padrões de defeitos por redes neurais artificiais 109
IV.1.1. Ensaios utilizando o 1^{o} conjunto de dados 112
IV.1.2. Ensaios utilizando o 2^{o} conjunto de dados 120
IV.1.3. Ensaios utilizando o 3^{o} conjunto de dados 124
IV.2. Pré-processamento dos sinais 126
IV.3. Curvas POD para a técnica de MFL 135
IV.3.1. POD experimental 135
IV.3.2. POD analítica 138
IV.3.3. Ajuste à uma distribuição de probabilidades 143
IV.4. Curvas POD para a técnica de ultra-som 146
IV.5. Curvas POD utilizando simulação 159

IV.5.1. Metodologia 160
IV.5.2. POD utilizando Simulação Monte Carlo 164
IV.5.3. Análise da detecção do defeito 167
IV.5.4. Exemplos de resultados numéricos 173
IV.5.5. Considerações finais 176

CAPÍTULO V – CONCLUSÕES 177

CAPÍTULO VI – REFERÊNCIAS BIBLIOGRÁFICAS 180

Anexo A – Corpos de prova para ensaio de MFL 198
Anexo B – Corpos de prova para ensaio de ultra-som 211
Anexo C – Resultados do ensaio de ultra-som pulso-eco automatizado 230
Anexo D – Resultados do ensaio de ultra-som por TOFD automatizado 257
Anexo E – Artigos publicados 272

CAPÍTULO I

INTRODUÇÃO

Transporte dutoviário é o método mais seguro e econômico para transferir fluidos (óleo e gás) em longas distâncias. Dado a sua grande eficiência, os dutos vêm sendo utilizados por diversas décadas, mas o seu envelhecimento aumenta o perigo de vazamento ou até mesmo de ruptura. Neste sentido, pode-se ressaltar ainda que muitos dutos passam próximos ou sob estradas, rodovias, vias navegáveis e mesmo dentro das cidades. Portanto, é necessário dispor de meios que permitam monitorar, avaliar e assegurar a integridade do duto, diminuindo o risco de vazamentos e consequentemente evitando danos contra o meio ambiente e a população. Há muito anos os ensaios não destrutivos vêm sendo usados com eficiência na avaliação das condições de dutos na indústria de petróleo.

Os Ensaios Não Destrutivos (END) são técnicas não invasivas largamente utilizadas na indústria com a finalidade de avaliar a integridade de produtos e equipamentos. A análise não destrutiva pode ser aplicada para a detecção e dimensionamento de descontinuidades nos materiais, avaliação de suas propriedades, medição de espessura, etc., podendo ser utilizada tanto no controle do processo e no controle da produção como sobre o equipamento em operação. Os END's podem ser aplicados ainda para auxiliar no desenvolvimento de novos materiais, aumentando sua qualidade, reduzindo seu custo e aumento sua vida útil.

Técnicas de ensaios não destrutivos estão sendo cada vez mais pesquisadas e utilizadas como métodos de avaliação de estruturas e sistemas de engenharia, tanto no projeto como durante toda sua vida útil. Na indústria do petróleo estas pesquisas vêm obtendo especial atenção principalmente devido às grandes conseqüências de uma falha em seus equipamentos, que vai desde desastres ambientais até perdas de vidas humanas. No entanto, um dos parâmetros que deve ser conhecido para a seleção mais adequada da técnica de ensaio não destrutivo que será empregada é a confiabilidade da mesma, a qual é avaliada através de curvas de probabilidade de detecção (POD), que representa a probabilidade de detectar um defeito de uma particular dimensão.

Existem várias técnicas de ensaios não destrutivos e dependendo do material, das condições do ensaio e dos objetivos desejados pode-se optar por uma ou por outra técnica para se obter uma melhor eficiência. Entre as técnicas mais utilizadas pode-se citar: ultra-som, radiografia, líquido penetrante, ensaio visual e as técnicas eletromagnéticas (correntes parasitas, partículas magnéticas e campo magnético de fuga). Na indústria petrolífera, para inspeção de dutos de transporte de fluido, três técnicas são consagradas devido sua eficiência e constante utilização: ultra-som, radiografia e campo magnético de fuga (do inglês *"Magnetic Flux Leakage" - MFL*).

A técnica do campo magnético de fuga é bastante difundida na indústria de petróleo para a detecção de descontinuidade e perda de espessura por corrosão em dutos. Esta técnica permite uma avaliação quantitativa do tamanho do defeito na parede do duto [1,2,3]. A técnica de MFL é utilizada para inspeção de dutos através de uma ferramenta conhecida por *pig* instrumentado ou *pig* inteligente. O *pig* se desloca no interior do duto impulsionado pela pressão do fluido e é equipado com vários sensores de MFL para registrar informações sobre as condições do duto.

Pigs com sensores ultra-sônicos também são utilizados para inspeção, sendo no entanto o seu uso mais restrito devido ao elevado custo desta operação e a necessidade de um líquido como acoplante entre o sensor e a parede do duto. Este tipo de equipamento é, portanto, geralmente utilizado apenas em situações que justifiquem seu uso, como por exemplo em dutos que apresentaram uma grande quantidade de indicações de descontinuidades na passagem do *pig* magnético. A inspeção por *pig* é a única utilizada em dutos onde não se tem acesso ou onde o acesso é precário, como por exemplo em dutos *offshore* ou enterrados. Já para dutos de fácil acesso, a técnica de ultra-som automatizado ou convencional é bastante utilizada, sendo que o método automatizado possui diversas vantagens sobre o método convencional, tais como: rapidez e fornecimento de imagens para interpretação dos resultados.

O ensaio radiográfico ainda é também muito utilizado na inspeção de dutos na indústria petrolífera. No entanto, esforços têm sido feitos no sentido de substituir a inspeção radiográfica por outros métodos devido, principalmente, aos inconvenientes da radiografia tais como: presença de radiação ionizante, que representa um perigo para o operador, e a necessidade de revelação do filme, que demanda tempo no informe dos resultados.

As técnicas de processamento de imagem, processamento de sinais e inteligência artificial, como as redes neurais artificiais, aliadas as técnicas de ensaios não destrutivos, têm dado importantes contribuições na avaliação da integridade de dutos.

Apesar do grande avanço nas tecnologias relacionadas ao desenvolvimento de novas técnicas de ensaios não destrutivos, pouco se tem feito no sentido de avaliar a confiabilidade tanto das técnicas ditas convencionais, de uso no dia a dia, como das novas técnicas que estão sendo pesquisadas e desenvolvidas.

O objetivo geral deste trabalho é avaliar a confiabilidade de técnicas de ensaios não destrutivos na inspeção de dutos utilizados na indústria de petróleo. Foram consideradas três diferentes técnicas de inspeção: MFL através da inspeção por *pig*, ultra-som automatizado e ultra-som manual.

Como objetivos específicos pode-se citar dois:

- Desenvolver classificadores de padrões de defeitos em cordões de solda de dutos, utilizando sinais de MFL e redes neurais artificiais.
- Desenvolver metodologia para gerar curvas POD (do inglês *Probability of Detection*) para o ensaio de ultra-som e MFL.

Os sinais de MFL foram avaliados utilizando classificadores de padrões implementados por redes neurais artificiais (RNA) para classificar automaticamente classes de defeitos em solda circunferencial de dutos. Com o propósito de simular a presença de defeitos, foram confeccionados dutos com defeitos inseridos artificialmente no cordão de solda. Os defeitos foram classificados em quatro classes: falta de penetração (FP), penetração excessiva (PE), corrosão interna (CI) e corrosão externa (CE). Foi avaliada a eficiência de redes neurais artificiais no reconhecimento destas classes de defeitos.

Para a inspeção com a técnica ultra-sônica, foram confeccionados dutos com duas classes de defeitos: falta de fusão (FF) e falta de penetração. Nestes ensaios foi utilizada a técnica de ultra-som automatizado empregando os métodos pulso-eco e *TOFD* (do inglês *Time of Flight Diffraction*) e a técnica ultra-sônica convencional empregando a inspeção manual por pulso-eco. Foi avaliada a eficiência destas técnicas na detecção destas classes de defeitos. Com o objetivo de quantificar a confiabilidade e sensibilidade das técnicas de ensaios não destrutivos, ultra-som e MFL, na detecção de defeitos, curvas POD foram desenvolvidas a partir dos dados obtidos nos ensaios experimentais.

Com o conceito de RBI (do inglês *Risk Based Inspection*) e manutenção centrada em confiabilidade as curvas PODs são de vital importância para otimizar o processo de inspeção. No conceito de RBI o resultado de inspeções anteriores pode ser utilizado para programar a próxima inspeção diferentemente do conceito de inspeções periódicas, em que durante toda vida útil do componente as inspeções eram realizadas em intervalos de tempo regulares, geralmente por exigências de certificadoras. Sendo que para a realização da inspeção era necessário parar a operação do componente, esvaziar, limpar e inspecionar e depois prepará-lo para colocar novamente em operação. No entanto, essas inspeções demandam tempo e dinheiro, não somente pelo custo da inspeção, mas principalmente pela retirada de um componente de operação. Entretanto, muitas vezes após todo este trabalho nenhuma ação é necessária.

A Figura I.1 apresenta genericamente a curva de projeto de um componente, onde a vida útil está no eixo das abscissas e o índice de confiabilidade β no eixo das ordenadas. Baseado na curva de projeto do componente e no nível de confiabilidade assumido, a primeira inspeção será realizada com aproximadamente 6 anos de operação do componente.

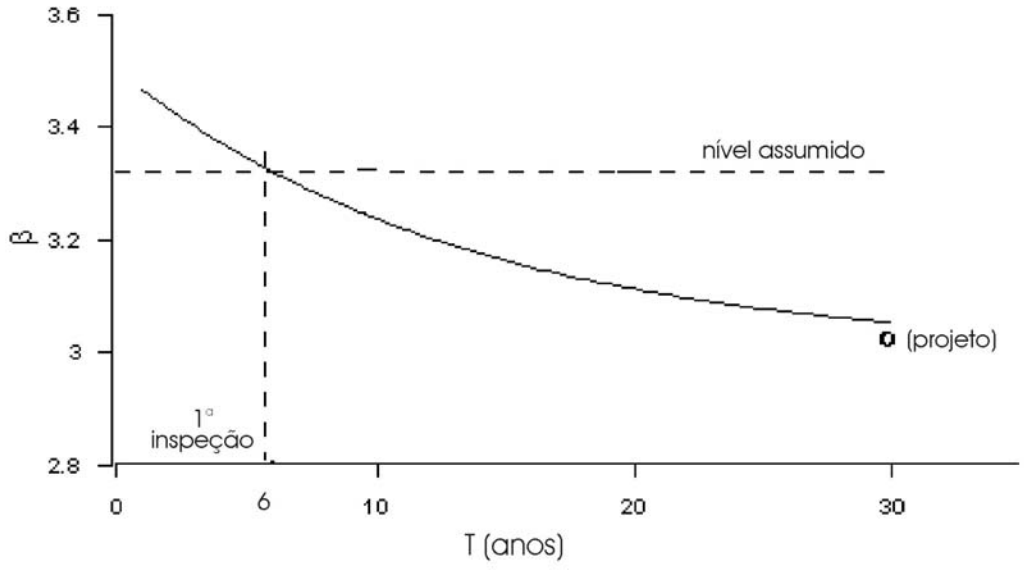

Figura I.1. *Variação do índice de confiabilidade em função do tempo.*

Após a estrutura ou equipamento estar operando, em função das diversas incertezas associadas ao sistema, também são realizadas inspeções periódicas para acompanhar os

possíveis pontos onde podem ocorrer propagações de trincas. Os resultados destas inspeções podem ser a detecção ou não de um de um defeito. Este resultado pode ser automaticamente incorporado na análise de confiabilidade, isto é, reavalia-se a probabilidade de falha ao longo do tempo condicionada ao resultado obtido na inspeção atual. Genericamente, isto é ilustrado na Figura I.2. Nesta figura, para fins didáticos, assume-se genericamente que no prazo que houve a primeira inspeção esperava-se uma trinca com um tamanho médio igual a E[a]. A curva A representa a confiabilidade após incorporar na análise o resultado de não detecção de trinca durante a inspeção realizada. Isto indica que a trinca não está crescendo como se imaginava e com isto a confiabilidade é maior do que a prevista inicialmente. Pode-se observar então que para o mesmo nível de confiabilidade (ou mesmo nível de risco) assumido na primeira inspeção, o prazo da segunda inspeção torna-se maior e, portanto, o custo global de manutenção da estrutura ou equipamento diminui.

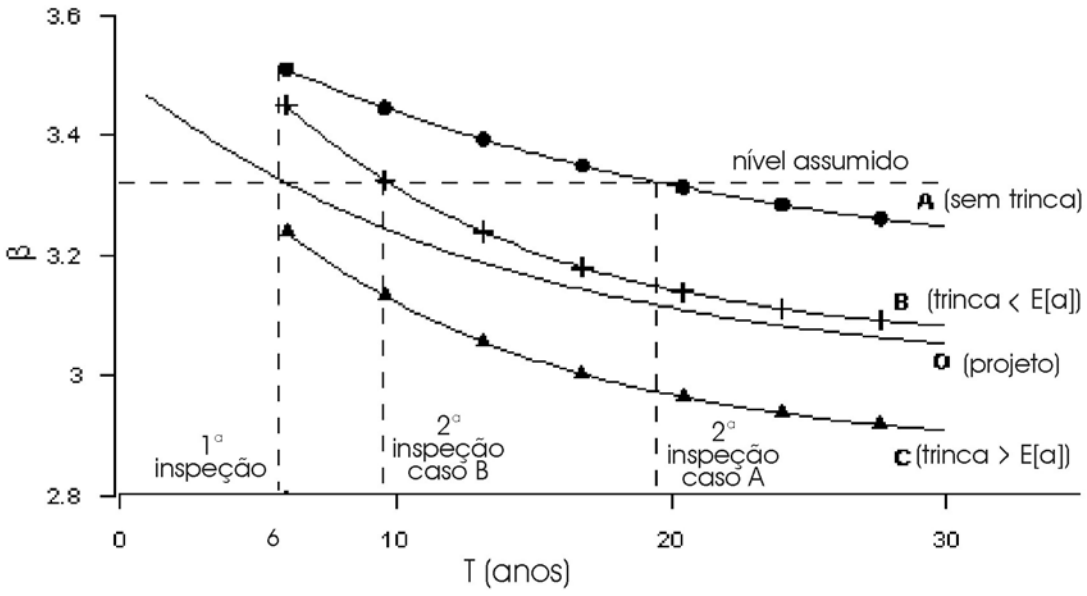

Figura I.2. *Variação da confiabilidade em função dos resultados das inspeções.*

A curva B ilustra genericamente o caso de detecção de uma trinca com um tamanho menor que o esperado e aponta para um prazo mais curto para a segunda inspeção. A curva C ilustra o caso de detecção de uma trinca cujo tamanho é maior que o valor esperado. Neste

último caso, indica-se uma re-avaliação da estrutura (ou equipamento) para decidir sobre repará-la ou não imediatamente.

Como apresentado anteriormente, as técnicas de confiabilidade permitem que os resultados de inspeções anteriores sejam levados em conta no planejamento de inspeções futuras bem como na tomada de decisões sobre a execução ou não de reparos.

Um aspecto importante nesta análise de resultados de inspeções é a confiabilidade da técnica não destrutiva de inspeção que está sendo utilizada. Neste tipo de análise este aspecto é representado pela curva POD da técnica de inspeção empregada. A POD é uma curva matemática similar a uma função cumulativa de probabilidades (varia entre 0 a 1), normalmente representada por POD(a). POD(a) significa a probabilidade da técnica de inspeção detectar defeitos com tamanhos iguais a "a". A Figura I.3 ilustra genericamente duas PODs, uma para a técnica de partículas magnéticas e outra para inspeção visual, ambas submersas. Nesta figura nota-se claramente que um defeito, por exemplo, de 4mm tem praticamente 100% de chance de ser detectado através de partículas magnéticas, enquanto que no caso de uma inspeção visual as chances diminuem para aproximadamente 50%.

Outra importante aplicação das curvas PODs é na seleção adequada da técnica de inspeção a ser utilizada. Por exemplo, se o objetivo de uma inspeção é detectar defeitos iguais ou superiores a 15mm, ou seja, defeitos menores do que este não oferecem risco para o equipamento, a partir das curvas da Figura I.3 pode ser constatado que para este comprimento de defeito, a técnica de inspeção visual possui a mesma probabilidade de detecção do que a técnica de partículas magnéticas, sendo que o custo da primeira é inferior.

Empregando-se uma metodologia baseada em confiabilidade é possível dar uma abordagem científica na elaboração de um planejamento racional de inspeções. Entretanto, uma das suas principais dificuldades recai no fato de que existem poucos dados disponíveis na literatura sobre as PODs das diversas técnicas não-destrutivas de inspeção. Por sua vez, existem vários fatores que influenciam sobre as mesmas tais como: local da inspeção, qualificação da mão-de-obra, grau de automatização, etc. Estes fatos enfatizam a necessidade de serem feitas mais pesquisas nesta área para que efetivamente possam ser realizadas inspeções baseadas em técnicas de risco.

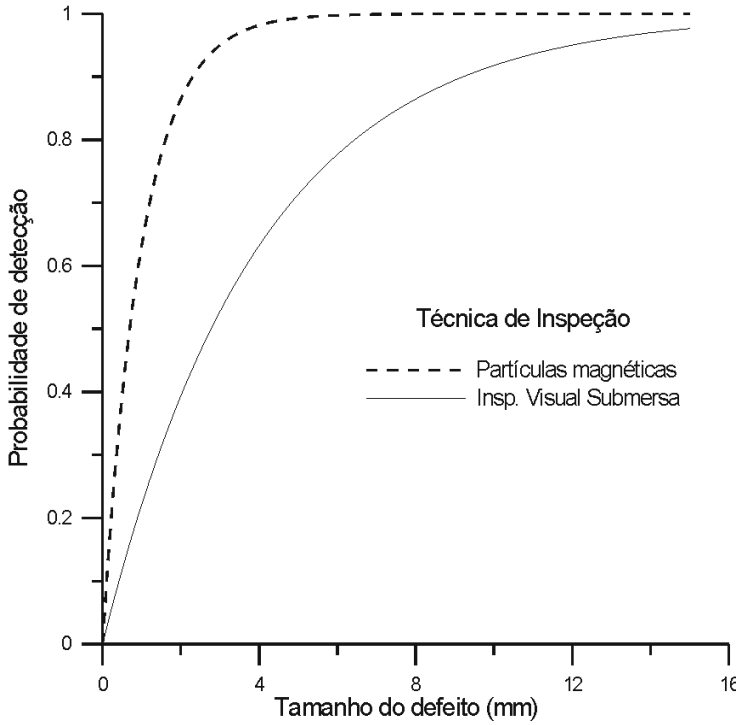

Figura I.3. *Curvas PoD.*

CAPÍTULO II

REVISÃO BIBLIOGRÁFICA

Neste capítulo é realizada uma revisão bibliográfica sobre os principais assuntos que envolvem o tema deste trabalho de tese para permitir um entendimento mais claro do seu desenvolvimento e objetivos. Inicialmente, faz-se um breve resumo sobre a ferramenta de *pig*, a qual é utilizada para inspeção de dutos (Seção II.1). Em seguida comenta-se sobre as técnicas de ensaios não destrutivos utilizadas no trabalho: campo magnético de fuga (Seção II.2) e ultra-som (Seção II.3). Na Seção II.4, faz-se uma abordagem sobre a ferramenta de redes neurais artificiais, utilizada neste trabalho como classificadores de padrões de sinais e a Seção II.5 apresenta alguns tipos de processamentos aplicados nestes sinais. Finalmente, na Seção II.6 faz-se uma explanação sobre a confiabilidade dos ensaios não destrutivos.

II.1. PIG

Pig é um dispositivo que é inserido dentro do duto e que se desloca livremente através dele, sendo impulsionado pelo próprio fluido. Os *pigs* são largamente empregados na indústria de petróleo para avaliação das condições de tubulações em todas as fases de operação.

O termo *pig* é originário dos Estados Unidos, mas a origem do termo nunca foi bem explicada. Existem várias hipóteses, sendo a mais largamente aceita a de que o som emitido pelo *pig* quando se desloca dentro do duto se assemelha ao emitido pelo animal porco (em inglês *pig*), e também a aparência do *pig* quando emerge da linha coberto por óleo cru e outras incrustações induz a uma analogia com o referido animal. A sugestão que *pig* seria um acrônimo para *Pipeline Inspection Gauge* (ou *Gizmo*) é bastante improvável, uma vez que a expressão é usada muito antes da inspeção tornar-se um fator importante [4].

Os *pigs* foram inicialmente desenvolvidos como ferramentas de limpeza para remover depósitos que podiam obstruir ou retardar o fluxo através de um duto, reduzindo

sua eficiência [5,6]. Hoje os *pigs* são usados durante todas as fases da vida do duto por diferentes razões. De uma maneira geral pode-se dizer que existem três motivos principais para a utilização de um *pig* [7,8]:

- Juntar ou separar produtos;
- Limpeza e remoção de sólidos e líquidos;
- Inspeção interna;

O *pig* utilizado para inspeção interna é denominado *pig* inteligente ou instrumentado (Figura II.1), enquanto que os demais são denominados de *pigs* convencionais. Como exemplo de *pig* convencional pode-se citar o *pig* de espuma, Figura II.2(a) e o *pig* de esfera, Figura II.2(b).

Figura II.1. *Exemplo de pig instrumentado.*

(a) (b) 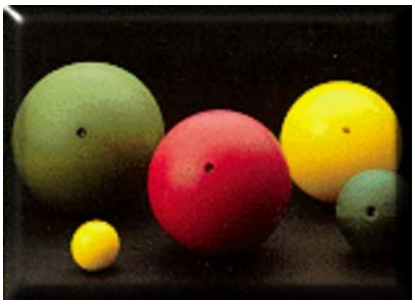

Figura II.2. *Exemplo de pig convencional; (a) pig de espuma, (b) pig de esfera [7].*

Os *pigs* inteligentes possuem instrumentação eletrônica adequada a cada método de inspeção para medir ou gravar parâmetros capazes de avaliar o estado de um duto. A utilização de *pigs* inteligentes permite o acesso aos dutos enterrados ou submarinos, o que seria impossível através dos métodos convencionais. Uma vantagem adicional é a possibilidade de executar a passagem do *pig* com o duto em operação, sem o transtorno causado pela parada de operação da linha. Apesar da principal aplicação deste dispositivo ser para dimensionamento de perda de espessura por corrosão e detecção de descontinuidades, existem várias outras informações que podem ser fornecidas pelos *pigs* inteligentes [4,9,10]:

- Medida do diâmetro e geometria da tubulação;
- Determinação do perfil do duto;
- Registro de pressão e temperatura;
- Detecção de perda de metal por corrosão;
- Detecção de defeitos;
- Inspeção visual por meio de câmara de vídeo;
- Detecção de vazamentos [11,12];
- Monitoramento e medidas de curvatura;

O grande desenvolvimento da ferramenta *pig* deve-se ao fato de que um crescente número de dutos vêm atingindo o final de sua vida útil de projeto, e desta forma devem ser rigorosamente inspecionados a fim de verificar possíveis falhas e permitir uma decisão segura quanto a sua continuidade operacional.

Embora o conhecimento do comportamento e eficiência dos *pigs* esteja caminhando para se tornar uma técnica mais precisa, muitas dúvidas e incertezas ainda existem nas operações com estes dispositivos. Com o auxílio de modelos numéricos de predição do comportamento dos *pigs* e com o nível de conhecimento hoje acumulado, é possível minimizar os riscos operacionais e até especificar o tipo de *pig* mais adequado para cada operação. O maior problema hoje, na operação de um *pig*, ocorre quando ele não chega na outra extremidade causando, em muitos casos, a interrupção da operação. *Pigs* podem ficar presos na linha por três motivos:

- Travado devido ao acumulo de detritos à frente do *pig* durante uma operação de limpeza;
- Bloqueado por um acessório ou por um dano existente na tubulação;
- Parado na tubulação devido a desgaste excessivo ou dano no *pig*.

Por esses motivos, em todos os projetos de sistemas de dutos devem ser previstas a utilização rotineira de *pigs* durante toda a vida útil da linha, que devem ser projetados prevendo facilidades para essa aplicação. Deverão existir lançadores e recebedores de *pigs*; os raios de curvatura das linhas deverão ser compatíveis com os tipos de *pigs* que se pretende utilizar e suas derivações em geral deverão ser dotadas de barras de direcionamento, exceto quando se deseja passar um *pig* de espuma de baixa densidade [8,13,14].

As primeiras tentativas de detectar corrosão interna em duto foram realizadas através de um *pig* que registrava a temperatura e a pressão do fluido dentro do duto e o seu respectivo posicionamento. A explicação atrás dessa metodologia é que variações na pressão do fluido e em particular na temperatura podem, geralmente, determinar o ponto onde possa existir acumulo de água e portanto onde corrosão pode ocorrer. Os técnicos da T.D.Williamson Inc. [15] foram os pioneiros nesta aproximação e eles construíram inúmeros protótipos de *pigs* para registrar tanto a temperatura quanto a pressão na linha. Muitos testes foram conduzidos por eles durante o final da década de 50 e o início da década de 60. O principal problema com o registro da temperatura era o baixo tempo de resposta dos sensores e quando a pressão era registrada o próprio *pig* causava diferenças

locais, ocasionando problemas ainda maiores. Modernos sensores de pressão e temperatura têm resolvido esses problemas.

Atualmente estão disponíveis mais de trinta tipos de *pigs* inteligentes capazes de prover várias informações à respeito do duto. Esses *pigs* são bastante diferentes entre si e altamente sofisticados [16,17,18,19]. Devido a especialização necessária não são comercializados, sendo normalmente disponíveis sobre a forma de contratação de serviços, oferecidos muitas vezes pelo próprio fabricante. O custo desses serviços varia bastante conforme a complexidade do equipamento e principalmente com a extensão do duto. Esses *pigs* são equipados com sensores, unidades de aquisição e processamento de dados e fontes de energia, podendo viajar por centenas de quilômetros submetidos a altas pressões em contato com o fluido.

Os métodos principais de inspeção utilizados por *pigs* inteligentes são: eletromecânico, ensaio visual por meio de câmaras de vídeo, ultra-som e magnéticos (Figura II.3). Os *pigs* eletromecânicos são dispositivos geométricos que detectam mudanças no diâmetro interno do duto causadas por problemas tais como: ovalizações, dentes, válvulas parcialmente fechadas, mudanças na espessura da parede, etc. Estes problemas são detectados através de braços articulados que são pressionados, por molas, contra a parede do duto [20,21]. Estes braços podem estar diretamente em contato com a parede do duto em rodas deslizantes, como mostrados na Figura II.3(e) ou podem ser montados dentro de copos. Qualquer mudança no diâmetro do duto causa um movimento no braço que é transladado mecanicamente para uma roda central, a qual é registrada por um módulo instrumentado dentro do corpo do *pig*. O pig geométrico pode ainda ser equipado com uma placa calibradora (Figura II.3(d)) com o objetivo de verificar a continuidade do diâmetro interno do duto. O *pig* topográfico (Figura II.3(a)) é um equipamento que permite obter a configuração espacial do duto e o seu princípio de funcionamento é baseado em um sistema inercial composto de giroscópios e acelerômetros que geram os dados referentes ao posicionamento e orientação do *pig*.

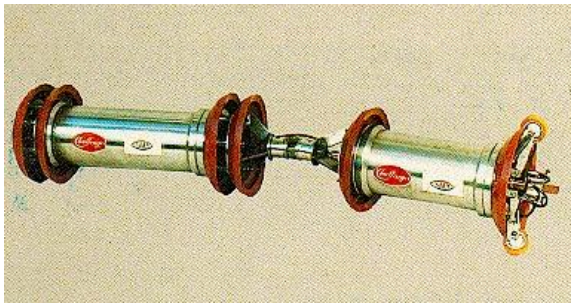

(a)

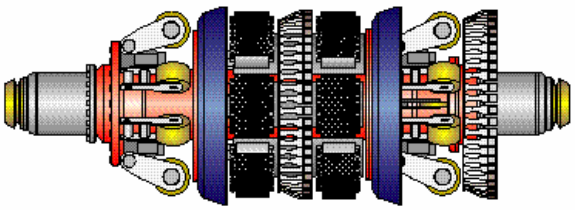

(b)

(c)

(d)

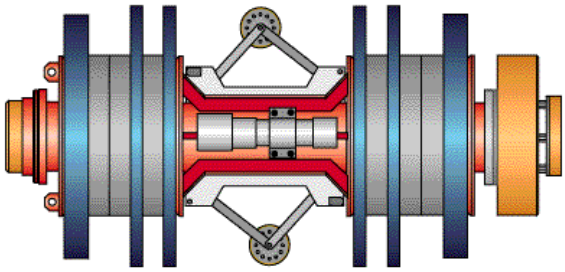

(e)

Figura II.3. *Exemplos de pigs inteligentes: (a) pig topográfico, (b) pig magnético, (c) pig ultra-sônico, (d) e (e) pig geométrico [22].*

Os *pigs* inteligentes destinados a detectar perda de espessura na parede do duto (Figura II.3 (b) e (c)) foram os que tiveram os maiores investimentos em pesquisa e desenvolvimento nos últimos anos e atualmente existem duas técnicas consagradas para essa aplicação: campo magnético de fuga (MFL, do inglês "*Magnetic Flux Leakage*") e ultra-sônico. Aproximadamente 90% de todas as inspeções de perda de metal com *pig* são realizadas utilizando a técnica do campo magnético de fuga, usualmente conhecido por *pig* magnético [1].

A técnica do campo magnético de fuga é baseada na magnetização da parede do duto e a detecção, por meio de sensores, do campo de fuga devido a perda de metal ou a outras irregularidades na tubulação. Através de padrões de sinais de MFL é possível identificar e reconhecer defeitos de perda de espessura por corrosão ou outras características do duto, tais como: solda circunferencial, solda com costura, válvulas, acessórios, goivagem, solda esmerilhada, dentes, trincas e inclusões não metálicas [1,23,24]. A Figura II.4 mostra um desenho esquemático do princípio de funcionamento do *pig* magnético e a Figura II.5 mostra um desenho deste dispositivo em operação. O *pig* magnético é composto, normalmente, por cinco módulos ou sistemas principais:

- Um módulo guia que é responsável pela propulsão da ferramenta através da linha. O diferencial de pressão agindo no módulo guia arrasta o *pig* através da tubulação;
- Um módulo de magnetização, responsável pela magnetização do duto;
- Um módulo de registro de dados, que amplifica, filtra e armazena os sinais medidos;
- Um sistema de sensores, usado para medir o sinal de fuga do fluxo magnético;
- Um sistema de potência, que fornece potência através de baterias para o sistema de registro dos dados e para o sistema de sensores (se necessário).

O princípio de funcionamento do *pig* ultra-sônico é semelhante ao *pig* magnético, não sendo, no entanto, necessário magnetizar a tubulação, uma vez que são utilizados transdutores (sensores ultra-sônicos) para detectar a perda de espessura na parede da tubulação (Figura II.6) [25,26].

Neste trabalho serão utilizados dados obtidos por *pig* magnético através da técnica de MFL.

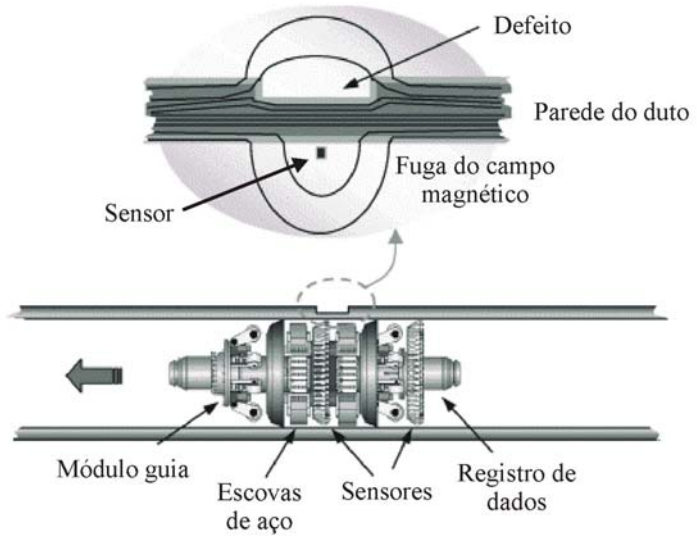

Figura II.4. *Princípio de funcionamento do pig magnético.*

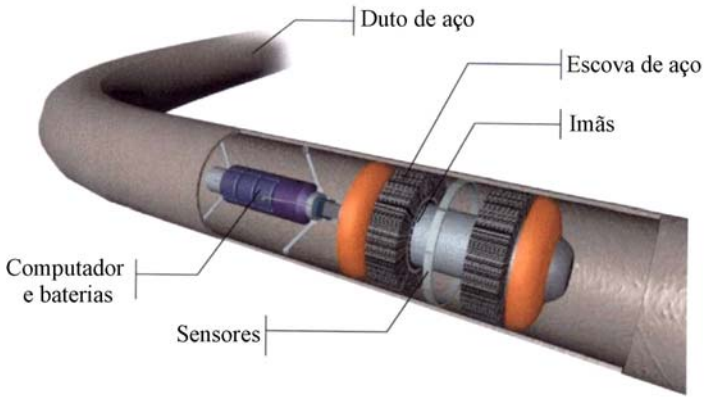

Figura II.5. *Pig magnético em operação.*

Figura II.6. *Pig ultra-sônico.*

II.2. CAMPO MAGNÉTICO DE FUGA ou *"MAGNETIC FLUX LEAKAGE" - MFL*

Inspeção com campo magnético inclui alguns dos métodos mais antigos e mais largamente utilizados para avaliação não destrutiva de materiais. Historicamente, tais métodos têm sido usados por mais de 50 anos na avaliação de materiais magnéticos para detecção de defeitos tais como trincas, vazios ou inclusões de materiais estranhos. Mais recentemente, métodos magnéticos para avaliação de outras propriedades, tais como tamanho de grão, textura ou dureza tem recebido especial atenção [27]. Todos os métodos magnéticos de detecção de falhas baseiam-se de alguma maneira na detecção e medida do campo magnético de fuga próximo a superfície do material, e que é causada pela presença da falha. Por esta razão, inspeções com técnicas magnéticas são geralmente descritas como fluxo do campo de fuga ou método de perturbação magnética [28].

A tecnologia do campo magnético de fuga ou "*Magnetic Flux Leakage" – MFL* tem sido utilizada com sucesso como ferramenta de inspeção em dutos desde sua introdução pela empresa Tuboscope em 1965 [29,30]. Como já dito anteriormente, aproximadamente 90% de todas as inspeções de perda de metal em dutos são realizadas por meio de *pig* inteligente utilizando a técnica do campo magnético de fuga. Portanto, a tecnologia MFL pode ser considerada como a técnica mais importante para inspeção de perda de metal e detecção de defeitos em dutos [1]. Esta técnica consiste em submeter um material magneticamente permeável a um campo magnético externo conhecido e medir a sua resposta através de sensores apropriados. Os princípios da magnetostática mostram que se o campo magnético externo for uniforme, o campo magnético dentro de um material homogêneo também o será. Numa geometria simples, como uma superfície plana, se o campo magnético aplicado for paralelo a esta superfície, o campo interno ao material também será paralelo mas com intensidade diferente. Caso este material apresente algum defeito não magnético na superfície ou no seu interior, o campo magnético externo sofrerá uma perturbação, que dependerá de vários fatores, tais como intensidade do campo magnético aplicado, geometria do defeito, material ensaiado etc [29,31,32,33]. Esta perturbação do campo é usualmente chamada de campo de fuga, pois aparenta ser uma "fuga" do campo magnético do material para o ar. A Figura II.7 ilustra as linhas de campo magnético para três níveis de magnetização distintos.

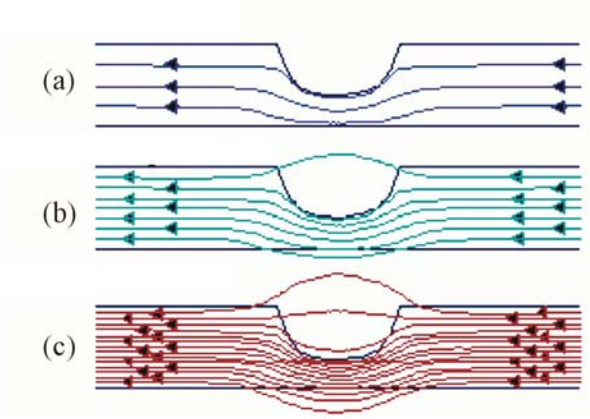

Figura II.7. *Linhas de fluxo magnético para três níveis de magnetização: (a) baixa magnetização, (b) média magnetização e (c) alta magnetização.*

Se o campo aplicado for suficientemente intenso para saturar o material magnético, a fuga pode ser explicada pela redução da área da seção reta do material transversal às linhas de campo [34]. Esta redução faz com que o fluxo aumente em torno do defeito, mas como o material já está saturado, o fluxo adicional escapa do material para o ar. Porém, mesmo com um campo aplicado baixo, como o terrestre, o efeito do campo de fuga aparece devido ao surgimento de pólos magnéticos na superfície do defeito, mas não sendo suficientemente intenso para ser medido por sensores [35]. Uma diferença importante entre níveis de magnetização baixo e alto é que para campos baixos é praticamente impossível detectar defeitos sub-superficiais ou superficiais no lado oposto ao da medida [36].

O principio do campo magnético de fuga em uma descontinuidade é ilustrado na Figura II.8. A Figura II.8(a) mostra uma barra uniformemente magnetizada, que consiste de um grande número de magnetos elementares alinhados com a direção da magnetização. Dentro do material, cada pólo magnético é compensado exatamente pela presença de um pólo adjacente de polaridade oposta e o resultado da rede é que os pólos internos não contribuem para o campo magnético fora do material. Na superfície, contudo, os pólos magnéticos não são compensados e portanto produzem um campo magnético na região em volta ao corpo de prova. Isto é ilustrado na Figura II.8(a) pelas linhas de fluxo conectando os pólos elementares não compensados.

Se um entalhe é cortado na barra, como ilustrado na Figura II.8(b), os pólos da superfície deste entalhe serão agora não compensados e portanto produzem um campo magnético localizado próximo ao entalhe. Este campo magnético adicional, que é representado pelas linhas de fluxo extras na Figura II.8(b), é o campo de fuga associado com o entalhe.

A Figura II.8 apesar de adequada para o entendimento qualitativo da origem do campo magnético de fuga, não produz uma precisa descrição quantitativa. A dificuldade está em assumir que a magnetização no material permanece uniforme quando a falha é introduzida. Em geral, isto não acontece, porque a presença da falha muda o campo magnético na sua vizinhança, e isto conduz a uma mudança na magnetização próximo a falha. Com relação a Figura II.8(b), isto significa que a força e orientação dos dipólos magnéticos realmente variam de ponto a ponto na vizinhança da falha e esta variação também contribui para o campo de fuga na falha. O resultado final é que a precisa descrição do campo de fuga na falha representa um difícil problema matemático que usualmente requer um algoritmo computacional especial para sua solução [35,37].

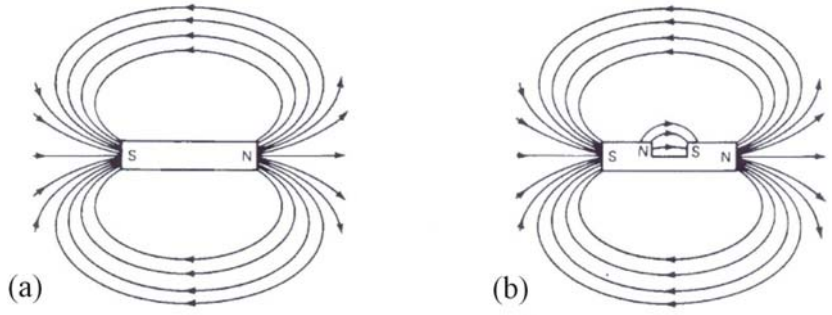

Figura II.8. *Origem do campo de fuga; (a) Linhas de fluxo magnético numa barra sem defeito; (b) Linhas de fluxo numa barra com um entalhe na superfície.*

Existem alguns fatores que afetam a precisão na detecção e caracterização de descontinuidades pela técnica MFL, estes fatores serão discutidos nas seções seguintes.

II.2.1. Magnetização

O sistema de magnetização de uma ferramenta de MFL tem por objetivo induzir um campo magnético na parede do duto para interagir com as descontinuidades produzindo assim fuga deste campo. O projeto de um sistema de magnetização tem por objetivo produzir um campo magnético que seja:

- Forte suficiente para estabelecer um fluxo magnético na parede do duto próximo a saturação;
- Uniforme ao longo da espessura da parede, de modo que o sinal medido seja relacionado mais linearmente as características da falha;
- Consistente em magnitude ao longo do comprimento do duto, para que medidas da fuga de fluxo possam ser comparadas em diferentes localizações durante a inspeção.

Em geral, a detecção de um defeito é mais fortemente afetada pela intensidade de campo aplicado, sem exigências quanto sua uniformidade, enquanto a caracterização da natureza do defeito requer um campo que seja forte, uniforme e consistente. O campo magnético aplicado é função do sistema de magnetização, do material do duto e de variações que são introduzidas por parâmetros operacionais, como a velocidade da ferramenta de *pig* e tensões na parede do duto devido a pressão do fluido [1, 29]. O nível de magnetização aplicado diminui com o aumento da velocidade do *pig*, enquanto que tensões na parede do duto afetam a permeabilidade do aço, tornando a análise do registro da inspeção mais difícil, vide Figura II.9 [29]. Entende-se por permeabilidade magnética uma medida da facilidade do fluxo magnético se propagar através de um material magnético.

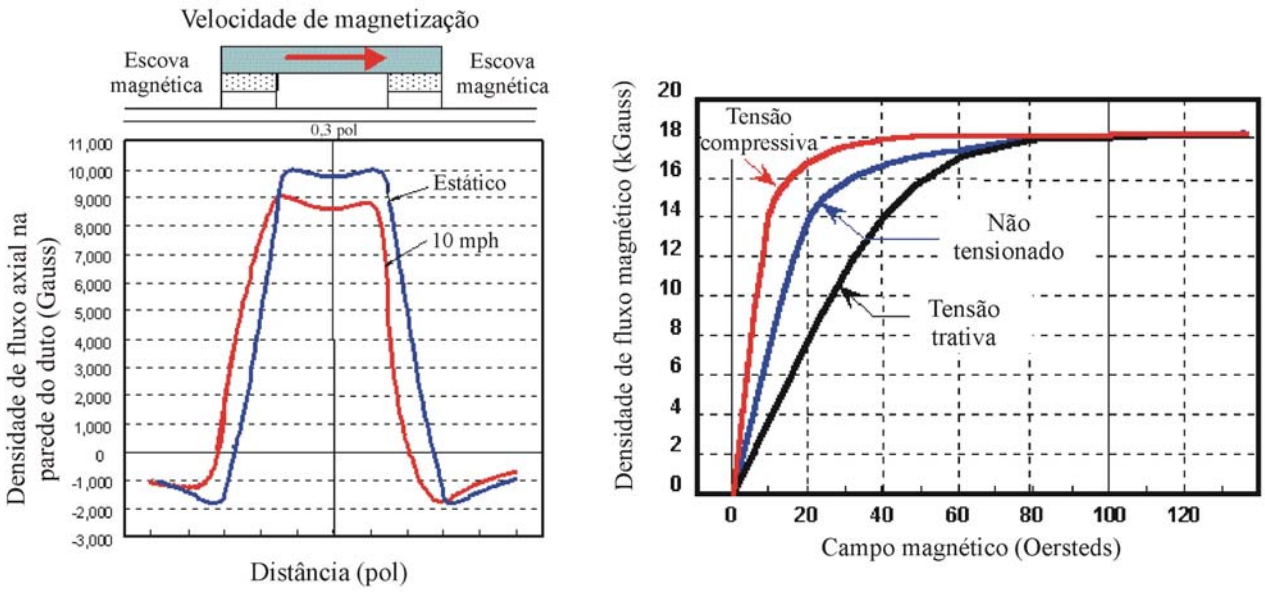

(a) (b)

Figura II.9. *Efeito da velocidade do pig (a) e da tensão na parede do tubo (b) na magnetização aplicada.*

A relação entre o campo magnético aplicado e a densidade de fluxo na parede do duto é não-linear (Figura II.10). Para baixos níveis de campo aplicado, uma pequena mudança neste campo produz uma grande mudança na densidade de fluxo. Para médios níveis, a relação é altamente não-linear. Para altos níveis, grandes mudanças no campo aplicado produzem pequenas mudanças no fluxo.

Portanto, a intensidade do sistema de magnetização tem uma forte influência no campo magnético aplicado. Alguns sistemas de magnetização para *pig* de detecção de corrosão, são geralmente projetados para produzir saturação magnética na parede do duto, de tal maneira que uma redução da espessura da parede cause uma fuga do fluxo magnético. Saturação magnética, pode ser definida como o grau de magnetização onde um aumento na intensidade do campo magnético não produz mudanças significativas na densidade de fluxo [29].

Para uma determinada intensidade de campo magnético, um aumento na espessura da parede do duto, diminuirá a densidade de fluxo no duto. Portanto, a intensidade do sistema de magnetização deve ser adequada à espessura da parede do duto a ser

inspecionada. Este é um fator limitante deste ensaio, porque dutos de parede muito espessa requerem alta intensidade de campo magnético para alcançar a saturação, o que pode vir a ser um problema em certos casos.

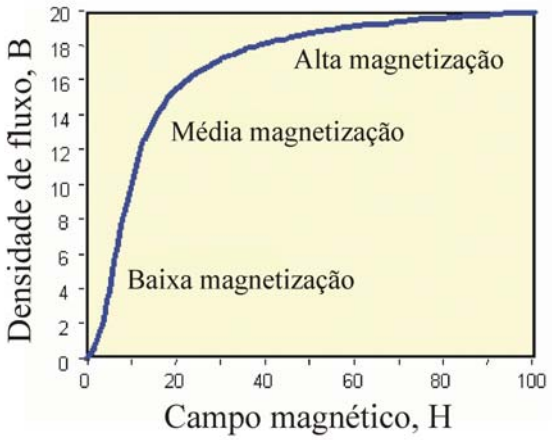

Figura II.10. *Curva de magnetização típica.*

O efeito do nível de magnetização no campo de fuga de fluxo magnético para um defeito de perda de metal é ilustrado na Figura II.11. O gráfico da Figura II.11 representa a componente tangencial do campo magnético na linha de centro da região de perda de metal [29]. O defeito possui profundidade de 50% da espessura da parede do duto, 38mm de comprimento e 50mm de largura. O duto possui 7,6mm de espessura de parede. Quatro campos de fuga de fluxo são mostrados separadamente: 6, 12, 16 e 18 kGauss. O nível de 6 kGauss corresponde a um baixo nível de magnetização, enquanto que os demais correspondem a um médio nível de magnetização.

Pode-se observar pelo gráfico da Figura II.11 que existem duas partes na medida do sinal: (1) a linha base do sinal e (2) a altura do pico do sinal. A linha base é o sinal que estará presente mesmo na ausência de perda de metal. A linha base é aproximadamente 320 Gauss para uma densidade de fluxo aplicada de 18 kGauss e 60 Gauss para uma densidade de fluxo de 6 kGauss [29]. A altura do pico do sinal corresponde ao sinal originado pela fuga do fluxo magnético no defeito. O sinal de fuga de fluxo magnético é 585 Gauss para uma densidade de fluxo aplicada de 18 kGauss e 80 Gauss para uma densidade de fluxo aplicada de 6 kGauss. O aumento na fuga de fluxo magnético devido ao defeito é a diferença entre a linha base e o sinal de fuga de fluxo total. Para o caso de 18 kGauss, o

aumento é de 256 Gauss (585 Gauss menos 320 Gauss), que é aproximadamente 80% da linha base. Para o caso de 6 kGauss, o aumento é 20 Gauss, que é aproximadamente 30% da linha base [29].

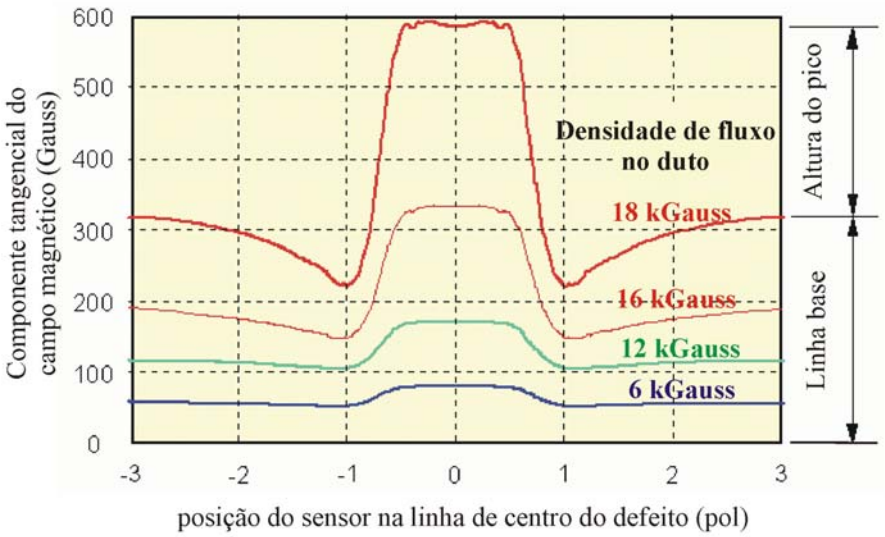

Figura II.11. *Efeito do nível de magnetização em um defeito.*

Um sistema de magnetização pode ser formado por magnetos permanentes (ou naturais) ou eletromagnetos. Magnetos permanentes têm carga constante e não requerem potência elétrica para operar. Por outro lado, eletromagnetos geram campos magnéticos por meio de uma corrente elétrica que passa através de uma bobina. A potência do eletromagneto pode ser ajustada pelo o aumento ou diminuição da corrente elétrica que passa através da bobina, ou ainda variando-se o número de voltas da bobina (Figura II.12).

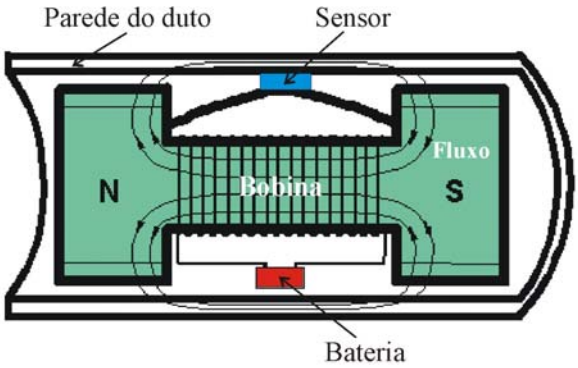

Figura II.12. *Desenho de um eletromagneto.*

O ajuste da intensidade magnética é um fator importante, uma vez que para detecção e caracterização da natureza de defeitos geométricos como perda de metal, altos níveis de magnetização são preferidos. Por outro lado, defeitos mecânicos como dentes ou goivagem [24], requerem médios ou baixos níveis de magnetização para sua detecção [29]. Isto ocorre porque enquanto um defeito de perda de metal causa um aumento da fuga do fluxo magnético, um defeito de goivagem causa uma redução deste fluxo.

Um sistema com magnetos permanentes é composto por um número de magnetos montados em volta da circunferência da ferramenta, igualmente espaçados para produzir um campo uniforme em toda circunferência da parede do duto. Estes magnetos são unidos a escovas de aço que friccionam contra a parede do duto (Figuras II.13 e II.14). As escovas são utilizadas para acoplar eficientemente o campo magnético à parede do duto e são parte integral do sistema de magnetização, ajudando a absorver choques em raiz de soldas, restrições e dentes na tubulação, que podem resultar em penetração interna.

O sistema de magnetização é também um fator limitante da velocidade do pig. Para duto de parede espessa, a velocidade deve ser reduzida consideravelmente para que haja tempo necessário para o fluxo saturar a parede do duto.

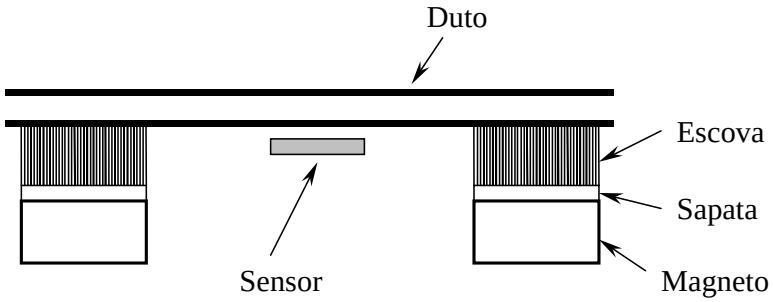

Figura II.13. *Esquema da montagem magnética.*

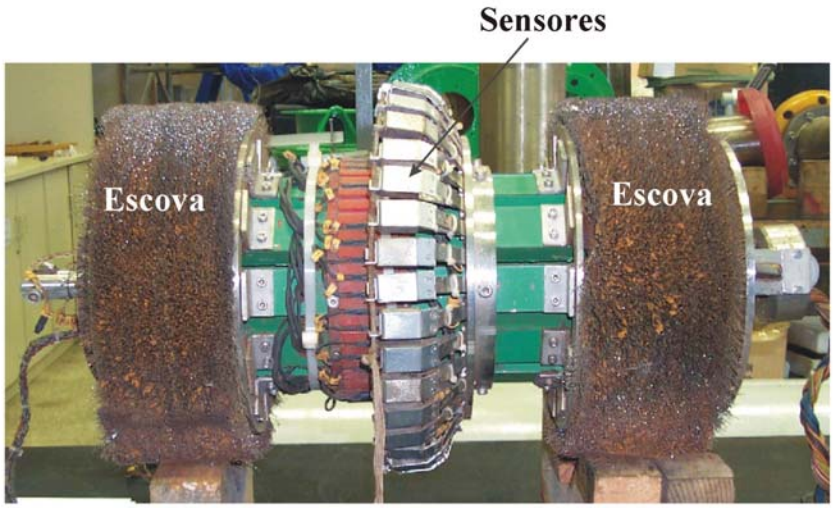

Figura II.14. *Montagem das escovas e sensores do pig magnético.*

II.2.2. Sensores

O objetivo do sistema de sensores de uma ferramenta de MFL é medir a fuga do fluxo magnético (Figura II.15). O sistema de medida converte o fluxo magnético em um sinal elétrico que pode ser armazenado e analisado. Todos os sistemas de sensores filtram e calculam a média do sinal real para reduzir ruídos presentes que podem dificultar a análise dos resultados. Pode-se dizer que o sistema de sensores possui duas metas principais: a primeira é produzir informação suficiente para permitir a detecção e caracterização dos defeitos e a segunda é produzir uma quantidade de informação que possa ser processada para análise das indicações. No entanto, estas duas metas são, geralmente, conflitantes, uma vez que a quantidade de informação necessária para a precisa caracterização, dimensionamento e localização das indicações ocupa, em geral, grande espaço de memória em computadores, dificultando senão inviabilizando seu processamento posterior, levando em consideração que o ensaio é realizado em longas extensões da tubulação. Por esse motivo, métodos de compactação de dados são geralmente utilizados.

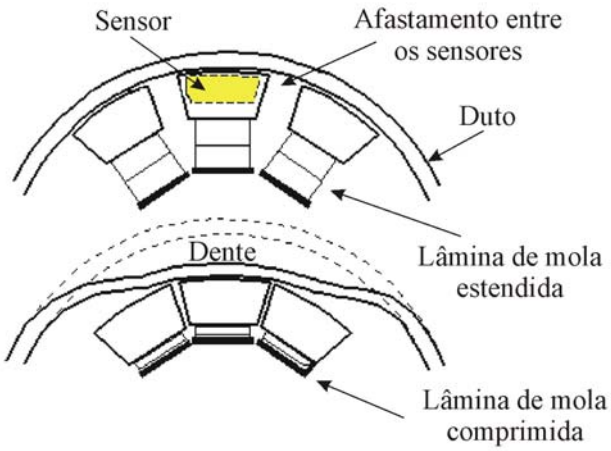

Figura II.15. *Sistema de sensores.*

Dois tipos de sensores são geralmente utilizados nas ferramentas de MFL: bobinas indutoras e sensores Hall (Figura II.16). Bobinas medem a taxa de mudança do campo magnético, enquanto elemento Hall mede o campo magnético absoluto. O elemento Hall converte diretamente nível de campo magnético em uma voltagem de saída. Historicamente, a bobina de indução tem sido o tipo de sensor mais largamente utilizado, principalmente porque não requer fonte de potência para o seu funcionamento; no entanto ela limita a velocidade de deslocamento da ferramenta de *pig*. Por outro lado, sensores Hall são mais sensíveis para pequenas indicações, são menores e não requerem um limite ou velocidade mínima para funcionar. Porém, a sua maior desvantagem, é a necessidade de uma fonte de potência para o seu funcionamento [1,29].

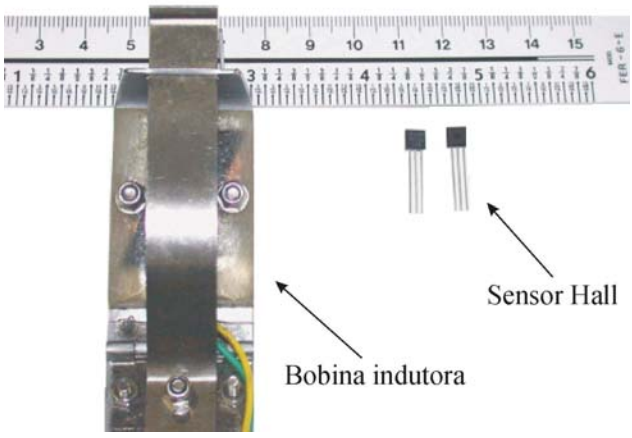

Figura II.16. *Tipos de sensores.*

Ao longo do ensaio por PIG uma malha de inspeção é formada sobre o duto em ambas direções, circunferencial e axial. O espaçamento circunferencial da malha é obtido pelo afastamento entre os sensores (Figura II.15) e na direção axial pela frequência de amostragem. A resolução da malha desempenha um papel importante na eficiência da detectabilidade e dimensionamento de pequenos defeitos, consequentemente, o melhor desempenho é obtido para pequenas malhas. Na indústria de *pigs* inteligentes, uma distinção é feita entre ferramentas de baixa e alta resolução referindo-se a qualidade da medida. No entanto, não existe uma definição própria de alta ou baixa resolução. Assim, o fato de um *pig* ser chamado de alta resolução não garante um bom desempenho [1]. A única maneira para selecionar corretamente um serviço de inspeção por *pig* de MFL para dutos, é definir claramente a necessidade em termos do tamanho mínimo e tipo de defeito que se deseja detectar [4].

Muitas ferramentas de MFL contém sensores adicionais para discriminar entre defeito interno e externo e para obter a medida da perda de espessura de parede. A discriminação entre interno e externo é realizada por meio de sensores que são sensíveis apenas a defeitos internos. Um primeiro anel de sensores detecta todos os defeitos de perda de metal e um segundo anel detecta a fuga do fluxo que pode ser causada somente por perda de espessura interna.

II.2.3. Registro e análise das descontinuidades

Como explicado anteriormente, uma ferramenta de MFL registra a fuga do fluxo em intervalos especificados em ambas as direções do duto, axial e circunferencial. O intervalo de registro de dados na direção circunferencial é definido pelo número de sensores e o intervalo de registro de dados na direção axial é definido pela capacidade de registro de dados dos sensores. Portanto, a quantidade de dados gerados durante uma inspeção depende do número de sensores, do número de amostras por unidade de distância e da distância deslocada. Como geralmente a distância deslocada é grande, a quantidade de dados gerados também o será. Devido ao grande volume de dados gerados, muitos projetistas de ferramentas usam sistemas de processamento para comprimir os dados e reduzir o espaço necessário para sua armazenagem eletrônica. Por exemplo, a quantidade de dados

armazenados pode ser reduzida registrando-se apenas canais que indiquem alguma mudança no sinal. Esta técnica de compressão de dados requer a definição prévia de um limiar para a inspeção.

A análise é o último passo na inspeção de uma ferramenta de MFL. Os dados de fuga de fluxo registrados devem ser analisados para identificar a presença de possíveis defeitos. Depois do defeito ser encontrado ele é avaliado para caracterizar sua geometria e severidade. A interpretação do sinal de MFL é difícil porque não existe uma relação simples entre a forma do sinal e a geometria ou severidade do defeito. A detecção e dimensionamento é normalmente realizada manualmente, contudo devido a dificuldade na interpretação destes sinais, técnicas computacionais para automatizar o processo estão começando a ser implementadas. Estes métodos incluem filtros casados, processamento de sinais, métodos estatísticos e redes neurais [29,38,39,40,41,42].

II.2.4. Sistema de potência

Os dispositivos de processamento e armazenagem dos dados e alguns sensores que são utilizados na ferramenta de MFL requerem potência elétrica para operar. Desta maneira, as baterias de potência que são disponíveis limitam a extensão que pode ser inspecionada em um determinado tempo. Muitas ferramentas utilizam baterias recarregáveis. A capacidade destas baterias e a energia requerida para a operação do sistema definem o máximo comprimento da inspeção. O projeto do sistema de potência deve levar em consideração ainda o efeito de choques e vibrações da ferramenta.

II.2.5. Visualização dos dados

Os dados registrados devem ser exibidos em um formato que permita a rápida detecção e identificação dos defeitos, assim como também todas as características da tubulação como cordões de solda, válvulas e uniões. Desde a introdução das ferramentas de MFL os sistemas de visualização de dados são feitos através de registros gráficos (Figura II.17), uma vez que os dados no papel permitem uma rápida detecção do defeito pelo especialista. Mais recentemente, o uso de técnicas computacionais têm conduzido a novos

métodos de visualização e avaliação dos dados. Um exemplo é a implementação de programas de visualização através de mapas de cores. A Figura II.18 apresenta este tipo de visualização para diferentes defeitos.

Outros fatores tais como tipo e dimensões do defeito, magnetização remanescente, tensões mecânicas na parede da tubulação, velocidade da ferramenta entre outros afetam a detecção e caracterização da natureza dos defeitos obtidos por ferramentas de MFL. Entretanto, não é objetivo descrevê-los neste trabalho, para maiores detalhes existe literatura específica [29,43].

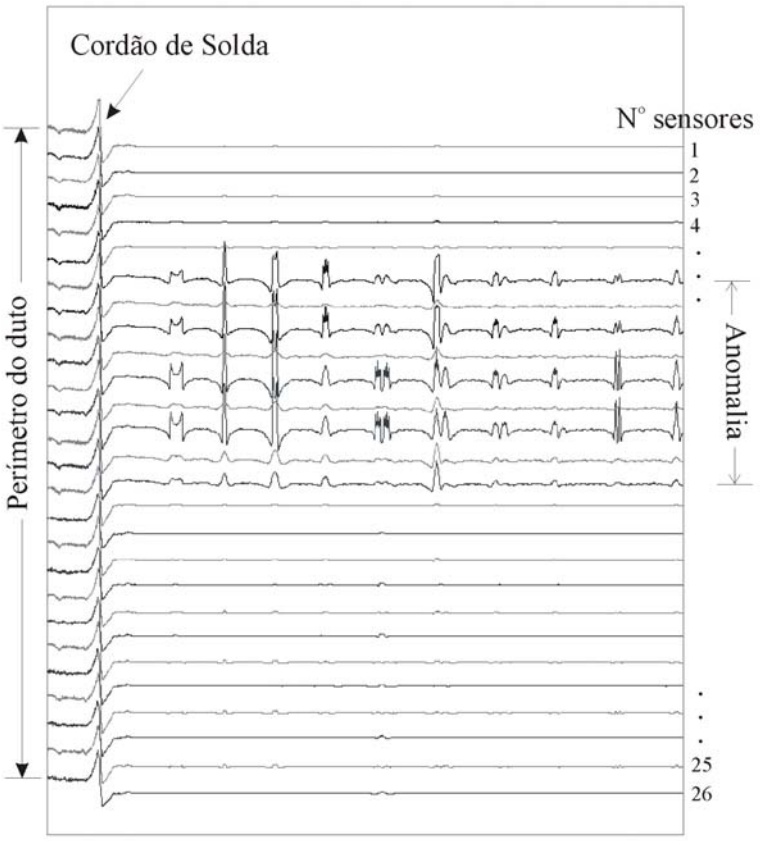

Figura II.17. *Registro gráfico de sinal de MFL.*

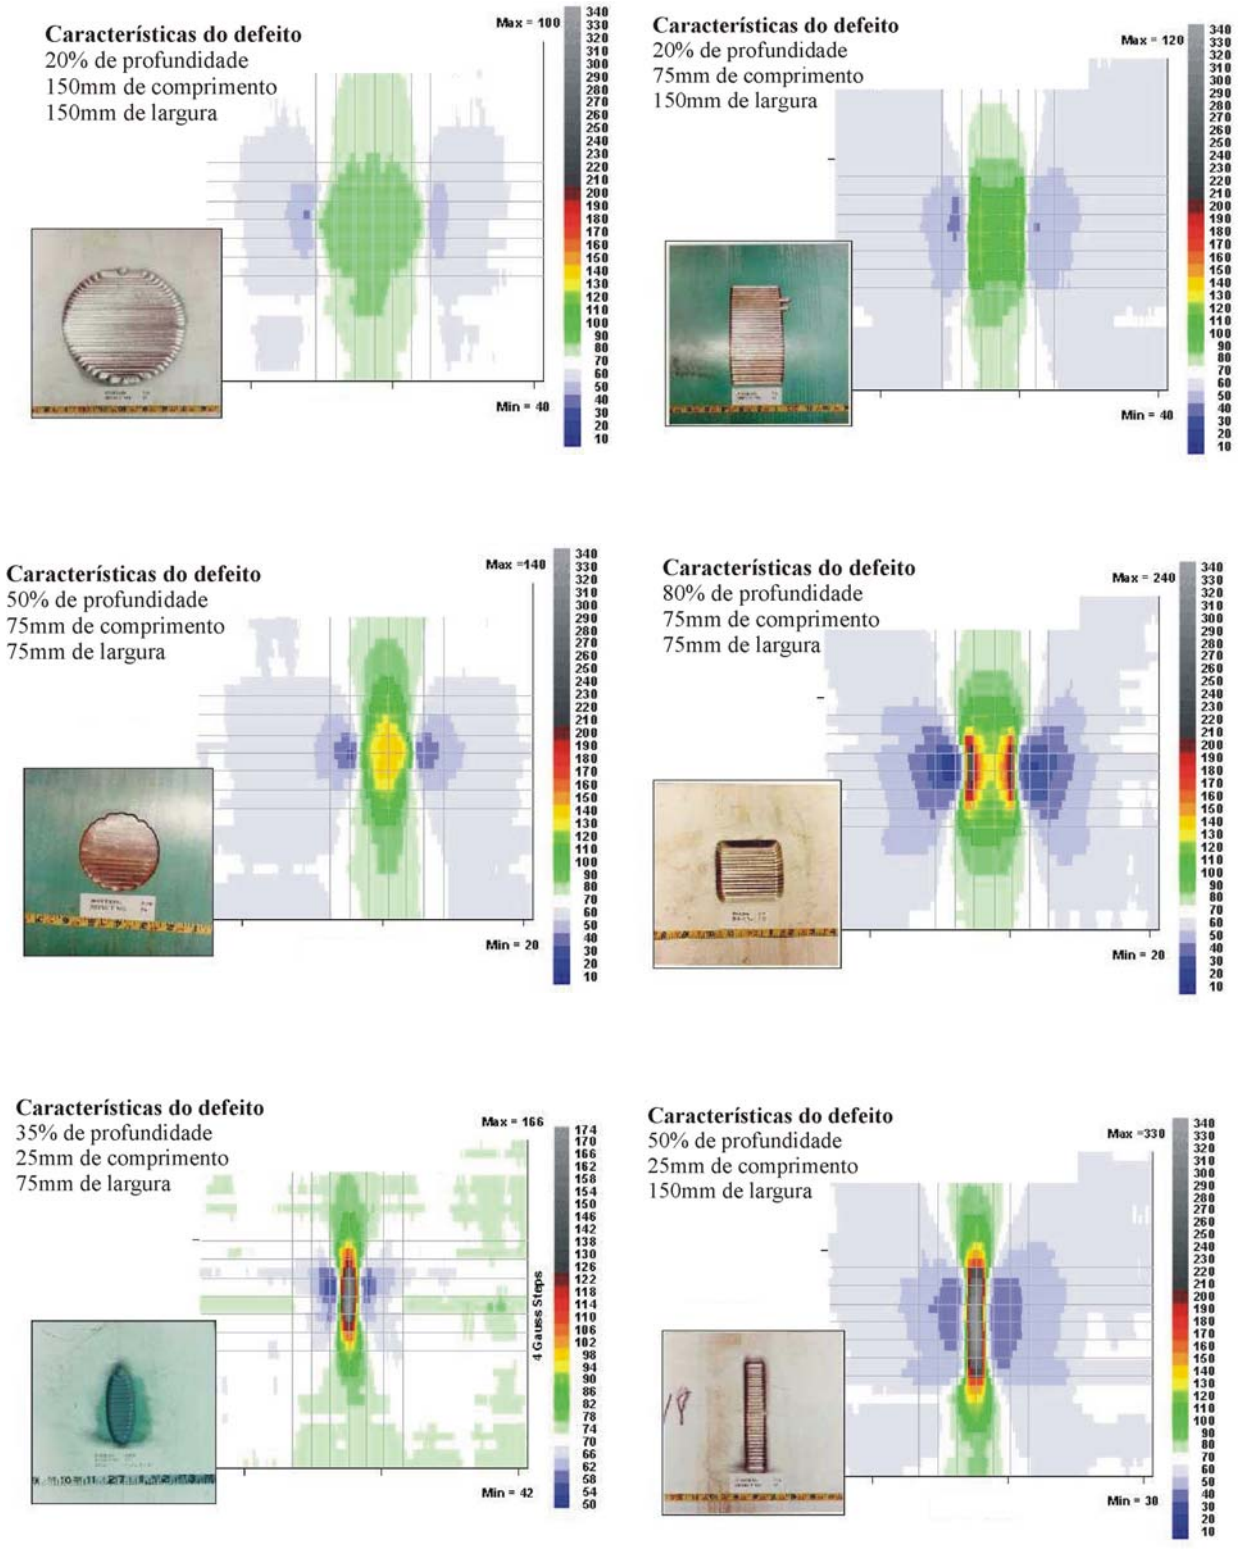

Figura II.18. *Visualização em mapas de cores de sinais de MFL [29].*

II.3. ENSAIO POR ULTRA-SOM

O ensaio ultra-sônico de materiais é feito com o emprego de ondas mecânicas ou acústicas, que propagam no meio em inspeção. Estas ondas possuem freqüência muito elevada, acima da faixa perceptível pelo ouvido humano (a qual vai de cerca de 20 Hz a 20 kHz) e são denominadas ondas ultra-sônicas. Qualquer onda mecânica é composta de oscilações de partículas discretas no meio em que se propaga. A passagem de energia acústica pelo meio faz com que as partículas que o compõe executem um movimento de oscilação em torno da posição de equilíbrio, cuja amplitude diminui com o tempo, em decorrência da perda de energia da onda. Assumindo-se que o meio em estudo é elástico, ou seja, que as partículas não estão rigidamente ligadas, mas que podem oscilar em qualquer direção, então pode-se classificar as ondas acústicas em três categorias:

- Ondas longitudinais – As partículas do meio vibram na mesma direção da propagação da onda;
- Ondas transversais – As partículas do meio vibram na direção perpendicular ao de propagação da onda. As ondas transversais são praticamente incapazes de se propagarem nos líquidos e gases, pela característica das ligações entre partículas, destes meios;
- Ondas superficiais ou ondas de Rayleigh – São assim chamadas pela sua característica de se propagar na superfície dos sólidos ou líquidos [44].

Deve-se observar que uma onda elástica não transporta massa pois, após cessado o movimento de oscilação, cada partícula volta à sua posição de equilíbrio. Assim, o que se propaga através do corpo elástico é apenas um estado de movimento e energia. É importante observar também, que a velocidade com que a maioria das ondas elásticas se propagam em um dado material é constante e independente da freqüência, depende apenas do material e do tipo de onda [27].

A maneira mais usual de geração de ondas ultra-sônicas é através do efeito piezelétrico, que é baseado no fato de que certos cristais geram corrente elétrica quando deformados mecanicamente. Inversamente, ocorre a deformação do cristal quando uma

diferença de potencial elétrico é aplicada entre as duas faces opostas do cristal (efeito piezelétrico reverso). Uma corrente elétrica alternada gera vibrações mecânicas no cristal na freqüência correspondente à freqüência de excitação. Estes cristais são chamados de transdutores por transformar energia de um tipo em outro (Figura II.19) [45].

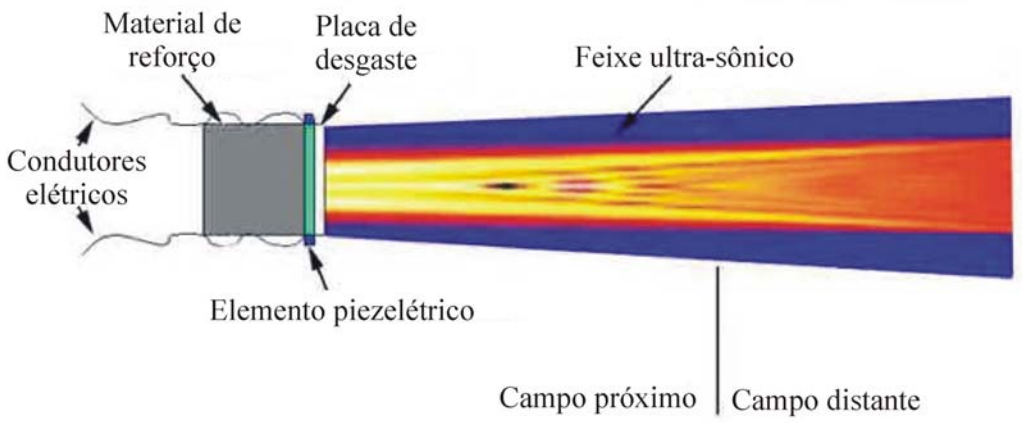

Figura II. 19. *Geração de ondas ultra-sônicas [46].*

II.3.1. Características e geometria do campo sônico

Para entendimento do campo sônico, imagine que o cristal piezelétrico, gerador de ondas ultra-sônicas, seja composto não de uma única peça, mas de infinitos pontos oscilantes. Cada ponto do cristal produz ondas que se propagam no meio, conforme Figura II.20.

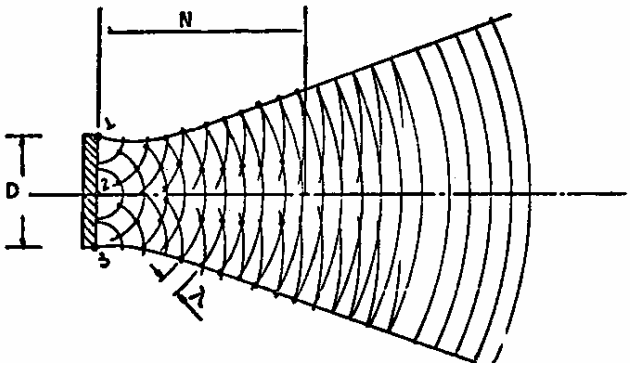

Figura II.20. *Sistema de ondas circulares, de comprimento de onda "λ", provenientes dos pontos 1, 2 e 3 [44].*

Pode-se notar que nas proximidades do cristal existe uma interferência ondulatória muito grande, assim como uma concentração de energia sônica. A medida que afasta-se do cristal, as interferências vão desaparecendo e a energia se dispersa. Em outras palavras, nas proximidades do cristal a sua dimensão e a energia sônica emitida são muito relevantes, entretanto, ao afastar-se as dimensões do cristal passam a ser irrelevantes no que diz respeito à forma do campo sônico.

Campo próximo

O campo próximo, ou zona de Fresnel, caracteriza-se pela grande variação da intensidade sônica na região imediatamente à frente do cristal, pelos fenômenos de interferência entre pressões máximas e mínimas [45].

O ponto de pressão máxima do feixe sônico determina o final do campo próximo. O comprimento do campo próximo (N) corresponde à distância entre o cristal e este ponto de intensidade máxima. Neste ponto o feixe sônico está concentrado ao máximo (Figura II.21).

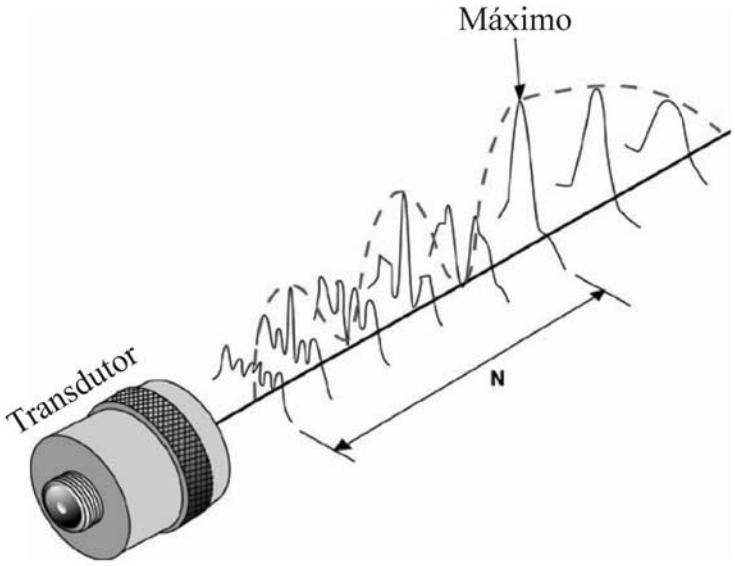

Figura II.21. *Variação da intensidade da pressão sônica no campo próximo [46].*

Todas as fontes sonoras têm campo próximo com dimensões que dependem da sua forma, das características do meio onde a onda se propaga e da frequência sônica. As expressões a seguir são usadas para calcular o comprimento do campo próximo [45].

Cristal circular

$$N = \frac{D_{ef}^2 \cdot f}{4V} \qquad \textit{Eq. II.1}$$

Cristal quadrado ou cristal retangular (com diferença entre lados de até 12%)

$$N = 1{,}3\frac{M_{ef}^2 \cdot f}{V} \qquad \textit{Eq. II.2}$$

onde:

N = Comprimento do campo próximo

V = Velocidade da onda

f = Freqüência

D_{ef} = Diâmetro efetivo do cristal (D_{ef} = 0,97 x Diâmetro real)

M_{ef} = Metade do comprimento efetivo do lado maior do cristal retangular (comprimento efetivo = 0,97 x comprimento real).

Campo distante

Para além do campo próximo, os fenômenos de interferência deixam de existir e o feixe ultra-sônico passa a ter um ângulo de abertura (divergência). Numa região, zona de transição, que varia aproximadamente de uma a três vezes a espessura do cristal, o ângulo de divergência é variável e o decréscimo da pressão sônica ainda não é proporcional ao quadrado da distância [45]. Após esta zona de transição o feixe passa a apresentar um ângulo de divergência constante e um decaimento de intensidade proporcional ao inverso do quadrado da distância, chamado então de campo distante ou zona de Fraunhofer (Figura II.22).

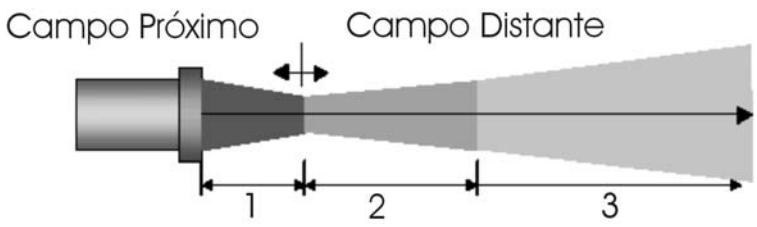

Figura II.22. *Regiões do feixe sônico: (1) Campo próximo, (2) zona de transição e (3) campo distante.*

Divergência do feixe

O campo gerado por um transdutor é composto de vários lóbulos, como mostra a Figura II.23. Na região central do feixe sônico, a sensibilidade, assim como a intensidade sônica é maior e a medida que nos afastamos do eixo central, num mesmo plano, diminui a sensibilidade (Figura II.24). Este efeito é conseqüência da divergência do feixe sônico, após percorrida a distância equivalente ao campo próximo. O ângulo entre o eixo central e o ponto de intensidade nula das bordas do lóbulo central é chamado de ângulo de divergência (Figura II.25).

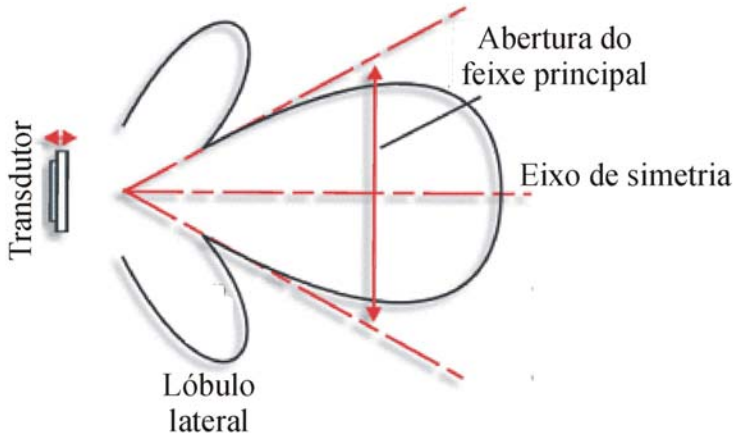

Figura II.23. *A intensidade do feixe traçado em coordenadas polares [47].*

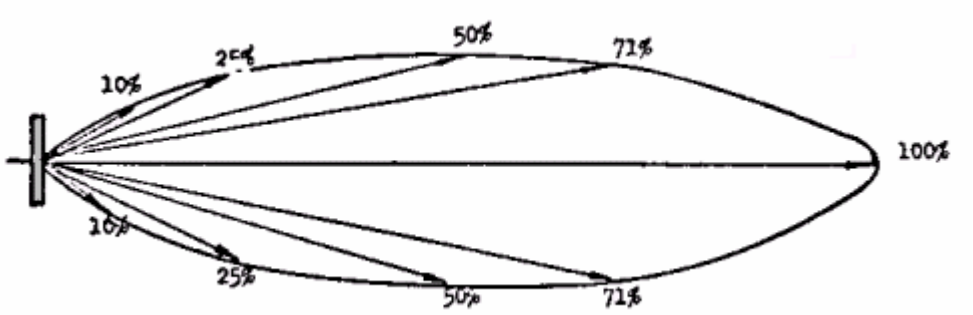

Figura II.24. *Medida da sensibilidade do feixe sônico.*

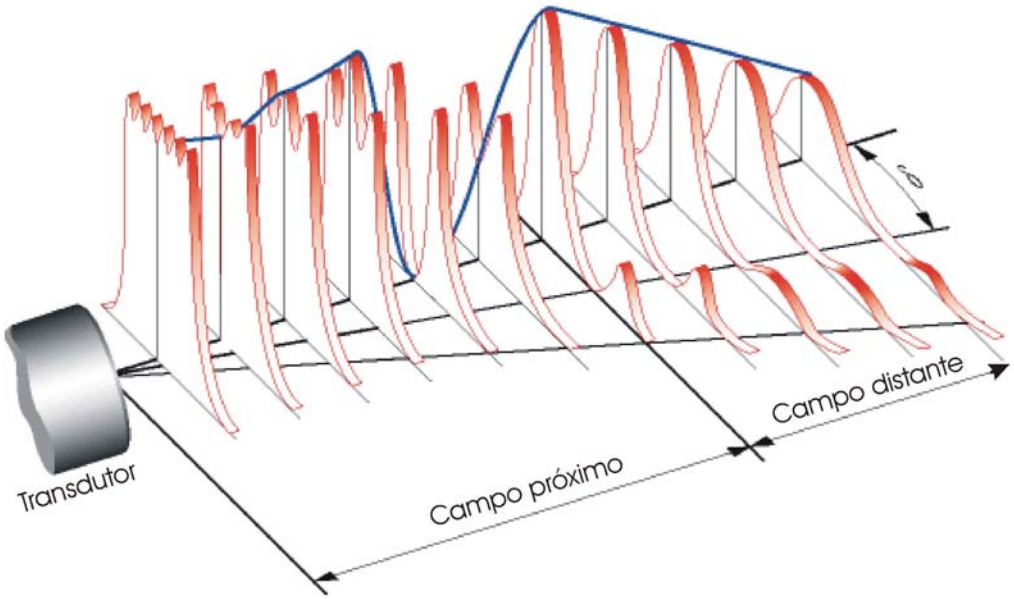

Figura II.25. *Divergência do feixe sônico [48].*

O ângulo de divergência do feixe ultra-sônico (δ) depende do diâmetro do transdutor e do comprimento de onda, e pode ser calculado a partir da equação:

$$\delta = \text{sen}^{-1}(\frac{1{,}22x\lambda}{D}) \qquad \textit{Eq. II.3}$$

onde:

D = diâmetro do transdutor;

λ = comprimento de onda.

A abertura do feixe ultra-sônico apresenta importância marcante na análise sônica, uma vez que esta pode alterar de maneira decisiva o resultado do ensaio. Portanto, é importante saber com alguma precisão a abertura do feixe para utilização prática de transdutores para fins específicos [49]. Quando o transdutor não é circular, o ângulo de divergência não pode ser calculado com precisão aplicando a Equação II.3. Neste caso, o ângulo de divergência é mais precisamente encontrado experimentalmente [27].

II.3.2. Interação da onda com uma descontinuidade

Silk [50] mostra uma representação estilizada da interação de uma onda ultra-sônica com um defeito linear. Quando a onda ultra-sônica atinge uma descontinuidade no material na qual ela percorre, esta onda pode ser refletida, difratada ou transmitida (Figura II.26). A ocorrência de um desses fenômenos vai depender da relação entre o comprimento de onda e o tamanho da descontinuidade [51,52,53]. Além desses fenômenos, ocorrem conversões de modo de ondas, isto é, a onda passa de um modo de propagação para outro, como por exemplo, muda do modo longitudinal para o transversal ou vice-versa.

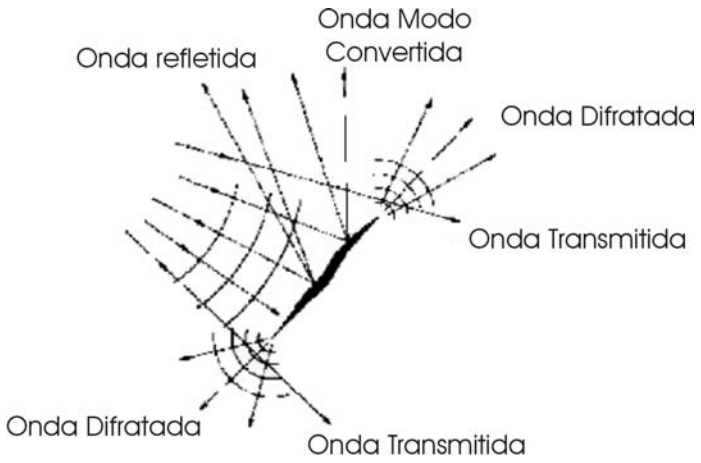

Figura II.26. *Interação da onda com uma descontinuidade.*

II.3.3. Realização do ensaio ultra-sônico

Vários parâmetros deverão ser selecionados para a realização do ensaio ultra-sônico. Parâmetros tais como, sensibilidade do ensaio, velocidade do som no material, ajuste da escala horizontal dentre outros, deverão ser selecionados pelo próprio operador no momento do ensaio, levando em consideração as dimensões e tipos de descontinuidades a serem detectadas, o tipo de material ensaiado, a geometria ou forma da peça ou a seção a ser examinada e as especificações de fabricação e inspeção.

Toda inspeção ultra-sônica deve ser realizada em conformidade com procedimentos escritos, contendo todas as informações necessárias aos ajustes e calibrações referentes ao ensaio. Tais ajustes e calibrações constituem fatores importantes que podem levar a aprovação ou rejeição do material ou peça ensaiada, e ainda determinam o nível de sensibilidade do ensaio.

O ensaio por ultra-som, como qualquer outra técnica de ensaio não destrutivo, requer a calibração prévia de todos os instrumentos utilizados na sua realização para a correta avaliação do material ensaiado. As calibrações são realizadas pelo próprio operador utilizando blocos de aço normalizados (blocos padrões) baseados em normas específicas. Devem ser calibrados a escala do aparelho de ultra-som, os transdutores que serão utilizados, e até mesmo os blocos padrões deverão ter sido fabricados com controle da integridade, rugosidade superficial e dimensões.

O ajuste da sensibilidade é a mais importante calibração a ser realizada no aparelho de ultra-som para o ensaio de um material. Calibrar a sensibilidade significa ajustar o controle de ganho (decibéis) do aparelho, de forma que sejam detectadas as descontinuidades importantes e desprezadas aquelas consideradas não significativas. A decisão a ser tomada pelo operador para considerar uma descontinuidade como sendo um defeito, depende da altura da respectiva indicação na tela do aparelho de ultra-som, que por sua vez depende das dimensões da descontinuidade e do ganho definido para o ensaio. Caso este tenha sido erroneamente ajustado, pequenas descontinuidades darão origem a indicações de grande altura na tela do aparelho e serão consideradas também erroneamente como defeitos, e vice-versa.

Para definir qual a calibração correta para cada tipo de peça ou equipamento, as normas de calibração dos equipamentos, como ASME, API, ASTM etc, definem exatamente como deve ser procedido [45]. Esta calibração pode ser realizada diretamente na peça, utilizando ecos provenientes da superfície ou de descontinuidades introduzidas com dimensões conhecidas, ou através de blocos padrões contendo refletores artificiais, geralmente furos e/ou entalhes, ou ainda através de diagramas que utilizam o comportamento do feixe sônico, como os diagramas DGS (do inglês *distance-gain-size*) [45].

II.3.4. Resultado da inspeção

O resultado de um ensaio por ultra-som pode ser um sinal de saída, modo A-scan, ou uma imagem, modos B-scan e D-scan. Condições aceitáveis são diferenciadas de condições inaceitáveis através de um limiar de discriminação na saída do aparelho de ultra-som. A discriminação pode ser automatizada ou realizada por um operador humano.

A viabilidade da aplicação de uma inspeção ultra-sônica para um determinado sistema depende do estabelecimento de uma relação entre a resposta de saída que o ultra-som pode gerar e as características de desempenho desejadas para o sistema. A relação entre a resposta de saída da inspeção ultra-sônica e as características de desempenho do sistema podem ser viáveis em aplicações sobre condições de laboratório, mas podem ser impraticáveis sob condições de produção ou serviço. Fatores tais como calibração, critério de aceitação, acessibilidade ao componente, condições superficiais, compatibilidade do material inspecionado e condições ambientais devem ser avaliados para determinar uma relação positiva entre a resposta de saída e o desempenho do sistema.

Apesar de atenção, disciplina, e das medidas de controle aplicadas para assegurar uma saída consistente como resultado da inspeção ultra-sônica, a saída variará dentro de parâmetros de controle estabelecidos, como conseqüência de variações nas propriedades dos materiais, geometria, condições superficiais, acesso, condições ambientais dentre outros. Se várias inspeções são realizadas sobre uma descontinuidade, uma distribuição densidade de probabilidade da saída sinal/imagem será gerada. Esta distribuição é similar a

obtida por repetidas medidas de uma dimensão, tais como o diâmetro ou o comprimento de um parafuso.

O resultado da inspeção por ensaios não destrutivos é geralmente uma medida indireta, e diversos sinais podem ser gerados de fontes não relevantes, tais como rugosidade superficial, estrutura granular, e variações geométricas. Estes sinais representam ruído inerente ao processo de inspeção ou ao procedimento de ensaio. A discriminação do resultado de saída do ensaio (sinal/imagem) deve ser derivado de todos sinais cujas amplitudes excedam a amplitude do ruído presente (Figura II.27). Análise de sinais e sinais mais ruído são comuns em equipamentos eletrônicos, ópticos e outros processos discriminatórios. Similarmente a razão das amplitudes sinal/ruído é o primeiro fator para estabelecer o nível de discriminação de um procedimento de ensaio. A redução da razão das amplitudes sinal/ruído, pode ser usada para avaliar o desempenho do procedimento de inspeção. Entretanto, é importante reconhecer que a fonte de ruído dominante em um processo de inspeção não é o ruído eletrônico, que pode ser reduzido por filtragem, amostragem múltipla e técnicas de cálculo de médias, mas sim o ruído devido a sinais não relevantes oriundos do material ou equipamento [27].

A avaliação da inspeção envolve medidas de parâmetros com variações inerente em ambos, o processo de medida e o objeto de teste. A saída deste processo de decisão pode ser analisado como um problema de probabilidade condicional. Quando a inspeção é realizada para o propósito de detecção de descontinuidade, a saída não é um simples processo binário de aceita/rejeita, como é freqüentemente imaginado. A saída será o produto da aceitação condicional devido a dependência entre o resultado medido e a decisão a ser tomada. Quatro possíveis saídas podem resultar da aplicação de um procedimento de inspeção para detecção de descontinuidades:

- *Verdadeiro positivo:* A descontinuidade existe e é detectada;
- *Falso positivo:* Descontinuidade que não existe é detectada;
- *Falso negativo:* Existe descontinuidade, mas não é detectada;
- *Verdadeiro negativo:* Não existe descontinuidade e não é detectada.

Os resultados desejados da aplicação de um procedimento de inspeção são: detecção de descontinuidade (sinal presente) ou não detecção (sinal ausente). A base para detecção é a presença de alguma indicação no sinal com amplitude acima de um limiar pré-determinado. A detecção e a interpretação do resultado de saída são dependentes do sinal (mais o ruído) e do ruído (ecos provenientes de fontes não relevantes) que estarão sujeitos ao meios de discriminação (automático ou operador humano).

Se um procedimento de inspeção é aplicado repetidamente em uma descontinuidade de uma determinada dimensão (com geometria fixada, condições superficiais, etc), o resultado de saída pode ser usado para construir um gráfico da distribuição densidade de probabilidade de ambos, sinal da descontinuidade e resposta do ruído (Figura II.27). Sobre condições ideais, como o resultado da inspeção de uma grande descontinuidade, a distribuição do sinal e do ruído serão bem separados, como mostrado na Figura II.27(a). Neste caso, a discriminação do sinal da descontinuidade do sinal do ruído é um processo simples [27].

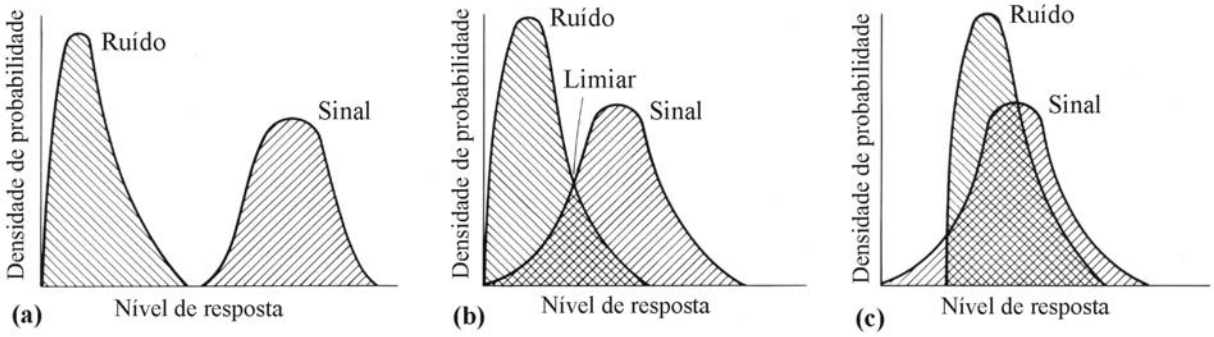

Figura II.27. *Distribuição densidade de probabilidade sinal/ruído para: (a) grande descontinuidade, (b) média descontinuidade e (c) pequena descontinuidade [27].*

Em aplicações praticas, a dimensão da descontinuidade não é fixa (e raramente é grande), e o processo de discriminação é mais complexo. De fato, o processo de discriminação é aplicado para uma faixa contínua de dimensões de descontinuidades, onde a capacidade de discriminação é dependente das características de desempenho do procedimento de inspeção e da separação do sinal (mais ruído) da resposta do ruído inerente ao processo.

Se o procedimento de inspeção é aplicado para uma única descontinuidade de tamanho intermediário (com geometria fixada, acabamento superficial, etc), a saída pode ser usada para gerar uma distribuição densidade de probabilidade para o sinal e para o ruído, como mostrado na Figura II.27(b). Para esta dimensão de descontinuidade, as distribuições se sobrepõem em parte, e a capacidade de discriminação é dependente do resultado de um único conjunto de sinais de saída. Se os sinais de saída estão bem separados (isto é, sinais nos extremos externos das distribuições), a resposta poderá ser interpretada como aceitável (sem descontinuidades), para todos os casos onde o nível do limiar de aceitação ficar situado entre o sinal e o ruído. Se os sinais de saída situam-se nos extremos internos da distribuição, a resposta poderá ser interpretada como aceitável (sem descontinuidade ou descontinuidade não detectada) ou pode ser interpretada como inaceitável (descontinuidades que não existem são detectadas) para o mesmo nível de limiar de aceitação. Se o processo é repetido para pequenas descontinuidades (sobre as mesmas condições de operação), o resultado da distribuição do sinal e do ruído serão aproximadamente coincidentes, como mostrado na Figura II.27(c).

Fica, portanto, evidente que o desempenho de um determinado procedimento de inspeção depende da natureza e distribuição dos sinais de saída, gerados sobre determinadas condições. É também evidente que o nível do limiar de aceitação aplicado no processo de discriminação é um fator importante para o sucesso do procedimento. Considere por exemplo um procedimento para detecção de grandes descontinuidades sobre condições que produzam uma separação significativa das distribuições densidade de probabilidades do sinal e do ruído, como mostrado na Figura II.28. Se o limiar de aceitação é colocado em um nível muito alto (Figura II.28(a)), algumas descontinuidades serão perdidas. Se o limiar de aceitação é colocado em um nível apropriado (Figura II.28(b)), resultará em uma nítida discriminação. Se o limiar de aceitação é colocado em um nível muito baixo (Figura II.28(c)), todas as descontinuidades serão rejeitadas, mas partes boas também serão rejeitadas [27].

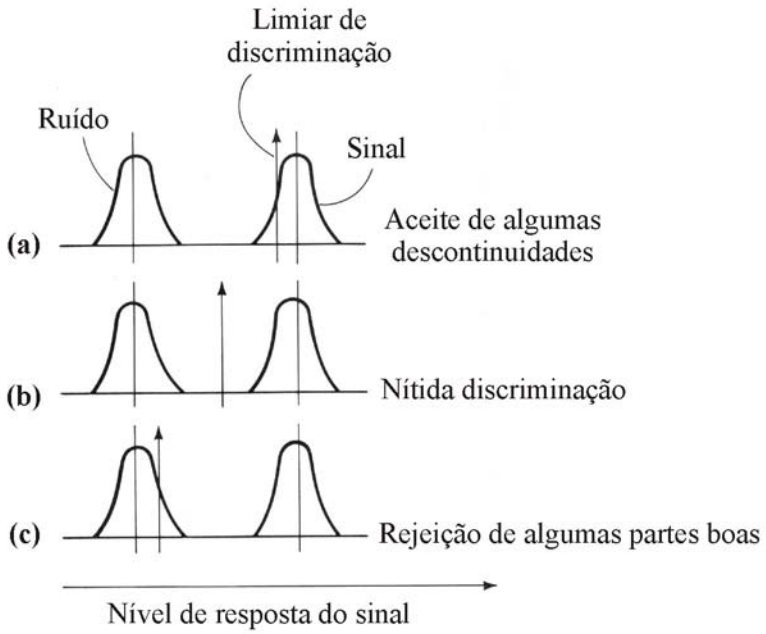

Figura II.28. *Influência do critério de aceitação no processo de discriminação. (a) Critério de aceitação muito alto, (b) critério de aceitação em um nível apropriado e (c) critério de aceitação muito baixo [27].*

Desta maneira, pode-se concluir que duas características importantes de desempenho em um procedimento de inspeção são a razão sinal/ruído (margem de separação) e o critério aplicado para o limiar de aceitação no processo de discriminação, como ilustrado na Figura II.29. A Figura II.29 ilustra, de maneira idealizada, quatro possíveis regimes de inspeção para a magnitude relativa do sinal da descontinuidade, S_o, o limiar de registro, L, e a amplitude média do ruído, R_o. A situação ideal é apresentada na Figura II.29(a), o nível do limiar é muito maior que o pico do ruído, e o sinal é maior que ambos, o limiar e o ruído. Nesta situação, o sinal da descontinuidade provavelmente será detectado e o ruído dificilmente excederá o limiar, evitando registro de falsas indicações. Reduzindo o limiar (Figura II.29(b)), a probabilidade de detecção das descontinuidades não será melhorada, mais poderá causar um aumento das falsas indicações. Aumentando o limiar Figura II.29(c), as falsas indicações serão reduzidas, mas a probabilidade de detecção também o será. Se o sinal do defeito não é muito diferente do ruído, então qualquer que seja a escolha do limiar, a probabilidade de detecção e a probabilidade de falsa indicação serão similares em magnitude (Figura II.29(d)) [54].

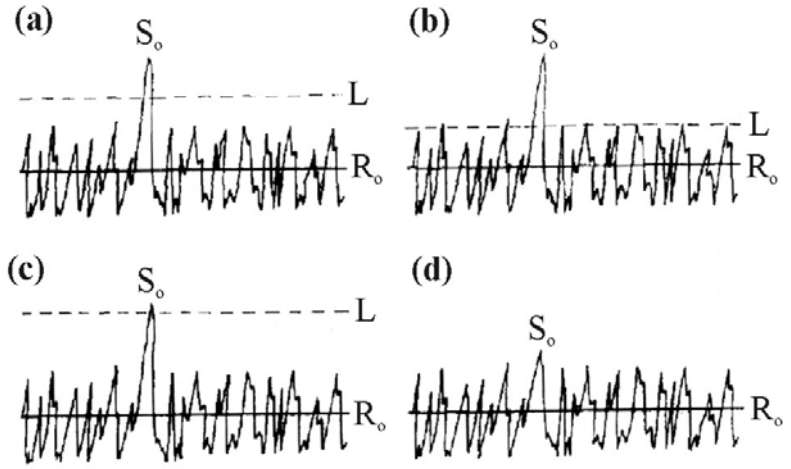

Figura II.29. *Quatro regimes de inspeções, onde a magnitude relativa da média do ruído (R_o), a amplitude do sinal (S_o), e o limiar (L), afetam a probabilidade de detecção e a probabilidade de falsa indicação. (a) O limiar é maior que o ruído e a amplitude do sinal é maior que ambos, ocorrerá alta probabilidade de detecção e reduzido número de falsa indicação; (b) o limiar é reduzido, a probabilidade de detecção não será melhorada , mais ocorrerá um aumento do número de falsas indicações; (c) o limiar é aumentado, as falsa indicações e a probabilidade de detecção serão reduzidas; (d) a amplitude do sinal é praticamente igual ao defeito, a probabilidade de detecção e as falsas indicações serão similares em magnitude [54*].

Existem várias técnicas ultra-sônicas e cada uma possui particularidades que justificam seu uso. As seções seguintes relatarão sobre duas técnicas ultra-sônicas que serão utilizadas neste trabalho.

II.3.5. Ensaio ultra-sônico pulso-eco

Pulso-eco é a técnica ultra-sônica mais largamente utilizada na inspeção de materiais, principalmente devido sua eficiência e simplicidade. Esta técnica envolve a detecção de ecos produzidos quando um sinal ultra-sônico é refletido por uma descontinuidade presente no material em teste. Sendo neste caso, utilizado somente um transdutor para emitir o pulso ultra-sônico (emissor) e receber o sinal refletido (receptor). Este método é utilizado na detecção, localização e dimensionamento de defeitos internos ao material. Após o defeito ser detectado sua localização pode ser determinada levando-se em

consideração três fatores: o tempo de percurso da onda entre o pulso inicial e o eco produzido pela falha, a distância do ponto de saída do feixe ao centro do cordão da solda e o ângulo de incidência do feixe sônico, conforme Figura II.30. É baseado na localização do defeito que o inspetor infere sobre a classificação da descontinuidade. O tamanho do defeito está diretamente relacionado com a amplitude do sinal refletido, pois se o pulso ultra-sônico encontra uma superfície refletora, parte ou toda energia é refletida. O percentual de energia que é refletida é diretamente dependente do tamanho da superfície refletora em relação ao tamanho do feixe ultra-sônico incidente [27,55].

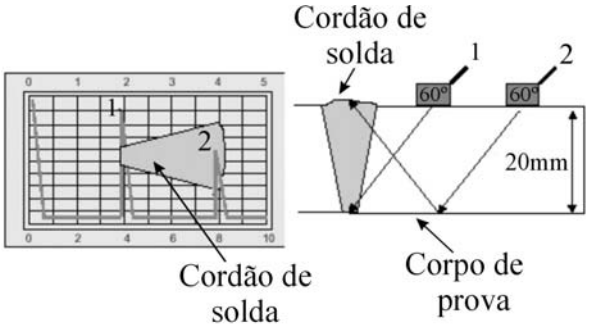

Figura II.30. *Inspeção ultra-sônica utilizando a técnica pulso-eco.*

Uma das vantagens desta técnica é a grande sensibilidade para detecção de pequenas descontinuidades presentes no material, além de detectar com precisão descontinuidades logo abaixo da superfície de entrada do feixe sônico, aumentando assim a região de detecção de falhas internas ao material [27,45,55].

O modo mais comum de apresentação do sinal ultra-sônico de pulso-eco é chamado modo A-scan. Este consiste de um gráfico amplitude versus tempo, no qual a linha horizontal em um osciloscópio representa o tempo decorrido e as deflexões verticais, as amplitudes dos ecos (Figura II.31). Através da comparação entre a altura do eco da descontinuidade com um outro refletor conhecido é possível inferir a medida da falha. O uso do mostrador tipo ‘A-scan’ não é limitado à detecção e caracterização de descontinuidades, ele pode ser utilizado também para medição de espessuras, velocidade sônica, atenuação e geometria do feixe sônico.

Outros modos de apresentação dos resultados de um ensaio ultra-sônico de pulso-eco são B-scan, C-scan e D-scan [53].

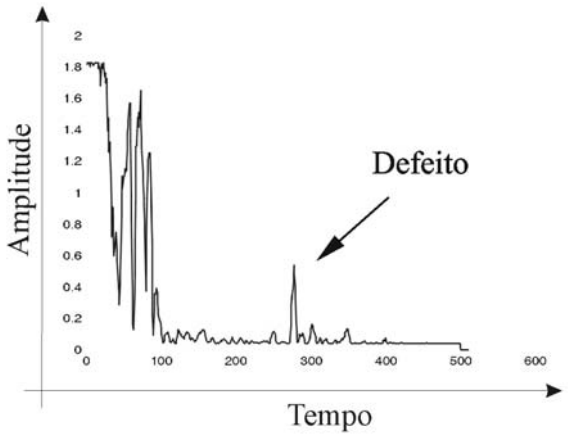

Figura II.31. *Modelo típico de sinal obtido (A-scan) pela técnica pulso-eco numa região contendo uma descontinuidade.*

II.3.6. Técnica do tempo de percurso da onda difratada ou TOFD (do inglês *Time of Flight Diffraction*)

Descrita primeiramente por Maurice G. Silk em 1975 [50], a técnica TOFD baseia-se na interação das ondas ultra-sônicas com as extremidades da descontinuidade. Desta interação resulta a emissão de ondas difratadas numa vasta gama de ângulos, a detecção destas ondas torna possível estabelecer a presença de defeitos. A dimensão do defeito é determinada a partir do tempo de percurso dos sinais ultra-sônicos que são difratados pela ponta superior e inferior do defeito (Figura II.32) [56,57]. A amplitude do sinal não é utilizada para estimar a dimensão do defeito, como ocorre na técnica pulso-eco.

A técnica TOFD adequa-se ao processo de automação da inspeção, aliando rapidez e confiabilidade no dimensionamento [58]. Recentemente, foi desenvolvido um mapeamento C-scan combinado a técnica TOFD com a técnica pulso-eco, como o sistema "rotscan" [59]. Este sistema tem sido aplicado para inspeção de solda circunferencial durante a construção de dutos de longa distância, permitindo a detecção, registro e rápida interpretação de todos os defeitos relevantes na solda [59,60,61,62].

A configuração convencional para a técnica TOFD utiliza dois transdutores, um emissor e outro 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 II.32) [63]. 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 [64,65]. Na ausência de descontinuidades, o segundo sinal a aparecer será o eco de fundo ("*backwall echo*"). Caso não se considere a 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 [66].

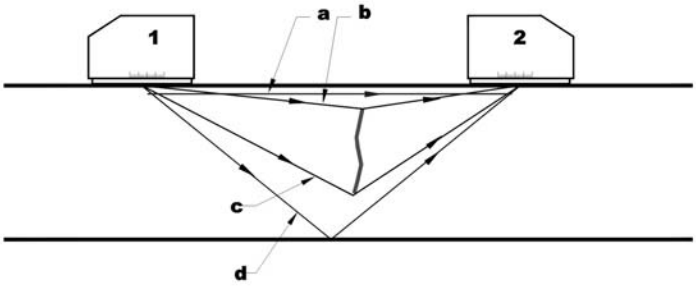

Figura II.32. *Arranjo típico para técnica TOFD: (1) Emissor, (2) Receptor, (a) Onda lateral, (b) Onda difratada pela ponta superior do defeito, (c) Onda difratada pela ponta inferior do defeito e (d) Eco de fundo.*

Um sinal A-scan típico obtido pela técnica TOFD é apresentado na Figura II.33. Como no ensaio pela técnica pulso-eco, existem outros modos de apresentação dos resultados do ensaio pela técnica TOFD. O modo mais usual de apresentação dos resultados na inspeção pela técnica TOFD é o modo 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 II.34).

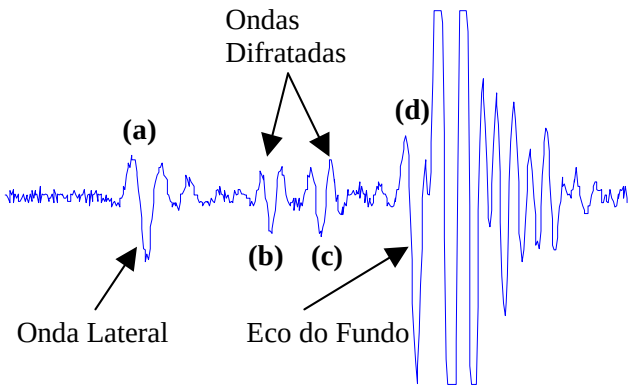

Figura II.33. *Modelo típico de sinal A-scan obtido pela técnica TOFD numa região contendo uma descontinuidade. (a) Onda lateral, (b) Onda difratada pela ponta superior do defeito, (c) Onda difratada pela ponta inferior do defeito e (d) Eco de fundo.*

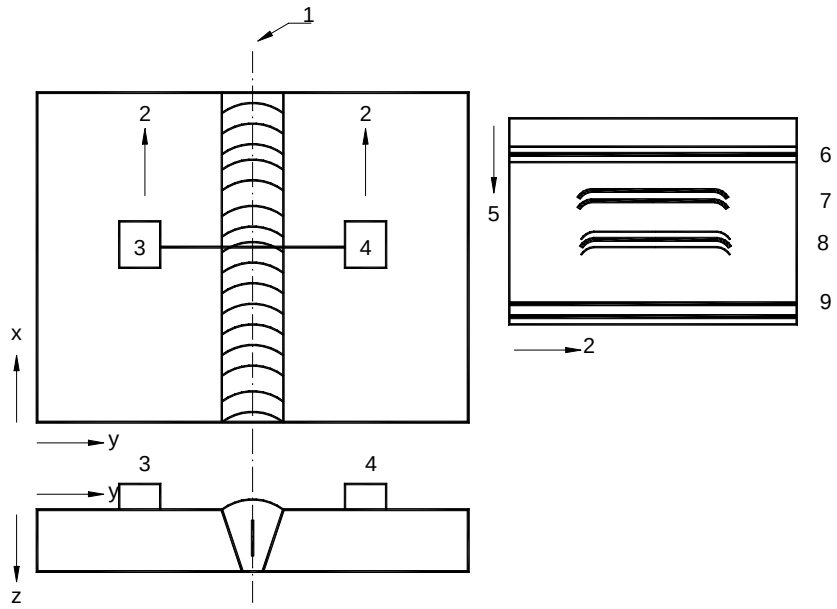

Figura II.34. *Inspeção não paralela, com a direção de deslocamento típica (à esquerda) e o D-scan correspondente à direita. (1) Linha de referência, (2) Direção do deslocamento dos transdutores (direção xx), (3) Emissor, (4) Receptor, (5) Tempo de percurso (na direção da espessura), (6) Onda lateral, (7) Extremidade superior da descontinuidade, (8) Extremidade inferior da descontinuidade, (9) Reflexão de fundo.*

A Figura II.35 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.

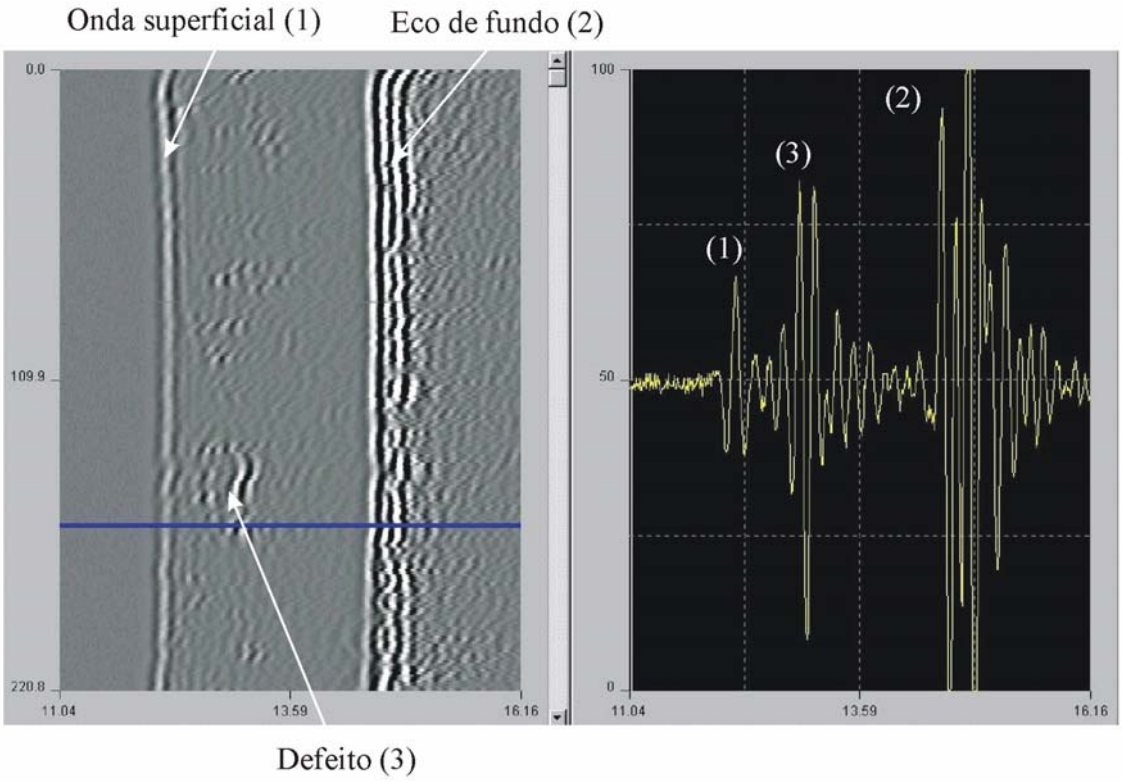

Figura II.35. *Imagem ultra-sônica D-scan obtida por TOFD, e o A-scan correspondente à posição selecionada pela linha horizontal presente na imagem D-scan.*

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 II.36 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.

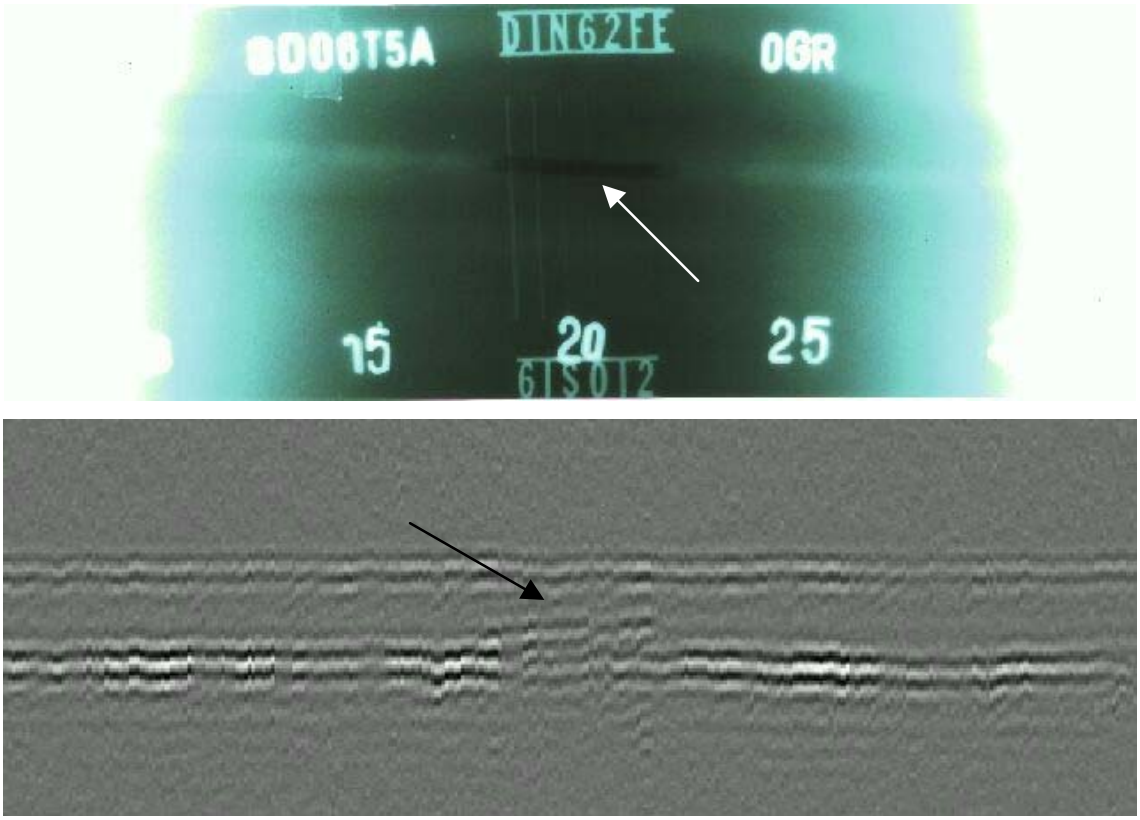

Figura II.36. *Comparação entre as imagens obtidas durante inspeção radiográfica e pela técnica TOFD realizadas em uma mesma região. As setas indicam a posição de um defeito de falta de penetração.*

Nesta seção foi realizado um breve resumo sobre os princípios do ensaio não destrutivo por ultra-som. Evidente que este é um tema muito mais abrangente, no entanto não é objetivo deste trabalho um maior aprofundamento neste assunto. Os tópicos abordados aqui tem a finalidade apenas de permitir um entendimento dos principais fatores que afetam na probabilidade de detecção do ensaio por ultra-som. Um estudo mais detalhado sobre este ensaio é apresentado em vasta literatura [27,45,55,58].

II.4. REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais (RNA) são modelos matemáticos, inspirados no princípio de funcionamento do cérebro humano, que possuem a capacidade de extrair conhecimento a partir de um conjunto de dados. Desta forma, as redes neurais conseguem modelar funções que são típicas do cérebro, tais como: aprender através de exemplos, generalizações, reconhecimento de padrões, criação de associações e aprendizado com experiência e treinamento.

O cérebro humano é constituído por unidades de processamento formadas por células computacionais denominadas neurônios, estes são conectados entre si e com as células sensoras e motoras por ligações sinápticas, também conhecidas como sinapses ou pesos sinápticos. Um cérebro em sua fase adulta possui normalmente bilhões de neurônios e trilhões de sinapses, formando uma rede neural biológica capaz de realizar as mais difíceis tarefas [67]. As redes de neurônios artificiais são sistemas de computação adaptativos inspirados nas características de processamento de informação encontradas nos neurônios reais (biológicos) e nas características de suas interconexões. São sistemas de computação maciçamente paralelos [67] que podem ser implementados tanto em hardware quanto em software, sendo que os elementos de processamento individualmente têm capacidades relativamente limitadas. Entretanto, a utilização de arquiteturas de redes com vários neurônios em paralelo e por vezes várias camadas destes, pode vir a construir uma ferramenta poderosa. Tais elementos de processamento básicos são os chamados neurônios artificiais, imitam de alguma forma o processamento de informação realizado por um neurônio biológico, e quando utilizados em conjunto e interagindo uns com os outros, compõem o que se denomina de rede neural. Outra denominação típica para os elementos de processamento das redes neurais é a expressão *nós de processamento*, ou nós da rede neural.

A aplicação de redes neurais em ensaios não destrutivos é relativamente recente, e têm sido aplicada na maioria das vezes na detecção de descontinuidades e reconhecimento de padrões [58,66,68-77]. No caso deste trabalho, rede neural artificial é aplicada no reconhecimento de classes de defeitos de sinais de MFL. Rede neural, neste caso, funciona como um especialista. O especialista de MFL observa o sinal e, visualmente, retira deste

sinal características relevantes que lhe permitem, através de seu conhecimento e experiência, inferir no tipo de defeito. Uma rede neural, assim como o especialista, também extrai informações do sinal para classificar o defeito, no entanto, por ser implementado em algoritmos computacionais, consegue muito mais precisão nos seus resultados, assim como também, consegue visualizar detalhes que o olho humano (especialista) não consegue.

Nesta seção será dada apenas uma abordagem introdutória ao assunto de redes neurais, para que o leitor possa entender a metodologia utilizada neste trabalho Para um maior aprofundamento neste assunto existe uma vasta literatura disponível [67,78,79,80].

II.4.1. Modelo de um neurônio artificial

O neurônio artificial foi projetado para imitar as características básicas de um neurônio biológico. É a unidade de processamento de informação que é fundamental para a operação de uma rede neural artificial. Um modelo de um neurônio artificial é mostrado na Figura II.37.

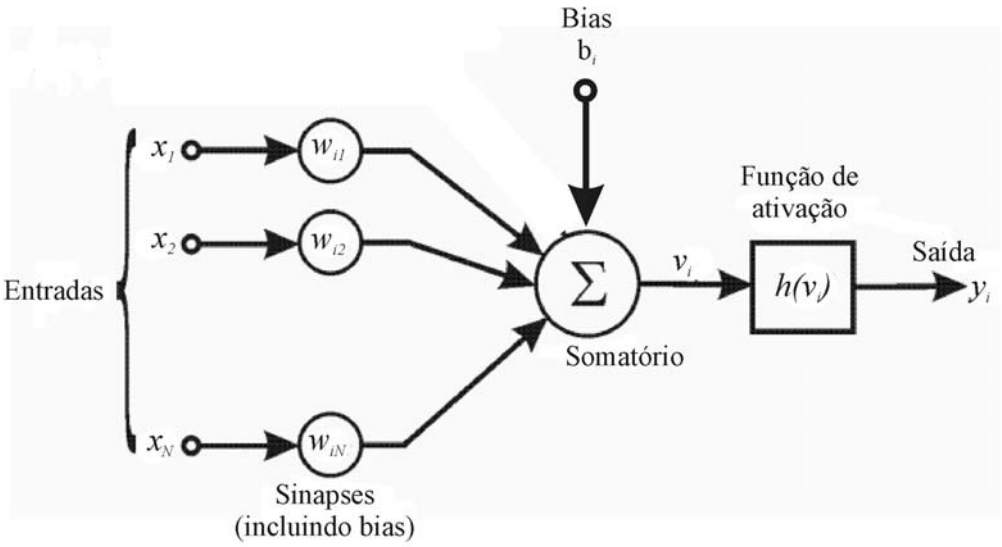

Figura II.37. *Modelo de um neurônio artificial.*

São identificados três elementos básicos em uma rede de neurônios:

1 – Um conjunto de sinapses, cada uma caracterizada por um peso ou força própria. Especificamente, um sinal x_j na entrada da sinapse j conectada ao neurônio i é multiplicado pelo peso sináptico w_{ij}. É importante notar a maneira como são escritos os índices do peso sináptico w_{ij}. O primeiro índice se refere ao neurônio em questão e o segundo se refere ao terminal de entrada da sinapse à qual o peso se refere. Ao contrário de uma sinapse do cérebro, o peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos, bem como positivos [67].
2 – Um somatório, que soma os sinais de entrada da rede, ponderados pelos respectivos pesos sinápticos do neurônio, executando uma combinação linear dos mesmos.
3 – Uma função de ativação, que é usada para restringir a amplitude de saída de um neurônio. Normalmente a amplitude de saída de um neurônio está contida no intervalo de [0, 1] ou [1, -1]. As funções de ativação mais utilizadas são: linear, degrau e tangente hiperbólica [67].

O modelo neuronal da Figura II.37 inclui também um *bias* aplicado externamente representado por b_i. O *bias* tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente.

Em termos matemáticos, pode-se descrever um neurônio i escrevendo o seguinte par de equações:

$$u_i = \sum_{j=1}^{N} w_{ij} \cdot x_j \qquad \textit{Eq. II.4}$$

$$y_i = h(u_i + b_i) \qquad \textit{Eq. II.5}$$

onde x_1, x_2, ..., x_N são os sinais de entrada; w_{i1}, w_{i2},..., w_{iN} são os pesos sinápticos do neurônio i; v_i é a saída do combinador linear devido aos sinais de entrada; b_i é o *bias*; $h(v_i)$ é a função de ativação e y_i é o sinal de saída do neurônio. O uso do *bias* tem o efeito de aplicar uma transformação *afim* à saída u_i do combinador linear como mostrado pela Eq. II.6.

$$v_i = u_i + b_i \qquad \textit{Eq. II.6}$$

Em particular, dependendo se o *bias* b_i é positivo ou negativo, a relação entre o campo local induzido ou potencial de ativação v_i do neurônio *i* e a saída do combinador linear u_i é modificada na forma ilustrada na Figura II.38. Pode-se observar que, com o resultado da transformação *afim*, o gráfico de v_i em função de u_i não passa mais pela origem [67].

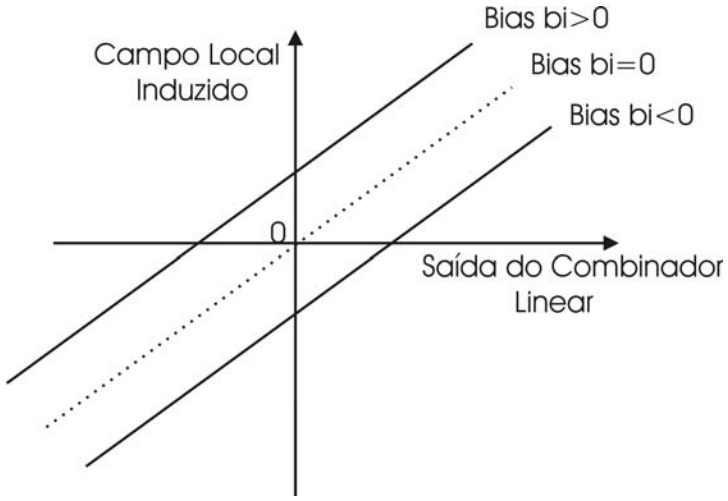

Figura II.38. *Transformação induzida pela presença de um bias.*

O *bias* b_i é um parâmetro externo do neurônio artificial *i*. Pode-se considerar o 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_{i0} = b_i. Pode-se, portanto, reformular a combinação das Eqs. II.4 até II.6 para obter a Eq. II.7.

$$v_i = \sum_{j=0}^{N} w_{ij} \cdot x_j \qquad \textit{Eq. II.7}$$

$$y_i = h(v_i) \qquad \textit{Eq. II.8}$$

II.4.2. Arquitetura da rede neural artificial

Do ponto de vista estrutural, a arquitetura das redes neurais pode ser classificada como estática, dinâmica ou *fuzzy* e de única camada ou múltiplas camadas. Além disso, diferenças computacionais surgem também quando se trata da maneira com que são feitas as conexões existentes entre os neurônios. Estas conexões podem ser estritamente no sentido de ida, no sentido de ida e volta, lateralmente conectadas, topologicamente ordenadas ou híbridas.

A definição da arquitetura de uma RNA é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede neural [79]. A arquitetura da rede é algo que deve ser configurado de acordo com o problema existente, levando em consideração a complexidade de sua solução, os dados de entrada e a saída desejada. Haykin [67] cita três classes de arquitetura de redes fundamentalmente diferentes:

1 – Redes alimentadas adiante com camada única

Neste tipo de rede os neurônios estão organizados na forma de camadas. Nesta organização, existe uma camada de entrada (denominada nós de fonte), que se projeta sobre uma camada de saída de neurônios (nós computacionais), mas não em vice-versa. Nesta topologia de rede não existe realimentação (Figura II.39).

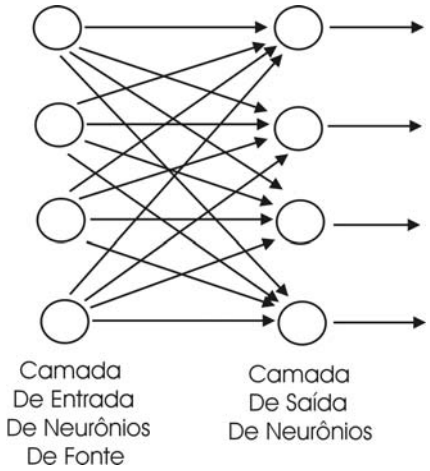

Figura II.39. *Rede alimentada adiante com uma única camada de neurônios.*

2 – Redes alimentadas diretamente com múltiplas camadas

Esta arquitetura de rede tem seu funcionamento similar a classe anterior, mas se distingue pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados de neurônios ocultos ou unidades ocultas (Figura II.40). Segundo Haykin [67], a função do neurônio oculto é intervir entre a entrada e a saída da rede de uma maneira útil.

Os elementos padrões de ativação fornecidos pelos nós da camada de entrada constituem os sinais de entrada aplicados aos neurônios na segunda camada. Os sinais de saída da segunda camada são utilizados como entradas para a terceira camada, e assim por diante para o resto da rede. O conjunto de sinais de saída da última camada, camada final, constitui a resposta global da rede para o padrão de ativação fornecido pelos nós de fonte da primeira camada (camada de entrada).

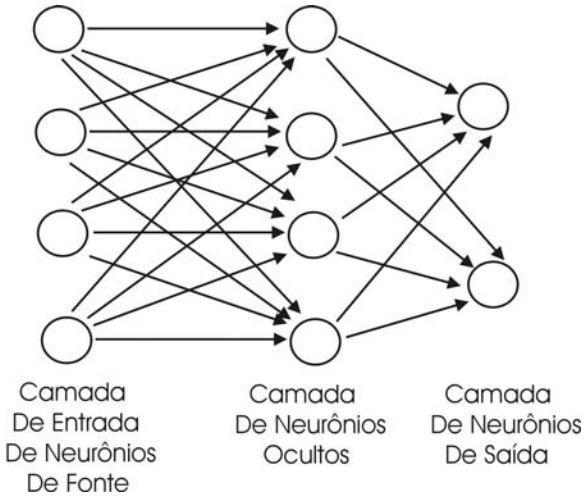

Figura II.40. *Rede alimentada adiante totalmente conectada com uma camada oculta e uma camada de saída.*

3 – Redes recorrentes

Em uma rede recorrente (Figura II.41) cada neurônio, de uma dada camada, alimenta com seus sinais de saída as entradas de todos os neurônios. Pode haver ou não laços de realimentação, que é uma situação onde a saída de um neurônio é realimentada para sua própria entrada.

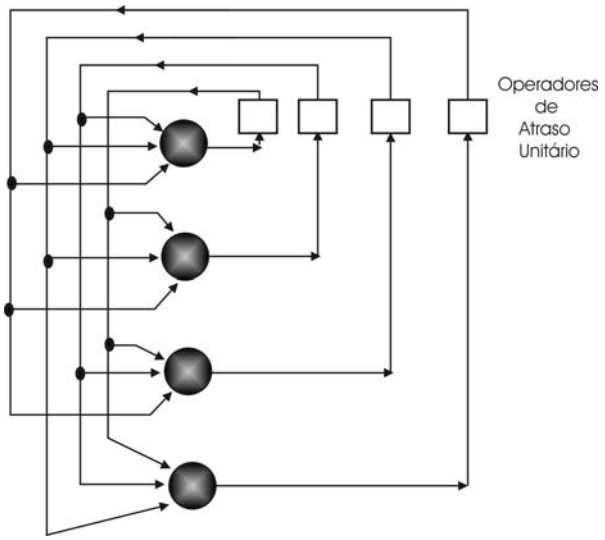

Figura II.41. *Rede recorrente sem laços de auto-realimentação e sem neurônios ocultos.*

II.4.3. Conhecimento

Uma definição genérica do que significa conhecimento é: *uma informação armazenada ou modelos utilizados por uma pessoa ou máquina para interpretar, prever e responder apropriadamente ao mundo exterior [67].*

Uma tarefa importante para uma rede neural é aprender um modelo do mundo (ambiente) no qual está inserida, e manter o modelo suficientemente consistente com o mundo real de maneira a atingir os objetivos especificados da aplicação de interesse. Um conjunto de exemplos representa o conhecimento acerca do ambiente de interesse que uma rede neural pode aprender através do treinamento. Um conjunto de pares de entrada-saída, um sinal de entrada e a resposta desejada correspondente, é referido como um conjunto de dados de treinamento ou amostra de treinamento. Para Haykin [67], o projeto de uma RNA pode prosseguir como segue:

1 – Uma arquitetura apropriada é selecionada para a rede neural. Um subconjunto de exemplos é então utilizado para treinar a rede por meio de um algoritmo apropriado. Esta fase do projeto da rede é denominada aprendizagem;

2 – O desempenho do conhecimento da rede treinada é testado com dados não apresentados anteriormente. O desempenho da rede é então estimado comparando-se o reconhecimento

da resposta gerada com a resposta correta da entrada em questão. Esta etapa é chamada generalização.

Em uma RNA com uma arquitetura específica, a representação do conhecimento do meio ambiente é definida pelos valores assumidos pelos parâmetros livres da rede (pesos sinápticos e *bias*).

A propriedade de importância primordial para uma rede neural é sua habilidade de aprender a partir de seu ambiente, e de melhorar o seu desempenho através da aprendizagem [67].

II.4.4. Processo de treinamento e aprendizagem

Para que ocorra o processo de aprendizagem é necessária a ocorrência em seqüência de tais eventos:

1 – A rede neural deve ser estimulada por um ambiente;

2 – A rede neural deve sofrer modificações nos seus parâmetros livres como resultado do estímulo recebido;

3 – A rede neural deve responder de uma maneira nova ao ambiente, devido as modificações ocorridas na estrutura interna.

Como dito anteriormente, a propriedade mais importante das redes neurais artificiais é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

Denomina-se algoritmo de aprendizado um conjunto de regras bem definidas para a solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais, estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

A rede neural se baseia nos dados para extrair um modelo geral. Portanto, a fase de aprendizado deve ser rigorosa e verdadeira, a fim de se evitar modelos hipotéticos ou não verdadeiros. Todo o conhecimento de uma rede neural está armazenado nas sinapses, ou seja, nos pesos atribuídos às conexões entre os neurônios. Do total de dados, 50 a 90% deve

ser separado para o treinamento da rede neural [79]. Estes dados devem ser escolhidos aleatoriamente a fim de que, a rede *aprenda* as regras ao invés de *decorar* exemplos. O restante dos dados só é apresentado à rede neural na fase de testes a fim de que ela possa *deduzir* corretamente o inter-relacionamento entre os dados.

A seguir estão descritos dois dos principais métodos de aprendizagem ou treinamento de redes neurais.

Treinamento supervisionado

No treinamento supervisionado pode-se considerar a existência de um professor que tem conhecimento do ambiente. O conhecimento é representado por um conjunto de exemplos entrada-saída. Mas, o ambiente é desconhecido pela RNA. A rede e o professor são expostos a um vetor de treinamento retirado do ambiente. Por possuir prévio conhecimento, o professor é capaz de fornecer à rede uma resposta desejada para aquele vetor de treinamento. A resposta desejada corresponde a ação ótima a ser realizada pela rede. Os parâmetros da rede são ajustados sob a influência combinada do vetor de treinamento e do sinal de erro. O sinal de erro é definido como a diferença entre a resposta desejada e a resposta real da rede. Este ajuste é feito iterativamente com o objetivo de seguir o exemplo do professor. Então, o conhecimento do ambiente disponível ao professor é transferido para a rede através do treinamento, da forma mais completa possível. Neste tipo de aprendizado a rede tem suas saídas comparadas com a resposta correta e recebe informações sobre seus erros. O professor diz quais são as respostas corretas.

Treinamento não-supervisionado

No treinamento não-supervisionado não há a presença de um professor externo ou um crítico para supervisionar o processo de aprendizagem. A rede se ajusta às regularidades estatísticas dos dados de entrada e então, desenvolve a habilidade de formar representações internas para as características de entrada, e de criar automaticamente novas classes.

Neste tipo de aprendizagem não há certo e errado. A rede precisa descobrir por si só classes interessantes ou características nos dados de entrada [81].

II.4.5. Perceptrons

Perceptrons de camada única

Rosenblatt [82] em 1958 propôs o perceptron como o primeiro modelo para aprendizagem com um professor (aprendizagem supervisionada). Rosenblatt desenvolveu algoritmos para ajustar os parâmetros livres de uma rede neural no seu modelo cerebral de perceptron.

O perceptron é a forma mais simples de uma rede neural usada para a classificação de padrões ditos linearmente separáveis (padrões que se encontram em lados opostos de um hiperplano), Figura II.42. Basicamente, ele consiste de um único neurônio com pesos sinápticos ajustáveis e *bias*. O perceptron é construído em torno de um único neurônio e é limitado a realizar classificação de padrões com apenas duas classes. Expandindo a camada de saída do perceptron para incluir mais de um neurônio, podemos realizar classificação com mais de duas classes, sendo estas classes linearmente separáveis para que o perceptron funcione adequadamente. Isto significa que os padrões a serem separados devem estar suficientemente separados entre si para assegurar que a superfície de decisão consista de um hiperplano.

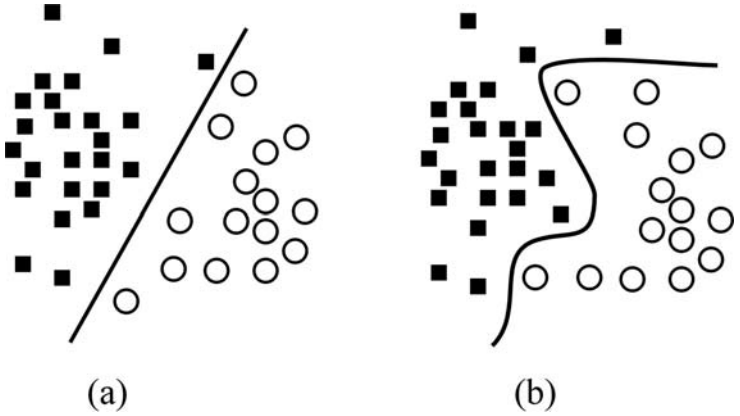

Figura II.42. *(a) Um par de padrões linearmente separáveis. (b) Um par de padrões não linearmente separáveis.*

Perceptrons de várias camadas

A solução de problemas não linearmente separáveis, passa pelo uso de redes com uma ou mais camadas ocultas ou intermediárias. As redes de múltiplas camadas alimentadas adiante, consistem de uma camada de entrada (unidades sensoriais), uma ou mais camadas ocultas (nós computacionais) e uma camada de saída [67]. Neste tipo de rede, os sinais de entrada se propagam apenas para a frente, camada por camada. Esta rede consiste numa generalização do perceptron de camada única.

Segundo Wasserman [78], a grande limitação dos perceptrons de camada única (separação apenas de dados linearmente separáveis) foi resolvida adicionando-se mais camadas. O que vem a mostrar que todo tipo de problema pode ser resolvido com uma mudança na arquitetura da RNA. Ele ainda afirma que o desempenho pode ser de classificação geral, separando pontos que estão em regiões próximas.

No projeto de redes neurais, deve-se ter cuidado para não utilizar um número de camadas excessivas, o que pode levar a rede a memorizar os padrões de treinamento, ao invés de extrair as características relevantes que permitirão a generalização ou o reconhecimento de padrões não vistos durante o treinamento (este problema é chamado *overfitting*). Por outro lado, um número muito pequeno de camadas, pode forçar a rede a gastar tempo em excesso tentando encontrar uma representação ótima (as unidades utilizadas podem ficar sobrecarregadas, tendo que lidar com um elevado número de restrições). Segundo Braga [79], uma rede com uma camada oculta pode implementar qualquer função contínua. A utilização de duas ou mais camadas ocultas permite a aproximação de qualquer função. Deve ser observado que permitir a implementação da função não implica a garantia de implementação efetiva da função. Dependendo da distribuição dos dados, a rede pode convergir rapidamente ou demorar muito para encontrar a solução desejada.

Os perceptrons de múltiplas camadas têm sido aplicados com sucesso para resolverem diversos problemas difíceis através do treinamento de forma supervisionada com um algoritmo muito popular conhecido como algoritmo de retropropagação do erro (do inglês *error backpropagation)* [67].

II.4.6. Algoritmo de retropropagação do erro

A aprendizagem por *retropropagação* de erro consiste, resumidamente, de duas etapas: um passo para frente, a propagação do sinal, e um passo para trás, a *retropropagação* do erro. Um vetor de entrada é fornecido à camada de entrada da rede e seu efeito se propaga através da rede, camada por camada. Ao final da rede, um conjunto de saídas é produzido como resposta real da rede. Na etapa de propagação, os pesos sinápticos são mantidos fixos. Após esta etapa, a saída da rede é subtraída da saída desejada, produzindo um erro que é então *retropropagado* através da rede linearizada, sendo os pesos sinápticos ajustados de acordo com uma regra de correção de erro. O objetivo é aproximar ao máximo possível a saída real da rede da saída desejada, minimizando o erro [79].

Resumidamente o algoritmo de retropropagação do erro pode ser descrito nos seguintes passos:

1. Iniciar os pesos sinápticos, *bias* e parâmetros da rede.
2. Repetir até que um critério de parada previamente estabelecido seja atingindo (erro mínimo, número de épocas, etc.).
    2.1. Para cada padrão de treinamento:
        2.1.1. Calcular a saída da rede na fase de propagação.
        2.1.2. Comparar as saídas produzidas com as saídas desejadas.
        2.1.3. Atualizar os pesos sinápticos através da fase de *retropropagação* e equações descritas.

O Algoritmo de retropropagação do erro é baseado na regra delta proposta por Widrow e Hoff [83], sendo também chamada de regra delta generalizada. Este algoritmo propõe uma forma de definir o erro nos nós das camadas intermediárias, possibilitando o ajuste de seus pesos. Os ajustes dos pesos são realizados utilizando-se o método do gradiente [67,78,79].

II.5. PROCESSAMENTO DE SINAIS

Nesta seção será realizada uma breve descrição dos pré-processamentos (Transformada de Fourier, Transformada *Wavelet*, Filtro média móvel e Filtro Savitzky–Golay) aplicados em um conjunto de sinais de MFL antes de serem fornecidos como entradas de uma rede neural, com o objetivo de melhorar o desempenho da rede na discriminação destes padrões de sinais. O objetivo do pré–processamento aplicado nestes sinais é simplesmente uma tentativa de reduzir características do sinal que dificultam a sua classificação, como ruído e altas frequências por exemplo.

II.5.1. Análise de Fourier

Existe na atualidade uma grande quantidade de ferramentas para processamento de sinais. Dentre todas estas, talvez, a mais conhecida e utilizada seja a Análise de Fourier, que consiste em decompor um sinal em suas componentes harmônicas de diferentes freqüências (Figura II.43). Um outro modo de ver a análise de Fourier é como uma técnica matemática para mudar a visualização do sinal do domínio do tempo para o domínio da freqüência [84, 85].

Figura II.43. *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 ± ∞ do

sinal *f(t)* multiplicado por uma exponencial complexa (relembrando que uma exponencial complexa pode ser decomposta em componentes senoidais reais e imaginárias).

Os resultados da transformada são os *coeficientes de Fourier F(ω)* que, quando multiplicados por senóides de freqüências apropriadas ω, geram as componentes senoidais do sinal original. Graficamente, o processo está representado na Figura II.44.

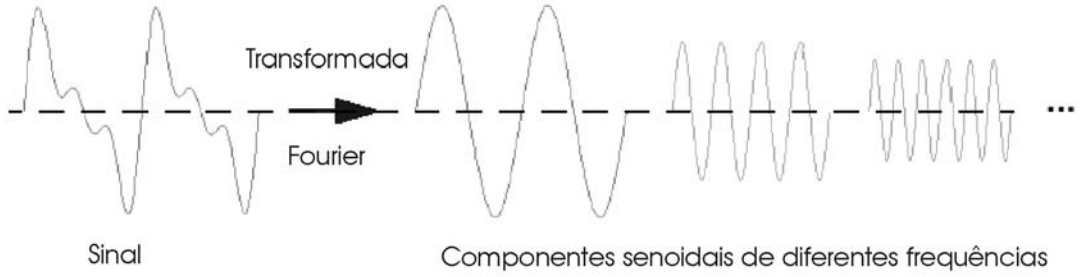

Figura II.44. *Componentes senoidais geradas pela decomposição da transformada de Fourier.*

Para muitos sinais, a análise de Fourier é extremamente útil porque a componente de frequência contém informações de grande importância. No entanto, a análise de Fourier possui um sério inconveniente. Quando o sinal é transformado para o domínio da frequência, a informação de tempo é perdida. Portanto, pela análise da transformada de Fourier de um sinal é impossível dizer em que momento significativamente um evento particular ocorreu.

Se as propriedades do sinal não variam com o tempo, ou seja, se o sinal é *estacionário*, este inconveniente não é muito importante. No entanto, muitos sinais interessantes contêm numerosas características transitórias ou *não-estacionárias*, tais como mudanças abruptas, flutuações, descontinuidades, etc. Estas características são muitas vezes a parte mais importante do sinal, e a análise de Fourier não é apropriada para detectá-las.

Objetivando corrigir esta deficiência, Gabor [85] adaptou a transformada de Fourier para analisar somente uma pequena seção do sinal no tempo - uma técnica chamada *windowing* (janelamento) do sinal (Figura II.45). A adaptação de Gabor, conhecida como *Short Time Fourier Transform* (STFT), mapea um sinal em uma função bidimensional de tempo e freqüência.

Figura II.45. *Short-Time Fourier Transform (STFT).*

A STFT representa um tipo de compromisso entre uma visão baseada no tempo e frequência do sinal. Esta técnica fornece informações sobre quando e em que frequências um evento do sinal ocorre. Entretanto, esta informação só pode ser obtida com limitada precisão, e esta precisão é determinada pelo tamanho da janela.

Enquanto o compromisso da STFT entre informações de tempo e frequência pode ser útil, a desvantagem é que uma vez escolhido um tamanho particular para a janela de tempo, esta será a mesma para todas as frequências. Muitos sinais requerem mais flexibilidade, onde se possa variar o tamanho da janela para determinar mais precisamente tanto o intervalo de tempo quanto a faixa de frequências.

Geralmente, os filtros de suavização de ruído atuam diretamente sobre o sinal 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. No entanto, existem filtros que atuam diretamente sobre as frequências que compõem o sinal, possibilitando a remoção seletiva de ruído. Estes filtro são conhecidos como filtros de remoção de ruídos, sendo os mais populares baseados na transformada de Fourier e em transformada wavelets [86].

II.5.2. Análise Wavelet

A análise Wavelet foi desenvolvida com o intuito de superar a limitação da janela fixa proposta pela técnica STFT, utilizando uma técnica de janelamento variável. Desta forma é utilizada uma janela temporal pequena onde se deseja informações mais precisas de alta freqüência, e janelas temporais maiores onde se desejam informações de baixa

freqüência. A principal vantagem de sua utilização é a capacidade de realizar análises de áreas locais, desta forma a análise Wavelet é capaz de revelar aspectos de dados que outras técnicas de análise de sinais poderiam perder. A Figura II.46 mostra o funcionamento da análise Wavelet, enquanto a Figura II.47 ilustra uma comparação entre a análise de STFT e a análise Wavelet.

Figura II.46. *Transformada Wavelet.*

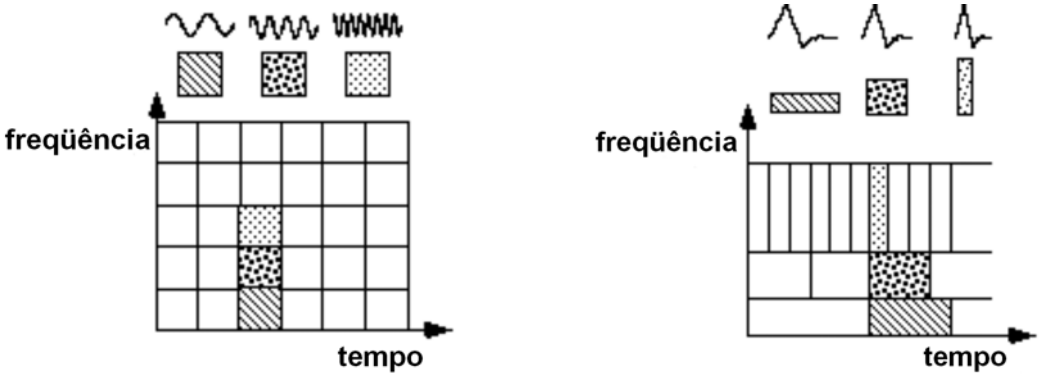

(a) *(b)*

Figura II.47. *Análise do sinal utilizando janelas de (a) tamanho fixo (transformada de Fourier com janelamento) e (b) tamanho variável (transformada Wavelet).*

Uma Wavelet pode ser definida como uma onda de duração limitada e de valor médio nulo e cuja forma tende a ser irregular e assimétrica, ao contrário das senóides, que variam entre $\pm \infty$ e são suaves e regulares (Figura II.48). Portanto, um sinal de forma variável pode ser melhor relacionado a análise wavelet do que a análise de Fourier.

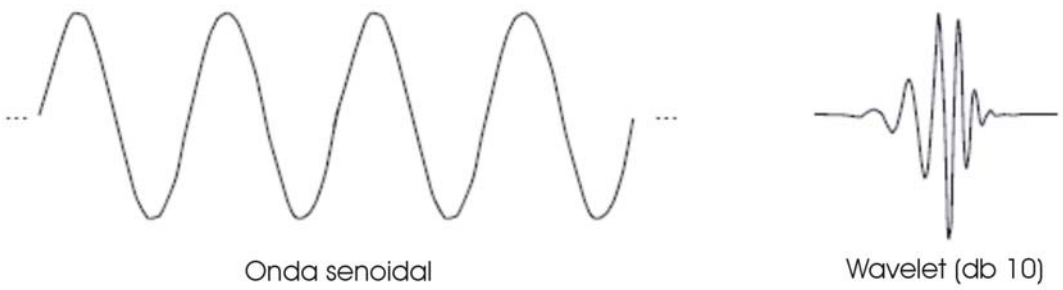

Figura II.48. *Onda senoidal e Wavelet Daubechies 10 (db 10).*

De forma similar à Transformada de Fourier, que consiste na decomposição de um sinal em funções senos de várias freqüências, a Transformada Wavelet é a decomposição de um sinal em componentes (Waveletes) que variam em escala (estendidas ou comprimidas) e em localização (transladadas) em relação a Wavelet original ou "Wavelet mãe".

A transformada Wavelet contínua (CWT) é definida como o somatório sobre todo o tempo do sinal multiplicado por uma versão escalonada e transladada da função wavelet ψ:

$$C(escala, posição) = \int_{-8}^{\infty} f(t).\psi(escala, posição, t)dt \qquad \textit{Eq. II.9}$$

O resultado da CWT é uma enorme quantidade de C*oeficientes Wavelet C*, que são funções da escala e posição. Multiplicando cada coeficiente por uma wavelet apropriada, escalonada e transladada, geram-se os componentes wavelets do sinal original, Figura II.49.

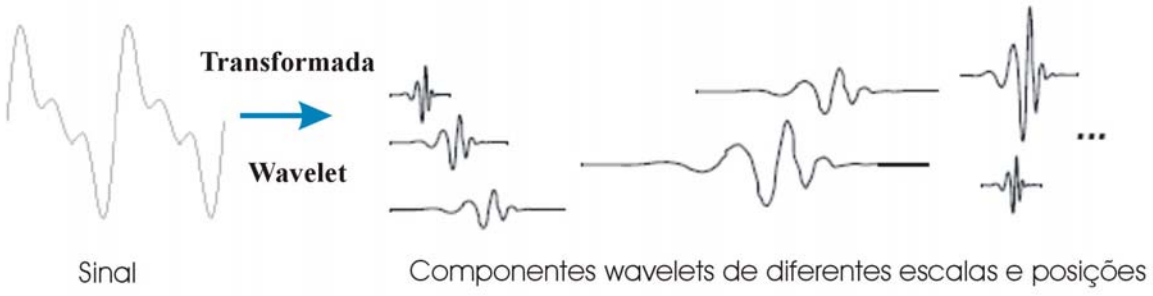

Figura II.49. *Componentes geradas pela decomposição da Transformada Wavelet.*

II.5.2.1. Escala

Escalonar uma wavelet significa simplesmente esticá-la ou comprimi-la. A Figura II.50 exemplifica o escalonamento de uma wavelet.

Quanto mais estendida a wavelet, uma maior parte do sinal é comparada e deste modo as mudanças lentas e os aspectos mais grosseiros do sinal 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. Existe uma correspondência entre o coeficiente de escala e a frequência.

Alto coeficiente a $\Rightarrow$ *Wavelet estendida* $\Rightarrow$ *Aspectos grosseiros* $\Rightarrow$ *Baixa frequência* ω

Baixo coeficiente a $\Rightarrow$ *Wavelet comprimida* $\Rightarrow$ *Detalhes finos* $\Rightarrow$ *Alta frequência* ω

(a) *(b)*

Figura II.50. *Escalonamento de uma wavelet (a) baixo coeficiente (comprimida: aspectos finos) e (b) alto coeficiente (esticada: aspectos grosseiros).*

II.5.2.2. Translação

A função de translação age atrasando ou adiantando a wavelet conforme pode ser observado na Figura II.51.

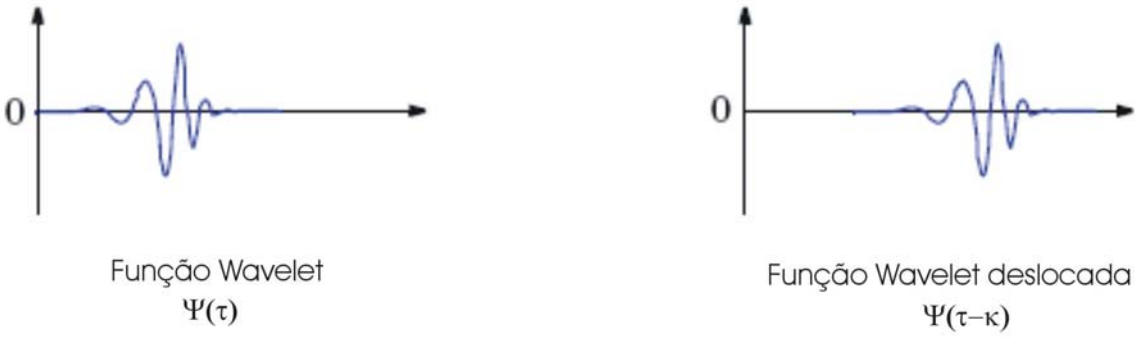

(a) *(b)*

Figura II.51. *Translação da função Wavelet (a) momento t e (b) momento t-k.*

A partir do exposto anteriormente, pode-se resumir o processo de uma transformada wavelet contínua em cinco passos, conforme a seguir:

1. Escolhe-se uma wavelet apropriada, de acordo com a aplicação desejada, e compara-se essa wavelet com a seção inicial do sinal.

2. Calcula-se um coeficiente C, que representa a similaridade da wavelet com esta seção do sinal (Figura II.52). Quanto maior o coeficiente, maior a similaridade. O resultado, logicamente, vai depender da forma da wavelet escolhida.

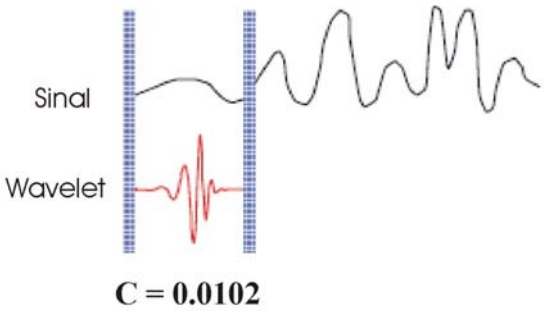

Figura II.52. *Medida da correlação "C" entre a wavelet e uma seção do sinal.*

3. Translada-se a wavelet para direita e o passo 2 é repetido até percorrer todo o sinal (Figura II.53).

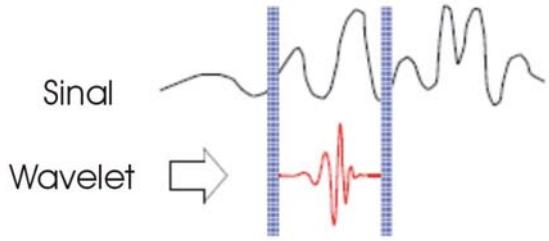

Figura II.53. *Translação e medida da correlação entre a wavelet e a seção do sinal.*

4. Altera-se a escala da wavelet e os passos 1,2 e 3 são repetidos (Figura II.54).

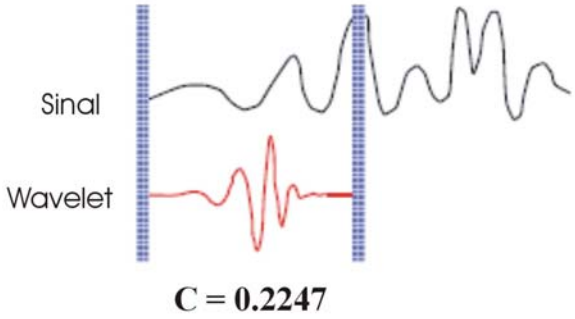

Figura II.54. *Medida da correlação "C" entre a wevelet redimensionada e uma seção do sinal.*

5. Repete-se os passos 1 até 4 para todos as escalas.

Após finalizar estas operações, os resultados obtidos podem ser colocados em um gráfico no qual o eixo x representa o tempo, o eixo y representa a escala e a cor ou nível de cinza o coeficiente C como ilustrado na Figura II.55 [71].

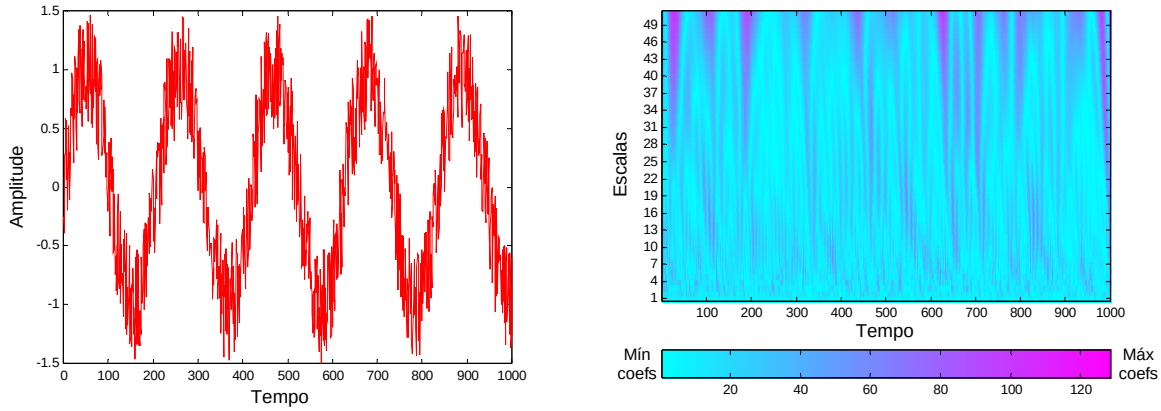

(a) *(b)*

Figura II.55. *(a) sinal de uma senóide com ruído e (b) transformada wavelet contínua [71].*

Os coeficientes wavelets podem ser apresentados também em um gráfico tridimensional conforme mostrado na Figura II.56.

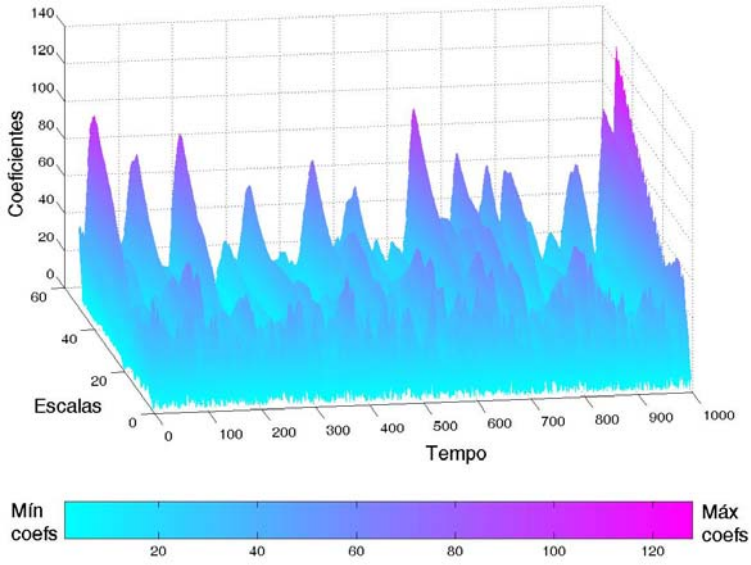

Figura II.56. *Transformada wavelet contínua, vista tridimensional.*

Como pôde ser visto, a transformada wavelet contínua de um sinal de uma dimensão gera uma representação de duas dimensões no espaço tempo-escala. No entanto, o cálculo dos coeficientes de todas as possíveis escalas requer um enorme esforço computacional e gera informações redundantes.

Uma alternativa à CWT é a utilização da parâmetros de escalonamento e translação discretos. Neste tipo de análise pode ser utilizado apenas um subconjunto de escalas e posições mais apropriadas, tornando a análise mais eficiente e precisa [85]. A esta análise dá-se o nome de *Transformada Wavelet Discreta (DWT*).

II.5.2.3. Remoção de ruído

As wavelets podem ser utilizadas para remover ruídos de sinais através das técnicas conhecidas como "*Wavelet shrinkage"* e *"thresholdings methods"*. Primeiramente, as wavelets agem como filtros, dividindo os sinais em aproximações e detalhes. Caso estes detalhes possuam amplitudes muito baixas, estes podem ser removidos, reduzindo o nível de ruídos, sem perda de informações. A idéia de "*thresholdings"* (limiares) é cortar (zerar) todos os coeficientes de detalhes que estejam abaixo de um certo limiar. Estes coeficientes são utilizados na matriz de transformação inversa filtrando o sinal. A Figura II.57 mostra um sinal antes e após remoção de ruídos via wavelets. Esta técnica se torna particularmente interessante pois permite a remoção de ruídos sem alisamento de picos e descontinuidades [71].

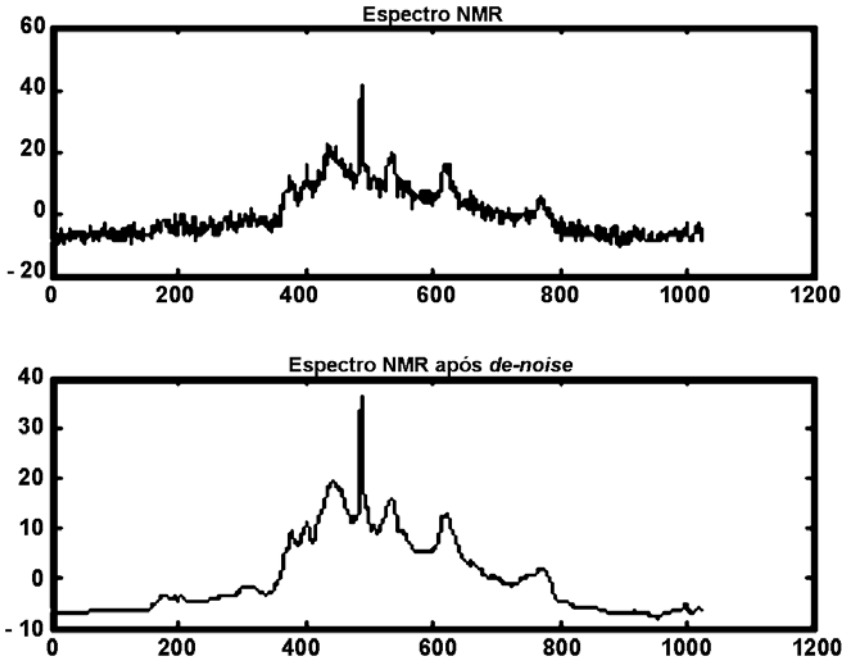

Figura II.57. *Sinal de ressonância magnética nuclear antes e após remoção de ruídos via wavelets [71].*

II.5.3. Filtro média móvel

Filtro média móvel é um procedimento numérico que suaviza dados substituindo cada ponto dos dados originais do sinal com a média dos pontos vizinhos definidos dentro de um dado comprimento.

II.5.4. Filtro Savitzky-Golay

O Filtro de Alisamento Savitzky-Golay, também chamado filtro de suavização polinomial ou filtro de suavização por mínimos quadrados, é tipicamente utilizado para suavizar um sinal com ruído e com grande intervalo de frequências.

O filtro Savitzky-Golay é menos sensível à largura do intervalo pois o novo ponto, isto é, o ponto do sinal já suavizado, é obtido através do ajuste dos pontos do intervalo por um polinômio e não pela simples média dos pontos vizinhos, 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. Esta característica possibilita que o filtro de Savitzky-Golay seja aplicado a sinais analíticos com picos estreitos, apresentando resultados superiores aos obtidos com o filtro de média móvel.

Embora os filtros Savitzky-Golay sejam mais efetivos em preservar as componentes de alta frequência do sinal, eles são menos eficientes do que os filtros média móvel para rejeitar ruídos.

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. Ajusta-se através do método de mínimos quadrados, um polinômio de grau variável aos pontos restantes;
5. Utiliza-se o polinômio para estimar o valor do ponto em questão;
6. Desloca-se o intervalo para o ponto seguinte do sinal original e repete-se o processo anterior.

Portanto, antes da aplicação do filtro Savitzky-Golay, dois parâmetros devem ser escolhidos: a ordem do polinômio e o tamanho da janela do filtro. A escolha desses dois parâmetros deve obedecer 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 impar e (3) a ordem do polinômio deve ser menor do que o tamanho da janela escolhida. As Figuras II.58 e II.59 mostram a influência desses parâmetros na suavização do sinal, onde pode-se perceber que quanto menor o grau do polinômio e quanto maior o tamanho da janela, maior o nível de suavização alcançado.

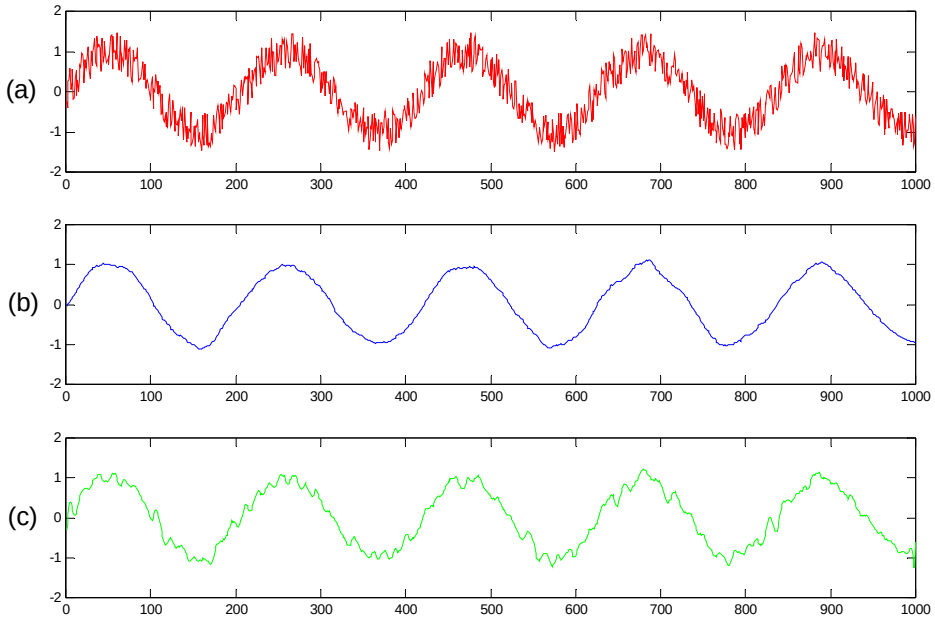

Figura II.58. *Influência da ordem do polinômio na suavização do sinal: (a) seno com ruído, (b) aplicação de um polinômio de ordem 3 e (c) aplicação de um polinômio de ordem 11.*

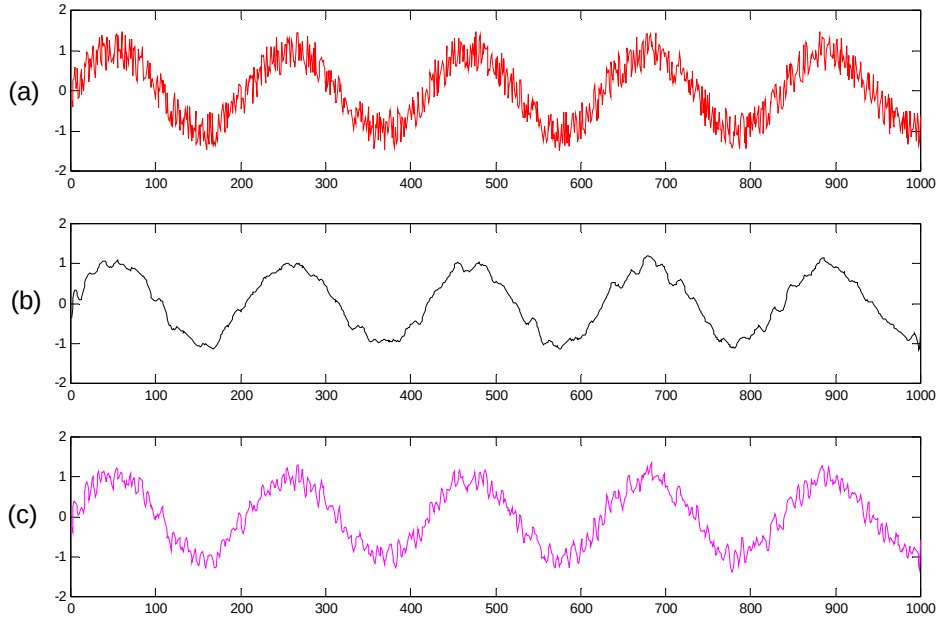

Figura II.59. *Influência do tamanho da janela na suavização do sinal: (a) seno com ruído, (b) janela de tamanho 63 e (c) janela de tamanho 21.*

II.6. CONFIABILIDADE DOS ENSAIOS NÃO DESTRUTIVOS

Inspeção por técnicas de ensaios não destrutivos (END) tem dado importantes contribuições para a integridade e segurança de componentes e estruturas de engenharia, provendo informações sobre as condições de operação e a presença de descontinuidades. No entanto, ensaio não destrutivo, como qualquer técnica de diagnosticar descontinuidades, não é perfeito, e dependendo de vários fatores, importantes descontinuidades podem não ser detectadas, colocando em risco o sistema avaliado.

Somente em meados da década de 70 tornou-se comum questões sobre a confiabilidade das técnicas de inspeção através de ensaios não destrutivos. O conhecimento e quantificação desta confiabilidade permite avaliar a importância e o valor a serem atribuídos aos métodos de inspeção, servindo também como ferramenta para melhorar a eficiência da técnica, e consequentemente melhorar sua confiabilidade [87].

Em inspeções com ensaios não destrutivos diversos fatores podem influenciar se a inspeção resultará em uma correta avaliação quanto a presença ou ausência de descontinuidades. Em geral, ensaios não destrutivos compreendem a aplicação de um estímulo sobre o material em teste e a interpretação da resposta ao estímulo. Repetidas inspeções de uma mesma descontinuidade podem produzir diferentes magnitudes do estímulo devido à variações momentâneas no ajuste e calibração do equipamento. Esta variabilidade é inerente ao processo. Assim como, diferentes descontinuidades de mesma dimensão podem produzir diferentes magnitudes de resposta devido a diferenças nas propriedades dos materiais, geometria e orientação das descontinuidades. A interpretação da resposta pode ser influenciada pela capacidade de interpretação (manual ou automática), a acuidade mental do inspetor quando influenciado por fadiga ou panorama emocional, a facilidade de acesso e o ambiente de inspeção. Todos esses fatores contribuem para incertezas na inspeção e conduzem para uma caracterização probabilistica da capacidade da inspeção [27].

O método mais utilizado para quantificar a confiabilidade e sensibilidade de uma técnica de ensaio não destrutivo é a sua curva de probabilidade de detecção, POD (do inglês *probability of detection*). A curva POD sintetiza uma metodologia para estimar a capacidade de detecção de um método de inspeção em função da dimensão da

descontinuidade, ou seja, a curva POD mostra a probabilidade de detecção de um defeito como uma função da sua dimensão para uma técnica de inspeção especifica [88]. Para uma técnica ideal, a POD para defeitos menores que um tamanho crítico é zero, enquanto a POD para algum defeito maior que este tamanho é um (100%). No caso ideal, não existirá nem falsa rejeição de partes boas nem falso aceite de partes defeituosas. Contudo, curvas POD para técnicas de ensaios reais, nunca são tão discriminatórias como a curva ideal, e como resultado existirão regiões de incertezas com falsa rejeição e falso aceite (Figura II.60).

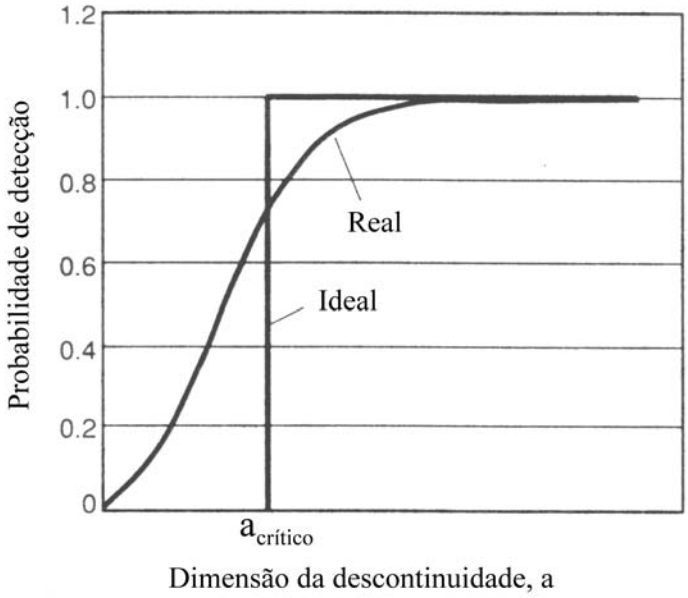

Figura II.60. *Curvas POD para técnicas de inspeção real e ideal.*

Até recentemente, todas as aplicações de POD eram essencialmente empíricas, isto é, um número significante de amostras eram preparadas com defeitos artificiais e então experimentos eram realizados por um determinado número de operadores para avaliar uma técnica de ensaio. Para levantamento da curva POD o conjunto de amostras deve possuir defeitos com dimensões, tipo e localizações conhecidas e deve ser grande o suficiente para reproduzir o mais próximo possível as condições reais de operação. No entanto, para produzir um espaço amostral estatisticamente significante que simule adequadamente as condições prováveis de serem encontradas em aplicações reais, os ensaios podem exigir um

conjunto de amostras suficientemente grande que torne o processo inviável ou o custo da operação pode ser tão elevado que seja impraticável [89, 90].

Nos últimos anos, com o advento da modelagem computacional, a POD pôde ser calculada utilizando esta tecnologia. Empregando esta tecnologia, uma curva POD pode agora ser simulada para um conjunto específico de condições e verificada com poucas amostras experimentais com custo relativamente baixo e com a capacidade de estender o diagnóstico para outras condições de inspeção. A vantagem de usar modelos é que o estudo do desempenho das variáveis que influenciam no processo de inspeção pode ser realizado com relativa facilidade e baixo custo. Normalmente ensaios são realizados variando-se um parâmetro (tais como posição ou geometria do defeito) para obter estimativas consistentes de seu efeito na POD. A modelagem matemática permite, então, uma considerada otimização do processo de inspeção [87].

A confiabilidade da inspeção ultra-sônica depende de vários fatores. Os mais importantes são: tipo, tamanho e orientação do defeito, morfologia do defeito, localização da descontinuidade, tipo de material inspecionado, restrições geométricas (inacessibilidade) da inspeção, fator humano, equipamento e procedimento de inspeção e condições ambienteis no trabalho de inspeção [91,92].

Um modelo de confiabilidade adotado no *1st European-American Workshop* sobre confiabilidade ocorrido em Berlin em junho de 1997, identificou três funções que podem ter uma relação de dependência com a confiabilidade dos ensaios não destrutivos: a capacidade intrínseca do sistema, características de aplicações específicas e o fator humano. O modelo adotado sugeriu que a confiabilidade de uma técnica de inspeção nunca será melhor que a idealizada. Assim, a confiabilidade de uma técnica de END quando aplicada para um tipo específico de descontinuidade pode ser representada usando o modelo conceitual dado por [93,94,95]:

$$\mathrm{Re} \equiv f(IC) - g(AP) - h(HF) \qquad \textit{Eq. II.10}$$

onde,

Re é a confiabilidade total do sistema;

$f(IC)$ é uma função da capacidade intrínseca do sistema de END;

$g(AP)$ é uma função dos parâmetros aplicados (restrições ao acesso, acabamento superficial do material, etc.);
$h(HF)$ é uma função do fator humano (experiência, treinamento, habilidade, etc.).

Este modelo conceitual sugere meramente que alguma função f, dependente da capacidade intrínseca da técnica, é representativa da confiabilidade do sistema sobre condições ideais. Quando aplicações de parâmetros (desvio das condições ideais) são consideradas, a confiabilidade idealizada será reduzida de acordo com a natureza de outra função, g. Quando fatores humanos associados com inspeções manuais são considerados, a confiabilidade efetiva é reduzida mais ainda, seguindo a função h. Uma representação gráfica desta relação é apresentada na Figura II.61, onde do lado esquerdo tem-se um nível de confiabilidade idealizado, estabelecido pela capacidade intrínseca da técnica de inspeção. Do lado direito tem-se o nível predito de confiabilidade derivado do impacto negativo da aplicação dos parâmetros e do efeito do fator humano.

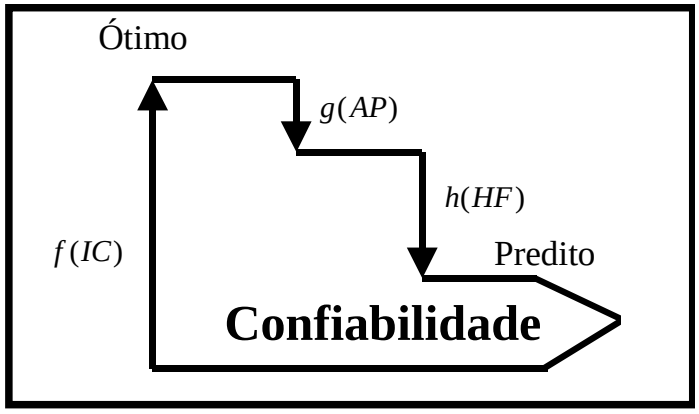

Figura II.61. *Representação gráfica do conceito de confiabilidade em END.*

Segundo a análise de Forsyth et al. [96], a POD de uma trinca de dimensão característica "a" é definida pela probabilidade de detecção média de todas as trincas de dimensão "a". Esta definição reflete o fato de que a detectabilidade de trincas varia com um determinado número de fatores. Portanto, a curva POD mostrada na Figura II.62 é traçada a partir da POD média para cada dimensão de trinca, e o nível de confiança associado com a curva reflete o fato de que a curva foi calculada usando uma população amostral finita. O

comprimento da descontinuidade é a característica normalmente mais usada para relações de POD, mas outras medidas podem também ser utilizadas [96].

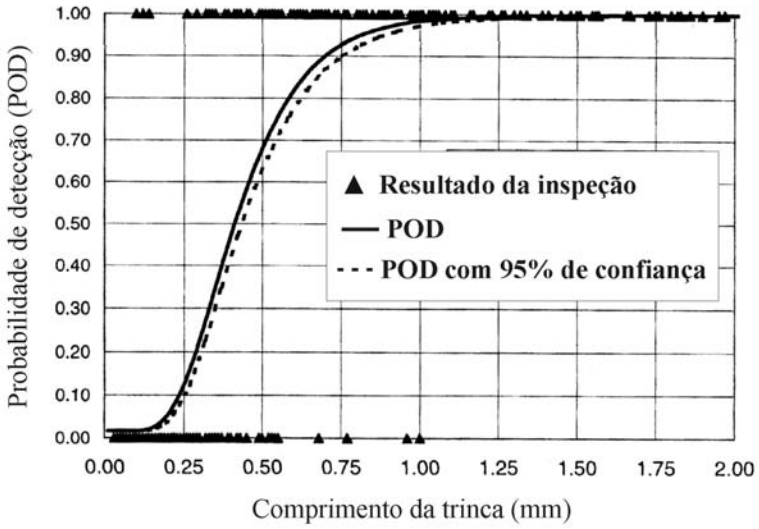

Figura II.62. *Exemplo de curva POD para inspeção de trincas em chapas.*

Diversos modelos estatísticos têm sido propostos para estimar a curva POD [97]. Estes modelos utilizam dados obtidos através de duas análises em ensaios não destrutivos: análise $\hat{a}$ versus a e análise acerto/erro (do inglês *hit/miss)* [27,98]. Alguns procedimento de ensaios não destrutivos produzem uma resposta *"$\hat{a}$"* do sinal, que está relacionada com a dimensão física real *"a"* da descontinuidade, se a descontinuidade é detectada. No entanto, muitos métodos de inspeção não dão informações da dimensão do defeito e o resultado da inspeção é registrado apenas em função da detecção ou não detecção do defeito. Por ser mais simples a análise *hit/miss* é a mais usual [27]. Portanto, enquanto a análise *hit/miss* produz como resultado de saída "defeito" ou "não-defeito", a análise $\hat{a}$ versus a produz uma saída escalar que é função da dimensão da descontinuidade. Ambos os métodos podem ser usados para o desenvolvimento da curva POD, mas diferentes resultados serão obtidos se os dois métodos de análise são aplicados para o mesmo conjunto de dados [27]. A Figura II.63 mostra o esquema da filosofia do método $\hat{a}$ versus a para a determinação da POD.

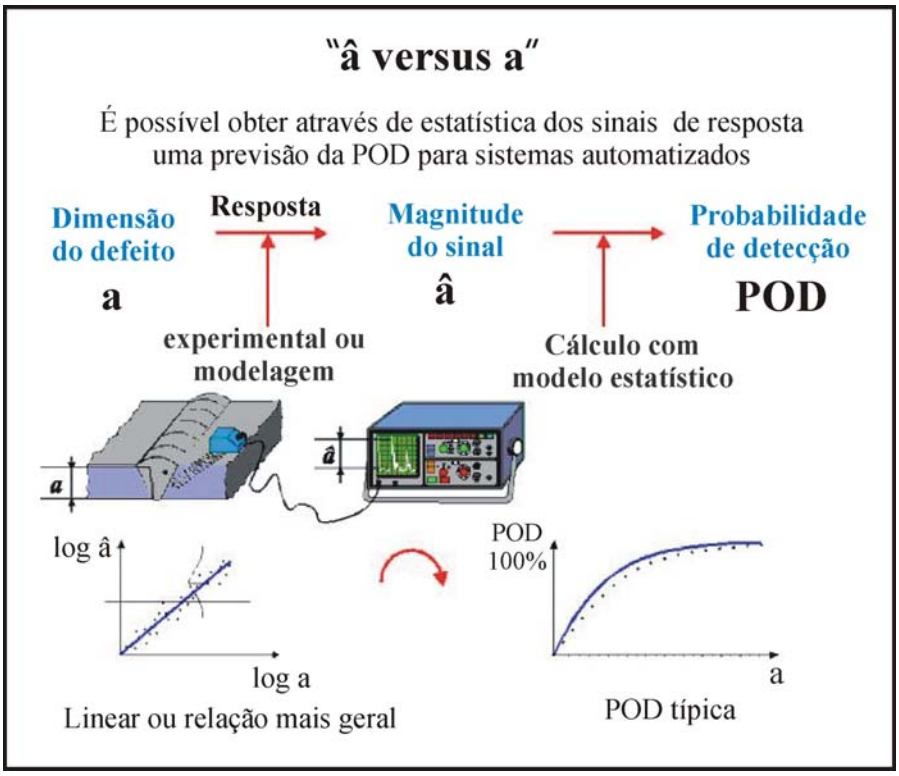

Figura II.63. *Esquema da filosofia do método â versus a para determinação da POD [99].*

Na Figura II.63, pode-se observar um corpo de prova com um defeito de dimensão *a*, que através do ensaio experimental produzirá como resultado no aparelho de ultra-som um sinal de magnitude *â*, que é função da dimensão real *a* do defeito. A partir da equação ajustada *â* em função de *a* e do erro observado neste ajuste é possível se estabelecer a curva POD, conforme descrito em (27).

A tarefa de inspeção executada pelo operador é geralmente uma tarefa difícil e pode ser dividida em dois passos [100,101]:

- Detectar defeitos presentes ou detectar defeitos presentes que apresentem uma determinada dimensão ou ainda determinar um tipo específico de defeito;
- Confirmar se componentes livres de defeitos realmente não possuem defeitos ou confirmar se defeitos iguais ou maiores que uma determinada dimensão não estão presentes ou ainda confirmar se defeitos de um determinado tipo não estão presentes.

A Figura II.64 mostra uma ilustração típica de uma tarefa de inspeção, onde um corpo de prova contendo descontinuidades reais é dividido em seções e ensaiado por uma técnica de ensaio não destrutivo. Os resultados da inspeção, tipo de defeito e grau de importância (criticidade), são registrados no relatório de inspeção.

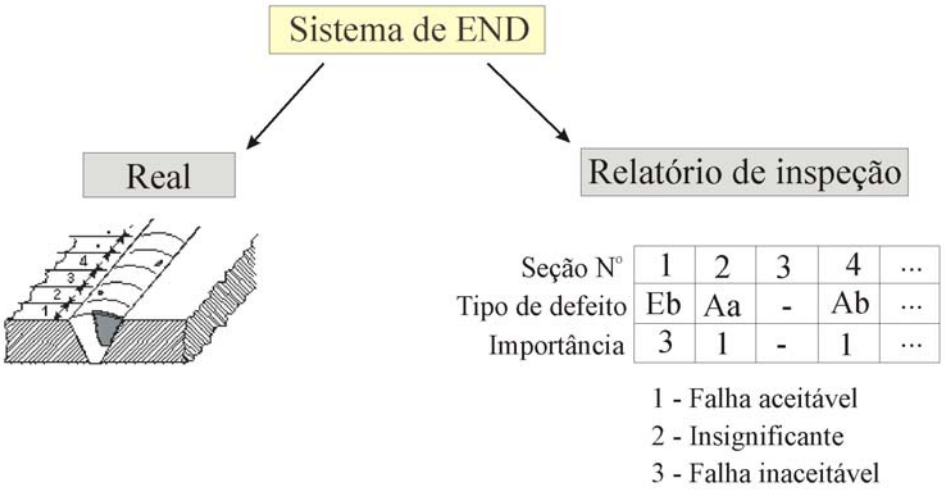

Figura II.64. *Configuração típica para uma tarefa de inspeção.*

Baseado nos ensaios experimentais registrados no relatório de inspeção da Figura II.64, a confiabilidade do ensaio pode ser avaliada através da probabilidade de detecção de defeito (POD), para dados obtidos pelo método $\hat{a}$ versus a ou pelo método *hit/miss*, utilizando uma modelagem matemática.

Assumindo que a resposta de END pode ser quantificada e registrada em termos de um parâmetro $\hat{a}$, que é relacionado com a dimensão da descontinuidade, então $\hat{a}$ resume a informação para determinar se uma positiva indicação do defeito será obtida.

Em qualquer procedimento de inspeção, se a amplitude do sinal de um defeito está abaixo de um limiar de registro, o defeito não será detectado. Inversamente, suprimindo erros humanos e de equipamento, qualquer sinal acima deste limiar será registrado e o defeito será detectado. Entre estes dois extremos está a curva POD [54]. Em alguns procedimentos, apenas se $\hat{a}$, exceder um limiar definido de decisão, $\hat{a}_{dec}$, a descontinuidade será registrada como detectada. A Figura II.65 mostra um gráfico de dados de $\hat{a}$ *versus* a

para 28 trincas obtidas por uma determinada técnica. Para 2 trincas nenhum sinal foi registrado, porque seu valor $\hat{a}$, estava abaixo do limiar de registro do sinal, $\hat{a}_{th}$. Estes pontos são indicados por uma seta para baixo em $\hat{a}_{th}$, indicando que o valor está abaixo do limiar de registro. Igualmente, o valor de $\hat{a}$ para 5 destas trincas excedeu o limite de saturação, $\hat{a}_{sat}$, do sistema de registro. Estes pontos estão indicados por uma seta para cima em $\hat{a}_{sat}$, indicando que a resposta foi um valor indeterminado acima do limite de saturação de registro. Na Figura II.65, o limiar de decisão é ajustado em 250 pontos. Apenas trincas cujo valor de $\hat{a}$ estão acima deste valor serão detectadas.

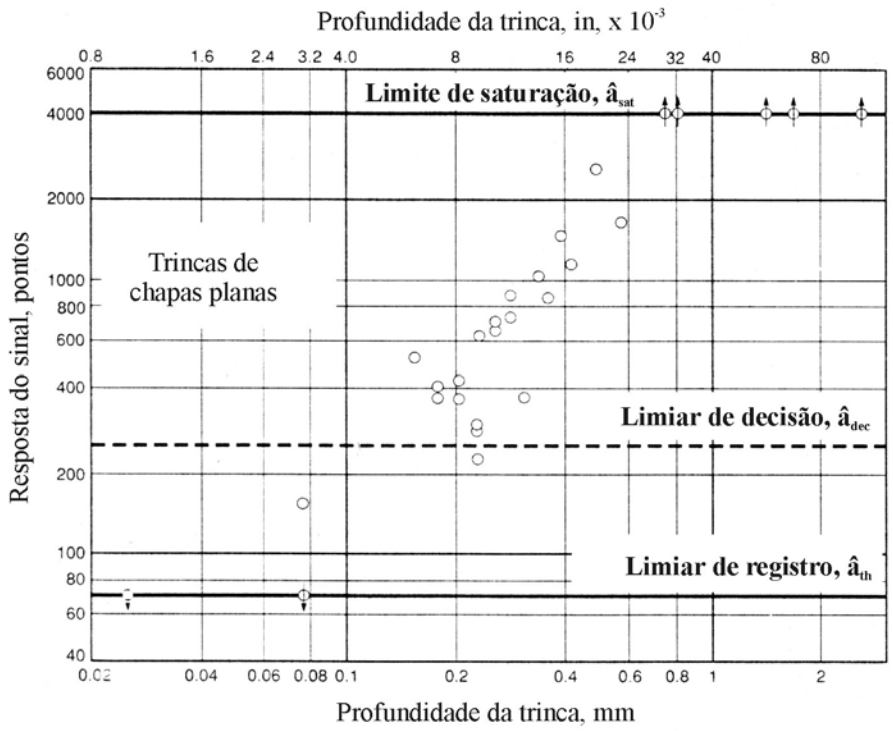

Figura II.65. *Exemplo de resposta do sinal de inspeção como função da profundidade da trinca.*

Concluindo, pode-se dizer que embora a POD seja uma medida do desempenho de um processo de inspeção em um tempo específico, ela reflete a capacidade do procedimento e pode ser somente vista como um processo de medida de confiabilidade se a inspeção está sobre controle (fator humano, equipamento e variáveis do processo).

II.7. CONSIDERAÇÕES FINAIS

Como resultado da passagem de uma ferramenta de *pig*, pode-se ter várias indicações de defeitos que deverão ser analisadas e tomadas decisões quanto a sua permanência ou remoção do duto avaliado. No entanto, muitas vezes a simples indicação gráfica ou a representação em escalas de cores do defeito não é suficiente para saber o tipo de descontinuidade e principalmente a sua criticidade, o que permitiria uma maior segurança na decisão a ser tomada. Além do mais, na maioria das vezes, o acesso ao local do duto para corrigir a descontinuidade é difícil e exige tempo e pessoal treinado para esta operação. Cabe ressaltar ainda, que em alguns casos, após um longo trabalho para se chegar até o local da indicação, o que se imagina ser um defeito pode ser apenas um pequeno amassamento ou uma pedra forçando o duto e que oferece pouco risco a sua integridade estrutural.

A classificação automática do tipo de descontinuidade, como proposto neste trabalho, será importante uma vez que vai permitir tomar decisões mais rápidas e precisas a respeito das indicações resultantes do ensaio por *pig* magnético. Os trabalhos que têm sido desenvolvidos nesta linha de pesquisa estão mais interessados na detecção, dimensionamento e forma do defeito [39,40,102].

O ensaio ultra-sônico de pulso-eco tem sido utilizado indiscriminadamente por diversas empresas e institutos de pesquisa na avaliação de materiais e equipamentos. No entanto poucos estudos têm sido realizados a respeito da confiabilidade desta técnica de inspeção. Um estudo nesta linha de pesquisa vai permitir uma avaliação da melhor técnica e dos parâmetros a serem utilizados para a detecção de descontinuidades de determinada dimensão. Alguns trabalhos nesta área já foram desenvolvidos pelo autor [103,104], Anexo E.

CAPÍTULO III

MATERIAS E MÉTODOS

III.1. INTRODUÇÃO

Neste capítulo serão descritas as metodologias e procedimentos experimentais utilizados no desenvolvimento deste trabalho de tese. Inicialmente, são apresentadas as características dos materiais utilizados, identificando os corpos de prova e as características dos equipamentos. Para um melhor entendimento os ensaios de MFL e ultra-som serão apresentados separadamente.

III.2. ENSAIOS DE MFL

III.2.1. Corpos de prova para ensaio de MFL

Foram empregados na confecção dos corpos de prova dutos de especificação API 5L-X65, sem costura, diâmetro nominal de 304,8mm, espessura de parede de 7,137mm e comprimento de 9100mm. Nestes corpos de prova foram realizadas 12 soldas circunferenciais com defeitos inseridos artificialmente durante o processo de soldagem (Figura III.1 e III.2). Quatro classes de defeitos foram simuladas nos cordões de solda: falta de penetração (FP), penetração excessiva (PE), corrosão interna (CI) e corrosão externa (CE). Os defeitos foram dispostos ao longo do cordão de solda e distanciados de 90^{o}, no total de quatro defeitos por cordão. Os defeitos FP e PE foram inseridos por metodologia própria realizada no momento da deposição do cordão de solda, enquanto que os defeitos CI e CE foram simulados por furos não passantes inseridos manualmente utilizando limas rotativas e pedras abrasivas (Figura III.3 e III.4). Foram confeccionados quatro corpos de prova com as mesmas configurações para obtenção de dados suficientes para o estudo proposto. Os defeitos possuem comprimentos entre 10 e 50mm e altura entre 3 e 5mm no

caso da CE, CI e FP enquanto que o defeito de PE possui altura que varia entre 4 e 7mm, Anexo A.

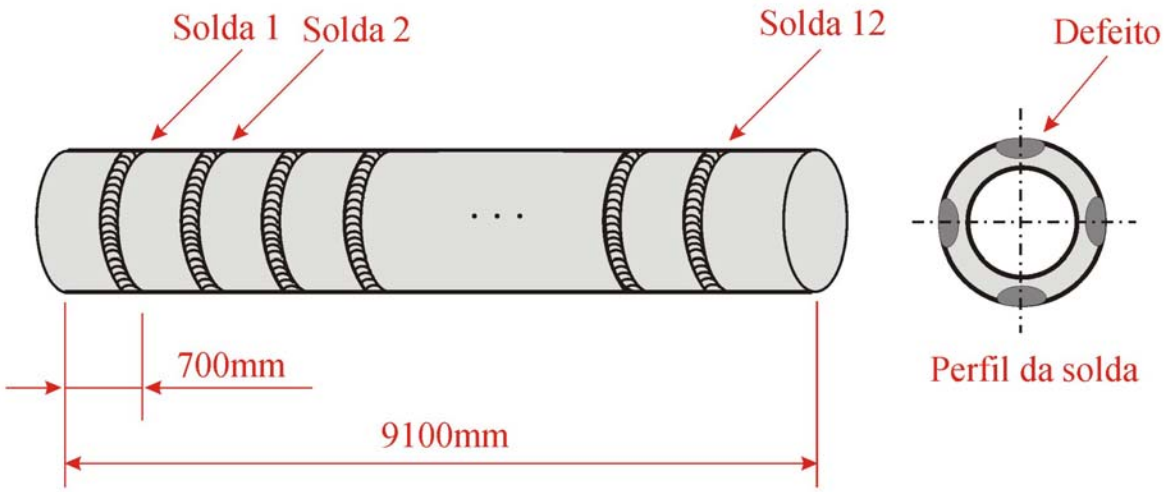

Figura III.1. *Desenho esquemático do corpo de prova para ensaio de MFL.*

Figura III.2. *Corpos de prova para ensaio de MFL. Dutos com soldas circunferenciais com defeitos inseridos artificialmente.*

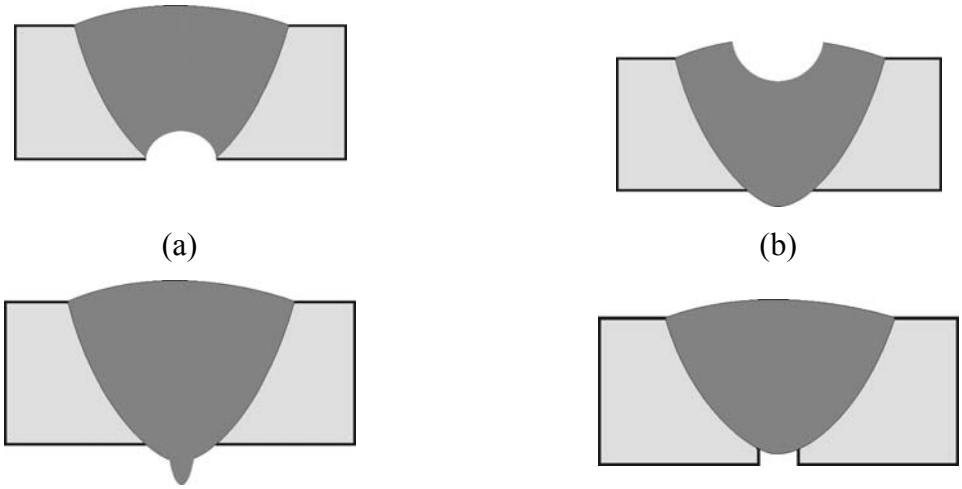

(a) (b)

(c) (d)

Figura III.3. *Desenho esquemático de um cordão de solda com defeito: (a) corrosão interna, (b) corrosão externa, (c) penetração excessiva e (d) falta de penetração.*

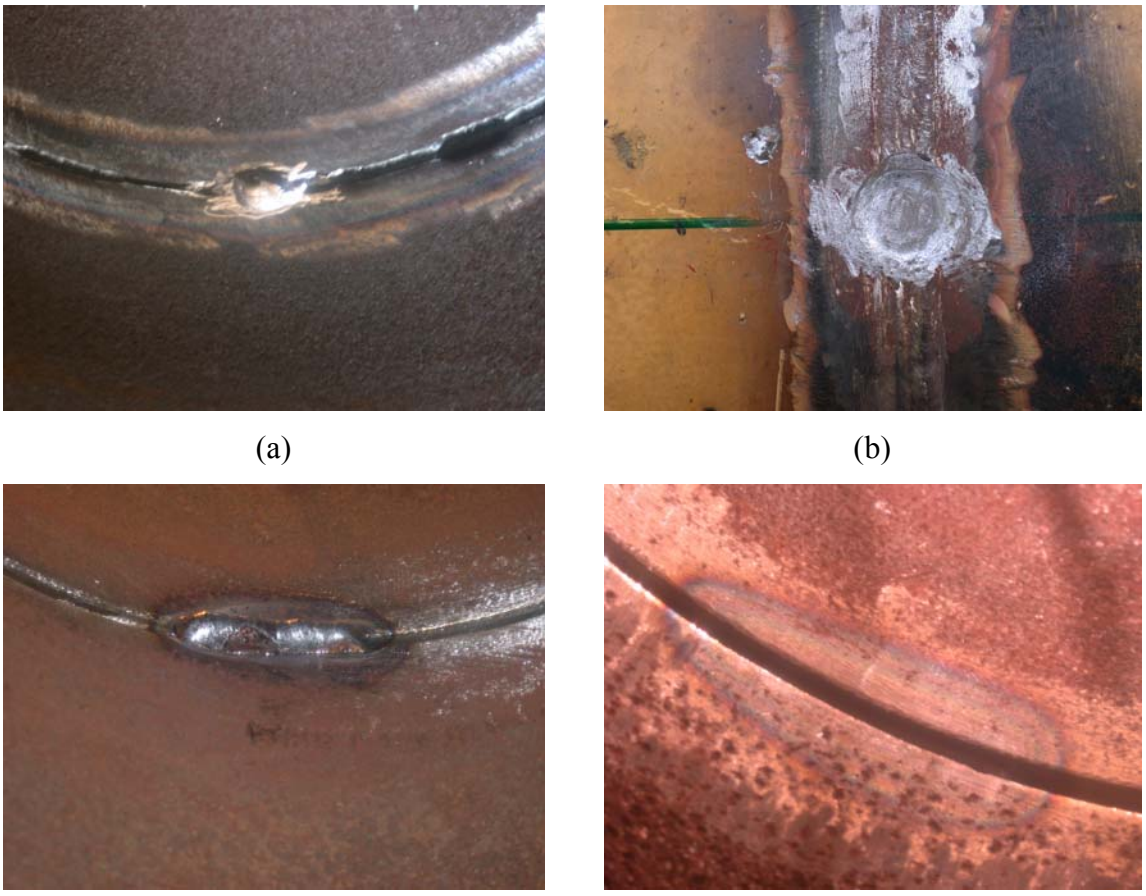

(a) (b)

(c) (d)

Figura III.4. *Defeitos inseridos nos corpos de prova: (a) CI, (b) CE, (c) PE e (d) FP.*

As soldas foram realizadas utilizando dois processos de soldagem diferentes. Foi utilizado TIG (do inglês "*Tungsten Inert Gas*") na raiz da solda e eletrodo revestido no enchimento, uma vez que o processo TIG permite um melhor controle da soldagem e consequentemente um melhor controle na introdução do defeito, enquanto que eletrodo revestido permite uma maior rapidez do processo. Todas as soldas foram realizadas com chanfro em V, 70^{o} de inclinação, 5mm de abertura na raiz e 2mm de nariz, conforme Figura III.5. Em cada extremidade do corpo de prova foi soldado um duto de 2000mm para aceleração e desaceleração do *pig*, e após este, foi soldada uma calha de 3000mm para colocar e retirar o *pig* do corpo de prova.

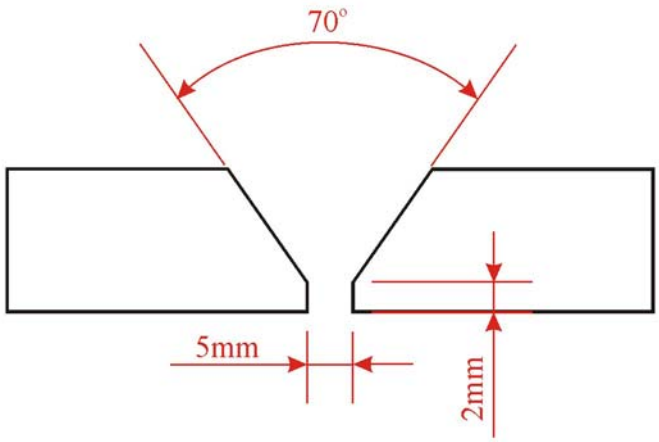

Figura III.5. *Desenho da junta soldada.*

III.2.2. Inspeção dos corpos de prova com pig de MFL

Os corpos de prova foram inspecionados utilizando *pig* magnético para aquisição dos sinais de MFL. Durante a inspeção os sinais aquisitados, os quais contém as informações das condições da parede do duto, são armazenados em hardware no interior do *pig* para posterior avaliação.

Foi utilizado nos ensaios uma ferramenta de pig magnético (MFL) contendo 136 sensores do tipo Hall e um anel de sensores do tipo bobina (Figura III.6), para discriminar entre defeitos internos e externos. Esta ferramenta é de propriedade da empresa PIPEWAY, com a qual o LABOEND/COPPE/UFRJ estabeleceu convênio para esta pesquisa. Antes da

inspeção com pig magnético, foi aplicado um pig de espuma para limpeza interna do duto (Figura III.7). Os ensaios foram realizados na bancada para ensaio de pig (pigódromo) do CENPES/PETROBRAS localizado na unidade de dutos e terminais do sudeste (DTSE) em Duque de Caxias no Rio de Janeiro.

Na inspeção por pig, o próprio fluido é o responsável pelo deslocamento da ferramenta dentro do duto, conforme mencionado anteriormente. Na bancada de ensaio utilizada neste trabalho (Figura III.8), foi empregado um cabo de aço e um motor elétrico para impelir ao pig a velocidade necessária para a inspeção. O ensaio foi repetido 3 vezes (3 corridas) e os dados armazenados em uma placa PCMCIA no interior do pig para posterior avaliação.

Após os ensaios os sinais foram transferidos do pig para um *notebook* e levados para o laboratório para análise. A visualização e análise dos sinais é realizada a partir do programa PipeScan de propriedade da empresa PipeWay, o qual permite exportar os sinais em formato TXT para serem tratados em outros programas computacionais.

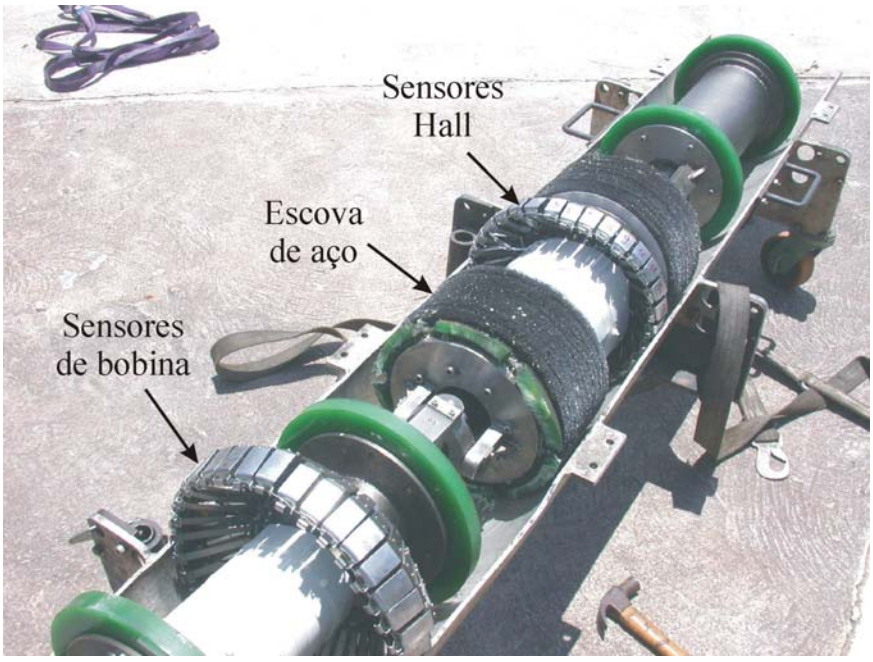

Figura III.6. *Pig magnético utilizado no ensaio.*

Figura III.7. *Pig de espuma utilizado para limpeza interna do duto.*

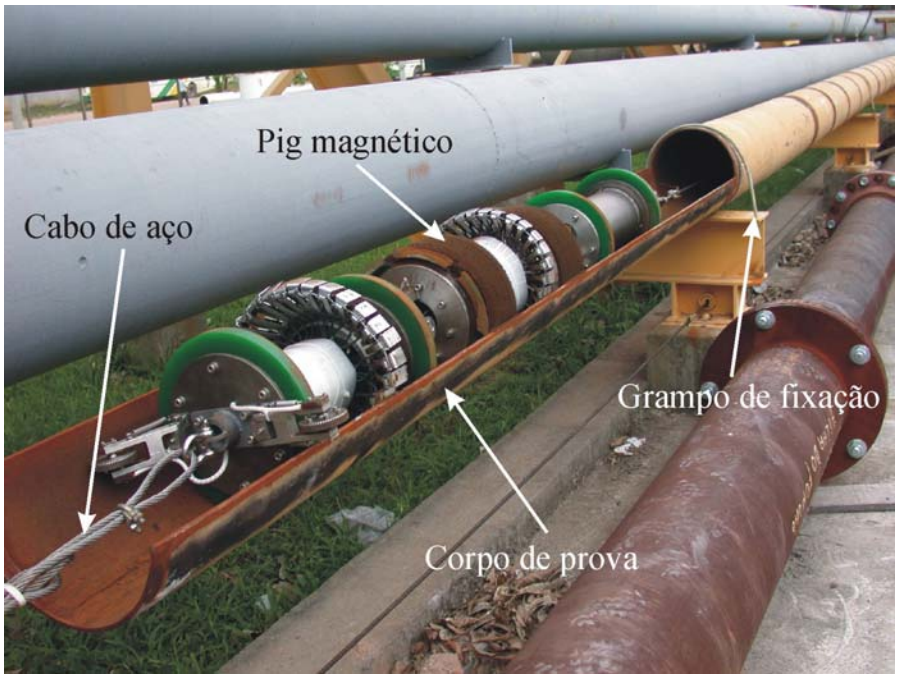

Figura III.8. *Bancada de ensaio.*

III.2.3. Reconhecimento de padrões de sinais de MFL

Neste trabalho classificadores de padrões não lineares foram implementados utilizando redes neurais artificiais tipo supervisionada com algoritmo de treinamento por retropropagação do erro com duas camadas, uma camada intermediária e uma camada de saída. Foi utilizado o programa MATLAB versão 5.3 para a implementação dos algoritmos das redes neurais. Variando-se o número de neurônios na camada intermediária e observando-se o desempenho do classificador e o erro no fim do treinamento, foi possível obter o número mais adequado de neurônios nesta camada para o estudo proposto. Na melhor configuração foram utilizados 15 neurônios na camada intermediária. Em uma RNA para classificação de padrões o número de neurônios na camada de saída corresponde ao número de classes estudadas, no caso deste trabalho, inicialmente foram utilizados 2 neurônios para discriminar entre defeito e não defeito e posteriormente foram utilizados 3 neurônios para discriminar entre as classes de defeitos CE, CI e FP. Dessa forma, o próprio sinal de MFL, digitalizado com 1025 pontos, foi fornecido como entrada da RNA, sendo que cada ponto correspondia a uma entrada da rede, enquanto a saída indicava uma das classes, conforme mostrado na Figure III.9. A classe de defeito de PE não foi levada em consideração neste trabalho porque não foi detectada pelo pig.

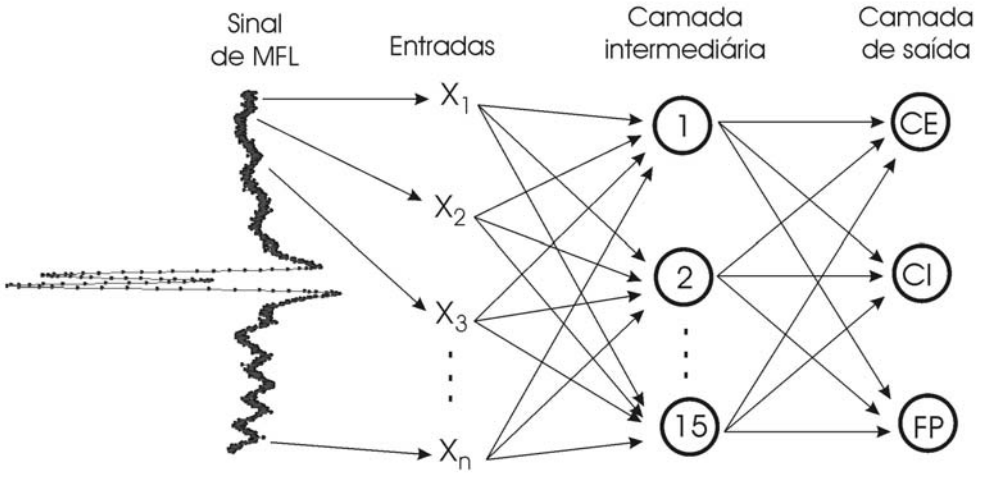

Figure III.9. *Rede neural usada nos ensaios.*

Cada classe de defeito possui características próprias e é esta informação que a rede neural utiliza para classificar as diferentes classes. A Figura III.10 apresenta um exemplo de um sinal característico de MFL em uma solda sem defeitos e em uma solda contendo defeitos. Cada linha horizontal dessa imagem corresponde a um sinal que foi digitalizado com 1025 pontos e depois fornecido como entrada da rede neural para classificação.

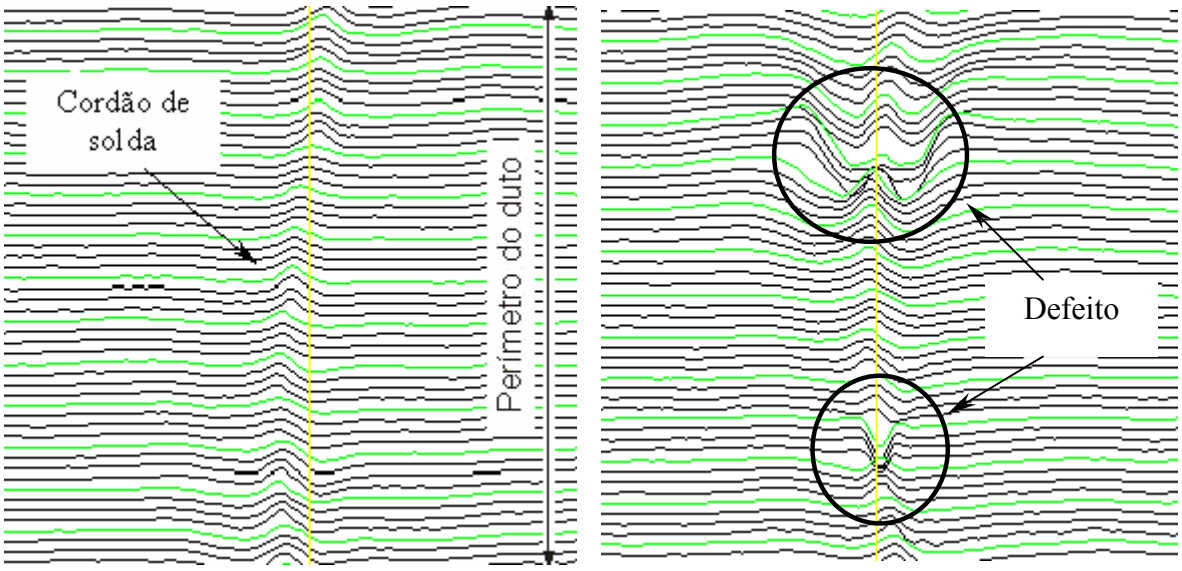

Figura III.10. *Exemplo de sinais característicos de MFL em solda: (a) sem defeito, (b) com defeitos.*

III.2.4. Componentes Principais de Discriminação Não-Linear (CPDNL)

O cálculo das componentes principais de discriminação é bastante útil, pois permite visualizar, de forma otimizada, a distribuição dos dados em um gráfico bidimensional, além de ser uma técnica para reduzir a dimensão dos dados de entrada nos classificadores. Uma das maneiras de se desenvolver as componentes principais é utilizando as redes neurais artificiais, conforme descreve Haykin [67] para o caso de auto-representação. Neste caso, elas podem ser usadas tanto para redução das componentes de representação, quanto para discriminação de classes de padrões, a partir da projeção do espaço original de dados na base de componentes principais.

Suponha que um sistema de classificação de padrões tenha um vetor $\underline{x}$ de dimensão *n* como entrada, no qual se deseja reduzir a dimensão do vetor de entrada para um vetor $\underline{z}$ de dimensão *m*, *m* < *n*, contendo somente as informações mais relevantes do conjunto de dados, tem-se a representação:

$$\underline{x}\,(\dim n) \rightarrow \underline{z}\,(\dim m) \qquad m<n \tag{III.1}$$

Então, considerando-se um problema de discriminação de padrões, o vetor $\underline{z}$ será composto pelas *m* componentes principais de discriminação. Imaginando estas componentes desenvolvidas de forma hierárquica, a primeira componente é formada pela projeção ortogonal do vetor $\underline{x}$ na direção $\underline{w}_1$ ($|\underline{w}_1|=1$), que representa a direção principal de discriminação dos dados em questão. Esquematicamente isto é mostrado na Figura III.11.

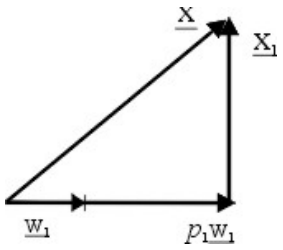

Figura III.11. *Projeção $p_1\,\underline{w}_1$ de $\underline{x}$ na direção principal de discriminação.*

Então a componente principal p_1 é a projeção ortogonal de $\underline{x}$ em $\underline{w}_1$ e pode ser representada como:

$$p_1 = \underline{x}^t\,\underline{w}_1 \tag{III.2}$$

onde,

$\underline{w}_1$: vetor representando a direção principal de discriminação;

e a representação de $\underline{x}$ visando uma única componente principal é:

$$\underline{x} \cong p_1 \underline{w}_1 \qquad (III.3)$$

O erro de representação $\underline{x}_1$ é tal que:

$$\underline{x} = p_1 \underline{w}_1 + \underline{x}_1 \qquad (III.4)$$

O vetor $\underline{x}_1$ representa a informação não projetada de $\underline{x}$ na direção de $\underline{w}_1$. Decompondo o vetor $\underline{x}$ em *m* componentes, escrevemos:

$$\underline{x} = p_1 \underline{w}_1 + p_2 \underline{w}_2 + p_3 \underline{w}_3 + \cdots\cdots\cdots\cdots + p_m \underline{w}_m + \underline{\varepsilon} \qquad (III.5)$$

onde $\underline{\varepsilon}$ é o vetor erro residual para representação usando *m* componentes principais.

A primeira componente de discriminação não-linear pode ser obtida treinando-se uma rede de três camadas em *retropropagação* do erro como mostra a Figura III.12. A primeira camada é composta por apenas um neurônio do tipo linear e as demais por neurônios do tipo tangente hiperbólica [67].

O ajuste dos vetores sinápticos das três camadas é feito pelo método do gradiente descendente usando a função do erro médio quadrático como função objetivo [67]. Após treinamento, o vetor $\underline{w}_1$ representa a direção principal de discriminação não-linear das classes de padrões estudadas.

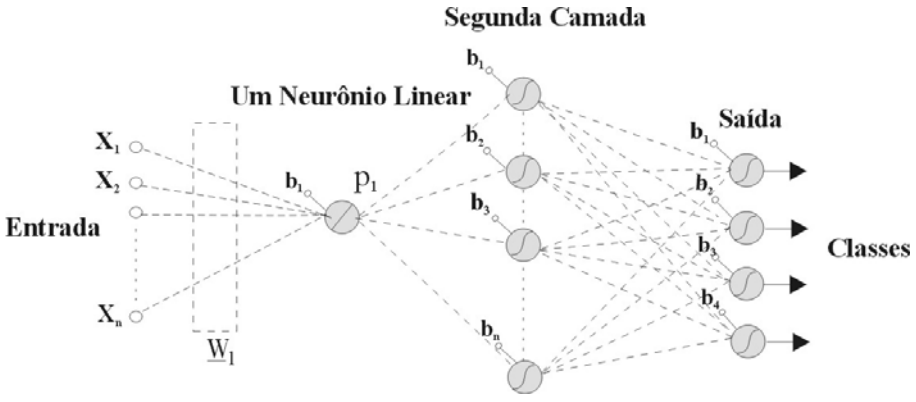

Figura III.12. *Rede para implementação da primeira componente principal de discriminação não-linear.*

Um caso especial de desenvolvimento das demais componentes consiste em torná-las ortogonais, ou seja, $\underline{w}_1 \perp \underline{w}_2 \perp \underline{w}_3 \cdots\cdots\cdots\cdots\cdots\cdots \perp \underline{w}_m$. Para tal, retreina-se a rede após obtenção de $\underline{w}_1$ da mesma maneira, mas a nova entrada utilizada será $\underline{x}_1$, e procede-se sucessivamente até a componente *m* (normalmente $m<n$). Aqui denominamos estas como componentes principais de atuação independente, uma vez que cada componente trabalha com o ruído $\underline{x}_j$ da informação não utilizada pelas anteriores:

$$\underline{x}_j = \underline{x} - \sum_{k=1}^{j-1} p_k \underline{w}_k \qquad \textit{(III.6)}$$

tentando fazer a classificação de forma independente, sem contar com a ajuda das componentes anteriores, já extraídas e portanto disponíveis.

Em um conjunto de dados de várias dimensões, é difícil visualizar a dimensão do problema de separação entre as classes, portanto, através do emprego das duas primeiras componentes principais de discriminação não-lineares é possível obter uma visualização otimizada da disposição das classes de padrões.

No presente trabalho, recorreu-se às componentes principais para discriminação não-linear, implementadas com redes neurais, sendo estas desenvolvidas com algoritmo de *retropropagação* do erro. Foram utilizadas as duas primeiras componentes principais independentes e não-lineares de discriminação com o objetivo apenas de visualizar o problema de separação das classes de defeitos em duas dimensões, para um maior aprofundamento existem outras literaturas [105,106,107].

III.3. ENSAIOS DE ULTRA-SOM

III.3.1. Corpos de prova para ensaios de ultra-som

Para os ensaios de ultra-som foram empregados quatro corpos de prova fabricados de dutos de especificação API X70, com diâmetro de 254mm, espessura de parede 19,05mm e comprimento de 3000mm. Cada corpo de prova foi confeccionado com 6 soldas circunferenciais com defeitos simulados, perfazendo um total de 24 cordões de solda. Estes corpos de prova foram inspecionados pelas técnicas de ultra-som manual e automatizada.

Os defeitos foram dispostos ao longo do cordão de solda em posições aleatórias ao longo do perímetro do duto. A Figura III.13 mostra representações esquemáticas de um cordão de solda com as 2 classes de defeitos investigadas neste trabalho e a Figura III.14 mostra o corpo de prova confeccionado.

Todas as soldas foram realizadas utilizando dois processos diferentes: TIG na raiz e eletrodo revestido no enchimento.

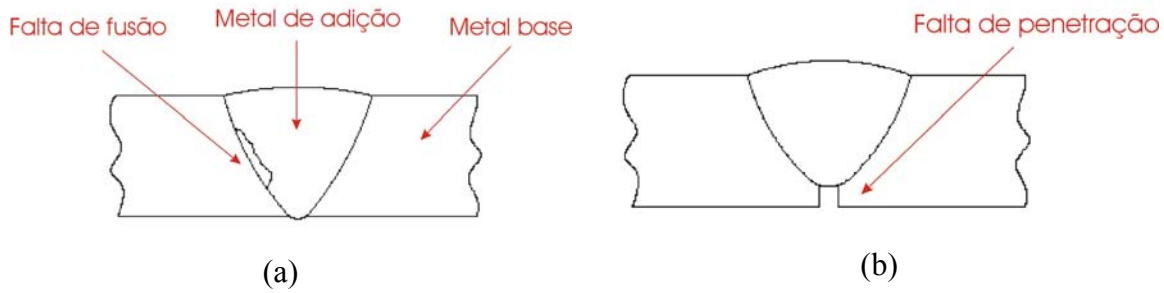

Figura III.13. *Desenho esquemático de um cordão de solda: (a) com defeito de falta de fusão e (b) com falta de penetração.*

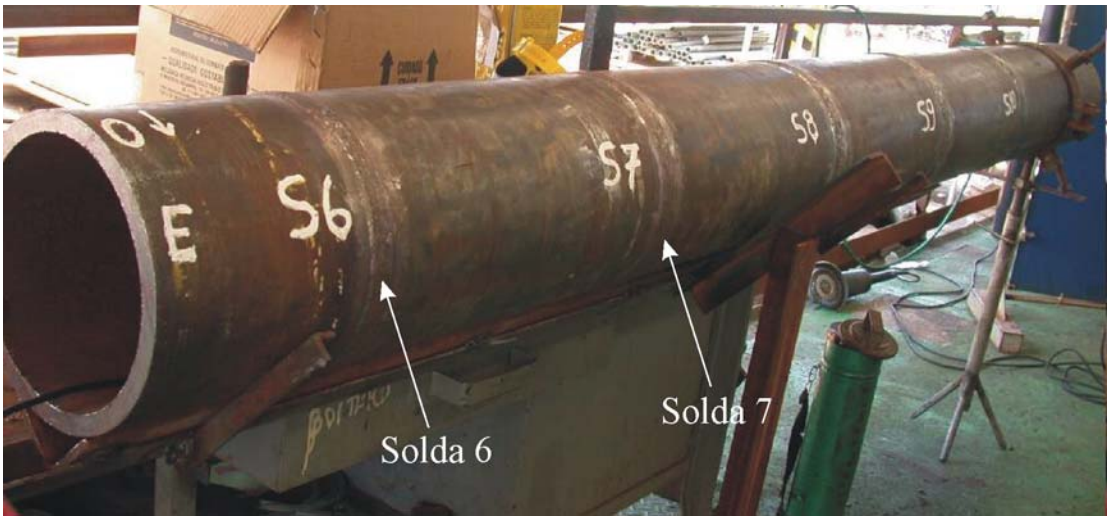

Figura III.14. *Corpo de prova confeccionado para ensaio de ultra-som.*

Os defeitos foram inseridos artificialmente por metodologia própria realizada no momento da deposição dos cordões de solda. Dois tipos de defeitos foram inseridos: falta de penetração e falta de fusão. O defeito de falta de fusão foi simulado por uma fina chapa, com as dimensões projetadas para o defeito, soldada na lateral do chanfro. A Figura III.15 mostra o defeito de falta de fusão simulado e a Figura III.16 mostra um defeito de falta de fusão de comprimento 1,5mm simulado que foi cortado após ter sido soldado para confirmação de sua existência. O defeito de falta de penetração foi simulado também por uma fina chapa colocada na altura projetada para o defeito de falta de penetração.

Os defeitos foram projetados com 4 diferentes comprimentos (3, 5, 7 e 10mm) e 3 alturas (2, 3 e 5mm), perfazendo um total de 12 defeitos com dimensões diferentes. Um defeito com a mesma dimensão foi repetido 5 vezes, perfazendo um total de 60 defeitos para cada classe. Adicionalmente foram inseridos 5 defeitos de FP e 5 defeitos de FF com comprimento de 20mm e altura de 3mm e ainda foram inseridos 20 defeitos de FF com comprimento e altura inferior a 3mm, Anexo B.

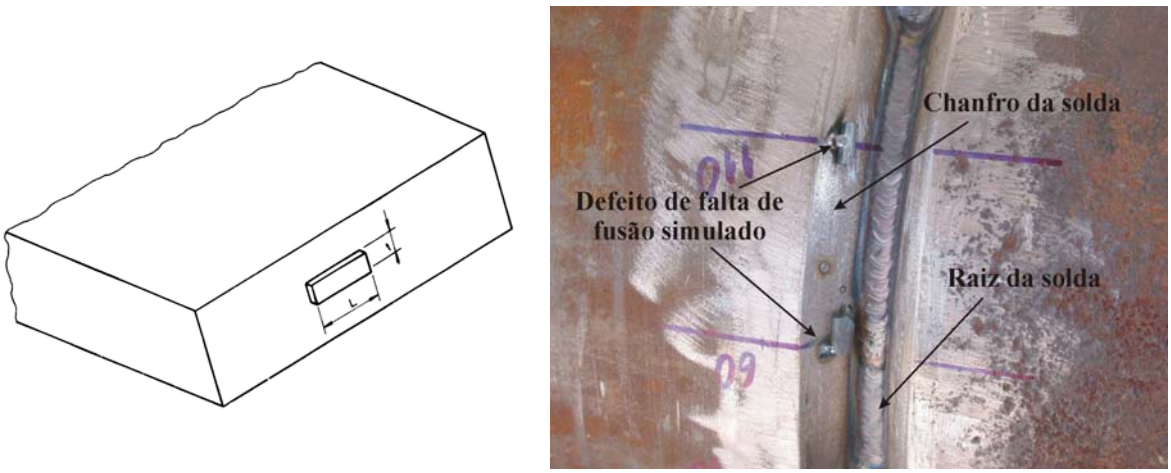

Figura III.15. *Metodologia para simulação de defeito de falta de fusão.*

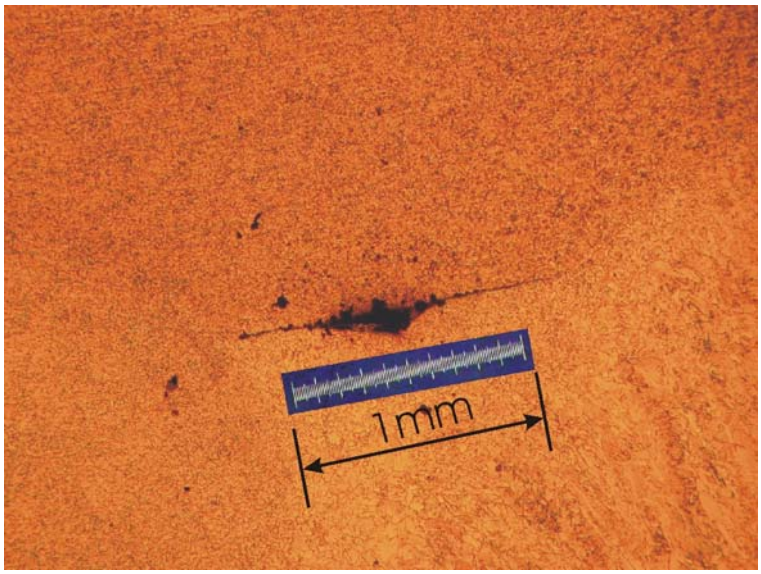

Figura III.16. *Confirmação, por microscopia óptica, do defeito após realização da solda.*

III.3.2. Inspeção dos corpos de prova por ultra-som

Para a realização desta pesquisa empregando o ensaio não destrutivo por ultra-som, foi utilizada tanto a técnica manual quanto automatizada. Para a inspeção dos corpos de prova com ultra-som manual foi utilizada a técnica de pulso eco enquanto que para a inspeção automatizada foi utilizando tanto a técnica pulso-eco quanto *TOFD*.

III.3.2.1. Inspeção manual

A inspeção pela técnica pulso-eco manual foi realizada por cinco (5) inspetores devidamente qualificados pelo sistema da ABENDE (Associação Brasileira de Ensaios Não Destrutivos), reconhecido pelo SNQC – Sistema Nacional de Qualificação e Certificação. Os inspetores possuíam diferentes níveis de qualificação e utilizaram como procedimento de inspeção a PR-011 [108]. Para calibração da curva DAC foi confeccionado um bloco de referência conforme mostrado no desenho da Figura III.17 e detalhado no procedimento de inspeção PR-011 [108]. Cada inspetor traçou sua própria curva DAC para a realização do ensaio.

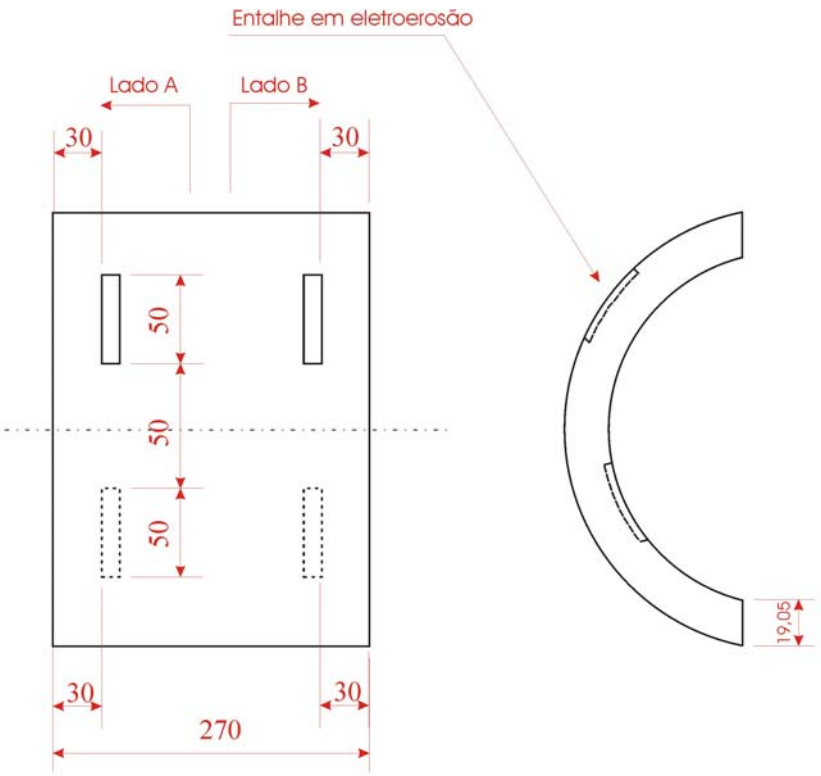

OBS.: Os entalhes possuem largura de 5mm e profundidade de 1,5mm para o Lado A e 2,1mm para o Lado B.

Figura III.17. *Bloco de referência para calibração da curva DAC.*

III.3.2.2. Inspeção automatizada

A inspeção automatizada foi realizada com o auxilio de um sistema desenvolvido especialmente para a realização deste trabalho de tese.

O sistema desenvolvido para inspeção automatizada é composto por um veículo de inspeção com rodas magnéticas, ao qual é fixada uma régua com um conjunto de sensores responsáveis pela varredura ao longo da solda, um aparelho de ultra-som convencional, um multiplexador para oito transdutores ultra-sônicos e um computador para controle do sistema e armazenagem dos dados para posterior avaliação. A Figura III.18 mostra um esquema do principio de funcionamento do sistema e a Figura III.19 mostra a respectiva foto.

O princípio de funcionamento do sistema pode ser descrito como segue. A saída de sinal analógico do equipamento de ultra-som é conectada ao computador através de uma placa conversora AD, com taxa de digitalização de 20Ms/s. Esta placa é responsável pela

digitalização do sinal de ultra-som que será armazenado na memória do computador. Este é responsável pelas seguintes operações: controlar via porta paralela qualquer um dos 8 transdutores do módulo multiplexador que será excitado; controlar a movimentação do veículo de inspeção via porta serial e armazenar os sinais digitalizados.

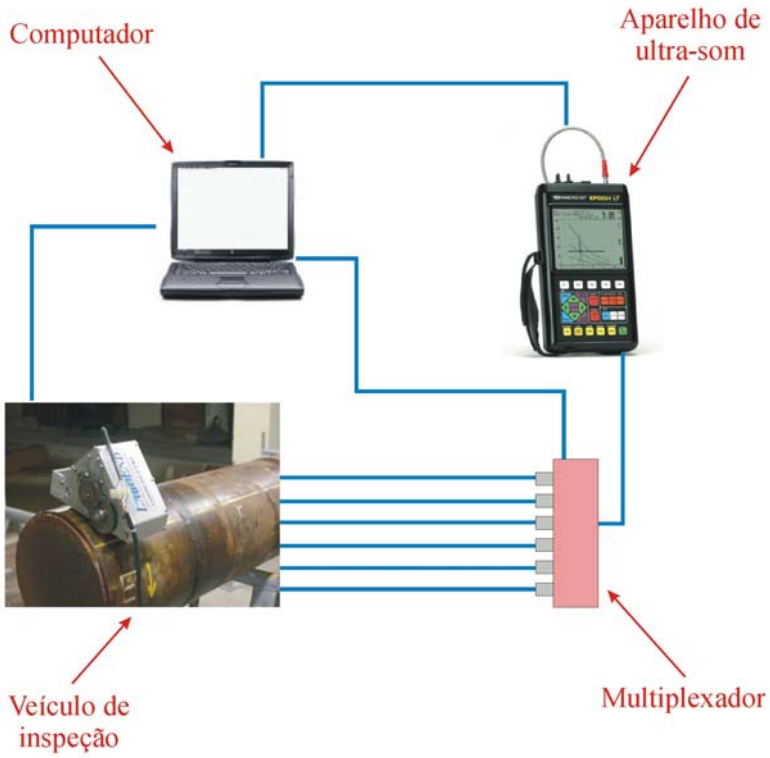

Figura III.18. *Esquema para inspeção ultra-sônica automatizada.*

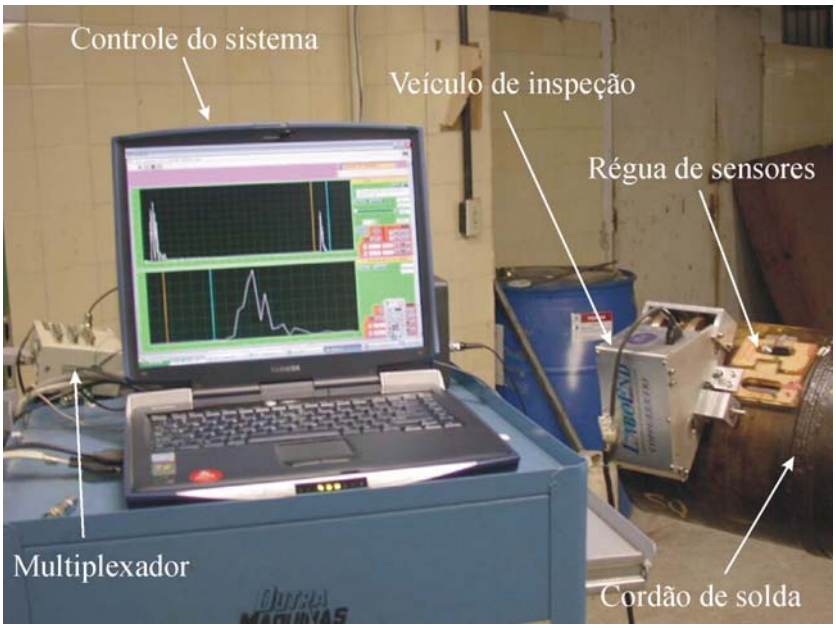

Figura III.19. *Sistema para inspeção ultra-sônica automatizada.*

A aquisição dos sinais foi realizada com um programa desenvolvido para o LABOEND – Laboratório de Ensaios não Destrutivos da UFRJ que, para a técnica pulso-eco, além de detectar a presença de possíveis descontinuidades no cordão de solda, permite avaliar seu comprimento e localização ao longo do perímetro do duto (Figura III.20).

Para a análise dos resultados da técnica *TOFD* foi utilizado o programa MATLAB e também foi desenvolvido um programa específico para leitura dos sinais A-scans e montagem de uma imagem D-scan, conforme Figura III.21. A partir deste programa é possível constatar a presença de descontinuidades ao longo do cordão de solda, determinando seu comprimento ao longo do perímetro do duto e a altura ao longo da espessura da solda. O sinal A-scan da Figura III.21 corresponde à aquisição representada pela linha horizontal amarela sobre a imagem D-scan. A partir de uma calibração realizada no programa é possível determinar o dimensionamento de todos os defeitos detectados.

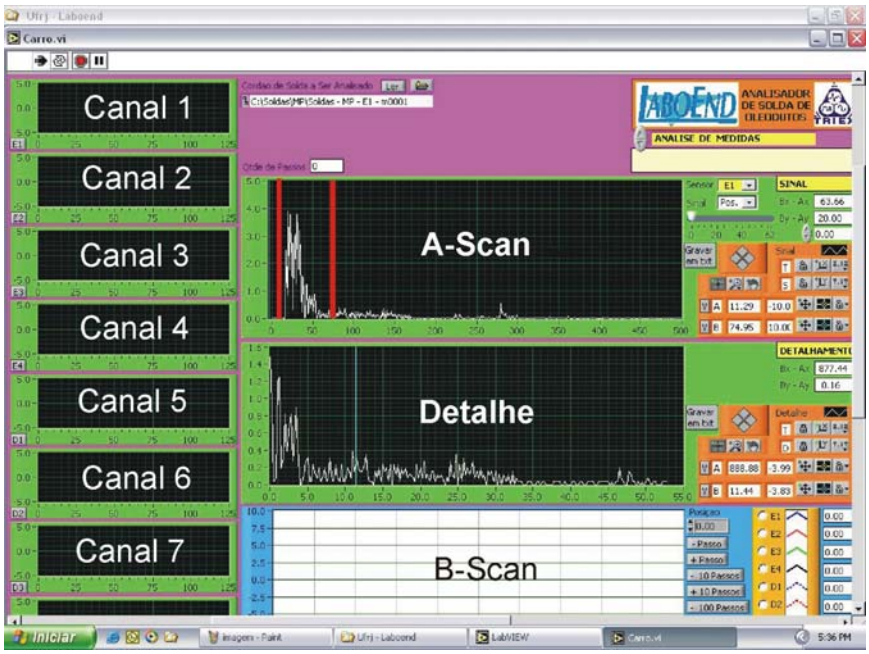

Figura III.20. *Programa para aquisição dos sinais.*

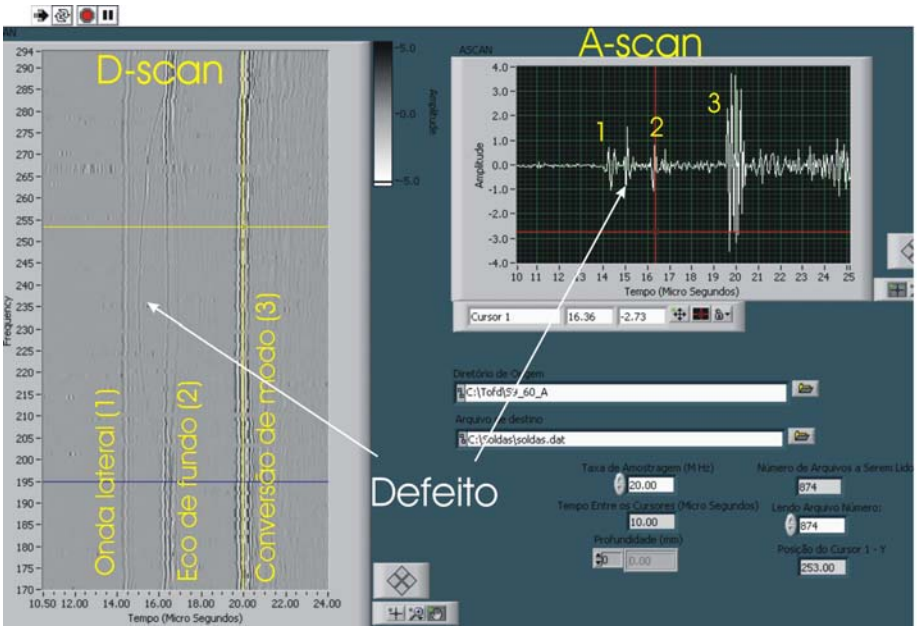

Figura III.21. *Programa para análise dos sinais pela técnica TOFD.*

Os transdutores utilizados foram do tipo normal de onda longitudinal, marca KRAUTKRAMER, 6 mm de diâmetro, modelo MSW/QC/PC, com freqüência central de 5 MHz. Para a obtenção de ondas longitudinais nos ângulos desejados foi utilizado um par de sapatas para ondas longitudinais com ângulo de incidência de 60° no aço (Figura III.22).

Foi empregado um aparelho de ultra-som convencional de fabricação KARL DEUTSCH, modelo ECHOGRAPH 1080 conectado a uma placa conversora A/D fabricada pela *National Instruments* modelo NI5102.

Figura III.22. *Transdutores e sapatas utilizados nos ensaios.*

III.4. Desenvolvimento de curva POD

A partir dos dados adquiridos, pelo método *hit/miss*, conforme discutido na seção II.5, foi desenvolvida uma metodologia para gerar curvas *POD* tanto para a técnica de MFL quanto para a técnica ultra-sônica de pulso-eco. Neste estudo foi avaliada a confiabilidade destas duas técnicas na detecção de defeitos de diferentes dimensões em cordões de solda.

Uma vez que a dimensão da amostra era limitada, utilizou-se a técnica de *bootstrap* [109] para definir o intervalo de confiança da curva calculada. A técnica de *bootstrap* foi introduzida por Bradley Efron em 1979 como abordagem ao cálculo de intervalos de confiança de parâmetros estatísticos, em circunstâncias em que outras técnicas não são aplicáveis, em particular no caso em que o número de amostras é reduzido.

A técnica *bootstrap* trata a amostra observada como se esta representasse exatamente toda a população (conjunto de experiências). Esta técnica tenta realizar o que seria desejável realizar na prática, se fosse possível, que é repetir a experiência inúmeras vezes. A partir de uma amostra $\mathbf{X} = (x_1, x_2, \ldots x_N)$ contendo N observações, pode-se construir B amostras $\mathbf{X^{*(1)}}, \ldots, \mathbf{X^{*(B)}}$ com N observações cada. Operacionalmente, o

procedimento *bootstrap* consiste na reamostragem de mesmo tamanho e com reposição dos dados da amostra original, ou seja, B amostras *bootstrap* $\mathbf{X^{*(1)}}$, ...,$\mathbf{X^{*(B)}}$ são obtidas a partir da própria amostra **X**. Cada componente de uma amostra $\mathbf{X^{*i}}$ corresponde a um dos N componentes de **X** tomados aleatoriamente. Desta forma numa amostra $\mathbf{X^{*i}}$ poderão existir valores repetidos dos componentes de **X**.

A partir das B amostras *bootstrap* $\mathbf{X^{*(1)}}$, ..., $\mathbf{X^{*(B)}}$ a incerteza correspondente a um dado parâmetro estatístico da população pode ser obtida [109]. Supondo que o parâmetro estatístico de interesse seja a média da população **X**, isto é, $\overline{X}$. Cada uma das B amostras *bootstrap* fornece um valor estimado de $\overline{X}$:

$$\overline{X}^{*i} = \frac{\sum_{j=1}^{N} x_j^{*(i)}}{N} \qquad \textit{Eq. III.7}$$

E desta forma o valor esperado da média de **X** em função do tamanho N da amostra pode ser obtido por:

$$\overline{X}^{*} = \frac{\sum_{i=1}^{B} \overline{X}^{*(i)}}{B} \qquad \textit{Eq. III.8}$$

e o desvio padrão deste estimador é dado por:

$$\sigma_{\bar{x}^*} = \left(\frac{\sum_{i=1}^{B} \left(\overline{X}^{*i} - \overline{X}^{*} \right)}{B-1} \right)^{1/2} \qquad \textit{Eq. III.9}$$

A partir dos valores calculados acima, e supondo que $\overline{X}^*$ seja gaussiana, pode-se obter uma estimativa do intervalo onde a média da população **X** se situa. Com 95% de certeza a média da população **X** está situada no seguinte intervalo:

$$\overline{X} = \overline{X}^* \pm 1{,}96\sigma_{\overline{X}^*} \qquad \textit{Eq. III.10}$$

No presente trabalho, como era impossível representar todo o universo de equipamentos, inspetores, condições de ensaio etc, utilizou-se a técnica de *bootstrap* para se obter o intervalo de confiança da curva POD a partir dos dados do número finito de inspeções realizadas. Para esta finalidade pôde-se formular o problema conforme descrito a seguir.

Para um determinado defeito de dimensão *a*, existirá um conjunto de observações **R** = (r_i, ..., r_N), onde N corresponde o total de experimentos (inspeções) para aquela dimensão. Utilizando a técnica *hit/miss* os resultados possíveis para os N experimentos podem ser:

$$\begin{cases} r_i = 1, \text{ se o defeito é detectado, ou} \\ r_i = 0, \text{ se o defeito não é detectado.} \end{cases}$$

A partir do conjunto **R**, contendo os N resultados dos experimentos do defeito de dimensão *a*, pode-se construir várias amostras *bootstrap*, $\mathbf{R_k^*}$ = (r_i^*,..., r_N^*), cada uma também contendo N observações. Para cada amostra *bootstrap* $\mathbf{R_k^*}$, a POD_k^* pode ser calculada como o número de acertos sobre o número total de experimentos:

$$POD_k^* = \frac{\sum_{i=1}^{N} r_i^*}{N} \qquad \textit{Eq. III.11}$$

A POD^* média para o defeito de dimensão *a* pode ser calculada a partir das POD_k^* de todas as amostras bootstrap:

$$POD^* = \frac{\sum_{k=1}^{B} POD_k^*}{B} \qquad \textit{Eq. III.12}$$

Ao invés de assumir a POD como gaussiana, uma estimativa do intervalo de confiança deste valor pode ser obtida da seguinte forma. Os B valores da POD_k^* são colocados em ordem crescente e para cada um deles é associado um estimador da função cumulativa de probabilidades $F_k^* = \frac{k}{B+1}$ [110], conforme mostra a Figura III.23. O intervalo de confiança de (1-α) da POD^*, [$POD^*_{\alpha/2}$, $POD^*_{1-\alpha/2}$], pode ser obtido a partir dos valores de POD^* associados aos valores $F^*=\alpha/2$ e $F^*=(1-\alpha/2)$ [110], conforme mostra a Figura III.23. Este procedimento é repetido para todas as *n* dimensões de defeitos consideradas, e com isto curvas podem ser ajustadas para os valores médios da POD^*, assim como para os seus limites dentro do intervalo de confiança desejado, conforme Figura III.24. Um valor normalmente utilizado na prática para caracterizar a POD, é aquele correspondente ao limite inferior do intervalo de confiança (1-α)=95% [96].

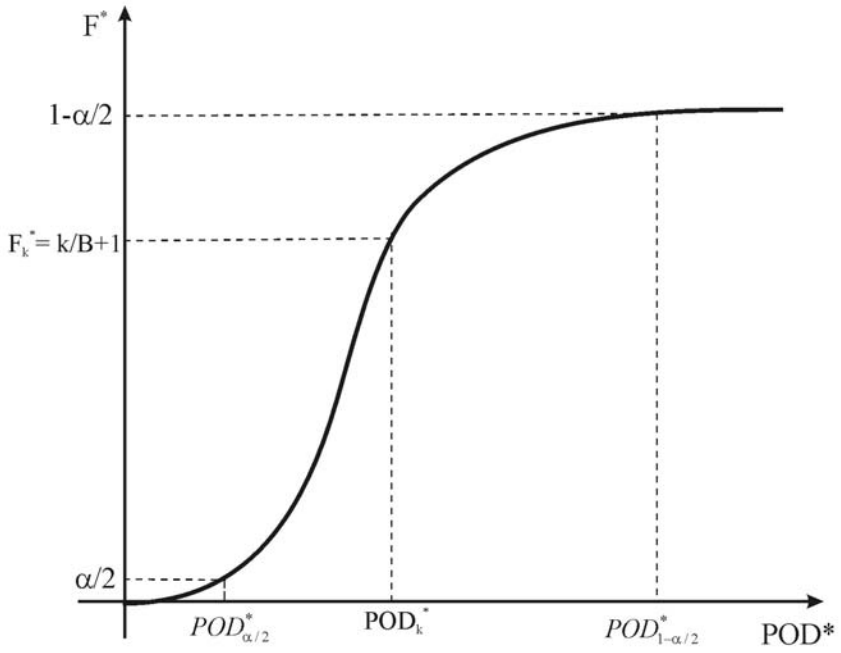

Figura III.23. *Limite de confiança das amostras bootstrap.*

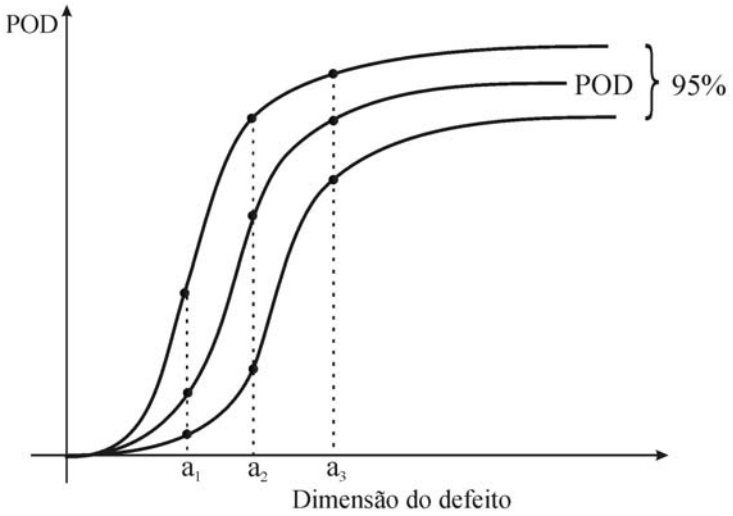

Figura III.24. *POD com intervalo de confiança de 95%.*

III.5. Curva ROC

Outra maneira utilizada para avaliar o desempenho de uma técnica de ensaio não destrutivo na detecção de descontinuidades é através da curva ROC (do inglês: *Receiver Operating Characteristic*). O método ROC é derivado da teoria de detecção de sinal e é utilizado a mais de 40 anos no campo de avaliação de sistemas de diagnóstico, tais como: técnicas de radar, testes de percepção humana e diagnósticos médicos [111]. A partir da década de 80 esta técnica tem sido aplicada também na avaliação de métodos de ensaios não destrutivos [111-116].

O princípio do método ROC consiste em caracterizar a precisão do sistema de inspeção avaliando a probabilidade de detecção de verdadeiros positivos –VPO – (registro de um defeito como presente no material quando de fato ele está presente) contra a probabilidade de detecção de falsos positivos – FPO – ou falsa indicação (registro de um defeito como presente no material quando de fato ele não existe) utilizando um critério de decisão (um critério de decisão, por exemplo, pode ser se o sinal é um defeito ou um ruído). Na área médica o termo verdadeiro positivo é também utilizado como sensibilidade enquanto a falsa indicação é também denominada de especificidade [117,118,119].

O principio de construção da curva ROC é mostrado na Figura III.25 onde seguindo a curva do canto inferior esquerdo para o superior direito a sensibilidade do sistema aumenta. Na prática, geralmente, o ensaio é realizado um número limitado de vezes, portanto é utilizado um pequeno número de pares de pontos de VPO e FPO e a partir destes pontos é ajustada uma curva utilizando um método qualquer de ajuste. A área sob a curva é uma medida da precisão do ensaio. Nos pontos 1 e 2 da Figura III.25 tem-se uma maior relação sinal/ruído e portanto uma alta detecção de verdadeiros positivos e apenas uma pequena quantidade de falsas indicações são registradas. Já nos pontos 3 e 4 a quantidade de verdadeiros positivos tende a aumentar mas também uma alta quantidade de falsas indicações são registradas.

A área da curva ROC pode exercer valores entre zero e um. Um teste onde a área sob a curva ROC é igual a 1 é um teste totalmente preciso porque a sensibilidade é máxima e a taxa de falsas indicações é zero. Por outro lado, um teste em que a área sob a curva ROC é igual a zero é totalmente impreciso, ou seja, toda indicação de defeito seria indicada como não defeito, enquanto que qualquer indicação de ruído seria erroneamente indicada como defeito. No entanto, provavelmente, este último resultado seria considerado pelo inspetor como totalmente preciso, pois a impossibilidade de um resultado como este o faria inverter a interpretação do resultado do teste [118,119]. Na prática o limite mínimo para a área da curva ROC é 0,5, que corresponde à área delimitada pela reta que vai do ponto (0, 0) ao ponto (1, 1), Figura III.26, (denominada diagonal do acaso). Se um teste depende somente de palpite para distinguir entre defeito e ruído, então a curva ROC é esperada ficar ao longo desta linha diagonal. Testes com área da curva ROC maior do que 0,5 tem pelo menos alguma habilidade para discriminar entre sinais de defeito e de ruído. Quanto mais a área da curva ROC se aproxima de 1, melhor é o resultado do teste. Se a área de uma curva ROC é 0,85 isto significa dizer que existe uma probabilidade de 85% que os sinais de defeitos tenham sido classificados corretamente como defeitos.

Neste trabalho foram utilizados os valores de VPO e FPO fornecidos pela saída da rede neural como forma alternativa de avaliar o desempenho da mesma na detecção dos defeitos, ou seja, na discriminação correta da classe de sinais com defeito.

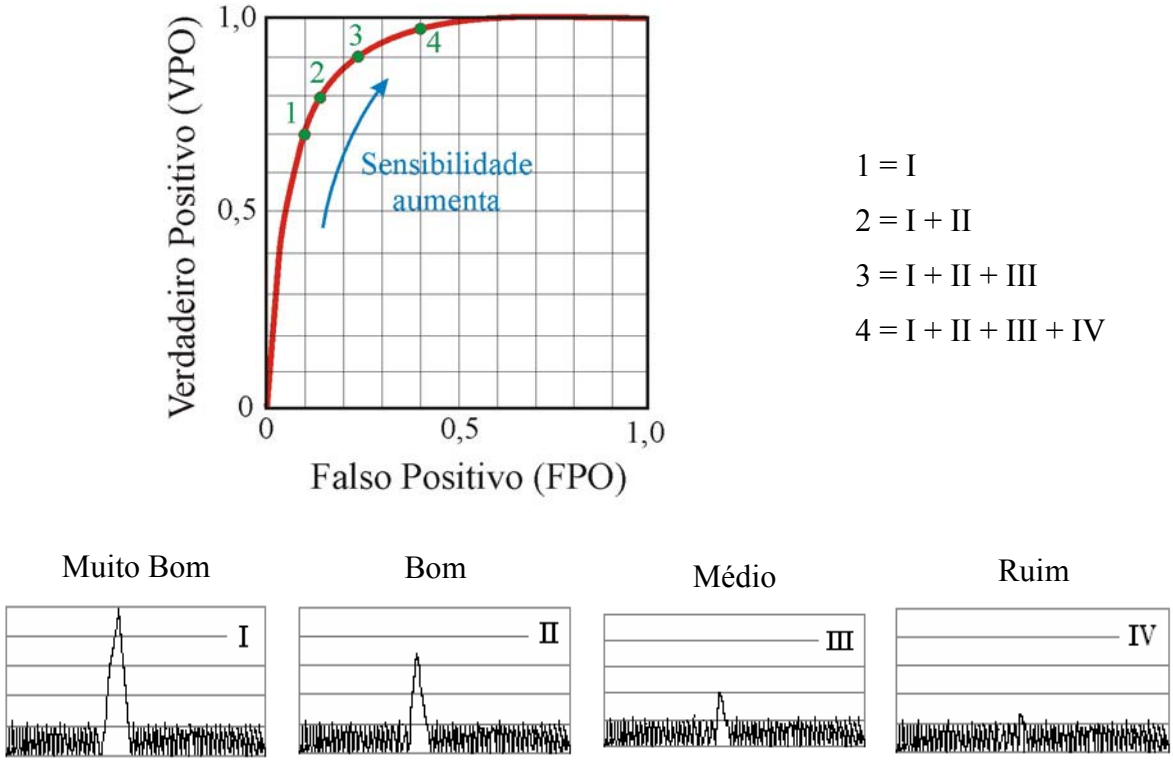

Figura III.25. *Principio da curva ROC.*

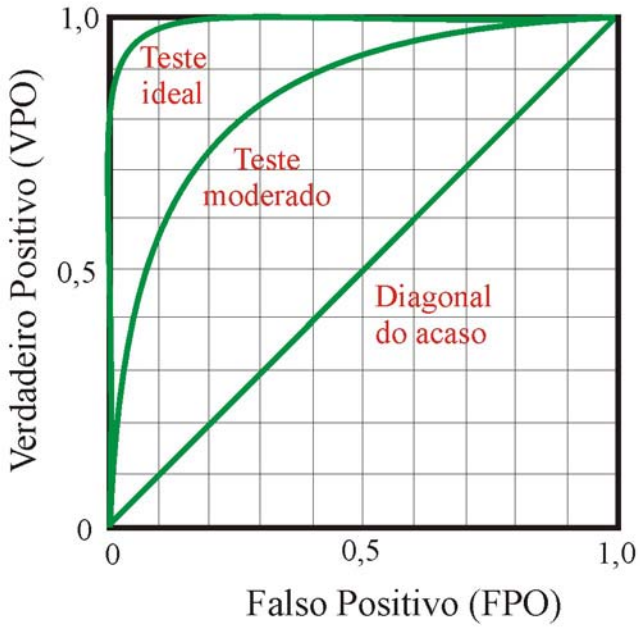

Figura III.26. *Curvas ROCs para 3 diferentes precisões do teste.*

CAPÍTULO IV

RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados obtidos neste trabalho de tese, bem como suas discussões. Inicialmente são mostrados os resultados de reconhecimento de padrões dos sinais de MFL obtidos via redes neurais artificiais. Posteriormente, ainda com os sinais de MFL, foram desenvolvidas curvas POD para esta técnica de ensaio não destrutivo. Finalmente, curvas POD foram construídas para a técnica de ensaio não destrutivo por ultra-som, tanto manual quanto automatizada.

IV.1. DETECÇÃO E CLASSIFICAÇÃO DE PADRÕES DE DEFEITOS POR REDES NEURAIS ARTIFICIAIS

Nesta seção, será avaliada a detecção e classificação de defeitos, a partir dos sinais obtidos nos ensaios de MFL em cordões de solda, via redes neurais artificiais. Inicialmente, será avaliada a eficiência de uma rede neural artificial não-linear, tipo supervisionada com algoritmo de treinamento por retropropagação do erro, na detecção de sinais de defeitos em cordão de solda. Portanto, nesta fase do trabalho o desempenho da RNA será avaliada na discriminação de duas classes: com defeito (CD) e sem defeito (SD). Na inspeção por pig, geralmente, o objetivo principal é a detecção dos defeitos ao longo do duto, para que medidas corretivas sejam tomadas antes que um acidente possa ocorrer. Portanto, essa pode ser considerada a etapa principal da inspeção. A classificação da natureza do defeito é um estágio complementar no processo de inspeção.

Em uma etapa posterior, a eficiência de redes neurais artificias foi avaliada na classificação de 3 diferentes classes de defeitos no cordão de solda: corrosão externa (CE), corrosão interna (CI) e falta de penetração (FP). A classe de defeito de penetração (PE) excessiva não foi levada em consideração uma vez que não foi detectada pelo pig. Foram utilizados nos ensaios sinais de 4 corpos de prova, denominados CP1, CP2, CP3 e CP4, que foram especialmente confeccionados para os testes.

A eficiência da RNA foi testada com três diferentes conjuntos de dados, para avaliar a generalização da rede neural para sinais distintos. Inicialmente, os sinais de cada corpo de prova foram separados em dados de treinamento e teste e a rede foi treinada e testada com cada conjunto separadamente, obtendo-se um resultado distinto para cada corpo de prova. Depois os sinais dos quatro corpos de prova foram agrupados em um único conjunto e separados em dados de treinamento e teste, e novamente a eficiência da rede foi avaliada. O segundo caso é um teste mais interessante e mais recomendado, pois tenta-se treinar a rede com o maior número possível de padrões das classes avaliadas, o que pode aumentar o poder de generalização da rede e por esse motivo, o desempenho deste tipo de treinamento tende a ser melhor. No entanto, nem sempre se dispõe de número suficiente de dados para este tipo de avaliação. Finalmente, os sinais de três dos quatro corpos de prova (CP1, CP2 e CP4) foram agrupados em um único conjunto e separados em dados de treinamento e teste, e os dados do corpo de prova que não participou do treinamento (CP3) foram utilizados somente para testar o desempenho da RNA. Este último caso tenta simular o que realmente pode ocorrer em uma análise real, ou seja, uma rede treinada com sinais de outros dutos seria utilizada para separar sinais provenientes de um teste de campo. No entanto, o desempenho deste último teste tende a ser inferior aos dos demais, uma vez que os sinais que são apresentados a rede serão totalmente desconhecidos e, normalmente, existem variações nos parâmetros de um ensaio para outro. Para que a rede neural seja a mais confiável possível, o conjunto de treinamento deve conter padrões que sejam o mais próximo possível dos sinais a serem classificados. Vale ressaltar que para todos os conjuntos de dados utilizados os sinais foram escolhidos aleatoriamente para treino e teste e sem reposição dos dados, ou seja, uma vez que um dado é selecionado para treinamento ou teste ele não entra mais nos próximos sorteios. E também, para cada corpo de prova o ensaio foi repetido 3 vezes. A Figura IV.1 mostra uma representação esquemática do tratamento realizado nos conjuntos de dados utilizados no estudo com redes neurais.

Técnicas de pré-processamento foram utilizadas apenas para o terceiro conjunto de dados, com o objetivo de eliminar características desnecessárias presentes no sinal, como ruído, por exemplo, que poderiam está dificultando a classificação e também para reduzir a quantidade de pontos que o sinal foi amostrado, facilitando sua discriminação. Os mesmos procedimentos que foram aplicados para este conjunto de dados poderão ser empregados

para os demais, no entanto, para não se tornar repetitivo aplicou-se somente a este conjunto. Como os sinais são de mesma natureza, o ganho de eficiência que estas ferramentas proporcionarem para estes dados poderá, provavelmente, ser conseguido pelos demais dados.

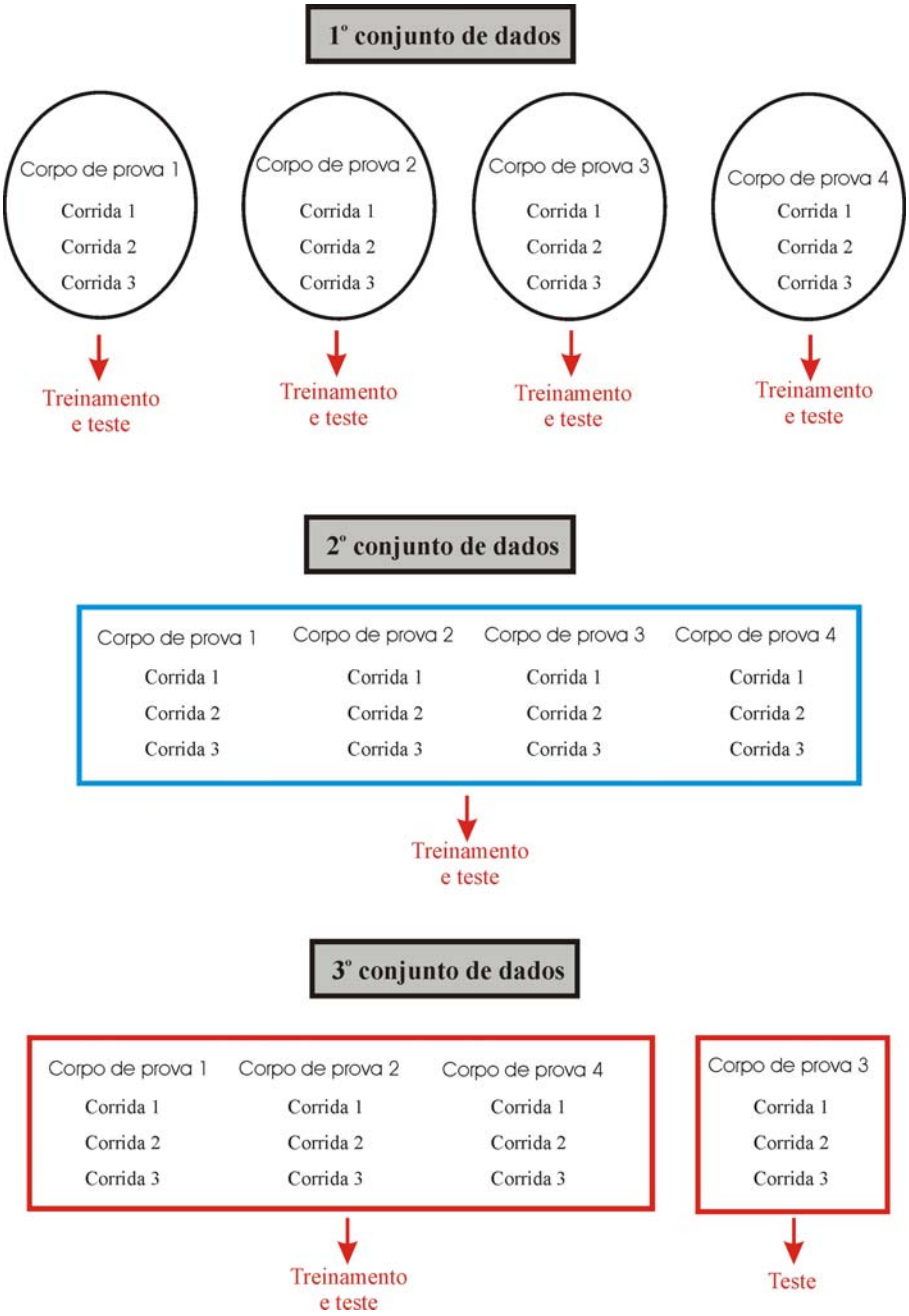

Figura IV.1. *Conjuntos de dados utilizados no estudo de redes neurais.*

IV.1.1. Ensaios utilizando o 1º conjunto de dados

A seguir são apresentados os resultados para treinamento e teste para cada corpo de prova separadamente. As Figuras IV.2 a IV.5 representam os gráficos de distribuição dos dados das classes sem defeito (SD) e com defeito (CD) segundo às duas componentes principais de discriminação não-linear (CPDNL). Este tipo de representação permite visualizar, da melhor maneira possível, a distribuição dos dados em um espaço bidimensional. Para cada ensaio foram utilizados 150 sinais da classe CD e 150 da classe SD para treinamento, e 60 sinais de cada classe para teste, sendo que na classe CD existe 1/3 de cada tipo de defeito que foi inserido no corpo de prova e o qual será classificado em uma etapa posterior.

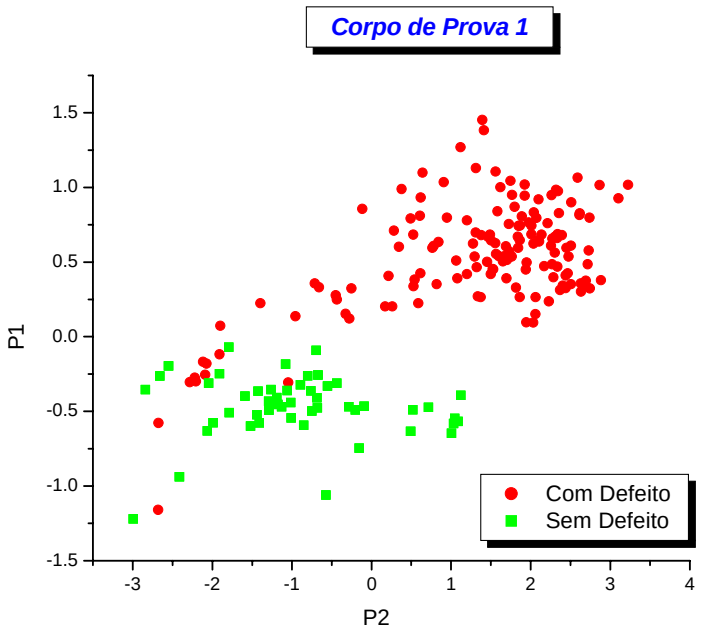

Figura IV.2. *Gráfico das componentes principais de discriminação não-linear referente ao CP1, para as classes CD e SD.*

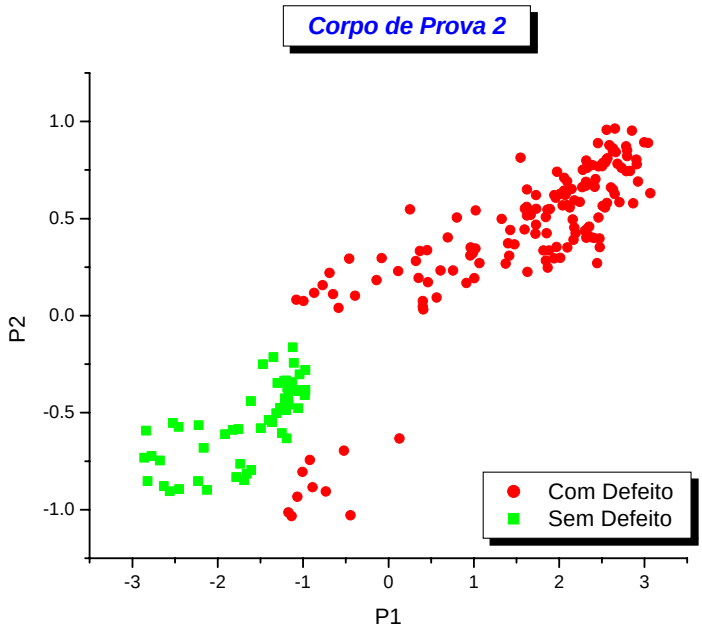

Figura IV.3. *Gráfico das componentes principais de discriminação não-linear referente ao CP2, para as classes CD e SD.*

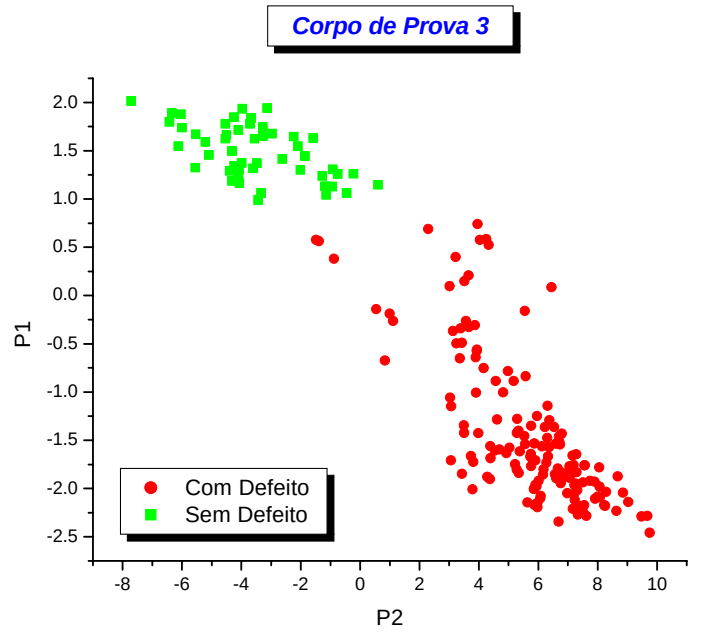

Figura IV.4. *Gráfico das componentes principais de discriminação não-linear referente ao CP3, para as classes CD e SD.*

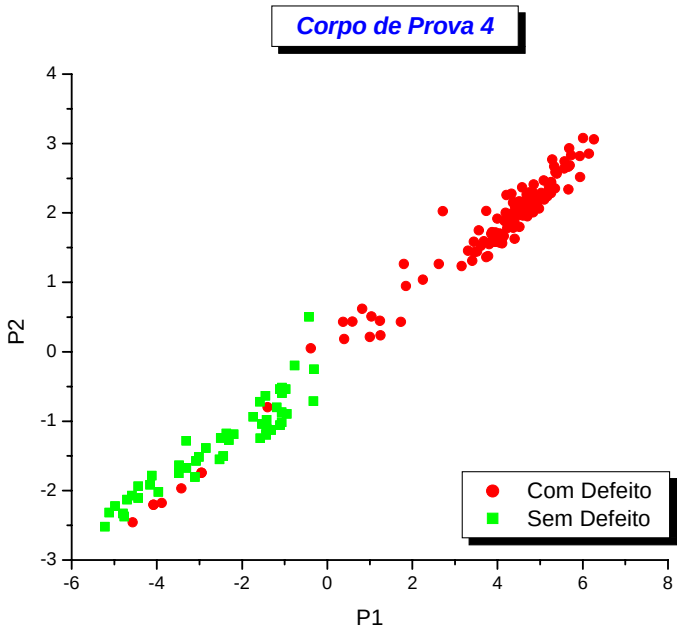

Figura IV.5. *Gráfico das componentes principais de discriminação não-linear referente ao CP4, para as classes CD e SD.*

Através dos gráficos das Figuras IV.2 a IV.5 constata-se que existe um considerável nível de separação entre as classes CD e SD no espaço bidimensional. Nos corpos de prova CP2 e CP3 existe uma região de separação bem definida, sendo portanto fácil de ser separado por classificadores não-lineares. Os dados referentes ao corpo de prova CP3 podem, inclusive, ser separados por um classificador linear. Nos corpos de prova CP1 e CP4 existe uma pequena região de confusão entre os dados, com algumas amostras da classe com defeito posicionadas na região da classe sem defeito. No entanto, mesmo nesses corpos de prova o índice de separação pode ser muito alto, uma vez que os classificadores não-lineares são capazes de desenvolver superfícies de separação bastante complexas.

As Tabelas IV.1 a IV.4 apresentam os resultados para treinamento e teste da rede neural, para a classificação das classes CD e SD, para cada corpo de prova separadamente. Na primeira coluna das tabelas estão as duas classes avaliadas e as duas colunas seguintes indicam a percentagem de sinais de cada classe que foi classificada por cada neurônio da saída. Na interseção entre a linha de uma dada classe com a coluna da mesma classe (célula

hachurada), tem-se o percentual de sinal pertencente àquela classe que foi corretamente classificado.

Através das Tabelas IV.1 a IV.4 pode-se observar que o índice de detecção dos defeitos, para os quatro corpos de prova, foi sempre de 100% para os dados de treinamento. Na fase de teste este índice foi de 97,5% no corpo de prova CP3, alcançando 100% nos demais. Para o corpo de prova CP3 o índice de acerto na fase de treinamento foi um pouco superior à fase de teste, o que perfeitamente justificado uma vez que um dado de teste é totalmente novo para a rede, ou seja, não foi fornecido durante o treinamento.

O conjunto de treinamento corresponde a um conjunto de entradas e saídas empregado justamente para treinar a rede neural. O conjunto de teste é um outro conjunto independente de entradas e saídas conhecidas empregado para certificar que a rede neural pode responder corretamente às situações não experimentadas na fase do treinamento.

Uma possível explicação para a confusão que ocorreu com sinais da classe CD com sinais da classe SD no corpo de prova CP3, é que os defeitos de corrosão foram nele inseridos com diferentes profundidades na parede do duto, portanto defeitos com pequenas perdas de material geram sinais com amplitude mais baixa, podendo, perfeitamente ser confundidos com sinais da classe SD, principalmente se for levado em consideração que já existe a influencia da variação de espessura devido ao reforço do cordão de solda no sinal.

Tabela IV.1. *Detecção do defeito – Treinamento e Teste (%) – Corpo de prova 1.*

Treinamento			**Teste**		
	CD	SD		CD	SD
CD	100		CD	100	
SD		100	SD		100
Índice médio de acerto	**100**		**100**		

Tabela IV.2. *Detecção do defeito – Treinamento e Teste (%) – Corpo de prova 2.*

Treinamento			**Teste**		
	CD	SD		CD	SD
CD	100		CD	100	
SD		100	SD		100
Índice médio de acerto	**100**		**100**		

Tabela IV.3. *Detecção do defeito – Treinamento e Teste (%) – Corpo de prova 3.*

Treinamento			**Teste**		
	CD	SD		CD	SD
CD	100		CD	95	5
SD		100	SD		100
Índice médio de acerto	**100**		**97,5**		

Tabela IV.4. *Detecção do defeito – Treinamento e Teste (%) – Corpo de prova 4.*

Treinamento			**Teste**		
	CD	SD		CD	SD
CD	100		CD	100	
SD		100	SD		100
Índice médio de acerto	**100**		**100**		

Após a detecção dos defeitos, foi realizada a classificação das três classes de defeitos consideradas neste trabalho, CE, CI e FP, para cada CP separadamente. Para cada classe foram utilizados 50 sinais para treinamento e 20 para teste. A Figura IV.6 e a Tabela IV.5 mostram os resultados para o corpo de prova 1, enquanto a Figura IV.7 e a Tabela IV.6 apresentam os resultados para o corpo de prova 2. Em todas as tabelas são mostrados os percentuais de desempenho da RNA com o critério de desempate baseado no maior valor de saída, o que significa que um sinal pode ser classificado mesmo quando a rede não indica nenhuma classe ou indica mais de uma classe como verdadeira. Quando isso ocorre,

utiliza-se o maior valor algébrico da saída da rede como critério de classificação para indicar a classe. Estas tabelas também apresentam a percentagem de sinais de uma classe que foi confundida com a outra.

Os resultados da saída da rede neural apresentados na Tabela IV.5 mostram que ocorreu uma confusão de 5% entre os sinais da classe CI com a classe de CE para o corpo de prova 1 durante a fase de teste, enquanto que na fase de treinamento, todos os sinais foram corretamente classificados pela rede neural. Para este corpo de prova, os sinais da classe FP conseguiram 100% de separação das demais classes, tanto na fase de treinamento quanto na fase de teste. A confusão de sinais que ocorreu entre as classes de CI e CE era esperada, uma vez que esses sinais são de defeitos de mesma natureza, corrosão, sendo que a única diferença entre eles é que um está inserido na parede interna do duto e o outro na externa. No gráfico das componentes principais da Figura IV.7, observa-se em um espaço bidimensional, uma completa confusão entre as classes de defeito CE e CI, enquanto a classe FP consegue uma separação razoável por classificadores não-lineares. Vale ressaltar que a análise de CPDNL é uma forma otimizada de visualizar a distribuição dos dados em um gráfico bidimensional.

Os resultados da saída da rede apresentados na Tabela IV.6 mostram que, para o corpo de prova 2, as classes de defeitos são totalmente separáveis, tanto no treinamento quanto no teste. Pelo gráfico de CPDNL da Figura IV.7, observa-se que ocorreu a mesma tendência de classificação observada para o corpo de prova 1, ou seja, uma confusão entre as classes CE e CI e uma melhor separação para a classe FP. Convém ressaltar que o processamento da rede neural, tanto para este conjunto de dados quanto para os demais, foi repetido mais de cinco vezes e os resultados aqui apresentados são uma média dessas repetições. Para o corpo de prova 3 e 4 a rede neural obteve também índice de acerto de 100% tanto no treinamento quanto no teste.

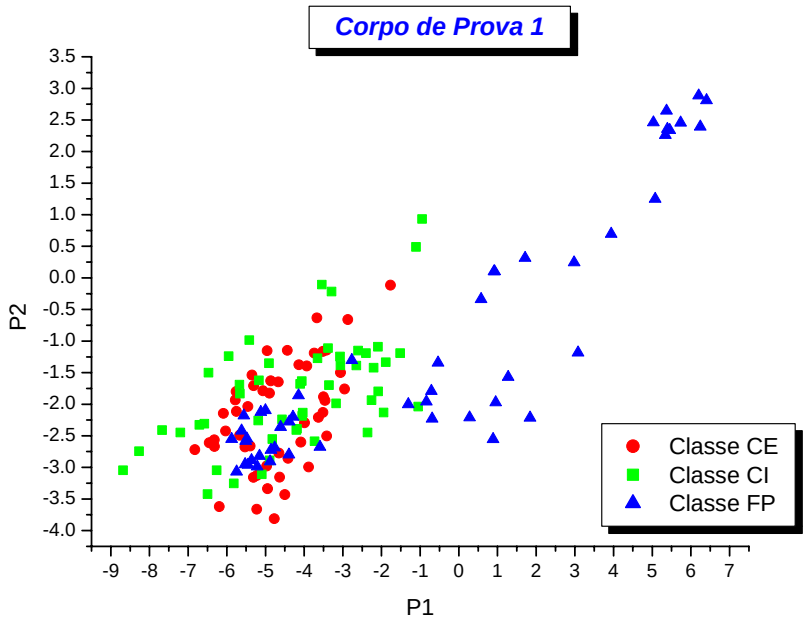

Figura IV.6. *Gráfico das componentes principais de discriminação não-linear referente ao CP1, para as classes: CE, CI e FP.*

Tabela IV.5. *Classificação do defeito – Treinamento e Teste (%) – Corpo de prova 1.*

Treinamento				**Teste**			
	CE	CI	FP		CE	CI	FP
CE	100			CE	100		
CI		100		CI	5	95	
FP			100	FP			100
Índice médio de acerto		**100**			**98,3**		

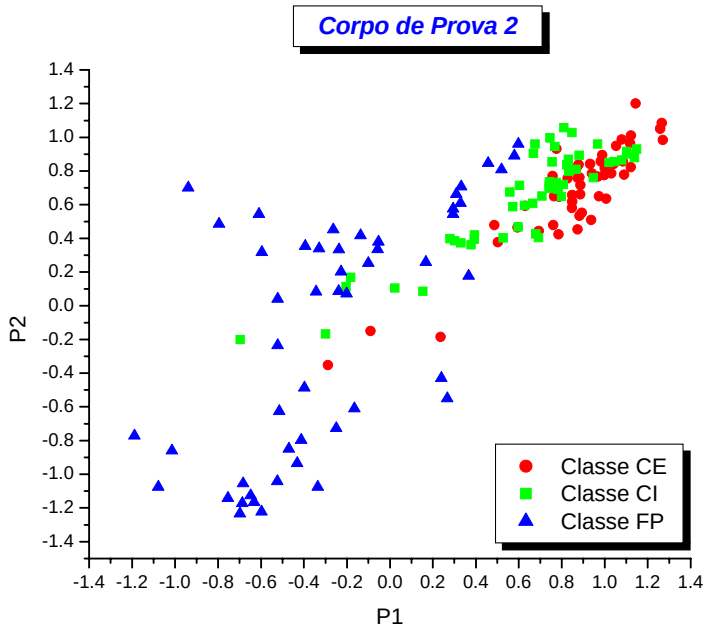

Figura IV.7. *Gráfico das componentes principais de discriminação não-linear referente ao CP2, para as classes: CE, CI e FP.*

Tabela IV.6. *Classificação do defeito – Treinamento e Teste (%) – Corpo de prova 2.*

Treinamento				**Teste**			
	CE	CI	FP		CE	CI	FP
CE	100			CE	100		
CI		100		CI		100	
FP			100	FP			100
Índice médio de acerto		**100**			**100**		

IV.1.2. Ensaios utilizando o 2º conjunto de dados

Como cada corpo de prova possui uma quantidade reduzida de defeitos, decidiu-se, como já mencionado, agrupar os sinais de todos os corpos de prova em um único conjunto de dados, aumentando desta forma o número de padrões de cada classe avaliada e assim garantir uma melhor generalização do aprendizado da rede. Pois, apesar dos defeitos dos corpos de prova serem semelhantes, é difícil manter um padrão uma vez que os mesmos foram inseridos manualmente utilizando ferramentas de usinagem e também pelo próprio soldador no momento da deposição do cordão de solda. Pode ser acrescentado que esta é uma situação mais próxima da realidade.

Seguindo o procedimento adotado neste trabalho, inicialmente foi realizada a detecção do defeito, e em uma etapa posterior foi feita a classificação das três classes de defeitos. Para a detecção foram utilizados 300 sinais de cada classe para a fase de treinamento e 120 sinais para a fase de teste. A Tabela IV.7 mostra os resultados de treinamento e teste da saída da rede neural para os quatro corpos de prova juntos, enquanto a Figura IV.8 apresenta o gráfico de CPDNL para estes dados. Observa-se pela Tabela IV.7 que o resultado para treinamento foi de 100% e para o teste a rede alcançou um índice médio de acerto de 97,5%. Para estes ensaios ocorreram 5% de confusão de sinais CD com sinais sem defeito, sendo esta uma situação mais crítica, pois a rede transmite uma situação de operação de falsa segurança em relação às condições reais. Na análise de CPDNL da Figura IV.8 também é constatada uma pequena confusão entre as duas classes avaliadas. No entanto, mesmo com este erro o índice de acerto pode ser considerado bastante satisfatório.

O desempenho do algoritmo de redes neurais na detecção de defeitos também foi determinado utilizando curva ROC (do inglês: *Receiver Operating Characteristic*), que pode ser vista como outra maneira de estimar a confiabilidade de detecção de defeito de um sistema. Na análise ROC é levado em consideração os valores de verdadeiros positivos, sinal indicado como defeito e que realmente é defeito, e os valores de falsa indicação ou falso positivo, indicação de um sinal como sendo defeito e que na realidade não é. Na curva POD a informação de falsa indicação não é levada em consideração. Por exemplo, se um corpo de prova existem 10 defeitos, e se o operador 1 encontrou todos os 10 sua POD é 100%. Por outro lado, se o operador 2 encontrou todos os 10 e acrescentou mais 5

indicações como defeitos quando na verdade eles não existem, sua POD será também de 100%. No entanto, o operador 1 foi muito mais eficiente.

A curva ROC apresentada na Figura IV.9 é um gráfico onde no eixo Y estão os valores de verdadeiro positivos (VPO), sinais da classe CD corretamente indicados como CD pela rede neural, e no eixo X estão os valores de falso positivo (FPO), sinais da classe SD erroneamente indicados como CD pela rede neural. A probabilidade dos sinais de defeitos terem sido corretamente classificados, neste caso, é determinada como sendo a área sob a curva da Figura IV.9. Os índices de VPO e de FPO para a estimação da curva ROC da Figura IV.9 são determinados pela razão entre o número de VPO e FPO indicados pela saída da rede neural e número total de sinais de cada classe. Neste trabalho, os índices de VPO e FPO foram determinados a partir de 15 conjuntos dados de teste contendo 240 sinais cada e a probabilidade dos sinais de defeitos terem sidos corretamente classificados, baseado nestes 15 conjuntos, foi de 99,16%. Este valor é bem próximo da taxa média de acerto obtida pelo algoritmo de redes neurais (97,5%).

Tabela IV.7. *Detecção do defeito – Treinamento e Teste (%) – Corpo de prova 1,2,3 e 4.*

Treinamento			**Teste**		
	CD	SD		CD	SD
CD	100		CD	95	5
SD		100	SD		100
Índice médio de acerto		**100**		**97,5**	

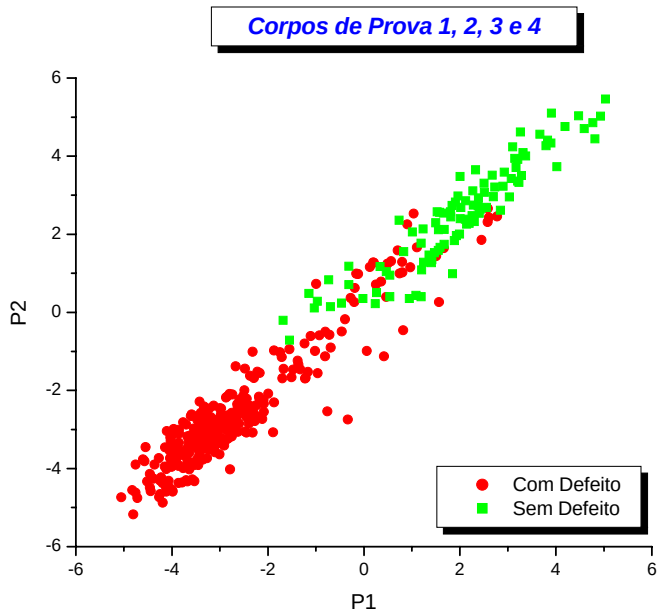

Figura IV.8. *Gráfico das componentes principais de discriminação não-linear referente aos CPs 1, 2, 3 e 4 para as classes: CD e SD.*

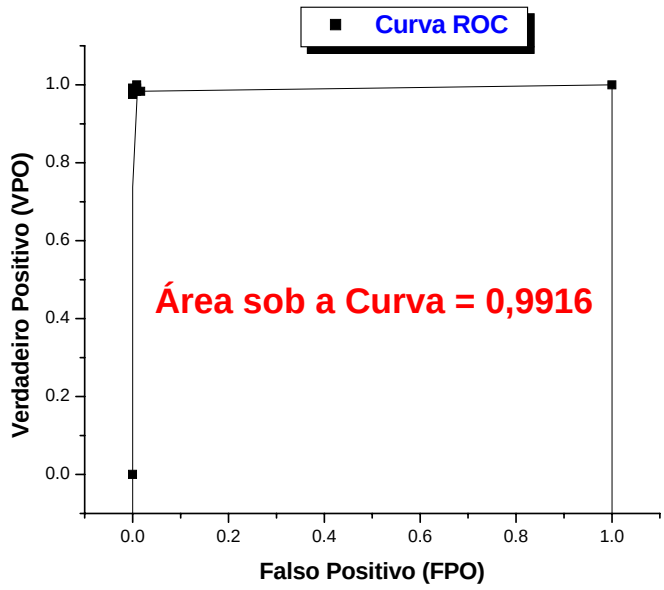

Figura IV.9. *Determinação da probabilidade de detecção de defeitos utilizando curvas ROC.*

A Tabela IV.8 apresenta os resultados da classificação pela RNA para três classes de defeitos, CE, CI e FP, para os quatro corpos de provas juntos. Neste caso foram utilizados 100 sinais para treinamento e 40 sinais para teste para cada classe. Pelo gráfico de CPDNL da Figura IV.10 observa-se uma razoável discriminação da classe FP das demais classes e uma confusão entre as classes CE e CI, fato que já tinha sido constatado nos gráficos anteriores. No entanto, isto não foi evidenciado pela Tabela IV.8, onde observa-se que a rede confundiu 10% dos sinais da classe CE, sendo 5% com a classe CI e 5% com FP. A RNA ainda classificou 2,5% dos sinais da classe FP como sendo da classe CE. Como já explicado anteriormente, esta confusão pode ter sido ocasionada por sinais de baixa amplitude. Mesmo assim, um índice médio de acerto de 95,8% pode ser considerado bastante satisfatório, o que justifica o uso de redes neurais artificiais na detecção e classificação de defeitos em cordões de solda de sinais de MFL.

Pôde ser constatado que apesar do 2º conjunto conter um número maior de dados, o índice médio de acerto no teste foi um pouco inferior ao índice obtido quando foi utilizado o 1º conjunto, em que a classificação foi realizada para cada duto separadamente. Isto se deve ao fato de que existem diferenças entre os padrões de defeitos de uma mesma classe, o que torna o processo de classificação pela rede neural mais difícil.

Tabela IV.8. *Classificação do defeito – Treinamento e Teste (%) – C. P. 1, 2, 3 e 4.*

Treinamento				**Teste**			
	CE	CI	FP		CE	CI	FP
CE	100			CE	90	5	5
CI		100		CI		100	
FP			100	FP	2,5		97,5
Índice médio de acerto		**100**			**95,8**		

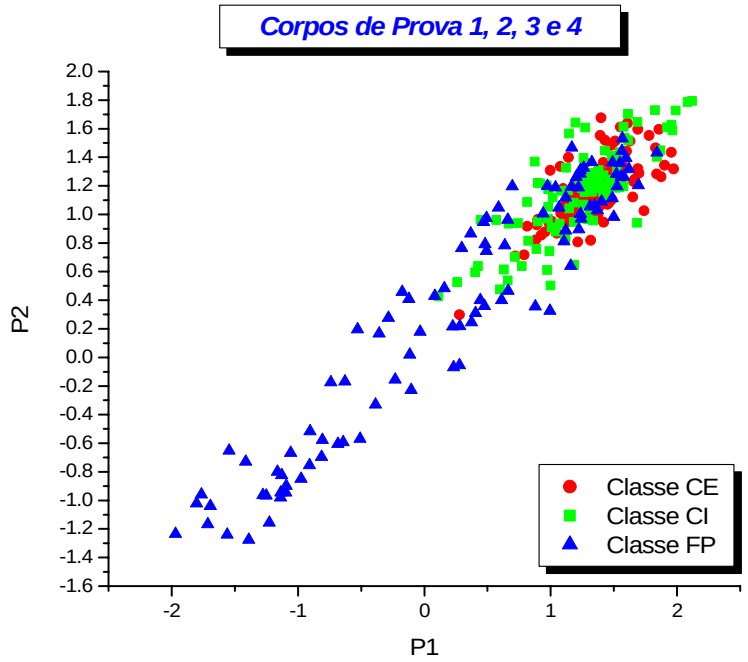

Figura IV.10. *Gráfico das componentes principais de discriminação não-linear referente aos CPs 1, 2, 3 e 4 para as classes: CE, CI e FP.*

IV.1.3. Ensaios utilizando o 3º conjunto de dados

Finalmente, foi realizado treinamento e teste da rede neural utilizado somente três corpos de prova (CP1, CP2 e CP4) e o corpo de prova que não entrou no treinamento (CP3) foi utilizado somente para teste da rede neural. Como o corpo de prova 3 não foi utilizado durante o treinamento, espera-se que o índice de acerto da rede neural seja menor do que nos casos anteriores e principalmente porque, propositalmente, o campo magnético utilizado no experimento deste duto foi diferente dos demais.

A Tabela IV.9 mostra os resultados obtidos para este ensaio para a detecção do defeito, sendo que na fase de teste, para efeito de comparação, é apresentado o resultado para o conjunto de dados contendo os corpos de prova 1, 2 e 4, os quais entraram no treinamento, e para o corpo de prova 3, que não fez parte do conjunto de treinamento. Para este ensaio foram utilizados 300 sinais para treinamento e 120 para teste da rede neural,

para cada classe. Nesta tabela, constata-se que no treinamento a rede neural apresentou um índice médio de acerto de 100%, e no teste o acerto foi de 100% para o conjunto de dados contendo os corpos de prova 1, 2 e 4, e 94,2% para o corpo de prova 3. Para o CP 3 a rede neural confundiu 10% dos sinais da classe CD como sendo sinais da classe SD, seguindo a mesma tendência já observada e explicada anteriormente.

A Tabela IV.10 apresenta os resultados de treinamento e teste para a classificação dos defeitos para o conjunto de dados contendo os corpos de provas 1, 2 e 4 e para o corpo de prova 3. O índice médio de acerto para o conjunto de sinais dos CPs 1, 2 e 4 foi alto, 100% no treinamento e 95,8% no teste. Enquanto que para o corpo de prova de teste (CP 3) este resultado caiu bastante, apresentando um índice médio de acerto de 66,7%, sendo que a maior confusão ocorreu entre as classes CE e CI o que era esperado uma vez que esses sinais são bem semelhantes. A classe FP apresentou um índice de acerto satisfatório, 92,5%.

Tabela IV.9. *Detecção do defeito – Treinamento e Teste (%) – Corpo de prova 3.*

Treinamento			**Teste (CP 1, 2, 4)**			**Teste (CP 3)**		
	CD	SD		CD	SD		CD	SD
CD	100		CD	100		CD	90	10
SD		100	SD		100	SD	1,7	98,3
Índice médio de acerto	**100**		**100**			**94,2**		

Tabela IV.10. *Classificação do defeito – Treinamento e Teste (%) – Corpo de prova 3.*

Treinamento				**Teste (CP 1, 2, 4)**				**Teste (CP 3)**			
	CE	CI	FP		CE	CI	FP		CE	CI	FP
CE	100			CE	92,5	2,5	5	CE	42,5	47,5	10
CI		100		CI	2,5	97,5		CI	20	65	15
FP			100	FP	2,5		97,5	FP	5	2,5	92,5
Índice médio de acerto			**100**			**95,8**				**66,7**	

IV.2. PRÉ-PROCESSAMENTO DOS SINAIS

Devido ao baixo índice de acerto obtido pela rede neural (66,7%) quando foi utilizado para teste o conjunto de dados do CP 3, decidiu-se pré-processar os sinais de entrada da rede na tentativa de eliminar características irrelevantes que poderiam está dificultando a discriminação das classes de defeitos. Portanto, com o objetivo de melhorar o desempenho da rede neural para o teste com o conjunto de dados do CP3, as entradas apresentadas à rede neural foram pré-processadas pelos seguintes métodos: transformada de Fourier, transformada wavelet, filtro média móvel e filtro Savitzky-Golay, sendo que a transformada wavelet foi utilizada na forma contínua, discreta e como um filtro para remoção de ruído (*de-noised* wavelet). Pode-se observar que foram aplicados, inclusive, ferramentas que proporcionam resultados semelhantes, no entanto, é conhecido que dependendo do tipo de sinal a ser processado, uma ferramenta pode apresentar um resultado melhor do que outra que funciona com o mesmo objetivo. A Figura IV.11 mostra um sinal da classe CE original e após vários processamentos realizados. A Figura IV.12 apresenta o mesmo tratamento para um sinal da classe FP. Esses são apenas exemplos, pois a reprodução no texto dos resultados de pré-processamento em todos os sinais seria tediosa, repetitiva e por isso desnecessária.

As Tabelas IV.11 a IV.16 trazem os resultados da saída da rede para os sinais pré-processados. Ficou constatado através destas tabelas que não ocorreu melhorias significativas no desempenho da rede para o teste com conjunto de dados do CP 3. Sendo o melhor resultado apresentado quando foram utilizados os coeficientes da wavelet continua como entrada para a rede neural (71,7%) e o pior quando foi utilizada a amplitude do espectro de freqüência (61,7%). Isto significa que os detalhes não são preponderantes para a classificação do sinal, ou seja, a diferença entre as classes está mais na forma do sinal do que nos detalhes. No entanto, o pré-processamento reduziu consideravelmente o tempo de treinamento da rede neural, uma vez que o sinal original continha 1025 pontos e em alguns casos, quando o sinal foi processado, este número foi reduzido para 128 pontos. Se for levado em consideração que isto será aplicado para ensaios de pig, onde uma corrida tem quilômetros de inspeção, o tempo de processamento é um fator muito importante.

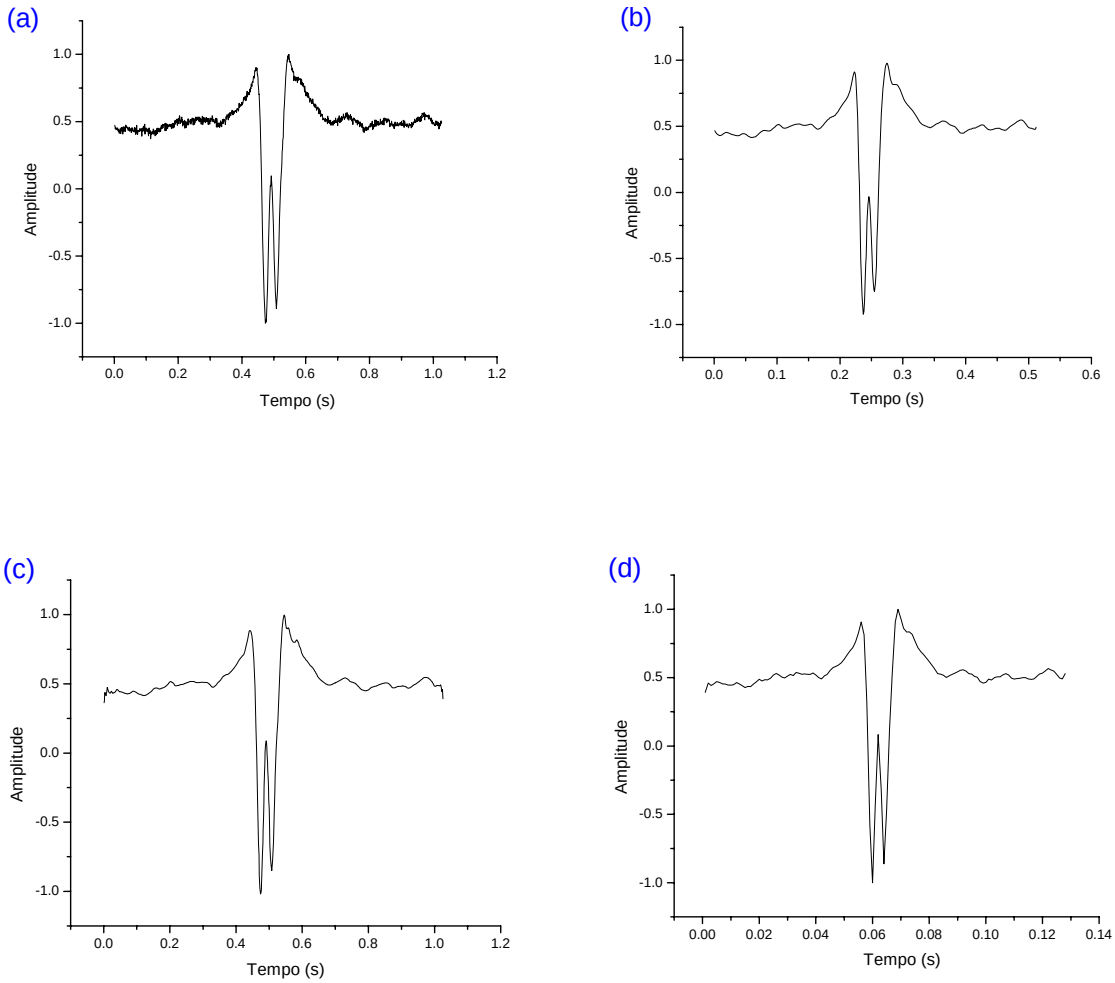

Figura IV.11. *Sinal da classe CE: (a) sinal original, (b) sinal após média móvel de dois pontos e aplicação do filtro Savitzky-Golay, (c) de-noised wavelet e (d) coeficientes wavelet. As amplitudes foram normalizadas.*

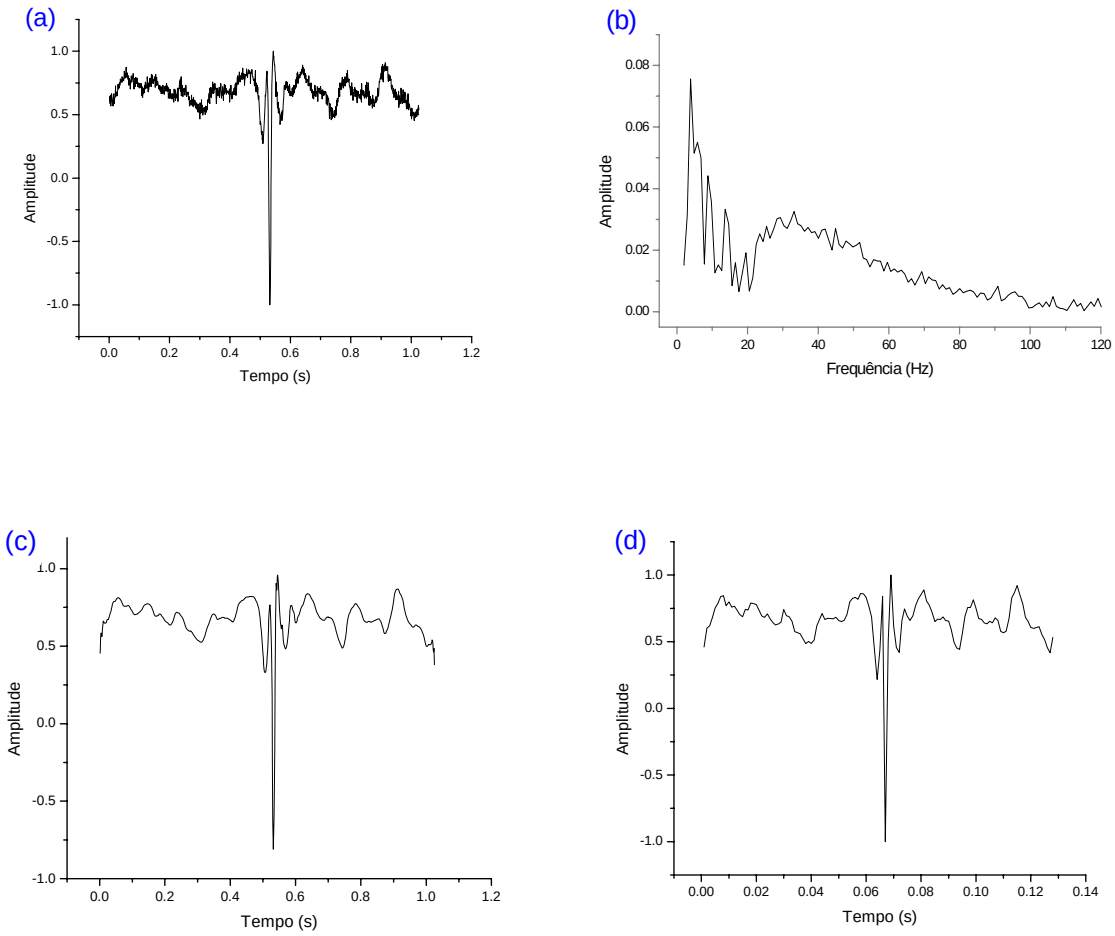

Figura IV.12. *Sinal da classe FP: (a) sinal original, (b) espectro de freqüência, (c) de-noised wavelet e (d) coeficientes wavelet. As amplitudes foram normalizadas.*

Tabela IV.11. *Classificação do defeito – Treinamento e Teste (%) – C. P. 3 - FFT*

Treinamento				**Teste (CP 1, 2, 4)**				**Teste (CP 3)**			
	CE	CI	FP		CE	CI	FP		CE	CI	FP
CE	100			CE	95	5		CE	32,5	47,5	20
CI		100		CI	2,5	97,5		CI	37,5	62,5	
FP			100	FP			100	FP	7,5	2,5	90
Índice médio de acerto			**100**			**97,5**				**61,7**	

Tabela IV.12. *Classificação do defeito – Treinamento e Teste (%) – C.P. 3 – Média-móvel*

Treinamento				**Teste (CP 1, 2, 4)**				**Teste (CP 3)**			
	CE	CI	FP		CE	CI	FP		CE	CI	FP
CE	100			CE	97,5	2,5		CE	32,5	60	7,5
CI		100		CI	2,5	95	2,5	CI	15	80	5
FP			100	FP	2,5	2,5	95	FP	7,5	2,5	90
Índice médio de acerto			**100**			**95,8**				**67,5**	

Tabela IV.13. *Classif. do defeito – Treinam. e Teste (%) – C.P. 3 – Média-móvel - SGolay*

Treinamento				**Teste (CP 1, 2, 4)**				**Teste (CP 3)**			
	CE	CI	FP		CE	CI	FP		CE	CI	FP
CE	100			CE	100			CE	42,5	50	7,5
CI		100		CI	2,5	92,5	5	CI	27,5	67,5	5
FP			100	FP	2,5	2,5	95	FP	5	2,5	92,5
Índice médio de acerto			**100**			**95,8**				**67,5**	

Tabela IV.14. *Classif. do defeito – Treinamento e Teste (%) – C.P. 3 – Wavelet – De-noised*

Treinamento				**Teste (CP 1, 2, 4)**				**Teste (CP 3)**			
	CE	CI	FP		CE	CI	FP		CE	CI	FP
CE	100			CE	100			CE	32,5	55	12,5
CI		100		CI	2,5	92,5	5	CI	22,5	72,5	5
FP			100	FP	2,5	2,5	95	FP	5	5	90
Índice médio de acerto			**100**			**95,8**				**65**	

Tabela IV.15. *Classif. Do defeito – Treinamento e Teste (%) – C.P. 3 – Wavelet – contínua*

Treinamento				**Teste (CP 1, 2, 4)**				**Teste (CP 3)**			
	CE	CI	FP		CE	CI	FP		CE	CI	FP
CE	100			CE	95	5		CE	40	45	15
CI		100		CI	2,5	97,5		CI	7,5	85	7,5
FP			100	FP	2,5	5	92,5	FP	7,5	2,5	90
Índice médio de acerto			**100**			**95**				**71,7**	

Tabela IV.16. *Classif. do defeito – Treinamento e Teste (%) – C.P. 3 – Wavelet – discreta*

Treinamento				**Teste (CP 1, 2, 4)**				**Teste (CP 3)**			
	CE	CI	FP		CE	CI	FP		CE	CI	FP
CE	100			CE	97,5		2,5	CE	40	50	10
CI		100		CI	2,5	92,5	5	CI	25	70	5
FP			100	FP		2,5	97,5	FP		2,5	97,5
Índice médio de acerto			**100**			**95,8**				**69,2**	

De acordo com o código ASME B31.G [120] na determinação do máximo comprimento de corrosão permitido para um duto é levado em consideração apenas a profundidade máxima da corrosão "d" sem levar em consideração sua localização, ou seja, para a perda de espessura por corrosão é dado o mesmo tratamento independentemente da mesma se localizar na parede interna ou externa do duto.

Portanto, na prática, se for levado em consideração que os defeitos de corrosão externa e corrosão interna são igualmente perigosos para a integridade física do duto e que, para uma certa dimensão da área corroída, uma medida corretiva deve ser tomada para evitar um acidente, independente de sua localização (interna ou externa), pode-se juntar as duas naturezas de corrosões em uma única classe. Dessa forma o problema de classificação de três classes se limita a discriminar apenas duas classes: corrosão (CO) e falta de penetração (FP). Um ensaio utilizando este critério foi realizado para 100 sinais da classe CO e 100 da classe FP para treinamento e 40 sinais de cada classe para teste. Os resultados desta avaliação são mostrados na Tabela IV.17, onde observa-se um aumento considerável no desempenho das redes neurais para classificação dos sinais do corpo de prova 3 em relação aos ensaios anteriores. Um índice médio de acerto de 92,5% para os sinais do corpo de prova 3 pode ser considerado alto se for levado em consideração que os dados deste corpo de prova não entraram no treinamento da rede, chegando, inclusive, a se aproximar do resultado obtido pelos sinais dos corpos de prova que entraram no treinamento (95%).

Tabela IV.17. *Classificação do defeito – Treinamento e Teste (%) – Corpo de prova 3*

Treinamento			**Teste (CP 1, 2, 4)**			**Teste (CP 3)**		
	CO	FP		CO	FP		CO	FP
CO	100		CO	100		CO	90	
FP		100	FP		90	FP		95
Índice médio de acerto	**100**		**95**			**92,5**		

Dando continuidade a classificação das três classes: CE, CI e FP, e como o pré-processamento dos sinais não proporcionou melhorias significativas no desempenho da RNA, uma outra tentativa utilizada foi discriminar cada classe separadamente como ocorre no processo hierárquico de classificação [66]. No procedimento hierárquico, cada classe de defeito é separada por vez, ao invés de separar as três classes simultaneamente, como foi realizado anteriormente no processo não-hierárquico. A classificação com hierarquia obedece a um critério de separação onde as classes de mais fácil separação são primeiramente classificadas. Portanto, existe uma tendência da rede neural ser mais eficiente, uma vez que o problema de três classes será reduzido para duas e as classes onde existe maior confusão são separadas por último. Neste caso espera-se que exista um ganho significativo na eficiência, visto que foi constatado nos gráficos de CPDNL anteriores que a classe FP é consideravelmente separada das demais classes. No entanto, deve ser enfatizado que, se for possível reduzir o problema para duas classes: CO e FP, como visto anteriormente, as redes por hierarquia devem ser evitadas por requererem um procedimento mais trabalhoso para sua implementação.

No teste anterior os sinais da classe FP já foram discriminados dos sinais da classe CO (onde os defeitos de corrosão externa e corrosão interna são consideradas como uma única classe) e com um índice médio de acerto, para o pior caso (CP 3), bastante satisfatório (92,5%). Decidiu-se então, nesta etapa do trabalho, avaliar o desempenho da rede neural somente na discriminação das classes CE e CI. Como quase a totalidade dos sinais da classe FP foram corretamente classificados, os sinais classificados erroneamente não foram considerados neste novo teste, como deveria ocorrer em um processo por hierarquia. Portanto neste teste foram utilizados somente sinais da classe CE e CI.

A Tabela IV.18 mostra os resultados do desempenho da rede neural na discriminação das classes CE e CI, onde se pode constatar o que já havia sido observado nos testes anteriores, ou seja, que para o CP 3 os sinais das classes CE e CI são bastante difíceis de serem separados. O índice médio de acerto para o corpo de prova 3 foi de apenas 60%, sendo que a classe CI apresentou um índice de acerto (72,5%) melhor do que a classe CE (47,5%). Um índice de acerto médio de 60% pode ser considerado baixo se for imaginado que um acerto de 50% pode ser atribuído ao acaso. Por outro lado se for observado a Figura IV.13 e IV.14, onde é mostrado um sinal característico da classe de

defeito CE e outro da classe CI, este fato pode ser melhor entendido, uma vez os sinais característico das duas classes são bastante semelhantes o que dificulta a classificação pela rede neural, principalmente porque foi utilizado o próprio sinal como entrada da rede.

Tabela IV.18. *Classif. do defeito – Treinamento e Teste (%) – C.P. 3 – CE x CI*

Treinamento			**Teste (CP 1, 2, 4)**			**Teste (CP 3)**		
	CE	CI		CE	CI		CE	CI
CE	100	0	CE	95	5	CE	47,5	52,5
CI	0	100	CI	5	95	CI	27,5	72,5
Índice médio de acerto	**100**			**95**			**60**	

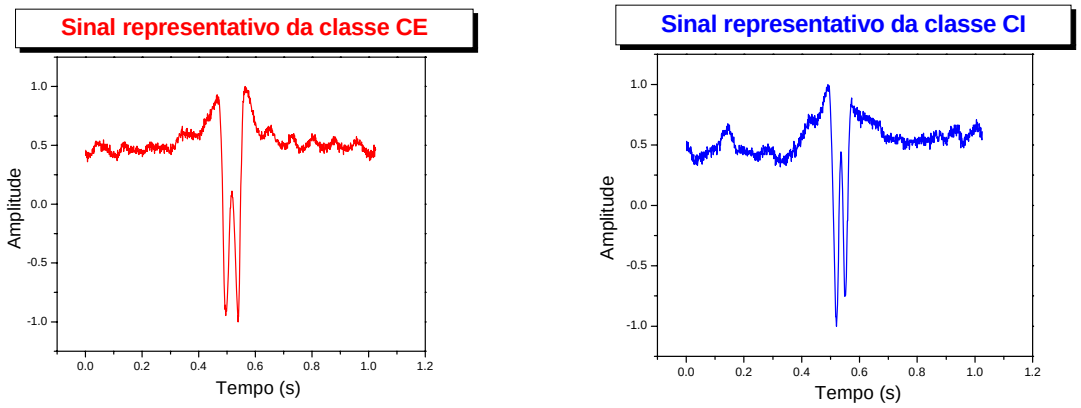

Figura IV.13. *Sinais representativos das classes de defeitos CE e CI. As amplitudes foram normalizadas.*

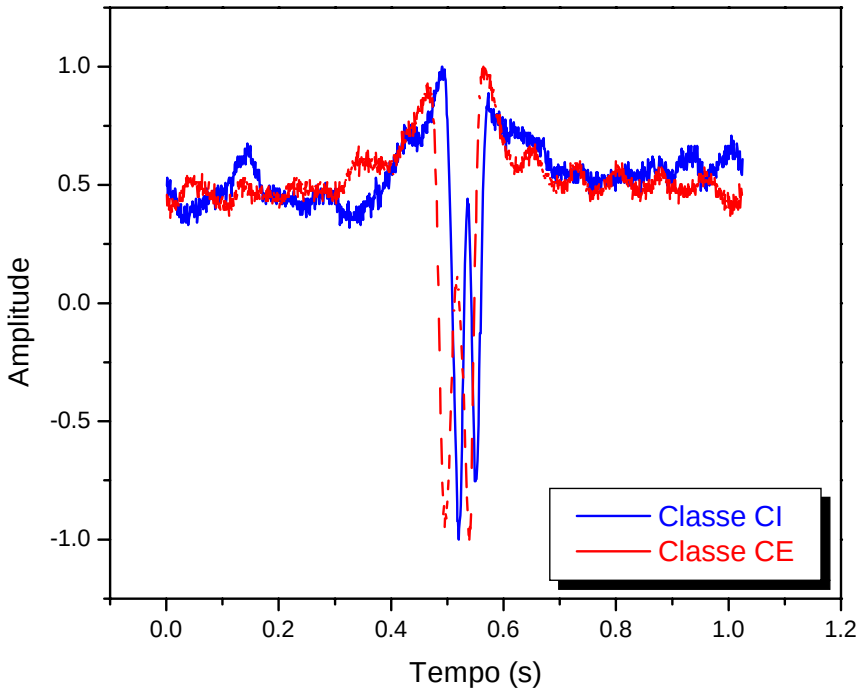

Figura IV.14. *Comparação entre os sinais representativos das classes de defeitos CE e CI. As amplitudes foram normalizadas.*

Finalizando, pode-se concluir que é possível classificar padrões de sinais de MFL com defeitos e sem defeitos utilizando redes neurais artificiais. Também é possível classificar padrões de sinais de defeitos de falta de penetração, corrosão externa e corrosão interna via rede neurais com alta eficiência. No entanto deve ser observado que os mesmos dutos de onde foram retirados os padrões para treinamento da rede devem ser retirados os sinais para teste para evitar uma confusão entre os padrões de sinais de corrosão externa e corrosão interna, o que também não chega a ser um problema, uma vez que os procedimentos vigentes que relatam sobre defeitos em dutos dão o mesmo tratamento ao defeito de corrosão independente da localização (interna ou externa ao duto).

Pôde ser constatado também que as RNAs classificam com alto desempenho sinais de defeitos de falta de penetração de sinais de corrosão, mesmo para dados não fornecidos para RNA na fase de treinamento.

IV.3. CURVAS POD PARA A TÉCNICA DE MFL

IV.3.1. POD experimental

Baseado nos ensaios experimentais realizados com pig magnético nos quatro corpos de prova foram construídas curvas PODs para a técnica de MFL. As curvas POD foram desenvolvidas para três classes de defeitos: CE, CI e FP. A classe de PE não entrou nesta análise uma vez que os defeitos desta classe não foram detectados na inspeção por pig magnético, portanto, sua POD é zero.

Como já explicado anteriormente, a curva POD fornece a probabilidade de detecção de um determinado defeito como uma função de sua dimensão para uma técnica de inspeção especifica. O comprimento da descontinuidade é a característica normalmente mais usada para relações de POD, mas outras medidas podem também ser utilizadas. Portanto, neste trabalho para o desenvolvimento das curvas POD experimentais foram utilizados os comprimentos de defeitos que foram inseridos artificialmente nos corpos de prova, ou seja, 10mm, 20mm, 30mm, 40mm e 50mm, sendo que nos quatro corpos de prova foram inseridos em média 24 defeitos de cada dimensão e foi utilizado o método *hit/miss* na avaliação da inspeção.

Como o número de defeitos era limitado, um conjunto com 24 amostras para cada dimensão de defeito, utilizou-se a técnica de *bootstrap* para definir um intervalo de confiança para a curva calculada. Utilizando esta técnica cada conjunto contendo 24 amostras de cada dimensão foi replicado para 1500 novos conjuntos com 24 amostras cada um deles. A reamostragem foi feita a partir do conjunto original e mantendo a mesma dimensão deste, sendo realizada com reposição dos dados originais, ou seja, uma amostra sorteada uma vez volta para o sorteio e pode ser novamente sorteada. Desta forma cada conjunto *bootstrap* terá no final 24 amostras mas podendo conter dados repetidos. Para criar os 1500 conjuntos aleatórios utilizou-se rotinas de geração de números aleatórios através do programa MATLAB.

As Figuras IV.15, IV.16 e IV.17 mostram as curvas PODs experimentais para as classes de defeitos CE, CI e FP respectivamente com um intervalo de confiança de 95%. Através destas figuras constata-se que para as três classes de defeitos a probabilidade de

detecção é 100% para defeitos iguais ou superiores a 40mm. Enquanto que para defeitos iguais ou inferiores a 10mm a probabilidade de detecção é praticamente zero para as três classes de defeitos. O melhor desempenho foi observado para a classe de defeito de CE, na qual alcançou 100% de detecção para defeitos acima de 30mm, seguido pela classe CI, enquanto que a classe FP apresentou o pior desempenho. Esta constatação pode ser explicada pelo fato de que os defeitos das classes CE e CI, por serem defeitos circulares, tinham uma área maior do que os defeitos da classe FP, que é um defeito linear. Isto pode ser observado no Capítulo III.

A não detecção da classe de defeito de PE e de alguns defeitos das outras classes, inclusive quase todos os defeitos de 10mm, pode ser atribuída a várias incertezas relacionadas ao processo de inspeção, como por exemplo qualificação dos operadores, confiabilidade da ferramenta de inspeção para aquela operação, ajuste dos parâmetros do pig para aquela espessura de parede, pequena fuga do campo magnético no defeito, distância entre os sensores e entre aquisições, entre outras. Devido a pequena perda de espessura dos defeitos que não foram detectados, a opção que parece ser mais coerente é relacionada a baixa fuga do campo magnético no defeito, dificultando a detecção desta fuga pelo sensor.

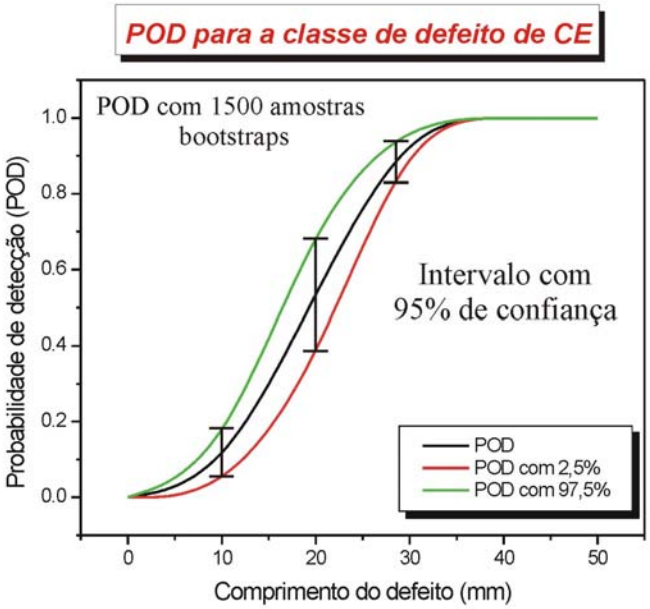

Figura IV.15. *Curva POD experimental para classe de defeito de CE.*

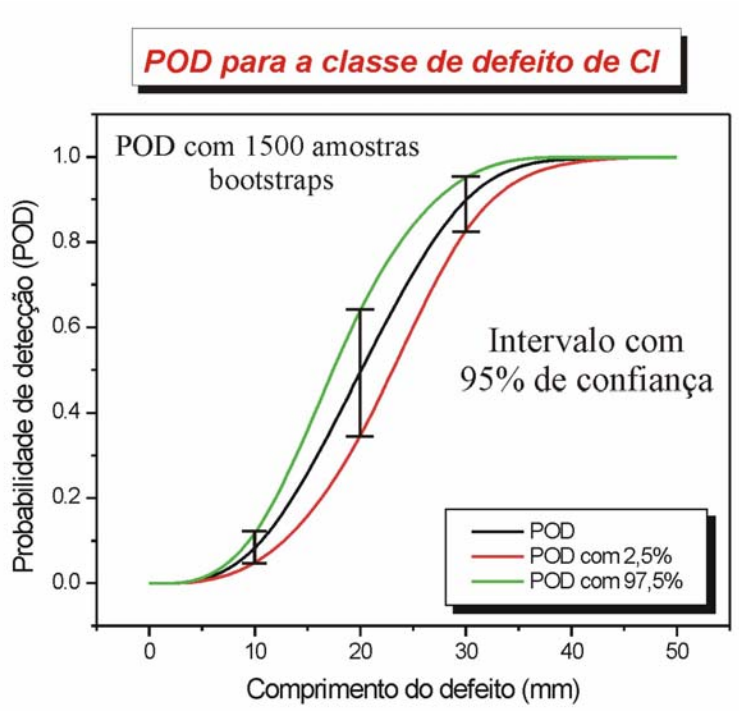

Figura IV.16. *Curva POD experimental para a classe de defeito de CI.*

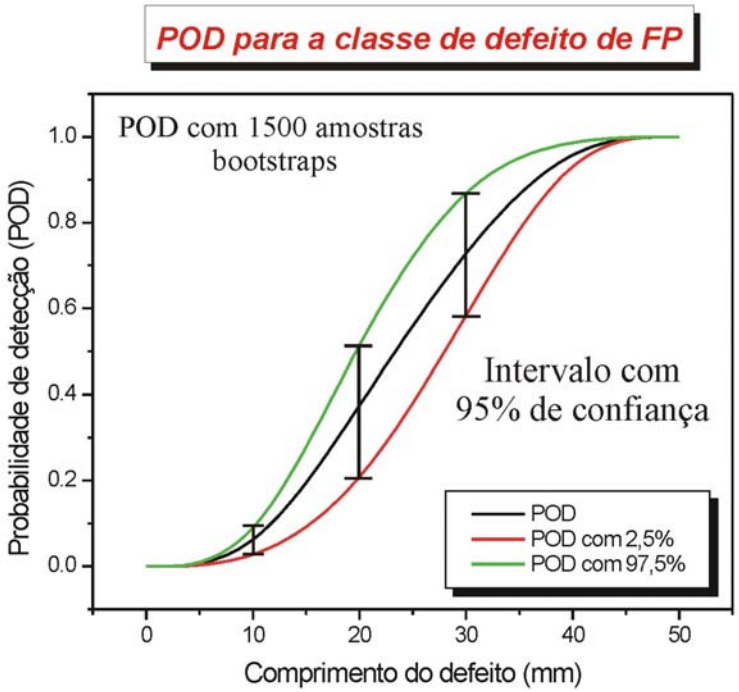

Figura IV.17. *Curva POD experimental para a classe de defeito de FP.*

IV.3.2. POD analítica

Como mencionado anteriormente, a detecção ou não de um defeito pode está relacionada a diversas variáveis do processo de inspeção, como por exemplo, a dimensão do defeito, a profundidade deste defeito e até mesmo o acabamento superficial da superfície inspecionada. No entanto, se for desconsiderada a influência de qualquer outra variável e for assumido que a detecção é função apenas do arranjo geométrico entre os sensores, da distância entre aquisições consecutivas e das dimensões do defeito, ou seja, uma vez que o sensor passe sobre um defeito este é detectado, a curva POD pode ser descrita analiticamente como mostrado a seguir.

Imagine a área a ser inspecionada como uma malha onde cada sensor é separado do seguinte pela distância "l_s" e a distância entre duas aquisições consecutivas de dados é "l_a", desta forma a área a ser inspecionada pode ser imaginada como a grade da Figura IV.18.

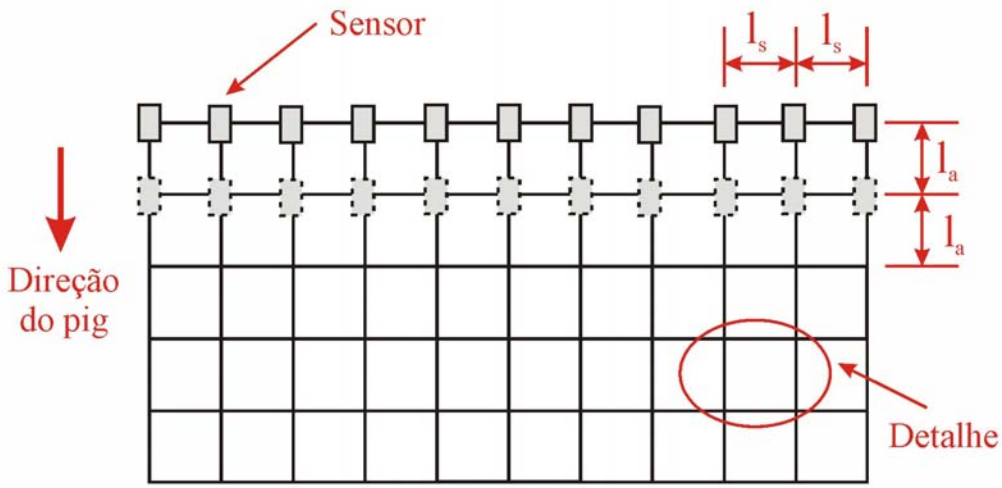

Figura IV.18. *Malha de inspeção. Onde um sensor é separado do outro pela distância "l_s" e cada aquisição é separada da outra pela distância "l_a".*

Analisando o detalhe da Figura IV.18, aumentado na Figura IV.19, pode-se observar quatro sensores de lados "A" e "B" e distância "l_s" entre eles, e um defeito de lados "a" e "b". O defeito mostrado na Figura IV.19 pode estar em qualquer posição dentro do retângulo limitado pelos lados "l_s" e "l_a", e a detecção ocorre quando pelo menos um dos sensores sobrepõe o defeito. Desta forma, se for considerado que a condição mínima

necessária para ocorrer detecção é que exista uma pequena sobreposição entre o sensor e o defeito, conforme Figura IV.20, e que a probabilidade de detecção associada ao tamanho do defeito depende somente desta malha de inspeção, pode-se representar analiticamente a POD pelas Equações IV.1 e IV.2 a seguir. A Figura IV.19 apresenta o caso para quando o defeito é retangular, enquanto a Figura IV.21 mostra o caso para o defeito circular, sendo que em ambos os casos os defeitos são considerados paralelos a superfície de inspeção.

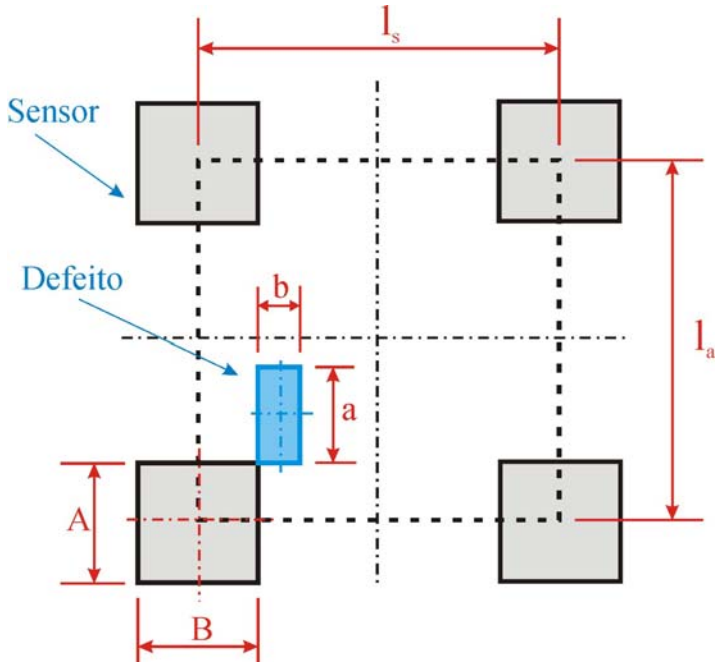

Figura IV.19. *Situação para o caso de defeito retangular.*

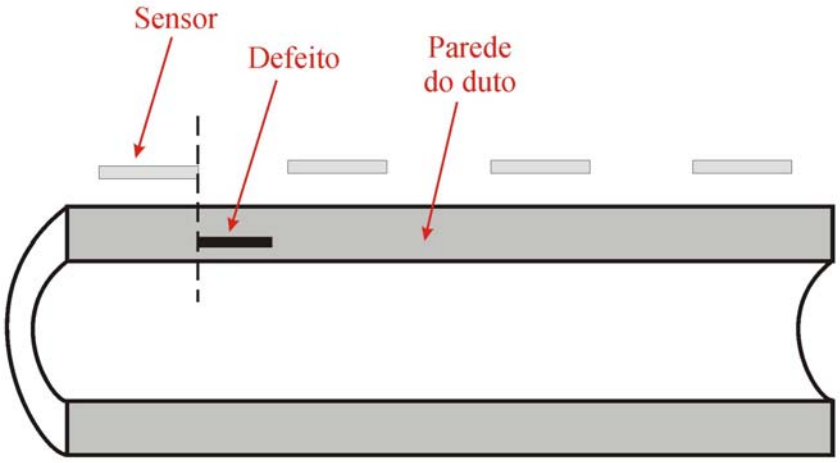

Figura IV.20. *Situação limite para detecção.*

1º caso: Defeito retangular

$$POD = \frac{\left(\frac{A+a}{2}\right).\left(\frac{B+b}{2}\right).4}{l_s.l_a} = \frac{(A+a).(B+b)}{l_s.l_a} \qquad \textit{Eq. IV.1}$$

2º caso: Defeito circular

$$POD = \frac{\left[\left(\frac{A}{2}.\frac{B}{2}\right)+\left(r.\frac{A}{2}\right)+\left(r.\frac{B}{2}\right)+\frac{\pi r^2}{4}\right].4}{l_s.l_a} = \frac{A.B+2r.A+2r.B+\pi r^2}{l_s.l_a} \qquad \textit{Eq. IV.2}$$

onde r é o raio do defeito.

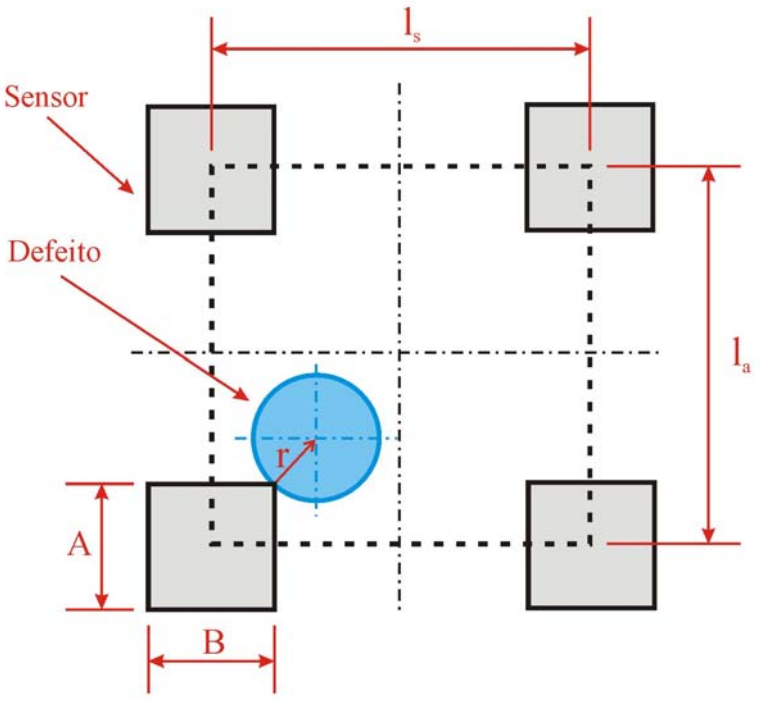

Figura IV.21. *Situação para o caso de defeito circular.*

Nos ensaios realizados neste trabalho ficou constatado que a não detecção de alguns defeitos não está relacionada a fatores geométricos e sim a outras variáveis do processo de inspeção. Esta constatação pode ser observada por meio do desenho esquemático apresentado na Figura IV.22. Nesta figura é possível verificar que cada quatro sensores são encapsulados dentro de uma única sapata e a distância entre eles é de aproximadamente 1mm, enquanto que a distância entre as sapatas é em média 5mm. Como o menor defeito inserido no corpo de prova foi de 10mm e a distância entre duas aquisições consecutivas foi de 0,5mm, torna-se impossível que pelo menos uma sapata não passe sobre o defeito, uma vez que este arranjo cobre todo o perímetro do duto. conforme Figura IV.23.

Para a determinação das curvas PODs experimentais apresentadas neste trabalho de tese foi necessário a confecção de quatro corpos de prova cada um contendo 12 soldas circunferenciais com vários defeitos de dimensões conhecidas inseridos artificialmente. Estes corpos de prova foram então ensaiados por uma ferramenta de pig istrumentado conseguida em uma parceria COPPE/UFRJ e a empresa PIPEWAY. No entanto, diferentemente do que foi realizado neste trabalho, na maioria das vezes a determinação de curvas PODs através de ensaios experimentais se torna quase impraticável devido ao custo e a necessidade de mão de obra qualificada para a confecção de vários corpos de prova com defeitos inseridos e principalmente a realização dos ensaios com pig magnético que requer um investimento muito elevado para contratação de empresas que executem este trabalho (por exemplo, só existe uma empresa nacional). Pode ser adicionado ainda o fato de que a POD é definida para uma situação específica com determinadas condições de ensaio e para determinados parâmetros, dessa forma qualquer alteração nestas condições poderá invalidar os resultados. Portanto, a determinação de curvas PODs analiticamente e mesmo numericamente por meio de simulação, como Monte Carlo por exemplo [110], se torna a única alternativa viável. A determinação da POD numericamente, como visto em Carvalho [103] por exemplo, pode, inclusive, abordar outras incertezas envolvidas no processo de inspeção como a confiabilidade do equipamento, experiência do operador, ambiente de inspeção, entre outras, porque diferentemente do que foi considerado neste trabalho no cálculo da POD analítica, para que o defeito seja detectado é necessário que o sensor passe sobre ele, mas isso não significa que a detecção é certa (essa condição não é suficiente para a detecção do defeito), uma vez que outras variáveis estão envolvidas na inspeção. No

entanto, vale ressaltar que muitas dessas variáveis são apenas aproximações uma vez que são impossíveis de serem simuladas, como o fator humano por exemplo e que por esse motivo são corrigidas utilizando um fator de incerteza.

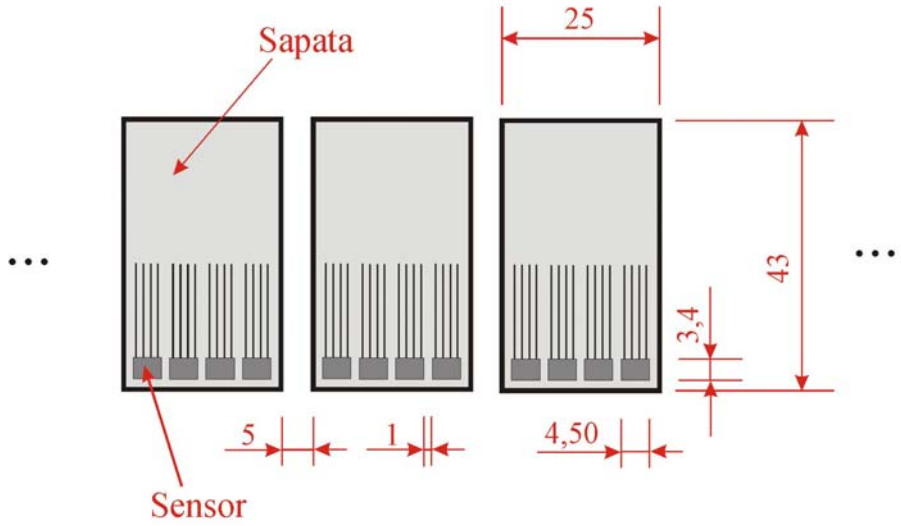

Figura IV.22. *Arranjo geométrico dos sensores e sapatas. Unidades em mm.*

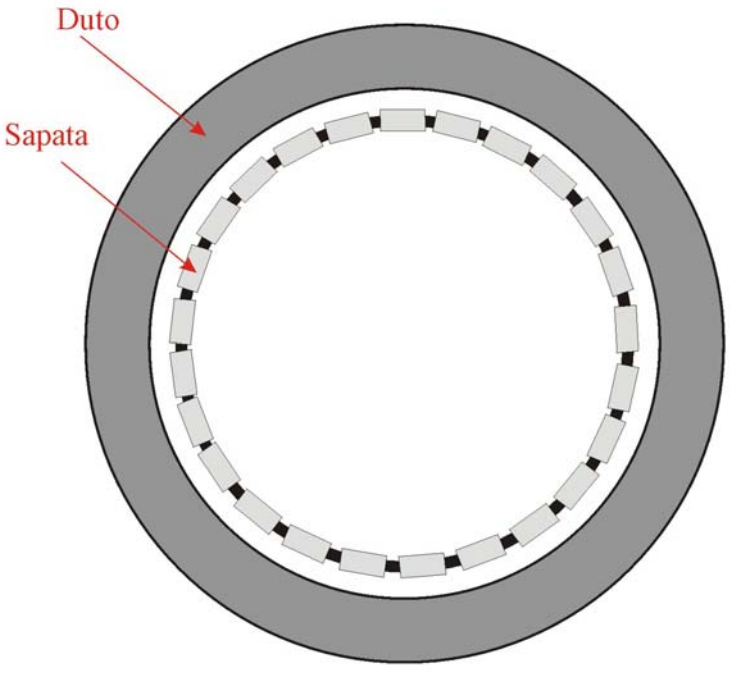

Figura IV.23. *Vista dos sensores dentro do duto.*

IV.3.3. Ajuste à uma distribuição de probabilidades

Para a maioria das aplicações, como por exemplo o planejamento de inspeção baseado em risco (RBI), uma curva analítica pode ser muito mais útil do que uma curva numérica. Uma curva POD analítica pode ser obtida também ajustando-se a curva experimental obtida a uma distribuição de probabilidades conhecida. Desta forma, através de testes de aderência [110] é possível comparar a distribuição teórica com a curva experimental e portanto obter a distribuição que melhor representa os dados experimentais. Entre os testes de aderência mais conhecidos pode-se citar o teste chi-quadrado e o teste Kolmogorov-Smirnov (K-S). Outra maneira de verificar o ajuste entre as curvas é visualmente. Através de programas de computador (Mathcad, Maple, etc) várias distribuições teóricas podem ser definidas e plotadas em um mesmo gráfico junto com a curva experimental. Então, visualmente é possível definir qual das curvas melhor se ajusta a curva experimental.

Neste trabalho várias distribuições de probabilidades teóricas foram ajustadas aos dados experimentais obtidos, como por exemplo Weibull, Lognormal, Frechet, Gumbel ente outras. Baseado no teste de Kolmogorov-Smirnov com um nível de significância de 5%, o melhor ajuste foi alcançado com a distribuição de probabilidade proposta por Ochi [121]. Esta distribuição é dada por:

$$Fe(x) := 1 - \exp\left(-a \cdot x^{m} \cdot \exp\left(-p \cdot x^{k}\right)\right) \qquad \textit{Eq. IV.3}$$

onde *a*, *m*, *p* e *k* são os parâmetros da distribuição.

As curvas PODs experimentais médias mostradas anteriormente foram aproximadas pela distribuição de probabilidades descrita pela Equação IV.3, conforme detalhado na referência [121]. As Figuras IV.24, IV.25 e IV.26 mostram os valores de POD obtidos no ensaios experimentais para as classes de defeitos CE, CI e FP e as respectivas distribuições teóricas dadas pela Equação IV.3.

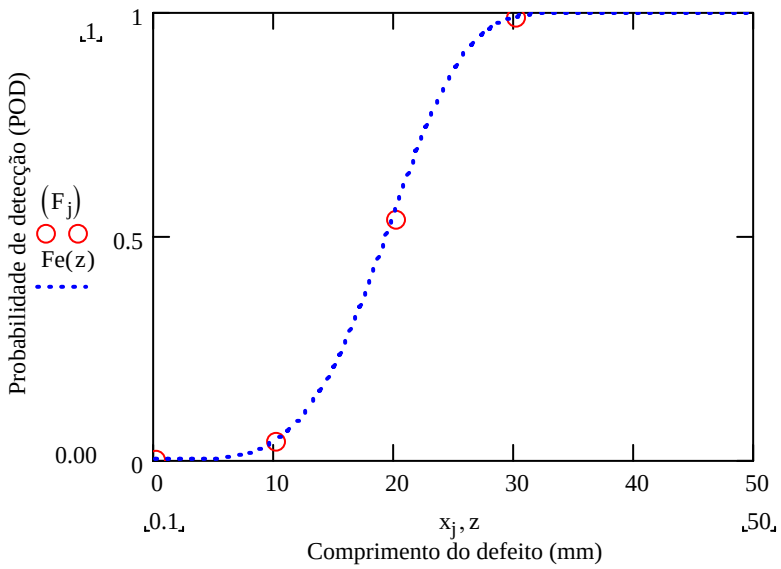

Figura IV.24. *Curva da distribuição teórica dada pela Eq. IV.3 (em azul) e pontos experimentais (em vermelho) para a classe de defeito de CE.*

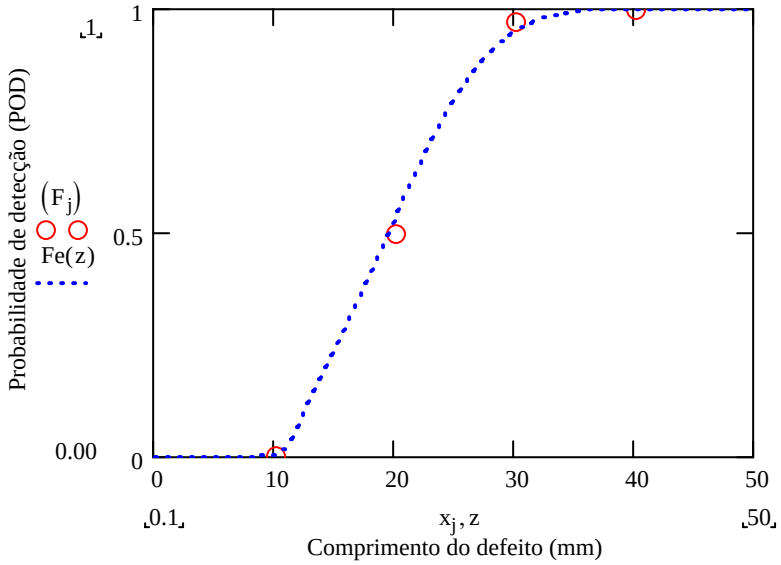

Figura IV.25. *Curva da distribuição teórica dada pela Eq. IV.3 (em azul) e pontos experimentais (em vermelho), para a classe de defeito de CI.*

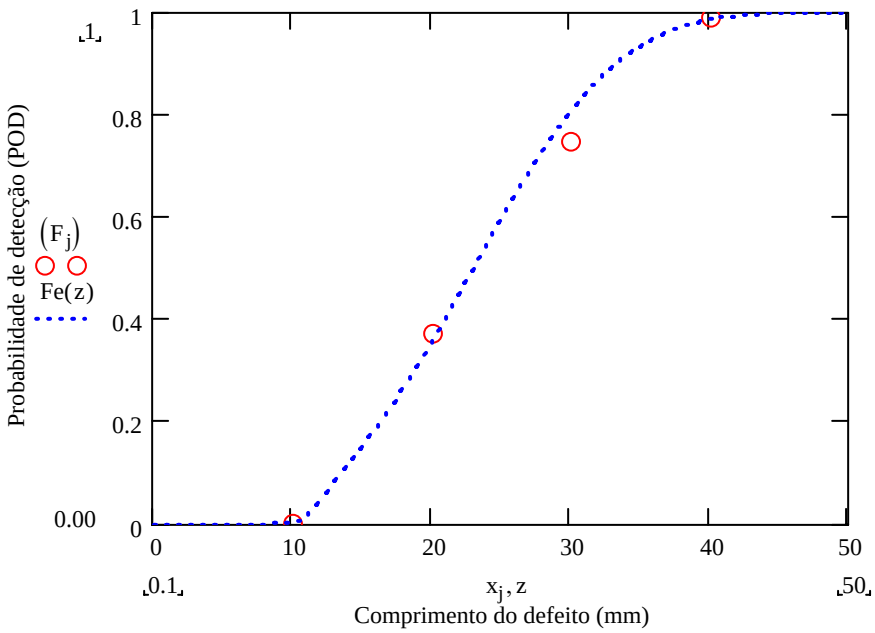

Figura IV.26. *Curva da distribuição teórica dada pela Eq. IV.3 (em azul) e pontos experimentais (em vermelho), para a classe de defeito de FP.*

IV.4. CURVAS POD PARA A TÉCNICA DE ULTRA-SOM

Ao longo dos últimos anos alguns projetos de pesquisa já foram desenvolvidos com o objetivo de fornecer uma base experimental sobre o desempenho de técnicas de ensaios não destrutivos na detecção, localização e dimensionamento de falhas [122]. Todos estes trabalhos se basearam em RRT (do inglês "*Round Robin Testing"*), nos quais amostras contendo defeitos induzidos e em posições aleatórias são inspecionadas por diferentes grupos utilizando técnicas de ensaios não destrutivos, tendo seus resultados confrontados posteriormente e sendo que os grupos não possuem nenhum conhecimento prévio sobre os defeitos inseridos. A localização e dimensionamento das falhas realmente presentes nos corpos de prova são depois confirmados, geralmente por técnicas de ensaios destrutivos ou pelo corte das amostras.

Contudo, um teste para avaliar o desempenho do operador na inspeção de END, como realizado em RRT ou como foi realizado neste trabalho de tese, dificilmente pode reproduzir todas as condições de uma inspeção real, de tal forma que o operador não consiga perceber que está sendo avaliado. Por esse motivo um inspetor quando é solicitado para um trabalho desta natureza permanece altamente motivado e interessado durante todo o período de teste, tanto pelo conhecimento de que seus resultados são importantes, quanto pela ocorrência geralmente regular de indicações [123].

A primeira grande experiência bem sucedida no mundo em um trabalho deste tipo foi o PISC (do inglês "*Programme for Inspection of Steel Components*") [124-132]. Este programa iniciou em 1974 e foi dividido em 3 partes, sendo que a primeira tinha o objetivo de avaliar os procedimentos de inspeção aplicados na época. Os resultados mostraram diversas falhas no procedimento ASME, contudo, a mais importante contribuição do PISC I foi mostrar a necessidade de melhorias nas tecnologias de END. Tamanha sua importância que o PISC II e PISC III se sucederam com o objetivo de avaliar mais detalhadamente as técnicas de END que poderiam fornecer um nível satisfatório de detecção e dimensionamento das descontinuidades.

Estimulados pelo sucesso do PISC outros programas surgiram no mundo, quase sempre com o objetivo de avaliar diferentes técnicas de END, sendo que a inspeção manual, por ser a mais usual, quase sempre estava presente. Entre os mais importantes

projetos pode-se destacar: NORDTEST, realizado na região da Escandinávia; NIL do instituto Holandês de soldagem (“Nederlands Instituut voor Lasterchniek”); ICON (do inglês “Inter Calibration of Offshore Non-destructive examination”) e o TIP (do inglês “Topside Inspection Project”) [122]. No geral estes programas destacaram a superioridade da inspeção automatizada sobre a inspeção manual, principalmente quando técnicas de processamento são incorporadas ao sistema, como o SAFT (do inglês “*synthetic aperture focussing techniques*”).

No Brasil um programa desenvolvido em 1985 pela Associação Brasileira de Ensaios Não Destrutivos (ABENDE) avaliou a inspeção ultra-sônica manual na detecção e dimensionamento de defeitos do tipo falta de fusão com dimensões que variavam entre 14,6mm a 73,8mm de comprimento [133].

Neste trabalho de tese, diferentemente dos demais, avalia-se a probabilidade de detecção para o ensaio de ultra-som manual e automatizado para uma faixa de dimensões que pode ser considerada quase que o limite inferior de detecção, mesmo porque defeitos menores dos que foram utilizados se tornam quase impossíveis de serem induzidos artificialmente. No presente caso, na tentativa de destacar apenas a influência do inspetor no ensaio, todos utilizaram o mesmo procedimento de inspeção, foram qualificados pela mesma instituição e realizaram os ensaios sob as mesmas condições. Dessa forma tentou se obter a POD mais representativa possível, para as classes de defeitos FF e FP, para a condição brasileira de trabalho.

Baseado nos ensaios experimentais realizados por 5 inspetores foram desenvolvidas curvas PODs para o ensaio ultra-sônico de pulso eco para as classes de defeitos de FP e FF. Para tanto foi utilizado como variável independente o comprimento do defeito. Foram inseridos em média 15 defeitos de cada comprimento considerado e variando-se as alturas, conforme já descrito anteriormente no Capítulo III. Como foram utilizados 5 inspetores, as curvas PODs foram construídas a partir de uma média de 75 defeitos de cada comprimento.

Como o número de defeitos era limitado, um conjunto com 75 amostras para cada dimensão de defeito, utilizou-se a técnica de *bootstrap* para definir um intervalo de confiança para a curva calculada. Utilizando esta técnica cada conjunto contendo 75 amostras de cada dimensão foi replicado para 1500 novos conjuntos *bootstraps* contendo

75 amostras em cada um deles. A reamostragem foi feita a partir do conjunto original e mantendo-se a mesma dimensão, sendo realizada com reposição dos dados originais, ou seja, uma amostra sorteada uma vez volta para o sorteio e pode ser novamente sorteada. Desta forma cada conjunto *bootstrap* terá no final 75 amostras, mas podendo conter dados repetidos. Para criar os 1500 conjuntos aleatórios utilizou-se rotina de geração de números aleatórios através do programa MATLAB.

A probabilidade de detecção média foi calculada para cada um dos 1500 conjuntos *bootstraps* contendo 75 amostras cada. Portanto, como existiam 1500 conjuntos *bootstraps*, os 1500 valores de POD foram colocados em ordem crescente e definido um limite de confiança de 95%, conforme mostrado na Figura IV.27.

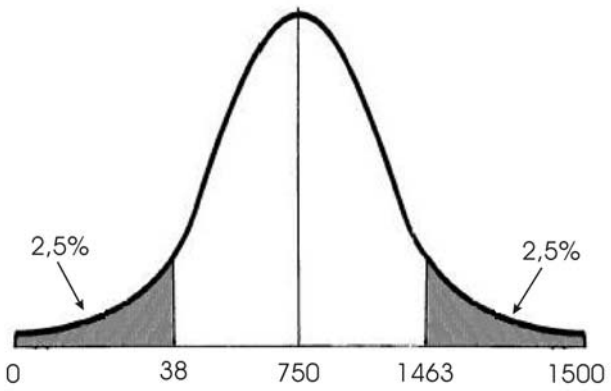

Figura IV.27. *Limite de confiança para a curva POD calculada.*

As Figuras IV.28 e IV.29 apresentam as curvas PODs experimentais para as classes de defeitos FP e FF, respectivamente, com um intervalo de confiança de 95%. Para as duas classes de defeitos pode-se observar que a probabilidade de detecção se aproxima de 100% para defeitos com comprimento igual ou superior a 20mm. Para efeito de comparação a Figura IV.30 apresenta as curvas PODs médias para as classes de defeitos FP e FF em um mesmo gráfico. Através desta figura pode-se constatar que a POD para a classe de defeito de FP cresce rapidamente e mantém-se quase que constante, enquanto que a POD para a classe de defeito de FF cresce lentamente a medida que o comprimento do defeito aumenta. Por exemplo, para um comprimento de defeito de 3mm a curva POD para a classe FP fornece um valor de aproximadamente 76%, enquanto que para a classe FF é apenas 38%,

já para o comprimento de defeito de 12mm a probabilidade de detecção é a mesma para as duas classes de defeitos (78%). A partir deste ponto a probabilidade de detecção é maior para a classe FF.

Em geral, pode-se observar que a probabilidade de detecção média é maior para a classe FP (77%) do que para a classe FF (63%) e isto pode ser explicado pelo fato de que o defeito FP se localiza na raiz da solda e, portanto possui uma chance dupla de detecção, uma vez que pode ser detectado por ambos os lados do cordão de solda durante o ensaio, enquanto que o defeito de FF é detectado apenas por um dos lados.

Por outro lado, grandes defeitos apresentarão grandes amplitudes e serão facilmente detectados, independentemente da origem deles ser FF ou FP. No entanto, o sinal do defeito de FP por está perto do eco de fundo poderá ser confundido com este, enquanto que com o sinal da classe FF, por está mais afastado, dificilmente ocorrerá este problema. Portanto, isto explica o fato da probabilidade de detecção, para maiores comprimentos de defeitos, ser maior para a classe FF. DIJKSTRA [134] evidenciou em seu trabalho que na inspeção de raiz de soldas com ultra-som automatizado existe uma dificuldade em diferenciar sinal proveniente da geometria do chanfro do sinal de um defeito.

No ***projeto PISC*** a eficiência do inspetor na detecção de falhas do tipo trinca de fadiga e falta de fusão ficou entre 65% e 100%, sendo que poucos inspetores conseguiram uma eficiência superior a 80%. No ***projeto NIL*** os mesmos defeitos foram avaliados e a probabilidade de detecção do ultra-som manual alcançou apenas 50%. Resultado interessante foi obtido no ***projeto NORDTEST***, onde uma POD de 90% foi obtida para o ensaio ultra-sônico quando foi utilizada a curva DAC de 20% como método de avaliação da descontinuidade do tipo falta de fusão e falta de penetração com altura igual a 10mm. No ***projeto ICON*** foi alcançada uma probabilidade de detecção na ordem de 100% quando foi utilizada a inspeção por TOFD em defeitos de falta de penetração e corrosão inseridas artificialmente. Já no projeto dirigido pela A***BENDE*** no Brasil [133] a probabilidade de detecção para os inspetores ficou entre 34,4% a 96,6% com uma POD média de 73,89%. FAUSKE [135] inspecionando corpos de prova contendo defeitos tipo trincas obteve uma POD média de 60% quando foi utilizado inspeção manual e 80% para inspeção automatizada, e concluiu ainda que uma trinca de 1mm de profundidade e 10mm de comprimento localizada do lado oposto de uma chapa de 80mm de espessura representava

o limite inferior de detecção. VERKOOIJEM [136] apresentou probabilidades de detecção para defeitos tipo falta de fusão, falta de penetração, inclusão e porosidade, tendo alcançado 52,3% para o ensaio de ultra-som manual, 83,6% para o pulso eco automatizado e 82,4% para a técnica TOFD.

No presente trabalho, considerando todos os defeitos de todos os inspetores a POD média para a classe de FF foi de aproximadamente 63%, enquanto que para a classe de FP foi de 77%. Estes resultados de PODs obtidos neste trabalho são da mesma ordem de grandeza dos resultados alcançados por outros autores, conforme citados anteriormente.

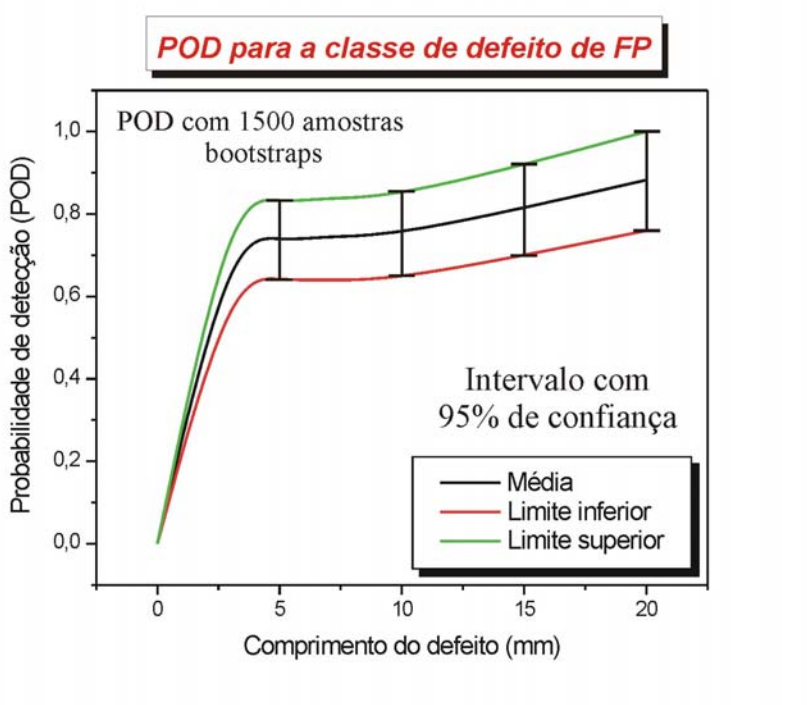

Figura IV.28. *Curva POD para o ensaio US de pulso-eco para a classe de defeito de FP.*

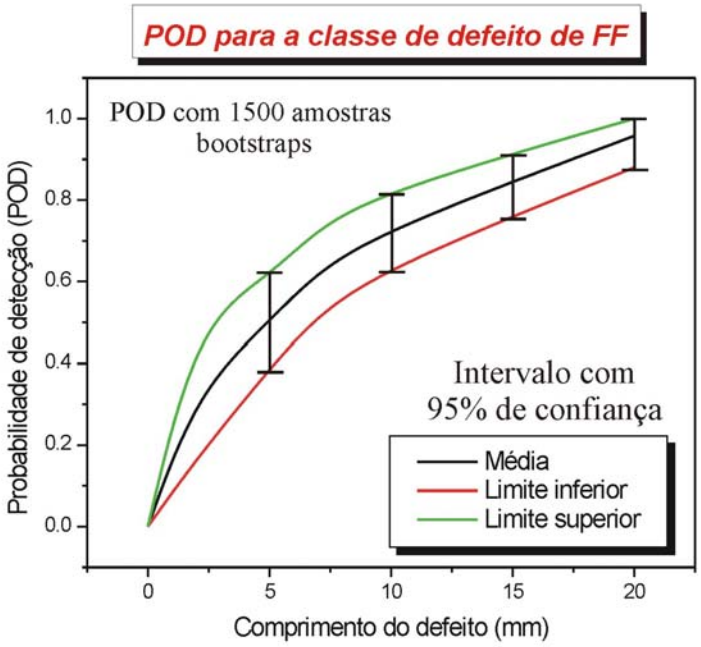

Figura IV.29. *Curva POD para o ensaio US de pulso-eco para a classe de defeito de FF.*

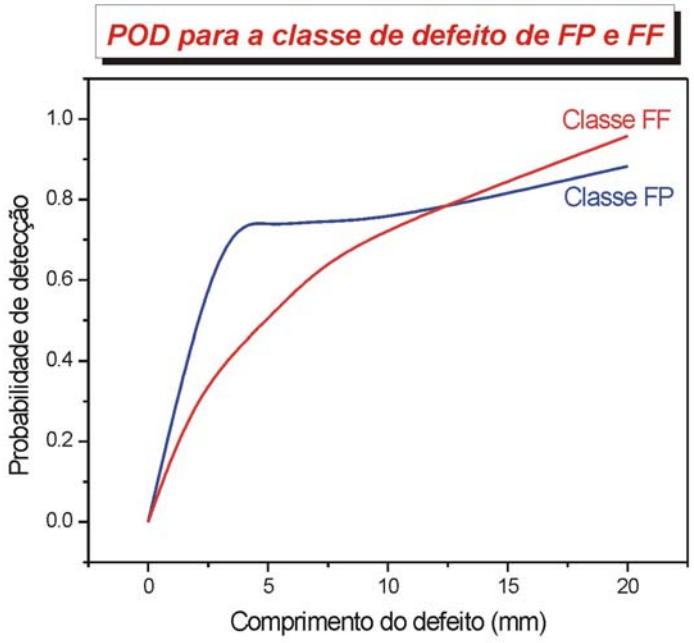

Figura IV.30. *Curva POD para o ensaio US de pulso-eco para as classes de defeito de FP e FF.*

Com o objetivo de realizar uma análise da dispersão dos resultados por inspetor, as Figuras IV.31 e IV.32 apresentam as curvas PODs para cada inspetor separadamente, para as classes de defeitos FF e FP, respectivamente. Nestas figuras é mostrada também a curva POD média com um intervalo de confiança de 95%, conforme Figura IV.30, e ainda a curva para o ensaio automatizado. O ensaio ultra-sônico automatizado foi realizado com auxilio do sistema de varredura detalhado no Capítulo III. O ensaio automatizado foi realizado tanto pela técnica pulso-eco quanto pela técnica *TOFD* e a probabilidade de detecção, para as duas classes de defeitos, por ambas as técnicas foi de 100%, conforme pode ser observado nas Figuras IV.31 e IV.32 a seguir e nos resultados apresentados nos Anexos C e D. A curva para o ensaio automatizado é semelhante a curva para uma técnica ideal mostrada na seção II.6, ou seja, a POD para defeitos menores que um tamanho crítico é zero, enquanto que a POD para defeitos maiores que este tamanho é 100%.

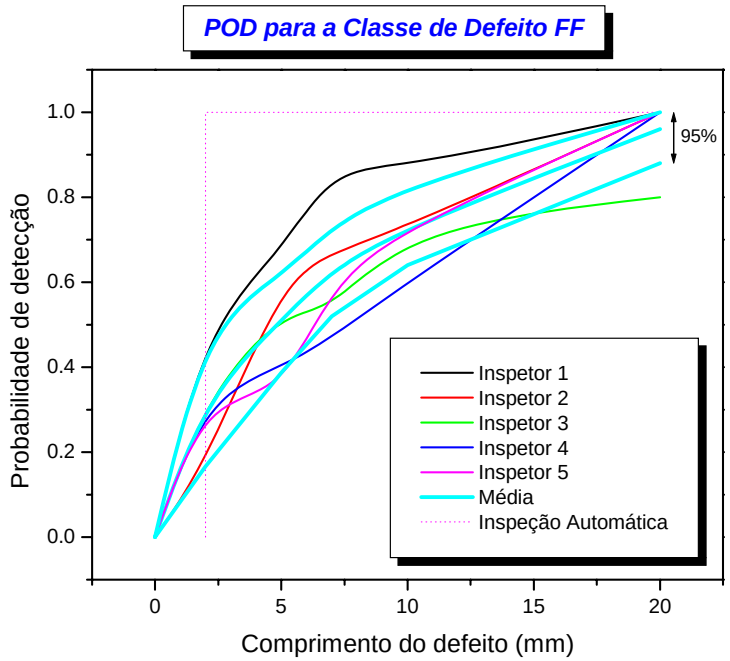

Figura IV.31. *Curvas PODs para o ensaio US de pulso-eco para a classe de defeito de FF.*

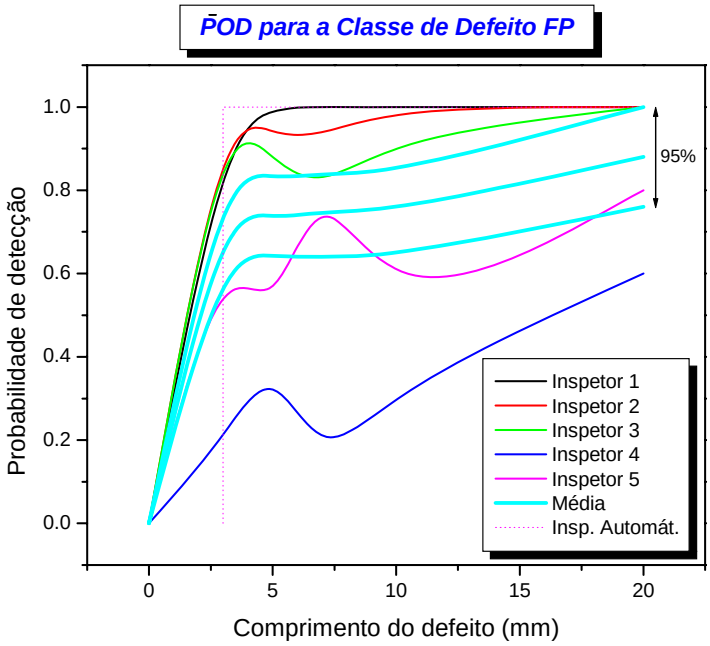

Figura IV.32. *Curvas PODs para o ensaio US de pulso-eco para a classe de defeito de FP.*

Vários outros trabalhos [134,137-140] têm evidenciado as vantagens do ensaio por ultra-som automatizado sobre o ultra-som manual, como por exemplo, o aumento da velocidade de inspeção, alta POD e conseqüente aumento da confiabilidade da inspeção, documentação do registro da inspeção, interpretação dos resultados por meio de imagens, possibilidade de processamento computadorizado como redes neurais artificiais [141,142,143], entre muitas outras. Alguns desses sistemas, inclusive, utilizam transdutores operando no modo pulso-eco e transdutores empregando a técnica TOFD em um mesmo dispositivo, para aumentar a eficiência da inspeção [144,145,146].

Através das Figuras IV.31 e IV.32 pode-se observar que a classe de defeito FP, apesar de apresentar uma probabilidade de detecção maior que a classe FF, possui uma maior dispersão dos resultados. Para a classe FF os resultados dos inspetores ficaram praticamente dentro do intervalo de confiança, enquanto que para a classe de defeito FP isto não ocorreu. O inspetor 4, por exemplo, ficou muito abaixo da média, uma vez que o mesmo não conseguia diferenciar, por deficiência de desempenho, defeito de FP do eco de fundo, fato esse que ocorreu também, algumas vezes, com o inspetor 5. Esse mesmo problema foi verificado por DIJKSTRA [134] para o caso do ultra-som automatizado.

A variação do desempenho entre diferentes grupos participantes de RRT foi evidenciada também em outros trabalhos, como no ***PISC*** [122], no ***NIL*** [122] e também no trabalho da ***ABENDE*** [133]. No presente trabalho ocorreu, inclusive, um caso em que o inspetor apresentou uma probabilidade de detecção zero, isto é, não detectou nenhum dos defeitos inseridos nos corpos de prova. O resultado deste inspetor não foi levado em consideração nos cálculos da POD.

O nível de qualificação também não foi um fator preponderante para um aumento na POD, uma vez que o inspetor 1, o qual obteve o melhor desempenho, é menos qualificado do que o inspetor 2. STEPHENS [147] também mostrou em seu trabalho que mesmo operadores experientes e bem treinados cometem erros. Segundo PASSI [148] no ensaio ultra-sônico manual além da interpretação ser totalmente dependente da habilidade e conhecimento do operador, existem três fatores, dependentes do inspetor, que afetam a confiabilidade da inspeção: a perda da trajetória pré-definida para o movimento do transdutor sobre o objeto de teste; a violação do acoplamento acústico e a falta de atenção nos ecos recebidos. JINHONG [149] ainda acrescentou que para assegurar qualidade numa inspeção de END são necessários além de inspetores bem treinados e qualificados, o uso de equipamentos e materiais avançados, bons procedimentos de inspeção e ainda adequada atenção deve ser dada para os impactos ambientais no resultado da inspeção.

A Figura IV.33 correlaciona os vários elementos presentes em uma atividade que envolve ensaios não destrutivos. Uma vez definido o componente que será inspecionado é necessário um prévio conhecimento do tipo de descontinuidade que se espera encontrar para fazer a escolha mais adequada da técnica de inspeção a ser utilizada. Essa informação é importante porque toda técnica possui capacidades e limitações e, portanto, esse conhecimento vai permitir aplicar corretamente o procedimento de inspeção e assim obter o máximo rendimento da técnica. Por exemplo, o ensaio por ultra-som é muito mais eficiente para detectar defeito de falta de fusão na lateral do chanfro do que o ensaio por radiografia. Todos esses elementos devem ser bem avaliados antes da inspeção para que a probabilidade de detecção seja a máxima possível.

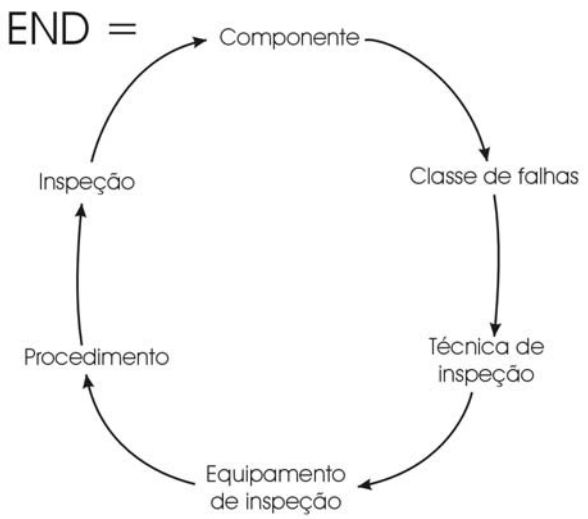

Figura IV.33. *Elementos envolvidos em uma atividade de ensaios não destrutivos.*

Não é objetivo neste trabalho avaliar a precisão no dimensionamento realizado pelos inspetores, no entanto como o dimensionamento do comprimento do defeito estava disponível nos relatórios de inspeção, foi feita uma breve análise dos resultados obtidos. As Figuras IV.34 e IV.35 apresentam os dimensionamentos realizados pelos os 5 inspetores para as classes de defeitos FF e FP, respectivamente.

Nestes gráficos é apresentado o comprimento esperado (projetado) para cada defeito contra o comprimento medido pelo inspetor. Para facilitar a visualização os eixos X e Y estão com escalas diferentes. Se os dois eixos estivessem na mesma escala a reta preta sobre o gráfico teria um ângulo de 45^{o} com a horizontal, o que significa dizer que se o inspetor dimensionasse o defeito com o valor correto, a medida estaria sobre esta reta. Através das Figuras IV.34 e IV.35 constata-se que na quase totalidade dos casos o inspetor super dimensionou o comprimento do defeito, uma vez que o valor medido ficou acima da reta. Constata-se também que a tendência de super dimensionamento é geral, isto é, todos os inspetores tenderam a super dimensionar o comprimento do defeito. Por exemplo, o inspetor 1 foi quem atribuiu maiores valores aos defeitos e isso ocorreu para todos os defeitos e para as duas classes. Em linhas gerais, é como se existisse um fator de segurança para cada inspetor. O que surpreende é que este fator de segurança é muito elevado, por exemplo, defeitos de 3mm, 5mm, 7mm e 10mm foram dimensionados com valores acima

de 20mm. Se por um lado isto é bom, porque está a favor da segurança, por outro lado pode causar, sem necessidade, a parada e a substituição de um trecho de duto.

No programa do ***PISC*** os inspetores também tenderam a super dimensionar o comprimento dos defeitos, enquanto no programa da ***ABENDE*** o comprimento do defeito foi sub-dimensionado.

Um ponto que todos os projetos desenvolvidos no mundo concordam, e também foi comprovado neste trabalho, é que o ensaio por ultra-som manual é um método incerto e, portanto necessita de melhorias para que possa aumentar a probabilidade de detecção e dessa forma garantir mais segurança nas inspeções. Apesar das várias modificações realizadas nos procedimentos de inspeção ao longo do tempo, dos bons programas para certificação de operadores e do rigor nos testes para qualificação de inspetores, medidas precisam ser tomadas para tentar eliminar erros absurdos como confundir sinal de defeitos de FP com sinal da raiz da solda, ou pior ainda, inspetores serem qualificados sem saber fazer uma inspeção. Infelizmente, baseado nos resultados obtidos neste trabalho e frente as várias evidencias observadas durante os ensaios como por exemplo, pressa para finalizar o serviço para conseguir outro contrato; cansaço devido longas horas de trabalho na tentativa de atender dois clientes simultaneamente e até falta de conhecimento teórico sobre a técnica, pode-se concluir que o principal vilão da inspeção ultra-sônica manual ainda continua sendo o operador.

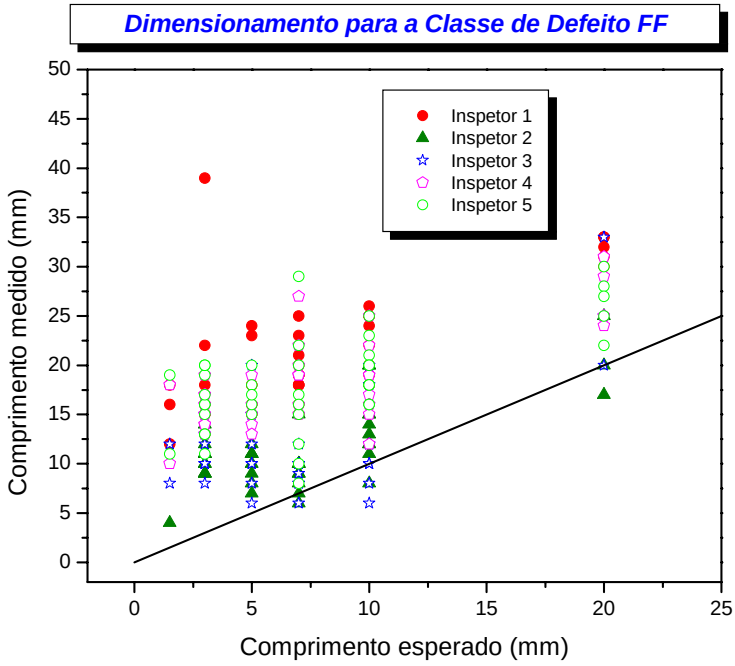

Figura IV.34. *Dimensionamento para a classe de defeito de FF.*

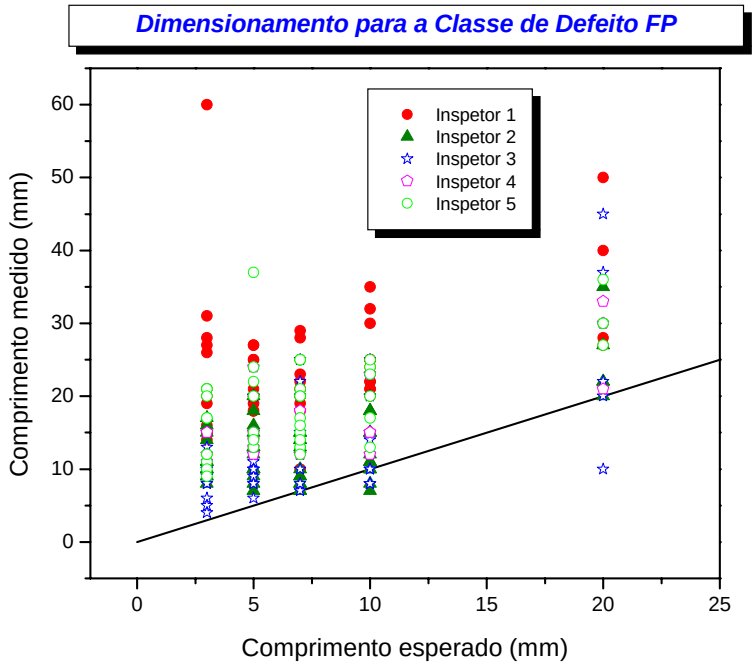

Figura IV.35. *Dimensionamento para a classe de defeito de FP.*

Vários outros estudos [147,150-152] têm mostrado que o fator humano continua sendo a causa da falha na detecção de descontinuidades e que mesmo operadores experientes e bem treinados cometem erros. Dessa forma a solução mais defendida para remover a influência do fator humano, e assim melhorar a capacidade de detecção e a confiabilidade no ensaio, é através da automação da inspeção. Para o ensaio ultra-sônico, por exemplo, a probabilidade de detecção de um sistema automatizado é muito maior do que o ultra-som manual.

No entanto, apesar das vantagens do ensaio ultra-sônico automatizado sobre o ultra-som manual, como pôde ser comprovado através de vários artigos citados e também por meio deste trabalho de tese, muitos autores tem constatado que na maioria das vezes o uso de ensaio automatizado não é economicamente viável [153,154]. Por exemplo, para pequenos comprimentos de soldas inspecionados, o que representa 70% dos casos práticos, a inspeção manual se torna muito mais econômica do que a automatizada. Pode ser levado em consideração ainda que mesmo sistemas automatizados requerem ajustes de operadores e interpretação humana [122,155]. Portanto, simplesmente substituir a inspeção manual talvez não seja a solução, e sim dispor de meios que melhorem o desempenho do inspetor, aumentando a confiabilidade na inspeção manual [153,156].

Deve ficar claro que quando se fala em custo de inspeção, este não é o custo direto pago por determinada técnica, deve ser levado em consideração a confiabilidade da técnica. Por exemplo, o custo de uma inspeção por uma técnica A pode ser 50% mais barato do que com uma técnica B, no entanto a probabilidade de detecção da técnica A, para determinada dimensão de defeito, pode ser somente 1/3 quando comparado com a técnica B. Dessa forma o valor final da técnica A pode ser superior ao da técnica B.

No presente trabalho se buscou trabalhar com defeitos que pudessem representar o limite mínimo de detecção, por isso que diferentemente da maioria dos trabalhos nesta linha de pesquisa foram inseridos defeitos com pequenas dimensões, com comprimento e profundidade de até 2mm. No entanto, o que se pôde constatar, através dos resultados obtidos, é que mesmo para essas dimensões de defeitos a probabilidade de detecção média se aproximou das PODs encontradas por muitos autores citados neste trabalho. A POD média para o defeito de FF foi de aproximadamente 63%, enquanto que para o defeito de FP foi de 77%. Entretanto, comparar PODs de diferentes trabalhos não faz muito sentido

uma vez que cada pesquisa tem suas particularidades, como por exemplo a técnica utilizada para inserir o defeito, o ambiente de inspeção, o nível de dificuldade exigido por cada instituição de qualificação onde o inspetor foi qualificado e principalmente o nível de satisfação do inspetor no país em que trabalha, entre muitas outras. Por esses motivos existe a necessidade de desenvolvimento de curvas PODs que sejam as mais representativas possíveis das condições reais que o inspetor irá encontrar no trabalho de campo.

Uma outra maneira de obter uma curva POD mais rápida e com um custo infinitamente inferior é através de simulação, a qual é utilizada em mais de 90% dos casos. No entanto, se na determinação da POD experimental já é difícil reproduzir as circunstâncias de uma inspeção real, a simulação é uma estimativa muito distante da realidade e que deve ser utilizada somente quando não se dispor de outra opção. Pois apesar da simulação conseguir modelar importantes variáveis relacionadas a inspeção e até mesmo algumas fontes de variabilidade, como ruído por exemplo, não é possível modelar a maior fonte de falhas na inspeção, como pôde ser constatado anteriormente, que é o fator humano [157].

IV.5. CURVAS POD UTILIZANDO SIMULAÇÃO

Conforme já discutido anteriormente, para o desenvolvimento de curvas PODs experimentalmente como foi realizado neste trabalho de tese, torna-se necessária a confecção de uma grande quantidade de corpos de prova com defeitos inseridos artificialmente durante a operação de soldagem, que sejam os mais representativos possíveis das condições encontradas em serviço. No entanto, geralmente para produzir um espaço amostral estatisticamente significante que simule adequadamente as condições prováveis de serem encontradas em aplicações reais, os ensaios podem exigir um conjunto muito grande de amostras que torne o processo inviável ou o custo da operação pode ser tão elevado que se torne impraticável. Por exemplo, segundo estudos da Força Aérea Americana (*MIL-HDBK-1823*) [27,158], seriam necessários corpos de prova com pelo menos 60 defeitos se o sistema produz um resultado *hit/miss* e no mínimo 40 se o sistema produz uma saída quantitativa $\hat{a}$, para um defeito de dimensão a. Sendo que estes defeitos devem ser distribuídas em uma faixa de dimensão apropriada e executadas por profissional

qualificado para tal função. No presente trabalho utilizou-se a técnica de *bootstrap* para replicar o conjunto original de dados e levar em conta a incerteza nos resultados devido ao tamanho finito de amostras. Porém, na maioria das vezes, a determinação de curvas PODs numéricas, por meio de simulação, torna-se a única alternativa viável.

Dessa forma, como alternativa ao método experimental é apresentado a seguir uma metodologia para desenvolvimento de curvas PODs utilizando Simulação Monte Carlo [110]. Através da Simulação Monte Carlo é possível definir um defeito de diâmetro "D" qualquer em um corpo de prova e para condições pré-definidas do ensaio determinar a probabilidade de detecção deste defeito através de condições geométricas, como será mostrado mais adiante. Neste trabalho esta metodologia foi desenvolvida para o ensaio de ultra-som automatizado.

Observa-se que a metodologia desenvolvida neste trabalho para a simulação da inspeção é somente o início de uma linha de pesquisa e que necessita de implementações para melhor modelar o feixe sônico e portanto tornar possível sua validação através de ensaios experimentais. Na abordagem utilizada neste trabalho foram feitas algumas considerações para simplificar o problema; dessa forma os resultados simulados não devem ser comparados com os resultados obtidos experimentalmente porque como foi dito anteriormente, o objetivo desta simulação é somente mostrar uma maneira alternativa de desenvolver as curvas PODs.

IV.5.1. Metodologia

A Figura IV.36 mostra o esquema de um corpo de prova contendo um cordão de solda o qual é inspecionado por um dispositivo com 4 transdutores. Cada transdutor se desloca na direção longitudinal ao cordão de solda ao longo de uma linha de varredura e irá sonificar uma certa área do mesmo. Por exemplo, o transdutor que se desloca sobre a linha de varredura 1 sonifica a raiz do cordão de solda. Para sonificar toda espessura "e" do cordão de solda devem ser utilizados vários transdutores simultaneamente ou realizar várias varreduras com apenas um transdutor com diferentes distâncias ao centro do cordão de solda, como foi realizado neste trabalho. Obviamente que o número de transdutores ou o número de varreduras a serem realizadas tem uma relação direta com a espessura "e" do

corpo de prova que está sendo ensaiado e o tamanho do defeito. Utilizando Simulação Monte Carlo é possível obter, para uma determinada espessura “e” e para uma dimensão de defeito determinada, o menor número de transdutores (ou varreduras) necessários para uma probabilidade de detecção desejada. Como estes sistemas são utilizados para inspeção em grande escala, a otimização do número de varreduras pode significar um ganho considerável no tempo de inspeção e, portanto, no custo da operação.

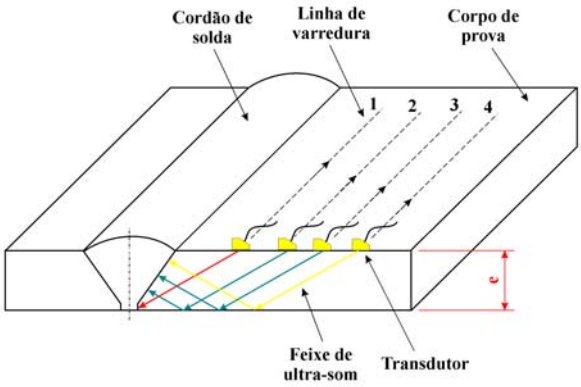

Figura IV.36. *Varredura por ultra-som.*

Para que toda a área inspecionada seja sonificada é necessário que a borda ou a superfície limite do feixe ultra-sônico de cada transdutor seja tangente à do seguinte para que se tenha uma cobertura total do cordão de solda pelo feixe ultra-sônico, conforme Figura IV.37. Na Figura IV.37 é mostrada uma vista de frente do corpo de prova de espessura “e” apresentado na Figura IV.36, que para facilitar o entendimento, ao invés de refletir o feixe de ultra-som na superfície inferior do corpo de prova rebateu-se o corpo de prova para baixo. Pode se constatar pela Figura IV.37 que para esta espessura e para um transdutor com a divergência de feixe apresentada, bastariam apenas 3 varreduras com distâncias d1, d2 e d3 para que todo o cordão de solda fosse sonificado pelos transdutores, considerando uma alta taxa de aquisição na direção longitudinal ao cordão de solda.

No entanto, é conhecido da teoria de ultra-som que o feixe ultra-sônico é divergente e não possui uma intensidade uniforme ao longo de toda sua abertura angular. Na região central do feixe sônico a sensibilidade, assim como a intensidade sônica é maior e à medida que se afasta do eixo central, em um mesmo plano, a sensibilidade diminui, conforme Figura IV.38. Portanto, isto significa dizer que se um defeito é sonificado pela parte central

do feixe o eco de reflexão terá uma amplitude elevada como resposta, enquanto que se ele for detectado com a borda do feixe a amplitude será menor, e dependendo da porção do feixe ultra-sônico que sobreponha o defeito a amplitude pode ficar tão baixa que possa vir a ser confundida com o ruído (Figura IV.39). Dessa forma a variável sobreposição do feixe ultra-sônico com o defeito é uma variável importante e que será considerada na Simulação Monte Carlo.

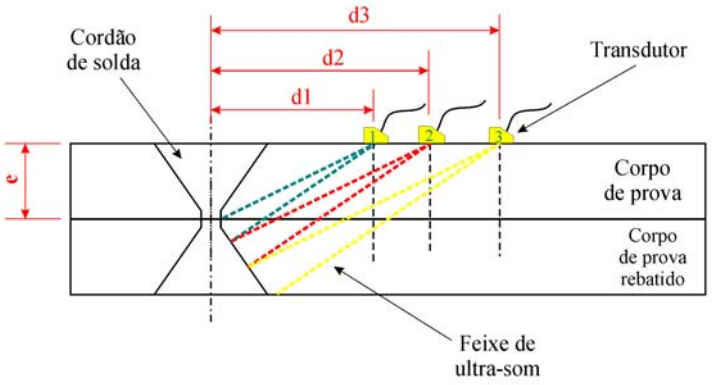

Figura IV.37. *Feixes de ultra-som incidido sobre o cordão de solda.*

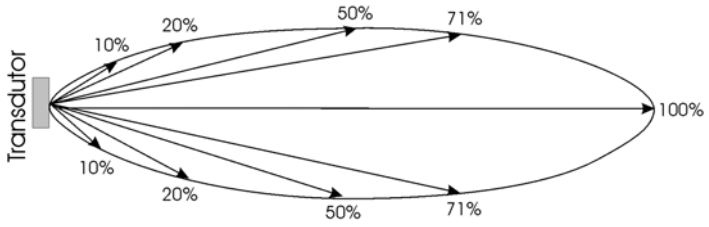

Figura IV.38. *Diagrama polar do feixe sônico.*

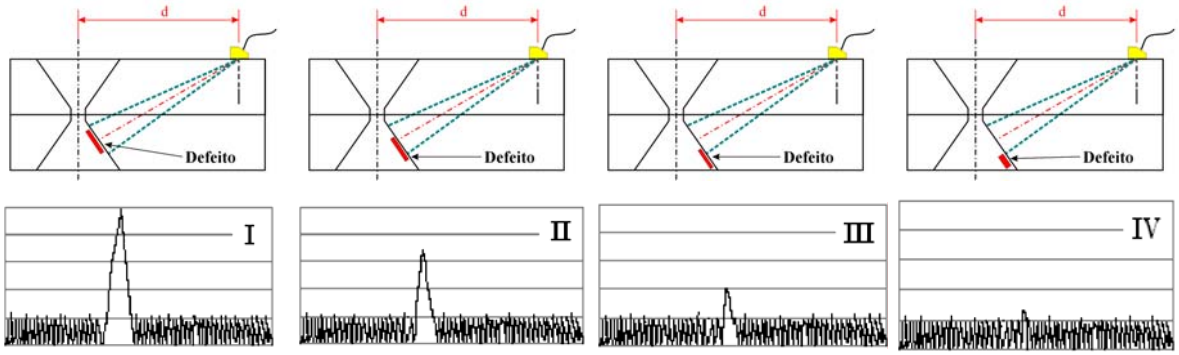

Figura IV.39. *Eco de um defeito para várias condições de detecção. (I) muito bom, (II) bom, (III) médio e (IV) ruim.*

De acordo com procedimentos de inspeção [45,108], para a avaliação das descontinuidades detectadas pelo ensaio de ultra-som, três curvas de referências devem ser traçadas: uma curva primária, correspondente à intensidade máxima obtido pelo feixe ultra-sônico incidente sobre uma descontinuidade de referência, uma curva secundária que corresponde a uma queda de 50% da curva primária e uma curva de 20% da curva primária (Figura IV.40). Baseado nestas 3 curvas pode-se definir um eco como sendo proveniente de um defeito ou de ruídos proveniente do sistema [45,108]. Por exemplo, se for definido como defeito todo eco que superar a curva de 20% é uma situação muito mais conservadora do que se for levado em consideração apenas os ecos que superem a curva de 50%.

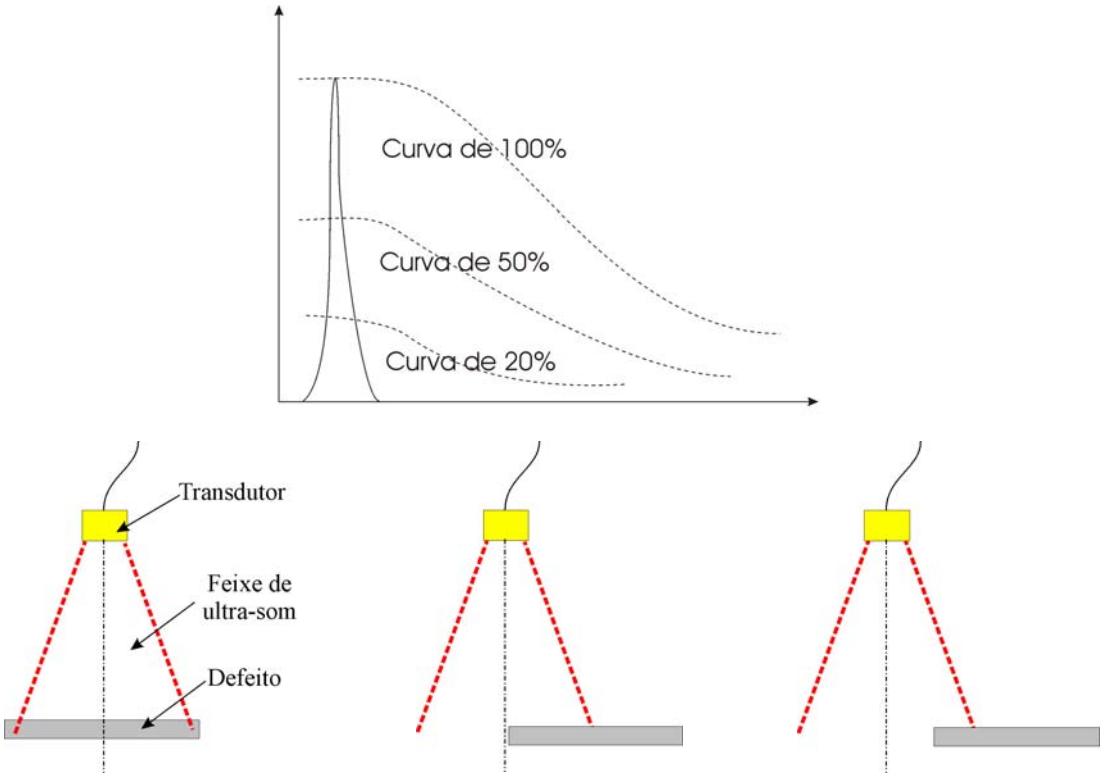

Figura IV.40. *Curvas de referência. (a) curva de 100%, (b) curva de 50% e (c) curva de 20%.*

IV.5.2. POD utilizando Simulação Monte Carlo

Baseado no que foi exposto anteriormente, a área do cordão de solda sonificada pelos transdutores pode ser representada por uma grade, conforme mostra a Figura IV.41, em que cada transdutor ou cada varredura é separada da seguinte pela distância “dt” e a distância entre duas aquisições consecutivas de sinais é “da”. Usando Simulação Monte Carlo um número N de corpos de prova, cada um contendo um defeito de diâmetro D, é gerado artificialmente. Analisando somente um quadrante (detalhe) da Figura IV.41 pode se observar que em cada vértice existe um feixe ultra-sônico, e um defeito de diâmetro D é gerado aleatoriamente em qualquer posição dentro desse quadrante. A detecção ocorre quando pelo menos um dos feixes ultra-sônicos sobrepõe o defeito e gera um eco que supera a curva de referência adotada, isto é, de 50% ou de 20%, conforme mostra a Figura IV.42. A probabilidade de detecção para o defeito de diâmetro “D” e para a malha de inspeção “dt” por “da” é dada aproximadamente pela razão do número de defeitos detectados pelo número total N de corpos de prova gerados, isto é, o número total de simulações.

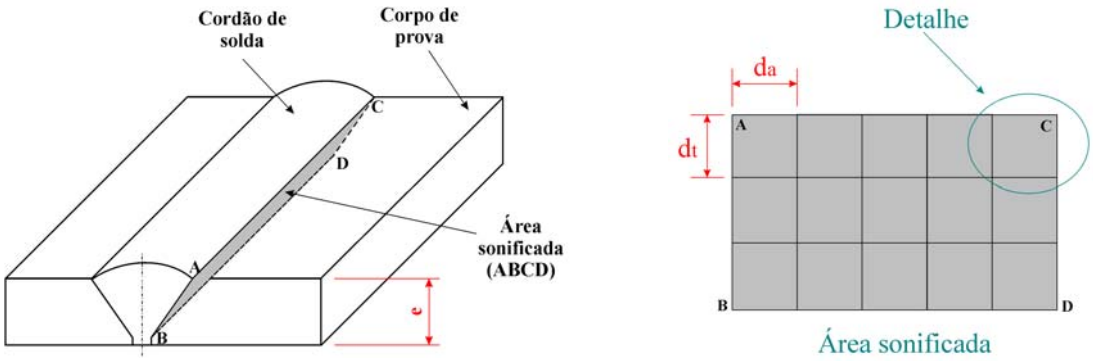

Detalhe

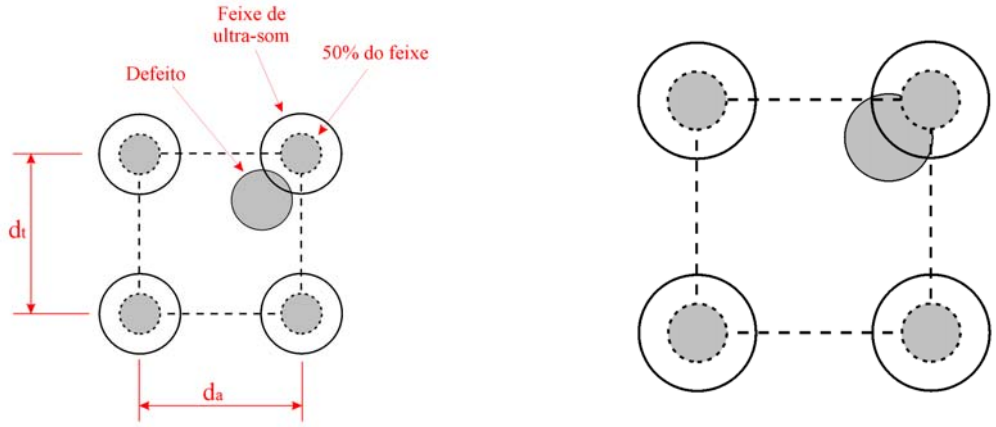

(a) Não detecção do defeito (b) Detecção do defeito

Figura IV.41. *Análise da detecção do defeito baseada na curva de referência de 50%.*

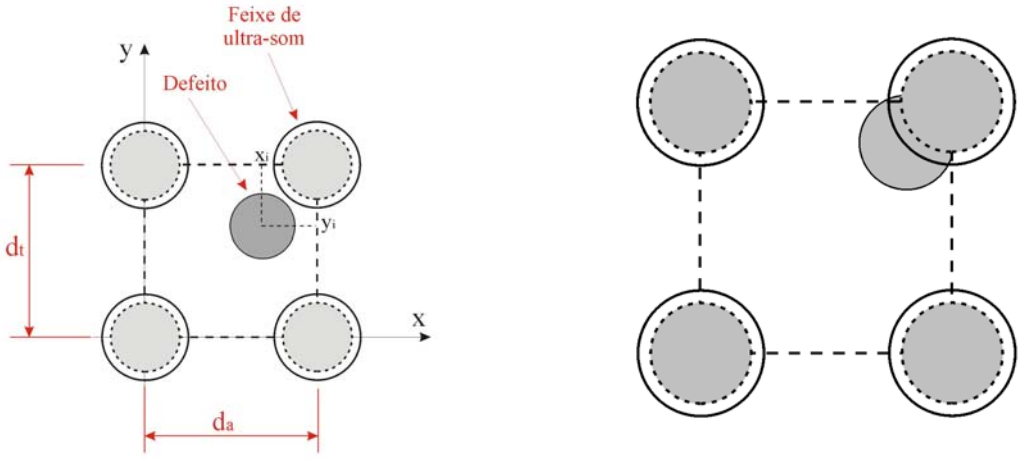

(a) Não detecção do defeito (b) Detecção do defeito

Figura IV.42. *Análise da detecção do defeito baseado na curva de 20%.*

Em termos matemáticos, a definição de POD, para um defeito de diâmetro “D”, através da Simulação Monte Carlo pode ser obtida por:

$$PoD(D) = E[I(x,y)] = \int_0^{da}\int_0^{dt} I(x,y)\, f_{x,y}(x,y)\,dxdy \qquad \textit{Eq. IV.4}$$

onde *X* e *Y* são variáveis aleatórias que definem geometricamente a posição do centro do defeito circular, *fx,y(x,y)* é a função densidade de probabilidade conjunta dessas duas variáveis aleatórias e *E[.]* é o valor esperado ou valor médio. Como o centro do defeito pode estar localizado em qualquer lugar dentro do retângulo, a função *fx,y(x,y)* é dada pelo produto de duas distribuições uniformes, uma para cada coordenada do ponto central, isto é:

$$f_{x,y}(x,y) = \frac{1}{da}\frac{1}{dt} \qquad \textit{Eq. IV.5}$$

O termo *I(x,y)* é a função indicadora, sendo igual a 1 se o defeito for detectado e 0 se não for detectado. Admite-se para efeito desta simulação que detecção ocorre quando existe pelo menos uma zona de sobreposição entre o defeito e o feixe ultra-sônico dos transdutores que gere um eco ou sinal igual ou superior a curva de referência adotada, conforme será explicado na seção seguinte. Os N corpos de prova (ou simulações) são gerados pela definição aleatória do centro do defeito *(x,y)* de acordo com a distribuição dada pela Equação IV.5 e então é verificado se ocorre ou não detecção para todos eles. Portanto, a Equação IV.4 pode ser escrita como:

$$PoD(D) = \sum_{i=1}^{N} \frac{I(x_i, y_i)}{N} \qquad \textit{Eq. IV.6}$$

O número N de simulações (corpos de prova artificiais) deve ser grande o suficiente para obter uma confiança razoável nos resultados simulados. De acordo com Ang et al [110], o erro percentual nos resultados dado pela Equação IV.6 com um nível de confiança 95% é dado por:

$$erro = 200\sqrt{\frac{1-PoD}{N.PoD}}(\%) \qquad \textit{Eq. IV.7}$$

Através da Equação IV.7 o número de simulações N pode ser determinado de forma a atender um desejado nível de erro.

IV.5.3. Análise da detecção do defeito

Para mostrar o principio da curva POD por meio de simulação numérica um modelo simples para a equação do feixe ultra-sônico foi desenvolvido, contudo um modelo mais sofisticado utilizando outras variáveis e equações mais robustas poderá também ser utilizado. Neste modelo foi considerado o efeito da divergência do feixe ultra-sônico, conforme já discutido anteriormente e mostrado na Figura IV.38, e o efeito da atenuação da energia sonora. Para implementar o modelo proposto foi considerado que a intensidade sonora diminui durante a propagação do feixe dentro do material devido principalmente à absorção e dispersão da onda em espalhadores do material [44].

Conforme já discutido anteriormente, a intensidade sônica no centro do feixe é máxima e à medida que se aproxima das bordas a mesma diminui. A intensidade sônica pode ser aproximada pela função de distribuição em forma de sino mostrada na Figura IV.43. Considera-se que a intensidade sônica é igual a "s_0" no centro do feixe e decai exponencialmente para zero nas bordas, conforme Figura IV.44. Dessa forma, pela Figura IV.44 pode-se observar que a medida que o centro do feixe ultra-sônico se afasta de um defeito o eco resultante da interação deste feixe com o mesmo será reduzido em decorrência da redução de intensidade sônica.

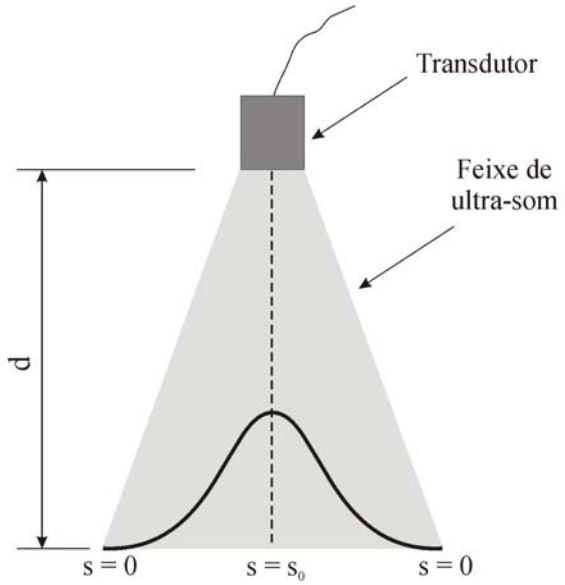

Figura IV.43. *Variação da intensidade sonora devido à divergência do feixe ultra-sônico.*

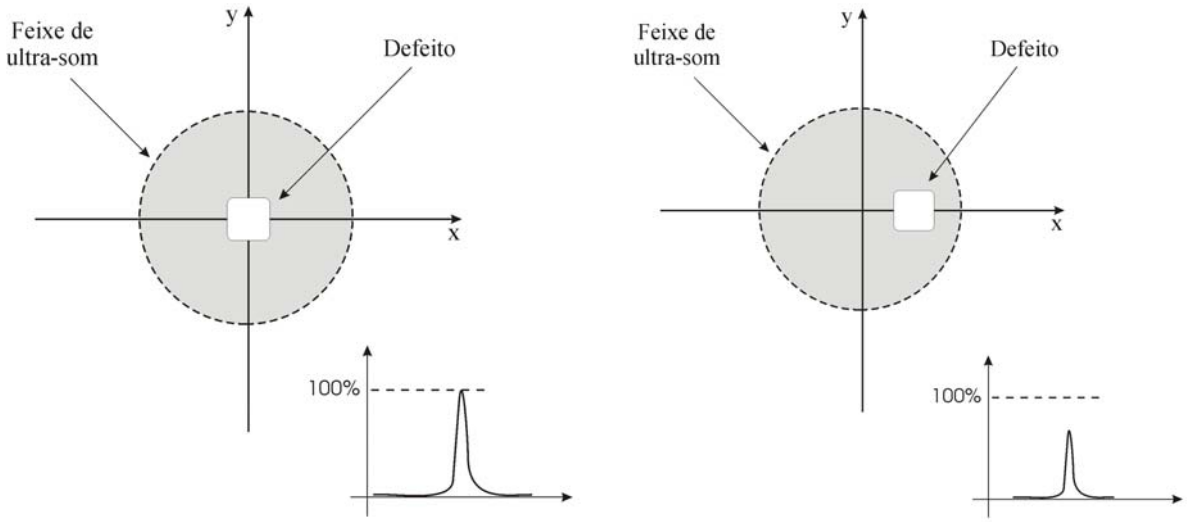

(a) (b)

Figura IV.44. *(a) A intensidade sônica refletida é máxima (igual a s_0), (b) A intensidade sônica refletida é menor do que s_0.*

O feixe ultra-sônico pode ser imaginado ainda como círculos concêntricos, conforme ilustrado na Figura IV.45, onde a intensidade sônica diminui do círculo mais interno para o mais externo.

Dessa forma a intensidade sônica incidente sobre um defeito na posição (i) da Figura IV.45 é máxima, a intensidade sônica incidente sobre este defeito agora na posição (ii) será inferior aquela incidente sobre o defeito na posição (i), enquanto que a intensidade incidente sobre este mesmo defeito na posição (iii) será menor ainda.

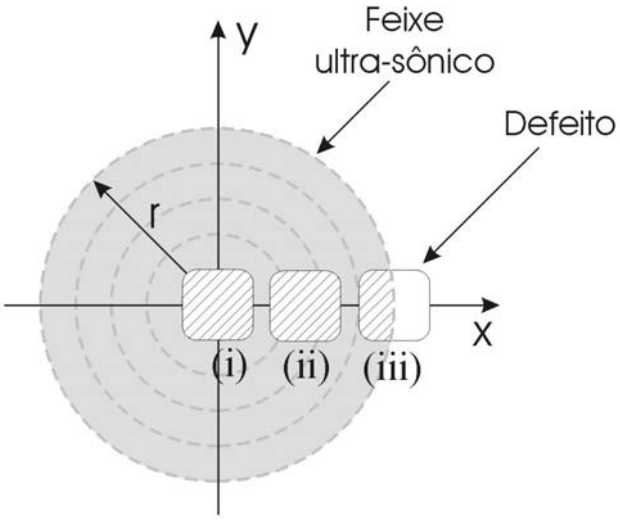

Figura IV.45. *Feixe ultra-sônico sobre defeitos em três posições diferentes. Onde a intensidade sônica* $s_{(ii)} < s_{(i)}$ *e* $s_{(iii)} < s_{(ii)}$.

Neste trabalho a distribuição da intensidade sônica referente à divergência (s) foi modelada pela Equação IV.8 a seguir, que descreve a equação da função em forma de sino apresentada na Figura IV.43.

$$s(x, y) = s_0 . \exp\left(- a\left(\sqrt{x^2 + y^2}\right)^b \right) \qquad \textit{Eq. IV.8}$$

sendo s_0 a intensidade sônica no centro do feixe e as constantes a e b determinadas a partir dos dados fornecidos pelos fabricantes dos transdutores utilizados.

Dessa forma a distribuição da intensidade sônica, numa distância "*d*" do transdutor, pode ser modelada por duas parcelas: uma devido à atenuação e outra devido à divergência do feixe ultra-sônico, conforme a seguinte equação:

$$s_d(x, y, d) = e^{-\alpha.d}.s_0.k(d).\exp\left(-a\left(\sqrt{x^2 + y^2}\right)^b\right) \qquad \textit{Eq. IV.9}$$

onde,

$s_d(x,y,d)$ = intensidade sônica incidente em um ponto (x,y) a uma distância d do transdutor;
α = coeficiente de atenuação do material;
d = distância entre o transdutor e o ponto de interesse;
$k(d)$ = fator para manter constante a intensidade sônica total em qualquer profundidade de um material ideal ($\alpha = 0$) levando em conta a variação da abertura do feixe.

Observa-se, então, que a intensidade sônica incidente sobre um defeito dentro do material é dependente da distância deste defeito ao transdutor. A intensidade sônica total incidente sobre dois defeitos de mesma dimensão nas posições A e B da Figura IV. 46 é maior para o defeito na posição A em função da maior concentração de energia sônica naquela distância, uma vez que a área do defeito é a mesma.

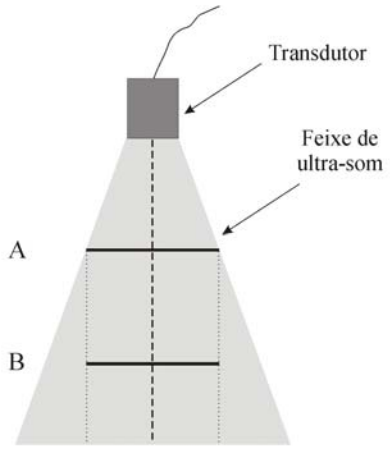

Figura IV.46. *Intensidade sonora incidindo sobre um defeito de mesma dimensão nas posições A e B do feixe sônico.*

Portanto, em função do que foi exposto anteriormente, no ensaio ultra-sônico, para determinar se ocorreu ou não detecção do defeito é traçada, inicialmente, uma curva de referência primária baseada em um bloco padrão contendo um mesmo defeito de calibração ($\varnothing_c$) em diferentes profundidades conforme mostra a Figura IV.47.

Com o feixe ultra-sônico situado no ponto de máxima reflexão de um defeito localizado na altura "d_1" do bloco padrão é determinada a intensidade sonora "s_1". Utilizando o mesmo procedimento são obtidas as intensidades sonoras "s_2" e "s_3" para as alturas "d_2" e "d_3", respectivamente. Baseado no valor destas três intensidades é possível traçar a curva de referencia primária (100%), conforme Figura IV.48, assim como também outras curvas secundárias, normalizando as intensidades com relação a "s_1" (ex.: curva de 50% da curva primária).

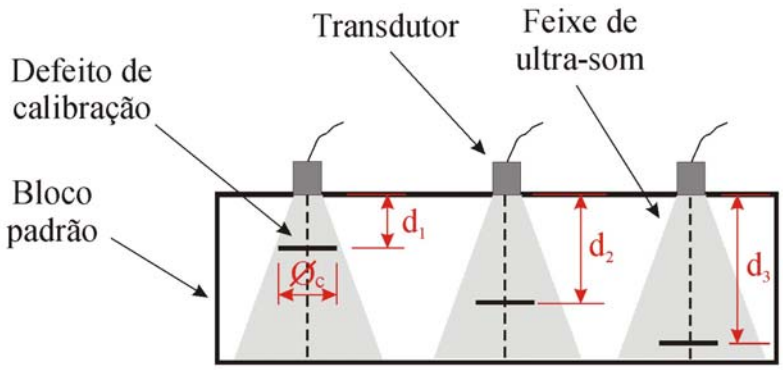

Figura IV.47. *Bloco padrão para traçar a curva de referência.*

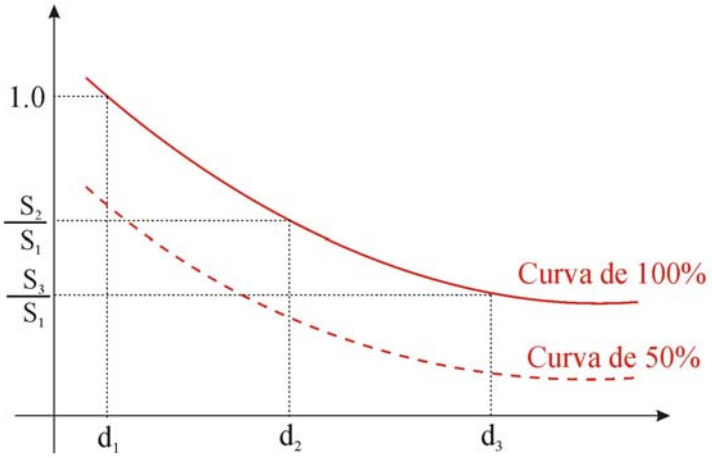

Figura IV.48. *Curva de referência para o defeito de calibração.*

Do ponto de vista numérico a mesma curva pode ser obtida integrando-se a distribuição de intensidade sônica sobre a área do defeito, isto é,

$$S_i = \iint_{\sqrt{x^2+y^2} \le \frac{\phi c}{2}} e^{-\alpha . d_i} . S_o . k(d_i) . \exp\left(- a\left(\sqrt{x^2 + y^2}\right)^b\right) dxdy \qquad \textit{Eq. IV.10}$$

Uma vez determinada a curva de calibração, será realizada a detecção do defeito de interesse. Para um defeito de diâmetro "∅" na posição "d", conforme Figura IV.49, a intensidade sônica total observada no ensaio depende da posição do feixe ultra-sônico com relação ao defeito. O valor medido é comparado ao valor da curva de referência na distância "d". Se o valor medido for maior do que o valor da curva, o defeito é detectado.

Numericamente a intensidade sônica total para esta nova situação é calculada por:

$$S_\phi = \iint_A e^{-\alpha . d} . S_o . k(d) . \exp\left(- a\left(\sqrt{x^2 + y^2}\right)^b\right) dxdy \qquad \textit{Eq. IV.11}$$

onde "A" é a área do defeito sonificada pelo feixe ultra-sônico, conforme pode ser observado na Figura IV.49.

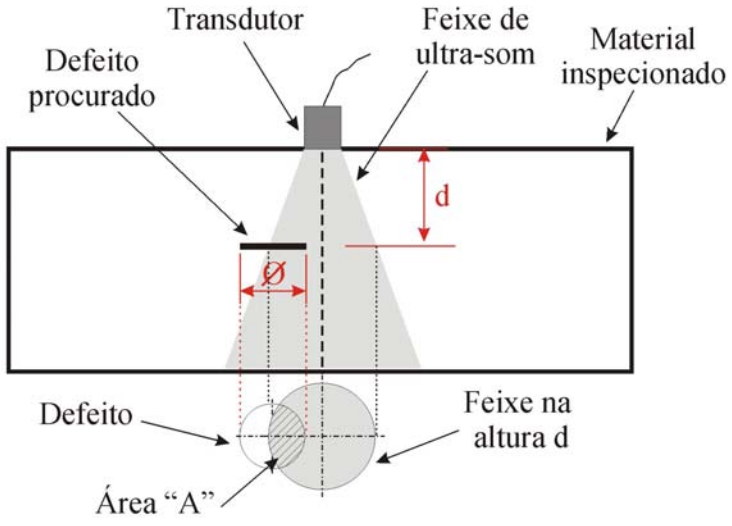

Figura IV.49. *Interação do feixe sônico com o defeito.*

A normalização deste resultado em relação ao defeito de calibração (∅c) na posição "*d*" é dado por:

$$R = \frac{S_{\phi}}{S_{\phi c}} \qquad \textit{Eq. IV.12}$$

onde,

$$S_{\phi c} = \iint_{\sqrt{x^2+y^2} \le \frac{\phi c}{2}} e^{-\alpha . d} . S_o . k(d) . \exp\left(- a\left(\sqrt{x^2 + y^2}\right)^b\right) dxdy \qquad \textit{Eq. IV.13}$$

o que resulta em:

$$R = \frac{\iint_A \exp\left(- a\left(\sqrt{x^2 + y^2}\right)^b\right) dxdy}{\iint_{\sqrt{x^2+y^2} \le \frac{\phi c}{2}} \exp\left(- a\left(\sqrt{x^2 + y^2}\right)^b\right) dxdy} \qquad \textit{Eq. IV.14}$$

portanto, se $R \geq R_{curva}$, o defeito é detectado, onde R_{curva} é o valor correspondente a curva de referência utilizada, isto é, R_{curva} = 1 para a curva de referencia de 100%, e assim por diante. Observa-se que com a simplificação *R* independe de s_0 e de *k(d)*.

IV.5.4. Exemplos de resultados numéricos

Utilizando esta metodologia foram simuladas curvas PODs, para uma chapa plana, para diversas distâncias entre transdutores e para diversos diâmetros de defeitos e os resultados dessas simulações são mostrados na Figura IV.50. Nesta figura constata-se que a medida que aumenta a distância entre transdutores a probabilidade de detecção diminui. Inversamente, a medida que o diâmetro do defeito é aumentado, a probabilidade de detecção aumenta. Para todas as curvas foi definido como defeito somente os ecos que superassem a curva de 50% da curva primária.

Na Figura IV.51 a curva POD foi simulada para duas condições de ensaio, primeiro foi levado em consideração que qualquer eco que superasse a curva de 20% era um defeito. Em uma segunda etapa considerou-se como defeitos os ecos que superassem a curva de 50%. Através desta figura constata-se que a curva de 20% apresenta uma POD maior do que a curva de 50%, o que vem comprovar o que tinha sido discutido anteriormente, isto é, a curva de 20% é mais conservadora, portanto, ecos com baixas amplitudes poderão ser considerados como defeitos.

Na Figura IV.52 o procedimento foi avaliado para duas profundidades diferentes do defeito com relação ao transdutor, ou seja, o procedimento foi testado para detecção a uma distância de 25mm da superfície e a 50mm, utilizando os mesmos parâmetros. Observa-se pela figura que a probabilidade de detecção é maior para uma distância de 50mm, e isto se deve ao fato do feixe ultra-sônico ser divergente e, portanto, ter uma abertura maior nesta profundidade.

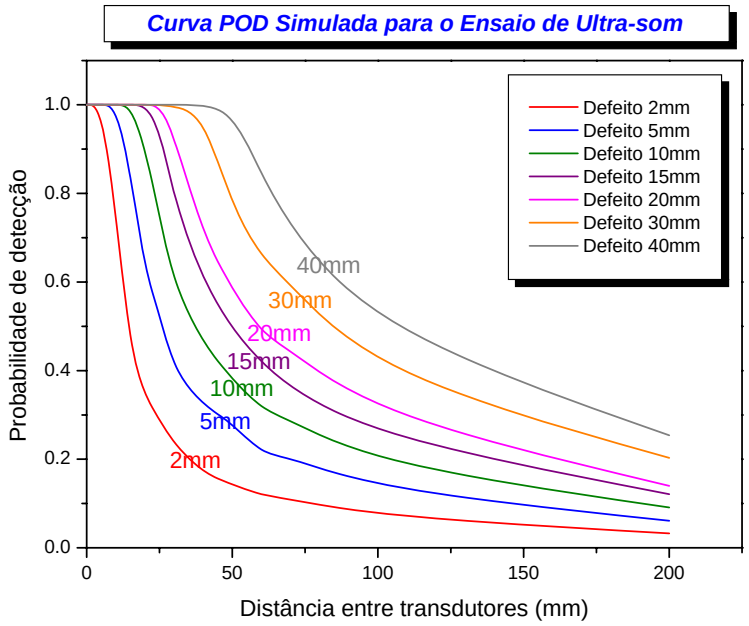

Figura IV.50. *POD simulada para o ensaio de ultra-som.*

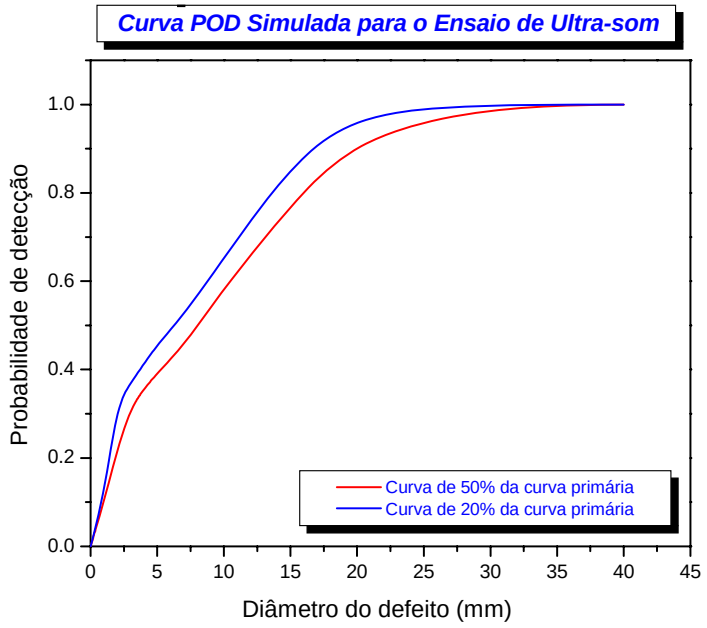

Figura IV.51. *POD simulada para o ensaio de ultra-som.*

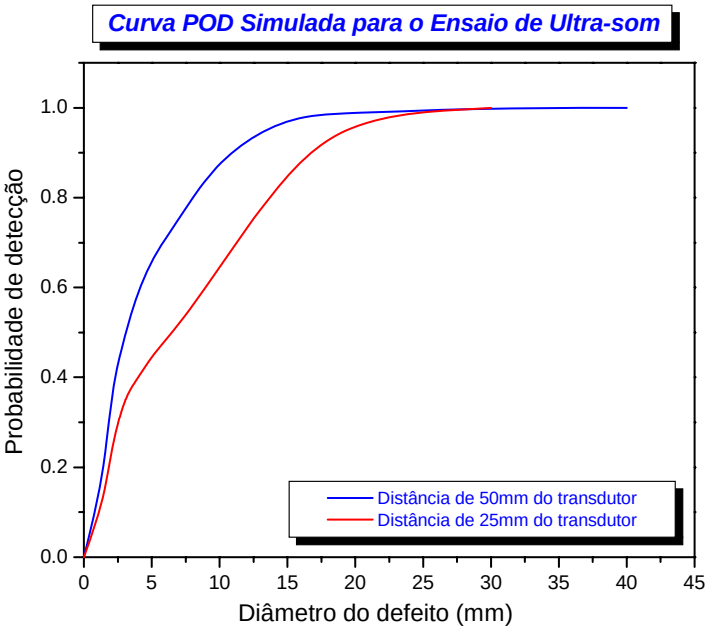

Figura IV.52. *POD simulada para o ensaio de ultra-som.*

IV.5.5. Considerações finais

Um aspecto ainda não levado em conta na simulação numérica proposta se deve ao fato de que quanto maior a profundidade, mais atenuada será a intensidade sônica e portanto, os ecos podem ser confundidos com ruídos do sinal.

Na simulação proposta a detecção do defeito foi realizada levando em consideração curvas de intensidade. No entanto, geralmente, na inspeção real o inspetor se baseia em curvas de amplitude (medida em dB) para decidir se a indicação é ou não defeito.

Pode-se concluir ainda que por mais que se tente aproximar a inspeção real por uma simulação, dificilmente será obtido o mesmo resultado, uma vez que existem variáveis que são impossíveis de serem quantificadas, como por exemplo, o desempenho do operador, pois existem vários fatores que podem influenciar neste desempenho e qualquer aproximação seria somente uma simples estimativa. Em MORÉ [100] estão descritos 59 atributos que podem influenciar no desempenho do inspetor de ultra-som, que podem variar desde características ambientais como iluminação e temperatura até fatores psicológicos como estado emocional do inspetor.

CAPÍTULO V

CONCLUSÕES

Baseado no estudo de reconhecimento de padrões de sinais de MFL de defeitos em soldas, por redes neurais artificiais, obtidos a partir de ensaio de pig instrumentado em dutos de aço API 5L-X65 com diâmetro nominal de 304,8mm e espessura de parede de 7,137mm e também nas curvas PODs desenvolvidas a partir de ensaios de ultra-som manual e automatizado em soldas circunferenciais de dutos de aço API X70 com diâmetro de 254mm e espessura de parede 19,05mm, pode-se concluir que:

- É possível classificar sinais de MFL com defeitos e sem defeitos utilizando redes neurais com taxa média de acerto entre 94,2% e 100%.

- É possível classificar sinais de MFL de corrosão e de falta de penetração via redes neurais com taxa média de acerto acima de 90% mesmo para sinais de corpos de prova que não foram utilizados no treinamento da rede.

- Discriminar sinais de MFL de corrosão externa de sinais de corrosão interna por redes neurais artificiais apresentou uma certa confusão pela rede, uma vez que os sinais são muito similares.

- Um pré processamento aplicado aos sinais antes de serem fornecidos como entradas da rede neural, na tentativa de reduzir ruídos presentes, não melhorou o índice de acerto da rede neural.

- O ensaio ultra-sônico por pulso-eco e por TOFD automatizado possui uma alta detecção de defeitos (100%) tanto para a classe de defeito de falta de penetração quanto para a classe de falta de fusão. Enquanto o ensaio por ultra-som manual alcançou 77% para a classe de falta de penetração e 63% para a classe de falta de fusão.

- Para o ensaio ultra-sônico pulso-eco manual foi constatada uma grande dispersão dos resultados dos inspetores para a classe de defeito de falta de penetração.

- Para o ensaio ultra-sônico pulso-eco manual alguns inspetores confundiram defeitos de falta de penetração com o eco da raiz da solda.

- A grande fonte de incertezas na inspeção ultra-sônica pulso-eco manual está relacionada ao operador.

- É possível obter curva POD através de simulação numérica quando não se dispõem de dados experimentais para desenvolvimento de curvas reais.

Trabalhos Futuros

Como propostas para trabalhos futuros podem ser citadas:

- Realizar o estudo de reconhecimento de padrões de sinais de MFL com dados reais de campo.

- Ampliar o estudo de reconhecimento de padrões de sinais de MFL para outras classes de defeitos e para o pig ultra-sônico.

- Realizar a validação da simulação numérica através de ensaios experimentais com corpos de prova fabricados em laboratório.

- Melhorar o modelo numérico utilizando outras equações para o feixe ultra-sônico e incluindo outras variáveis que influenciam na inspeção.

CAPÍTULO VI

REFERÊNCIAS BIBLIOGRÁFICAS

[1] BAI, Y., "Pipelines and Risers", Elsevier Ocean Engineering Series Editors, USA, Vol. 3, 2001.

[2] CAMERINI, C. S., SILVA, J. A., JANVROT, I. V., et al., "Desenvolvimento de PIG MFL de Alta Resolução", *Rio Pipeline – Conference & Exposition*, Rio de Janeiro, Outubro de 2003.

[3] BEUREN, J., MAC-CULLOCH, J. N. L. M., QUADRADO, F. E., "Vantagens e Desvantagens do Uso de PIG Instrumentado Quantitativo e PIG Instrumentado Qualitativo na Inspeção de Dutos da UN-BSOL", *7º COTEQ - Conferencia Sobre Tecnologia de Equipamentos*, Florianópolis, Setembro de 2003.

[4] CORDELL, J., VANZANT, H., "All About Pigging", On-Stream Systems Limited and Hershel Vanzant & Associates, USA, 3ª Ed., 2000.

[5] PAYNE, L. D., "The Importance of A Clean Pipeline", *Pipeline & Gas Journal*, March 2002, pp. 69-71.

[6] FISHER, H., "On-Stream Pigging For Corrosion", *Pipeline & Gas Journal*, March 2002, pp. 37.

[7] http://www.piggingassnppsa.com

[8] PAYNE, L. D., "Corrosion Inspection Is The Most Common Reason For Cleaning Pipelines Today", *Pipeline & Gas Journal*, June 2002, pp. 52-54.

[9] TIRATSOO, J. N. H., "Pipeline Pigging Technology", Gulf Publishing Company, 2ª Ed., 1992.

[10] ZHUKOVA, G. A., "Defectoscopy of the Mains Gas Pipelines to Defect the Presence of the Stress Corrosion of the Pipeline Wall", *15th WCNDT - World Conference on Nondestructive Testing*, Roma, October, 2000.

[11] CAMERINI, D. A., VON DER WEID, J. P., CAMERINI, C. S., et al., "Pig Detector de Vazamentos em Oleodutos", *Rio Pipeline – Conference & Exposition*, Rio de Janeiro, Outubro de 2003.

[12] SOUZA, C. E. M., OLIVEIRA, C. H. F., CAMERINI, D. A., et al., "Pig Para Detecção de Vazamentos – Desenvolvimento e Teste de Campo", *7º COTEQ - Conferencia Sobre Tecnologia de Equipamentos*, Florianópolis, Setembro de 2003.

[13] LINO, A. C. F., PEREIRA, F. B., GOMES, M. G. F. M., "Manual de Utilização de Pig", CENPES/DIPREX/SESUB, 1995.

[14] VABO, F., SILVA, G. C., "Pig's", Apostila do Curso de Inspetor de Dutos, SENAI, Rio de Janeiro, novembro de 2003.

[15] http://www.tdwilliamson.com

[16] KERSHAW, R., "Innovative Pigging Solutions For Pipelines", *Pipeline & Gas Journal*, August 2002, pp. 56-57.

[17] "Pigging: Increasing Appreciation Of an Industry Truly Come Of Age", 2002 PPSA Special Section *Pipeline & Gas Journal*, August 2002, pp. 48-51.

[18] MORENO, P., LAUER, G., "The Synergy of Combined Technologies: The Most Comprehensive Method of Pipeline Integrity Evaluation", disponível na internet: http://www.tuboscope-pipeline.com/

[19] PORTER, T. R., PARSONS, J., MARTIN, M., "Pipeline Integrity: Enhanced Decision Support With GIS", disponível na internet: http://www.tuboscope-pipeline.com/

[20] http://www.tuboscope-pipeline.com

[21] SILVA, J. A. P., PINHO, A. F., et al., "Ferramenta para Inspeção Geométrica de Dutos de 3pol", 3rd *Seminar on Pipeline*, Rio de Janeiro, Novembro de 2001.

[22] http://www.roseninspection.net

[23] LEIS, B. N., BUBENIK, T. A., NESTLEROTH., et al., "Developments in Detecting and Assessing The Severity of Mechanical Damage", *Pipeline Rehabilitation & Maintenance Conference*, Prague, 2000.

[24] PANETTA, P. D., DIAZ, A. A., PAPPAS, R. A., et al., "Mechanical Damage Characterization in Pipelines", disponível na internet: http://www.netl.doe.gov/scng/publications/

[25] JÚNIOR, J. A., ADAMOWSKI, J. C., TSUZUKI, M. S. G., et al., "Autonomous System for Oil Pipelines Inspection", *Mechatronics*, Nº 9, 1999, pp. 731-743.

[26] UZELAC, N. I., REBER, K., BELLER, M., et al., "Ultrasonic In-Line Inspection of Pipelines, New Generation of Tools", *Rio Pipeline – Conference & Exposition*, Rio de Janeiro, Outubro de 2003.

[27] Nondestructive Evaluation and Quality Control, *ASM Handbook*, 3ª. edição, Vol. 17, 1994.

[28] JILES, D. C., “Review Of Magnetic Methods For Nondestructive Evaluation”, *NDT International*, Vol. 21, N^{o} 5, October 1988.

[29] http://www.battelle.org/pipetechnology

[30] “Technology Status Assessment for Circumferential MFL for SCC”, Final Report on RESEARCH PROGRAM PR-3-9420 on "Evaluation of Circumferential Magnetic Flux Leakage for In-Line Detection of Stress Corrosion Cracks and Selective Seam Weld Corrosion" to NDT SUPERVISORY COMMITTEE PRC INTERNATIONAL, December 1999, Disponível na internet: http://www.netl.doe.gov/scng/

[31] American Society for Nondestructive Testing, *Nondestructive Testing Handbook*, 2$^{a.}$ Edição, Vol. 4, 1986.

[32] JILES, D. C., “Review Of Magnetic Methods For Nondestructive Evaluation (Part 2)”, *NDT International*, Vol. 23, N^{o} 2, April 1990.

[33] http://www.mfescan.com/mfl.htm

[34] LIJIAN, Y., HAIYING, F., YUMEI, W., “Research on Intelligent Pipeline Magnetic Flux Leakage Detector”, *10TH APCNDT – 10th Asia-Pacific Conference on Non-Destructive Testing*, Brisbane, September, 2001.

[35] GLADCHTEIN, R. S., “Solução do Problema Inverso Magnetostático Utilizando Elementos Finitos e Técnicas de Otimização”, Tese de D. Sc., PUC, Rio de Janeiro, 2002.

[36] ATHERTON, D. L., “Stress-Shadow Magnetic Inspection Technique for Far-Side Anomalies in Steel Pipe”, *NDT International*, Vol. 16, N^{o} 3, June 1983.

[37] FORSTER, R., “New Findings in the Field of Non-Destructive Magnetic Leakage Field Inspection”, *NDT International*, Vol. 19, N^{o} 1, February 1986.

[38] CALIXTO, M. F. L., "Detecção e Classificação de Acidentes Geográficos em Tubulações Por Inspeção Eletromagnética Com Pigs Inteligentes", Tese de M. Sc., COPPE/UFRJ, Rio de Janeiro, 1999.

[39] LUNIN, V., BARAT, V., PODOBEDOV, D., "Neural Network-Based Crack Parameterization Using Wavelet Preprocessing MFL Signal", *Quantitative Nondestructive Evaluation*, Vol. 20, 2001, pp. 641-648.

[40] SUTHERLAND, J., PAZ, H., "Advances in In-Line Inspection Technology for Pipeline Integrity", *V Annual International Pipeline Congress*, October 2000, Morelia.

[41] HWANG, K., MANDAYAM, S., UPDA, S. S., et al., "Characterization of Gas Pipeline Inspection Signals Using Wavelet Basis Function Neural Networks", *NDT & E International*, Vol. 33, 2000, pp. 531-545.

[42] AFZAL, M., UDPA, S., "Advanced Signal Processing of Magnetic Flux Leakage Data Obtained From Seamless Gas Pipeline", *NDT & E International*, Vol. 35, 2002, pp. 449-457.

[43] DOBMANN, G., WALL, G., HOLLER, P., "Magnetic Leakage Flux Testing With Probes: Physical Principles and Restrictions For Application", *NDT International*, Vol. 20, N^{o} 2, April 1987.

[44] Associação Brasileira de Ensaios Não Destrutivos. "Ensaio Não Destrutivo Ultra-som", São Paulo.

[45] SANTIN, J.L., "Ultra-som Técnica e Aplicação", 1^{a} Edição, Rio de Janeiro, Editora Qualitymark, 1996.

[46] http://www.ndt-ed.org

[47] http://www.americanpiezo.com

[48] http://www.signal-processing.com

[49] NEPOMUCENO, L. X., "Tecnologia ultra-sônica", 1ª edição, São Paulo, Editora Edgard Blücher, 1980.

[50] SILK, M.G., LIDINGTON, B.H., "Defect sizing using an Ultrasonic Time Delay Approach", *British Journal of NDT*, pp. 33-36, March, 1975.

[51] SILVA, I. C., "Avaliação da Técnica do Tempo de Percurso da Onda Difratada no Dimensionamento de Descontinuidades". Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, 1999.

[52] SILVA, S.G., "Técnica Ultra-Sônica do Tempo de Percurso da Onda Difratada na Detecção e Dimensionamento de Descontinuidades em Cordões de Solda de Aço", Tese de M. Sc., COPPE/UFRJ, Rio de Janeiro, 2000.

[53] CARVALHO, A. A., Detecção de Descontinuidades pela Técnica Ultra-sônica Pulso-eco Utilizando Um Sistema Multicanal. Tese de M. Sc., COPPE/UFRJ, Rio de Janeiro, 2002.

[54] OGILVY, J. A., "Model for Predicting Ultrasonic Pulse-echo Probability of Detection", *NDT & E International*, Vol. 26, N° 1, pp. 19-29, 1993.

[55] American Society for Nondestructive Testing, *Nondestructive Testing Handbook*, 2ª. Edição, Vol. 7, 1991.

[56] LAMY, C. A., "Um Estudo Sobre o Dimensionamento de Descontinuidades Superficiais Pela Técnica Ultra-sônica do Tempo de Percurso", Tese de D. Sc., COPPE/UFRJ, Rio de Janeiro, 1990.

[57]. SILK, M. G., “Change in Ultrasonic Defect Location and Sizing”, *NDT International*, Vol. 20, N°1, pp. 9-14, February, 1987.

[58] VEIGA, J. L. B. C., “Aplicação de Redes Neurais Artificiais na Classificação de Sinais Ultra-sônicos Pelas Técnicas Pulso-eco e TOFD”, Projeto Final do Curso de Engenharia Mecânica, Escola de Engenharia/UFRJ, Rio de Janeiro, 2002.

[59] AGTHOVEN, R. V., RAAD, J. A., “Reliability of Mechanised UT Systems to Inspect Girth Welds During Pipeline Construction”, *NDT.net*, Vol. 3, N^{o}. 11, November 1998.

[60] GINZEL, E., HOFF, M., “Further Developments in Ultrasonic Inspection of Pipeline Girth Welds”, *NDT.net*, Vol. 1, N^{o}. 06, June 1996.

[61] GINZEL, E., BOER, P., HOFF, M., “Application of Mechanized Ultrasonic Inspection to Manually Welded Pipeline Girth Welds”, *NDT.net*, Vol. 2, N^{o}. 05, May 1997.

[62] RAAD, J. A., DIJKSTRA, F. H., “Mechanised Utrasonic on Girth Welds During Pipeline Construction”, *NDT.net*, Vol. 3, N^{o}. 11, November 1998.

[63] 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.

[64] SILK, M. G., “Sizing Crack-like Defect by Ultrasonic Means”, *In Research Techniques in Nondestructive Testing*, vol. 3, Academic Press, pp. 51 - 79, 1977.

[65] TEMPLE, J. A . G., “Theoretical Work in Reation to Reliability: Time-of-Flight Difraction”, *Non-Destructive Examination for Pressurised Components*, ed. Elsevier Applied Science Publishers, pp 279-304, 1984.

[66] MOURA, E. P., “Reconhecimento De Padrões De Defeitos De Soldagem Em Sinais Ultra-sônicos Obtidos Pela Técnica *TOFD* Utilizando Redes Neurais Artificiais”, Tese de D. Sc. COPPE/UFRJ, Rio de Janeiro, 2003.

[67] HAYKIN, S., “Neural Networks, A Comprehensive Foundation”, Macmillian College Publishing. Inc.,1994.

[68] CARVALHO, A. A., VEIGA, J. L. B. C., SILVA, I. C., et al., “Preliminary Study of Classification of Defects by Ultrasonic Pulse-echo Using an Artificial Neural Network”, *Insight*, Vol. 45, N°. 11, pp. 754-757, 2003

[69] CARVALHO, A. A., SUITA, R. C. S. B., SILVA, R. R., et al., “Evaluation of the Relevant Features of Welding Defects in Radiographic Inspection”, *Materials Research*, Vol. 6, N° 3, pp. 427-432, 2003.

[70] MASNATA, A., SUNSERI, M., “Neural Network Classification of Flaws Detected by Ultrasonic Means”, *NDT & E International*, Vol. 29, N° 2, pp. 87-93, 1996.

[71] SIQUEIRA, M. H. S., “Inspeção Em Grandes Distâncias Utilizando Ondas Ultra-Sônicas Guiadas E Inteligência Artificial”, Tese de D. Sc., COPPE/UFRJ, Rio de Janeiro, 2002.

[72] SILVA, R. R., “Reconhecimento de Padrões de Defeitos de Soldagem em Radiografias Industriais”, Tese de D. Sc., COPPE/UFRJ, Rio de Janeiro, 2003.

[73] 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.

[74] SANTOS, J. B., PERDIGÃO, F., “Automatic Defects Classification – A Contribution”, *NDT & E International*, Vol. 34, N°. 5, pp. 313-318, 2001.

[75] OBAIDAT, M. S., SUHAIL, M. A., SADOUN, B., “An Intelligent Simulation Methodology to Characterize Defects in Materials”, *Information Sciences*, Vol. 137, pp. 33-41, 2001.

[76] VEIGA, J. L. B. C., CARVALHO, A. A., SILVA, I. C., et al., “Utilização De Técnicas Computacionais Para Automação da Inspeção Ultra-sônica Pela Técnica *TOFD*”, *CREEM*, 2002.

[77] VEIGA, J. L. B. C., CARVALHO, A. A., SILVA, I. C., et al., “Automação Da Análise Do Ensaio Ultra-sônico Pulso-eco Utilizando Redes Neurais Artificiais”, *3ª PANNDT - Conferência Pan-americana de Ensaios Não Destrutivos*, Rio de Janeiro, Brasil, Junho, 2003.

[78] WASSERMAN, P. D., “Neural Computing Theory and Practice”, New York, Nostrand Reinthold, 1989.

[79] BRAGA, A. P., CARVALHO, A. P. L. F., LUDERMIR, T. B., “Rede Neurais Artificiais: Teoria e Aplicações”, Editora Livros Técnicos e Científicos, Rio de Janeiro, 2000.

[80] KOVÁCS, Z. L., “Redes Neurais Artificiais: Fundamentos e Aplicações”, 2° edição, Edição Acadêmica, São Paulo, 1996.

[81] HERTZ, J., Krogh, A., Palmer, R.G., “Introduction to the Theory of Neural Computation”. Addison-Wesley Publishing Company, 1991.

[82] ROSENBLATT, F., “The Perceptron: A Probabilistc Model For Information Storage And Organization In The Brain”, *Psychological Review*, Vol. 65, pp. 386-408.

[83] WIDROW, B., “Generalization and Information Storage in Networks of Adaline Neurons”, Self-Organizing Systems, pp. 435-461, Washington, DC, Spartan Books, 1962.

[84] LATHI, B. P., “Communication Systems”, John Wiley & Sons, 1968.

[85] “*Signal Processing Toolbox for Use With MATLAB*”, User’s Guide, Version 4, 1999, The MathWorks Inc.

[86] MELLO, C. A., “Redes Neurais e Técnicas de Pré-Processamento de Sinais em Espectroscopia de Reflectância no Infravermelho Próximo”, Tese de D. Sc., Universidade Estadual de Campinas, Campinas, 1998.

[87] WALL, M., WEDGWOOD, F. A., BURCH, S., “Modeling of NDT Reliability (POD) and Applying Corrections for Human Factors”, *7th ECNDT - European Conference on Nondestructive Testing*, Copenhagen, May, 1998.

[88] FORSYTH, D. S., FAHR A., LEEMANS, D. V., et al., “Development of POD from In-Service NDI Data”, *Quantitative Nondestructive Evaluation*, Iowa, July, 2000.

[89] ACHENBACH J. D., “Quantitative Nondestructive Evaluation”, *International Journal of Solids and Structures*, Vol. 37, pp. 13-27, 2000.

[90] TOPP, D. A., DOVER, W. D., “Reliability of Non-Destructive Inspection Test”, *Análisis de Riesgo y confiabilidad Estructural de Instalaciones Marinas*, México, diciembre, 2001.

[91] SIMOLA, K., PULKKINEN U., “Models for Non-Destructive Inspection Data”, *Reliability Engineering and System Safety*, Vol. 60, pp. 1-12, 1998.

[92] SERABIAN, S., “Ultrasonic Probability of Detection of Subsurface Flaws”, *Materials Evaluation*, Vol. 40, pp. 294-298, 1982.

[93] WALL, M., BURCH, S., “Worth of Modeling for Assessing the Intrinsic Capability of NDT”, *15th WCNDT - World Conference on Nondestructive Testing*, Roma, October, 2000.

[94] GOLIS, M. J., "Application Parameters – A Definition and Their Role in NDE Reliability", *15th WCNDT - World Conference on Nondestructive Testing*, Roma, October, 2000.

[95] MUELLER, C., FRITZ, T., TILLACK, G. R., et al., "Theory and Application of the Modular Approach to NDE Reliability Bridging the Gap Between Safety Requirements and Economy", *NDT.net*, Vol. 06, N° 09, September, 2001.

[96] FORSYTH, D. S., FAHR A., "On the Independence of Multiple Inspections and the Resulting Probability of Detection", *Quantitative Nondestructive Evaluation*, Iowa, July, 2000.

[97] RUDLIN, J. R., WOLSTENHOLME, L. C., "Development of Statistical Probability of Detection Models Using Actual Trial Inspection Data", *British Journal of NDT*, Vol. 34, N° 12, pp. 583-589, 1992.

[98] RUMMEL, W. D., "Requirements for Demonstrating Nondestructive Evaluation Capabilities", *Quantitative Nondestructive Evaluation*, Iowa, July, 2000.

[99] NOCKEMANN, C., BELLON, C., NICKISCH, S., "Strategies of Validation in General Testing Compared to Experience in NDE", *European-American Workshop*, Berlin, June, 1997.

[100] MORÉ, J. D., "Aplicação da Lógica Fuzzy para Avaliação da Confiabilidade Humana nos Ensaios Não Destrutivos Tipo Ultra-som", Tese de D. Sc., COPPE/UFRJ, Rio de Janeiro, 2004.

[101] NOCKEMANN, C., TILLACK, G. R., BELLON, C., et al., "Metric for Reliability Measurement with Special Focus on Application Parameters", *15th WCNDT - World Conference on Nondestructive Testing*, Roma, October, 2000.

[102] GUIA, J. G. C., ARAÚJO, A. L., IRMÃO, M. A. S., et al., "Detecção de Falhas Utilizando Redes Neurais Artificiais em Dutos para Transporte de Petróleo e Gás", *Rio Pipeline – Conference & Exposition*, Rio de Janeiro, Outubro de 2003.

[103] CARVALHO, A. A., SAGRILO, L. V. S., SILVA, I. C., et al., "On the Reliability of an Automated Ultrasonic System for Hull Inspection in Ship-Based Oil Production Units", *Applied Ocean Research*, Vol. 25, pp. 235-241, 2003.

[104] CARVALHO, A. A., SAGRILO, L. V. S., SILVA, I. C., et al., "The POD Curve for the Detection of Planar Defects Using a Multi-Channel Ultrasonic System", *Insight*, Vol. 44, N°. 10, pp. 689-693, 2002.

[105] SILVA, R.R., CALÔBA, L.P., SIQUEIRA, M.H.S. et al., "Patterns Nonlinear Classifiers of Weld Defects in Industrial Radiographs", *3 rd Pan-American Conference for Nondestructive Testing (PANNDT*), pp. 1-11, Rio de Janeiro, June, 2003.

[106] BISHOP, C. M., "Neural Networks for Pattern Recognition", New York, Oxford University Press, 1995.

[107] DUDA, R. O., HART, P. E., STORK, D. G., "Pattern Classification", ed. 2, U.S.A., John Wiley & Sons, 2001.

[108] Procedimento de END – PR-011 – Ultra-som em soldas, ABENDE, São Paulo, Outubro de 2004.

[109] EFRON, B., TIBSHIRANI, R. J., "AN Introduction to the Bootstrap", 1ª Edição, New York, Editora Chapman & Hall/CRC, 1993.

[110] ANG, A. H. S., TANG, W. H., "Probability Concepts in Engineering Planing and Design – Decision, Risk and Reliability", Vol. 3, New York, Editora Jonh Wiley & Sons, 1984.

[111] MULLER, C., SCHARMACH, M., KONCHINA, V., et al., "General Principles of Reliability Assessment of Nondestructive Diagnostic Systems and Its Applicability to the Demining Problem ", *NDT.net*, Vol. 8, N°. 4, April, 2003.

[112] FUCSOK, F., MULLER, C., SCHARMACH, M., "Reliability of Routine Radiographic Film Evaluation – An Extended ROC Study of the Human Factor", *NDT.net*, Vol. 7, N°. 12, December, 2002.

[113] FUCSOK, F., MULLER, C., SCHARMACH, M., "Human Factor: The NDE Reliability of Routine Radiographic Film Evaluation", *15th WCNDT - World Conference on Nondestructive Testing*, Roma, October, 2000.

[114] ROUHAN, A., SCHOEFS, F., "Probabilistic Modeling of Inspection Results for Offshore Structures", *Structural Safety*, Vol. 25, pp. 379-399, 2003.

[115] MERY, D., BERTI, M. A., "Automatic Detection of Welding Defects Using Texture Features", *International Symposium on Computed Tomography and Image Processing for Industrial Radiology*, Berlin, June, 2003.

[116] GODOI, W. C., "Detecção de Defeitos em Isoladores Poliméricos por Radiografia Digital", Tese de M. Sc., Universidade Federal do Paraná, Curitiba, 2000.

[117] BRAGA, A. C. S., "Curvas ROC: Aspectos Funcionais e Aplicações", Tese de D. Sc., Universidade de Minho, Braga, 2000.

[118] OBUCHOWSKI, N. A., "Receiver Operating Characteristic Curves and Their Use in Radiology", *Radiology*, Vol. 229, pp. 3-8, 2003.

[119] CHAN, H. P., SAHINER, B., HELVIE, M. A., et al., “Improvement of Radiologists’ Characterization of Mammographic Masses by Using Computer-aided Diagnosis: An ROC Study”, *Radiology*, Vol. 212, pp. 817-827, 1999.

[120] ASME B31G – “Manual for Determining the Remaining Strength of Corroded Pipelines”, The American Society of Mechanical Engineers, 1999.

[121] Ochi, M. K., “Stochastic analysis and probability prediction of random seas”, Advances in Hydroscience, Vol. 13, New York: Academic Press; 1982.

[122] POD/POS Curves for Non-Destructive Examination – Offshore Technology Report, 2000/018. Prepared by Visser Consultancy Limited for the Health and Safety Executive (HSE).

[123] SILK, M. G., STONEHAM, A. M., TEMPLE, J. A. G., “The Reliability of Non-Destructive Inspection – Assessing the Assessment of Structures Under Stress” Editora Adam Hilger, 1987.

[124] WAITES, C., WHITTLE, J., “The Current Status of Performance Demonstration and Evaluation Developments”, *7th ECNDT - European Conference on Nondestructive Testing*, Copenhagen, May, 1998.

[125] ESTORFF, U. V., CRUTZEN, S., FRIGOLA, P., et al. “The Role of the Joint Research Center from the European Commission in the European Structural Integrity Networks AMES, ENIQ and NESC”, *Nuclear Engineering and Design*, Vol. 190, pp. 347-352, 1999.

[126] BASSANI, M. H. S., CAMERINI, C. S., REBELLO, J. M. A., "Avaliação da Confiabilidade da Inspeção Ultra-sônica de Juntas Soldadas em Chapas de Grandes Espessuras", *VII Seminário Nacional de Ensaios Não Destrutivos*, Rio de Janeiro, Setembro, 1987.

[127] LEMAITRE, P., KOBLÉ, T. D., "Summary of the PISC Round Robin Results on Wrought and Cast Austenitic Steel Weldments, Part I: Wrought-to- Wrought Capability Study", *International Journal of Pressure Vessels & Piping*, Vol. 69, pp. 5-19, 1996.

[128] LEMAITRE, P., KOBLÉ, T. D., "Summary of the PISC Round Robin Results on Wrought and Cast Austenitic Steel Weldments, Part II: Wrought-to-Cast Capability Study", *International Journal of Pressure Vessels & Piping*, Vol. 69, pp. 21-32, 1996.

[129] LEMAITRE, P., KOBLÉ, T. D., "Summary of the PISC Round Robin Results on Wrought and Cast Austenitic Steel Weldments, Part III: Cast-to-Cast Capability Study", *International Journal of Pressure Vessels & Piping*, Vol. 69, pp. 33-44, 1996.

[130] DOCTOR, S. R., LEMAITRE, P., CRUTZEN, S., "Austenitic Steel Piping Testing Exercises in PISC", *Nuclear Engineering and Design*, Vol. 157, pp. 231-244, 1995.

[131] REALE, S., TOGNARELLI, L., "Structural Integrity Significance of Round Robin Testing Trials Application to PISC III Action 3", *Nuclear Engineering and Design*, Vol. 157, pp. 257-268, 1995.

[132] TRIMBORN, N., "The Performance of the Time of Flight Diffraction (TOFD) Technique in Various International Round Robin Trials and the Continuing Research Work Underway", *NDT.net*, Vol. 3, N^{o}. 10, October, 1998.

[133] CAMERINI, C. S., "Análise da Confiabilidade da Inspeção por Ultra-som em Juntas Soldadas", *VI Seminário Nacional de Ensaios Não Destrutivos*, Belo Horizonte, Setembro, 1985.

[134] DIJKSTRA, F. H., RAND, J. A., "Why Develop Acceptance Criteria for Pipeline Girth Weld Defects?", *NDT.net*, Vol. 3, N°. 4, April, 1998.

[135] FAUSKE, T. H., DALBERG, P., HANSEN, A., "Ultrasonic Crack Detection Trials", *15th WCNDT - World Conference on Nondestructive Testing*, Roma, October, 2000.

[136] VERKOOIJEN, J., "The Need for Reliable NDT Measurements in Plant Management Systems", *7th ECNDT - European Conference on Nondestructive Testing*, Copenhagen, May, 1998.

[137] WASHER, G., "Nondestructive Evaluation for Highway Bridges in the United States", *Non-Destructive Testing in Civil Engineering 2003 (NDT-CE 2003) – International Symposium*, Berlin, September, 2003.

[138] GROSS, B., CONNELLY, T. S., DIJK, H. V., et al., "Flaw Sizing Using Mechanized Ultrasonic inspection on Pipeline Girth Welds", *NDT.net*, Vol. 6, N°. 7, July, 2001.

[139] COTTERILL, G., PERCEVAL, J., "A New Approach to Ultrasonic Inspection of Shafts", *10TH APCNDT – 10th Asia-Pacific Conference on Non-Destructive Testing*, Brisbane, September, 2001.

[140] HOPPENBROUWERS, M. B., "Advanced Ultrasonic Methods for in Service Condition Assessment of Industrial Process Installations", *NDT.net*, Vol. 5, N°. 3, March, 2000.

[141] DITCHBURN, R. J., BURKE, S. K., SCALA, C. M., "NDT of Welds: State of the Art", *NDT & E International*, Vol. 29, N°. 2, pp. 111-117, 1996.

[142] GUO-HUA, C., "The Advancement of NDT Technology and Its Application in the Safety Assessment of Pressure Vessels", *10TH APCNDT – 10th Asia-Pacific Conference on Non-Destructive Testing*, Brisbane, September, 2001.

[143] BETTAYEB, F., BENBARTAOUI, H., ROUAROUA, B., "The Artificial Intelligence in Service of Ultrasonic Inspection Reliability", *15th WCNDT - World Conference on Nondestructive Testing*, Roma, October, 2000.

[144] GINZEL, E., LOZEV, M. G., "Code Review: Time-of-Flight Diffraction and Pulse Echo Line Scanning", *NDT.net*, Vol. 6, N°. 2, February, 2001.

[145] MORENO, R. M., "Automatic Ultrasonic System – Nuclear and Conventional Applications", *NDT.net*, Vol. 8, N°. 3, March, 2003.

[146] ERHARD, A., EWERT, U., "The TOFD Method – Between Radiography and Ultrasonic in Weld Testing", *NDT.net*, Vol. 4, N°. 9, September, 1999.

[147] STEPHENS, H. M., "NDE Reliability – Human Factors – Basic Considerations", *15th WCNDT - World Conference on Nondestructive Testing*, Roma, October, 2000.

[148] PASSI, G. S., SHOEF, Y., KRITSKY, M. V., "Reducing Influence of Human Factors on the Manual Ultrasonic Weld Inspection Reliability", *NDT.net*, Vol. 1, N°. 5, May, 1996.

[149] JINHONG, L., JIANYING, D., ZAIQI, Z., "Quality Assurance for Non-Destructive Testing", *15th WCNDT - World Conference on Nondestructive Testing*, Roma, October, 2000.

[150] DYMKIN, G. Y., KONSHINA, V. N., "Systematics of NDT Reliability: A Practical Point of View", *15th WCNDT - World Conference on Nondestructive Testing*, Roma, October, 2000.

[151] RUMMEL, W. D., "Qualification and Validation of the Performance Capability (POD) for Nondestructive Inspection Procedures", *16th WCNDT - World Conference on Nondestructive Testing*, Montreal, September, 2004.

[152] FUCSOK, F., "Experiences and Problems of a Manual Ultrasonic Round – Robin Test", *7th ECNDT - European Conference on Nondestructive Testing*, Copenhagen, May, 1998.

[153] PASSI, G., KRITSKY, M., SHOEF, Y., "High Reliability Manual Ultrasonic Inspection", *7th ECNDT - European Conference on Nondestructive Testing*, Copenhagen, May, 1998.

[154] HANDS, G., "Automated NDT – Advantages and Disadvantages", *NDT.net*, Vol. 1, N°. 3, March, 1996.

[155] SYRKIN, M. M., "Improving Reliability of Automated Ultrasonic Testing", *Russian Journal of Nondestructive Testing*, Vol. 39, N°. 2, pp. 94-104, 2003.

[156] ALEXIEV, A. L., MIHOVSKI, M., "Human Reliability in Ultrasonic Inspection", *15th WCNDT - World Conference on Nondestructive Testing*, Roma, October, 2000.

[157] MEEKER, W. Q., CHAN, V., THOMPSON, R. B., et al., "A Methodology for Predicting Probability of Detection for Ultrasonic Testing", *Quantitative Nondestructive Evaluation*, Iowa, July, 2000.

[158] SAFIZADEH, M. S., FORSYTH, D. S., FAHR, A., "The Effect of Flaw Size Distribution on the Estimation of POD", *British Journal of NDT*, Vol. 46, N° 6, pp. 355-359, June, 2004.

Anexo A

Corpos de prova para ensaio de MFL

Mapa de defeitos: TUBO 1

Solda 1

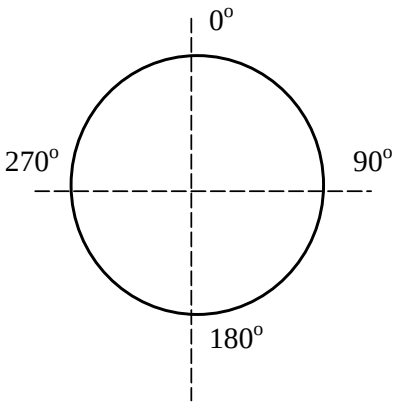

	0º	90º	180º	270º
	CE	CI	FP	PE
medida de projeto	ϕ = 50	ϕ = 20	L = 40	L = 30
medida real	ϕ = 50 P = 3,5	ϕ = 25 P = 3	L = 37 P = 4	L = 25 H = 5

Legenda	
SD	sem defeito
CI	corrosão interna
CE	corrosão externa
FP	falta de penetração
PE	penetração excessiva
E	espessura
L	comprimento
P	profundidade
H	altura
ϕ	diâmetro

OBS.: Unidades em milímetro

Solda 2

	45°	135°	225°	315°
	FP	CE	PE	CI
medida de projeto	L = 10	ϕ = 30	L = 50	ϕ = 30
medida real	L = 10 P = 4	ϕ = 32 P = 4	L = 45 H = 5	ϕ = 32 P = 4

Solda 3

medida de projeto medida real	Sem defeito

Solda 4

	0°	90°	180°	270°
	FP	PE	FP	PE
medida de projeto	L = 50	L = 10	L = 20	L = 40
medida real	L = 49 P = 5,5	L = 12 H = 4	L = 23 P = 3,9	L = 47 H = 4,5 - 7

Solda 5

	45°	135°	225°	315°
	CI	PE	CE	FP
medida de projeto	ϕ = 50	L = 20	ϕ = 10	L = 30
medida real	ϕ = 52,5 P = 3	L = 23,7 H = 4,6 - 5,7	ϕ = 17 P = 3	L = 30 P = 3,5

Solda 6

	0°	90°	180°	270°
	CI	CE	CI	CE
medida de projeto	ϕ = 40	ϕ = 20	ϕ = 30	ϕ = 40
medida real	ϕ = 43,5 P = 4	ϕ = 20 P = 3	ϕ = 31 P = 5	ϕ = 40 P = 4

Solda 7

medida de projeto	União
medida real	

Solda 8

	45°	135°	225°	315°
	PE	CI	CI	PE
medida de projeto	L = 20	ϕ = 40	ϕ = 20	L = 50
medida real	L =25,5 H = 5 - 7	ϕ = 41 P = 4	ϕ = 24 P = 4	L = 52 H = 4 – 5,5

Solda 9

	0°	90°	180°	270°
	CE	FP	PE	CI
medida de projeto	ϕ = 10	L = 40	L = 10	ϕ = 50
medida real	ϕ = 16 P = 2,5	L = 39 P = 5	L = 14 P = 5	ϕ = 50 P = 3,5

Solda 10

	45°	135°	225°	315°
	CE	CE	FP	PE
medida de projeto	ϕ = 20	ϕ = 40	L = 30	L = 40
medida real	ϕ = 20 – 22 P = 4	ϕ = 41 P = 5	L = 28,5 P = 2 - 3	L = 41,3 H = 3 - 4

Solda 11

	0°	90°	180°	270°
	FP	PE	CI	CE
medida de projeto	L = 20	L = 30	ϕ = 30	ϕ = 30
medida real	L = 21 P = 3 - 4	L = 32 H = 3 - 5	ϕ = 30 P = 5	ϕ = 30 P = 3,5

Solda 12

	45°	135°	225°	315°
	FP	FP	CI	CE
medida de projeto	L = 10	L = 50	ϕ = 10	ϕ = 50
medida real	L = 11,5 P = 5,5	L = 50 P = 5	ϕ = 13,5 P = 3,5	ϕ = 51 P = 5

Mapa de defeitos: TUBO 2

Solda 1

	0°	90°	180°	270°
	CE	CI	FP	PE
medida de projeto	ϕ = 50	ϕ = 20	L = 40	L = 30
medida real	ϕ = 50 P = 5,5	ϕ = 24 P = 4	L = 42 P = 3 - 4	L = 38 H = 3,5

Solda 2

	45°	135°	225°	315°
	FP	CE	PE	CI
medida de projeto	L = 10	ϕ = 30	L = 50	ϕ = 30
medida real	L = 11 P = 3,5 - 4	ϕ = 34 P = 5,5	L = 46 H = 4 – 4,5	L = 30 P = 4

Solda 3

medida de projeto	Sem defeito
medida real	

Solda 4

	0°	90°	180°	270°
	FP	PE	FP	PE
medida de projeto	L = 50	L = 10	L = 20	L = 40
medida real	L = 53 P = 3 – 3,5	L = 14,5 H = 4,5	L = 22,5 P = 4	L = 42 H = 4 – 4,5

Solda 5

	45°	135°	225°	315°
	CI	PE	CE	FP
medida de projeto	ϕ = 50	L = 20	ϕ = 10	L = 30
medida real	ϕ = 52 P = 4	L = 25 H = 4,5	ϕ = 15 P = 4	L = 33 P = 4,5 - 5

Solda 6

	0°	90°	180°	270°
	CI	CE	CI	CE
medida de projeto	ϕ = 40	ϕ = 20	ϕ = 30	ϕ = 40
medida real	ϕ = 43 P = 4	ϕ = 22 - 24 H = 4	ϕ = 36 P = 5	ϕ = 43 P = 3,5

Solda 7

medida de projeto	União
medida real	

Solda 8

	45°	135°	225°	315°
	PE	CI	CI	PE
medida de projeto	L = 20	ϕ = 40	ϕ = 20	L = 50
medida real	L = 24 H = 4	ϕ = 44 P = 5,5	ϕ = 23 P = 4,5	L = 53 H = 4 - 6

Solda 9

	0°	90°	180°	270°
	CE	FP	PE	CI
medida de projeto	ϕ = 10	L = 40	L = 10	ϕ = 50
medida real	ϕ = 14 P = 4,5	L = 43 P = 3 - 4	L = 15 H = 4 - 5	ϕ = 55 P = 4

Solda 10

	45°	135°	225°	315°
	CE	CE	FP	PE
medida de projeto	ϕ = 20	ϕ = 40	L = 30	L = 40
medida real	ϕ = 23 P = 4	ϕ = 41 P = 3 - 4	L = 31 P = 3 - 4	L = 41 H = 3,5 - 4

Solda 11

	0°	90°	180°	270°
	FP	PE	CI	CE
medida de projeto	L = 20	L = 30	ϕ = 30	ϕ = 30
medida real	L = 27 P = 4	L = 40 H = 4 - 5	ϕ = 35 P = 5	ϕ = 33 P = 4

Solda 12

	45°	135°	225°	315°
	FP	FP	CI	CE
medida de projeto	L = 10	L = 50	ϕ = 10	ϕ = 50
medida real	L = 13 P = 2,5	L = 51 P = 3,5	ϕ = 13 P = 4,5	ϕ = 49 P = 3,5

Mapa de defeitos: TUBO 3

Solda 1

	0°	90°	180°	270°
	CE	CI	FP	PE
medida de projeto	ϕ = 50	ϕ = 20	L = 40	L = 30
medida real	ϕ = 49 – 50 P = 5	ϕ = 25 P = 5 - 6	L = 40 P = 3 - 4	L = 32 H = 5 - 6

Solda 2

	45°	135°	225°	315°
	FP	CE	PE	CI
medida de projeto	L = 10	ϕ = 30	L = 50	ϕ = 30
medida real	L = 12 P = 4	ϕ = 33 P = 4	L = 55 H = 4 - 5	ϕ = 34 P = 5

Solda 3

medida de projeto	Sem defeito
medida real	

Solda 4

	0°	90°	180°	270°
	FP	PE	FP	PE
medida de projeto	L = 50	L = 10	L = 20	L = 40
medida real	L = 54 P = 4	L = 16 H = 3,5 - 4	L = 23 P = 3	L = 43 H = 4,5 - 5

Solda 5

	45°	135°	225°	315°
	CI	PE	CE	FP
medida de projeto	ϕ = 50	L = 20	ϕ = 10	L = 30
medida real	ϕ = 50 P = 5	L = 22 H = 4,5 - 5	ϕ = 14 P = 4	L = 30 P = 3 - 4

Solda 6

	0°	90°	180°	270°
	CI	CE	CI	CE
medida de projeto	ϕ = 40	ϕ = 20	ϕ = 30	ϕ = 40
medida real	ϕ = 44 P = 4 – 4,5	ϕ = 22 P = 4	ϕ = 35 P = 5	ϕ = 42 P = 3,5 - 4

Solda 7

medida de projeto	União
medida real	

Solda 8

	45°	135°	225°	315°
	PE	CI	CI	PE
medida de projeto	L = 20	ϕ = 40	ϕ = 20	L = 50
medida real	L = 23 H = 6	ϕ = 46 P = 5 - 6	ϕ = 25 P = 5	L = 53 H = 4 - 5

Solda 9

	0°	90°	180°	270°
	CE	FP	PE	CI
medida de projeto	ϕ = 10	L = 40	L = 10	ϕ = 50
medida real	ϕ = 14 P = 4	L = 43 P = 4	L = 11 H = 5	ϕ = 53 P = 4,5 - 5

Solda 10

	45°	135°	225°	315°
	CE	CE	FP	PE
medida de projeto	ϕ = 20	ϕ = 40	L = 30	L = 40
medida real	ϕ = 22 P = 5	ϕ = 42 P = 5	L = 31 P = 3 - 4	L = 42 H = 5 – 6

Solda 11

	0°	90°	180°	270°
	FP	PE	CI	CE
medida de projeto	L = 20	L = 30	ϕ = 30	ϕ = 30
medida real	L = 21 P = 3 - 4	L = 31 H = 4 - 5	ϕ = 35 P = 5	ϕ = 30 P = 4,5

Solda 12

	45°	135°	225°	315°
	FP	FP	CI	CE
medida de projeto	L = 10	L = 50	ϕ = 10	ϕ = 50
medida real	L = 14 P = 4	L = 53 P = 2 - 3	ϕ = 13 P = 4 - 5	ϕ = 52 P = 4 - 5

Mapa de defeitos: TUBO 4

Solda 1

	0°	90°	180°	270°
	CE	CI	FP	PE
medida de projeto	ϕ = 50	ϕ = 20	L = 40	L = 30
medida real	ϕ = 50 P = 4	ϕ = 25 P = 6	L = 42 P = 3 - 4	L = 38 H = 4 - 5

Solda 2

	45°	135°	225°	315°
	FP	CE	PE	CI
medida de projeto	L = 10	ϕ = 30	L = 50	ϕ = 30
medida real	L = 13 P = 4 – 5	ϕ = 32 P = 5	L = 49 H = 5,5 - 6	ϕ = 35 P = 4 - 5

Solda 3

medida de projeto	Sem defeito
medida real	

Solda 4

	0°	90°	180°	270°
	FP	PE	FP	PE
medida de projeto	L = 50	L = 10	L = 20	L = 40
medida real	L = 55 P = 3 - 4	L = 11 H = 5	L = 22 P = 2 - 4	L = 40 H = 5

Solda 5

	45°	135°	225°	315°
	CI	PE	CE	FP
medida de projeto	ϕ = 50	L = 20	ϕ = 10	L = 30
medida real	ϕ = 55 P = 5	L = 23 H = 5	ϕ = 14 P = 5	L = 30 P = 4

Solda 6

	0°	90°	180°	270°
	CI	CE	CI	CE
medida de projeto	ϕ = 40	ϕ = 20	ϕ = 30	ϕ = 40
medida real	ϕ = 45 P = 5,5	ϕ = 21 P = 5 - 6	ϕ = 35 P = 5,5	ϕ = 40 P = 5

Solda 7

medida de projeto	União
medida real	

Solda 8

	45°	135°	225°	315°
	PE	CI	CI	PE
medida de projeto	L = 20	ϕ = 40	ϕ = 20	L = 50
medida real	L = 22 H = 5,5	ϕ = 40 P = 5	ϕ = 20 P = 5	L = 52 P = 6

Solda 9

	0°	90°	180°	270°
	CE	FP	PE	CI
medida de projeto	ϕ = 10	L = 40	L = 10	ϕ = 50
medida real	ϕ = 15 P = 4,5	L = 42 P = 4	L = 12 H = 5 - 6	ϕ = 50 P = 5

Solda 10

	45°	135°	225°	315°
	CE	CE	FP	PE
medida de projeto	ϕ = 20	ϕ = 40	L = 30	L = 40
medida real	ϕ = 20 P = 4	ϕ = 40 P = 4	L = 30 P = 4	L = 40 H = 5

Solda 11

	0°	90°	180°	270°
	FP	PE	CI	CE
medida de projeto	L = 20	L = 30	ϕ = 30	ϕ = 30
medida real	L = 20 P = 4	L = 30 H = 6	ϕ = 30 P = 4	ϕ = 30 P = 4

Solda 12

	45°	135°	225°	315°
	FP	FP	CI	CE
medida de projeto	L = 10	L = 50	ϕ = 10	ϕ = 50
medida real	L = 10 P = 4	L = 50 P = 4,5	ϕ = 14 P = 5	ϕ = 50 P = 4

Anexo B

Corpos de prova para ensaio de ultra-som

Foram empregados na confecção dos corpos de prova dutos de especificação API-X70, com diâmetro de 254mm, espessura de parede 19,05mm e comprimento de 6000mm. Neste dutos foram inseridos defeitos artificiais nos cordões de soldas circunferenciais.

Classes de defeitos:
Falta de penetração (FP)
Falta de Fusão (FF)

Os defeitos foram projetados com 4 comprimentos diferentes e 3 alturas, perfazendo um total de 12 defeitos com dimensões diferentes.

comprimentos: l = 3mm, 5mm, 7mm e 10mm
altura: h = 2mm, 3mm e 5mm

Um defeito com a mesma dimensão foi repetido 5 vezes, perfazendo um total de 60 defeitos para cada classe.

Adicionalmente foram inseridos 5 defeitos de FP e 5 defeitos de FF com dimensões: l = 20mm e h = 3mm e ainda foram inseridos 20 defeitos de FF com comprimento e altura inferior a 3mm.

As Tabelas a seguir mostram o total de soldas realizadas e a distribuição de defeitos por solda. É apresentado também o dimensionamentos de todos os defeitos inseridos nos corpos de prova.

Tabela 1. Distribuição de defeitos por solda.

Nº da Solda	Nº Total de Defeitos	Nº de Defeitos (FP)	Nº de Defeitos (FF)
0	11	2	9
1	0	0	0
2	10	4	6
3	1	1	0
4	6	3	3
5	8	3	5
6	3	0	3
7	2	1	1
8	1	0	1
9	5	3	2
10	8	6	2
11	5	3	2
12	6	1	5
13	7	4	3
14	4	3	1
15	11	5	6
16	6	3	3
17	4	0	4
18	9	7	2
19	7	2	5
20	10	6	4
21	3	2	1
22	11	4	7
23	12	2	10
Total	**150**	**65**	**85**

SOLDA 0

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
20	FF	l = 20 h = 3	*l = 20,2* *h = 2,9*	E	**1**
70	FF	l = 1,5 h = 1,5	*l = 2,8* *h = 2,5*	E	**2**
180	FF	l = 1,5 h = 1,5	*l = 2,7* *h = 2,6*	D	**3**
240	FP	l = 20 h = 3	*l = 20* *h = 2,5*		**4**
320	FP	l = 20 h = 3	*l = 20,6* *h = 2,9*		**5**
400	FF	l = 1,5 h = 1,5	*l = 2,7* *h = 2,6*	E	**6**
450	FF	l = 1,5 h = 1,5	*l = 2,9* *h = 2,6*	D	**7**
500	FF	l = 1,5 h = 1,5	*l = 3* *h = 2,5*	E	**8**
600	FF	l = 1,5 h = 1,5	*l = 2,9* *h = 2,6*	E	**9**
720	FF	l = 1,5 h = 1,5	*l = 2,7* *h = 2,5*	D	**10**
800	FF	l = 20 h = 3	*l = 19,5* *h = 3*	D	**11**
Quantidade de defeitos	***11***				

SOLDA 1

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Número do defeito
SEM DEFEITOS				
Quantidade de defeitos	***0***			

SOLDA 2

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Número do defeito
70	FP	l = 10 h = 2	*l = 11* *h = 1,8*	**1**
120	FP	l = 5 h = 3	*l = 5* *h = 2,5*	**2**
180	FF	l = 3 h = 2	*l = 3* E *h = 2*	**3**
255	FF	l = 5 h = 3	*l = 5,3* *h = 3* E	**4**
300	FF	l = 5 h = 5	*l = 5,3* *h = 5,3* D	**5**
395	FF	l = 10 h = 3	*l = 10,6* *h = 3* E	**6**
570	FF	l = 3 h = 3	*l = 3* *h = 3* D	**7**
755	FP	l = 20 h = 3	*l = 19* *h = 3,3*	**8**
805	FF	l = 20 h = 3	*l = 19,6* *h = 3,1* E	**9**
850	FP	l = 5 h = 5	*l = 5* *h = 4,9*	**10**
Quantidade de defeitos	***10***			

OBS.: D significa que o defeito está do lado direito do chanfro, enquanto que E está do lado esquerdo (a marcação de esquerdo e direto está no tubo).

SOLDA 3

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Número do defeito
280	FP	l = 3 h = 3	*l = 3* *h = 3,5*	**1**
Quantidade de defeitos	***1***			

SOLDA 4

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Número do defeito
40	FF	l = 3 h = 5	*l = 3,6* *h = 4,9* D	**1**
140	FF	l = 5 h = 2	*l = 5,1* *h = 2,7* E	**2**
180	FP	l = 7 h = 2	*l = 7,1* *h = 2,8*	**3**
450	FF	l = 3 h = 3	*l = 3,5* *h = 3,2* D	**4**
550	FP	l = 3 h = 2	*l = 3,1* *h = 2,9*	**5**
600	FP	l = 3 h = 2	*l = 3,5* *h = 2,9*	**6**
Quantidade de defeitos	***6***			

SOLDA 5

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
15	FF	l = 3 h = 5	*l = 2,9* *h = 4,3*	D	**1**
100	FP	l = 10 h = 3	*l = 10,5* *h = 3,1*		**2**
160	FF	l = 7 h = 5	*l = 6,9* *h = 5,5*	D	**3**
260	FP	l = 3 h = 3	*l = 2,9* *h = 2,1*		**4**
470	FF	l = 10 h = 2	*l = 10,7* *h = 2,6*	E	**5**
590	FP	l = 3 h = 5	*l = 2,8* *h = 3,9*		**6**
680	FF	l = 10 h = 5	*l = 10,1* *h = 5*	D	**7**
830	FF	l = 5 h = 2	*l = 5,9* *h = 2,4*	E	**8**
Quantidade de defeitos	***8***				

SOLDA 6

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
0	FF	l = 3 h = 2	*l = 3,1* *h = 1,8*	E	**1**
495	FF	l = 3 h = 3	*l = 3* *h = 3*	D	**2**
630	FF	l = 5 h = 2	*l = 5,3* *h = 2*	D	**3**
Quantidade de defeitos	***3***				

SOLDA 7

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
340	FF	l = 3 h = 2	*l = 3,3* *h = 2,1*	D	**1**
775	FP	l = 5 h = 5	*l = 5,1* *h = 5,3*		**2**
Quantidade de defeitos	***2***				

SOLDA 8

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
120	FF	l = 1,5 h = 1,5	*l = 1,63* *h = 1,6*	D	**1**
Quantidade de defeitos	***1***				

SOLDA 9

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
55	FF	l = 5 h = 3	*l = 4,5* *h = 2,9*	D	**1**
200	FP	l = 3 h = 5	*l = 3* *h = 4,7*		**2**
360	FP	l = 10 h = 5	*l = 10* *h = 5,7*		**3**
650	FF	l = 10 h = 2	*l = 9,5* *h = 2,1*	D	**4**
770	FP	l = 7 h = 5	*l = 6,8* *h = 5,6*		**5**
Quantidade de defeitos	***5***				

SOLDA 10

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Número do defeito
85	FP	l = 5 h = 2	*l = 5,1* *h = 2,6*	**1**
230	FP	l = 7 h = 5	*l = 6,9* *h = 4,6*	**2**
330	FP	l = 5 h = 2	*l = 5,3* *h = 2,3*	**3**
375	FF	l = 10 h = 3	*l = 10* *h = 3* E	**4**
490	FP	l = 7 h = 3	*l = 6,5* *h = 2,4*	**5**
550	FP	l = 10 h = 2	*l = 9,8* *h = 2,5*	**6**
610	FP	l = 3 h = 2	*l = 3* *h =2,3*	**7**
700	FF	l = 7 h = 2	*l = 7,5* *h = 2,1* D	**8**
Quantidade de defeitos	***8***			

SOLDA 11

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Número do defeito
20	FP	l = 3 h = 3	*l = 2,9* *h = 1,9*	**1**
270	FP	l = 7 h = 2	*l = 7* *h = 2,2*	**2**
420	FP	l = 5 h = 3	*l = 4,9* *h = 2,8*	**3**
510	FF	l = 5 h = 5	*l = 5,1* *h = 5,0* E	**4**
820	FF	l = 3 h = 5	*l = 3* *h = 5* E	**5**
Quantidade de defeitos	***5***			

SOLDA 12

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Número do defeito
0	FF	l = 5 h = 2	*l = 5,2* *h = 2,1* D	**1**
150	FF	l = 5 h = 5	*l = 5,1* *h = 5,1* E	**2**
195	FF	l = 10 h = 2	*l = 9,4* *h = 1,9* E	**3**
400	FF	l = 3 h = 2	*l = 3,1* *h = 2,0* D	**4**
500	FF	l = 1,5 h = 1,5	*l = 1,5* *h = 1,3* E	**5**
700	FP	l = 3 h = 5	*l = 3* *h = 4,2*	**6**
Quantidade de defeitos	***6***			

SOLDA 13

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
90	FF	l = 10 h = 5	*l = 9,8* *h = 4,9*	D	**1**
220	FF	l = 7 h = 2	*l = 7* *h = 1,9*	E	**2**
300	FP	l = 10 h = 5	*l = 10,1* *h = 5*		**3**
430	FP	l = 10 h = 3	*l = 10* *h = 3,3*		**4**
530	FP	l = 5 h = 2	*l = 5* *h = 2*		**5**
800	FF	l = 7 h = 5	*l = 7* *h = 5*	E	**6**
840	FP	l = 5 h = 3	*l = 5* *h = 3,3*		**7**
Quantidade de defeitos	***7***				

SOLDA 14

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
35	FP	l = 10 h = 3	*l = 10* *h = 2,6*		**1**
150	FF	l = 1,5 h = 1,5	*l = 1,5* *h = 1,5*	D	**2**
350	FP	l = 3 h = 2	*l = 3,3* *h = 2,1*		**3**
730	FP	l = 3 h = 3	*l = 3,3* *h = 2,5*		**4**
Quantidade de defeitos	***4***				

SOLDA 15

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
10	FP	l = 7 h = 3	*l = 7,1* *h = 3,1*		**1**
60	FF	l = 10 h = 5	*l = 10* *h = 5*	D	**2**
110	FF	l = 10 h = 3	*l = 10* *h = 3*	D	**3**
160	FP	l = 5 h = 5	*l = 5,1* *h = 5*		**4**
250	FF	l = 5 h = 3	*l = 5* *h = 3*	E	**5**
350	FP	l = 7 h = 2	*l = 7,2* *h = 2,2*		**6**
450	FP	l = 7 h = 5	*l = 7* *h =5*		**7**
540	FP	l = 5 h = 3	*l = 5* *h = 3,2*		**8**
650	FF	l = 7 h = 3	*l = 7* *h = 3,1*	E	**9**
720	FF	l = 7 h = 2	*l = 7,3* *h = 2*	E	**10**
780	FF	l = 3 h = 5	*l = 3,1* *h = 5,1*	D	**11**
Quantidade de defeitos	***11***				

SOLDA 16

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Número do defeito
75	FP	l = 3 h = 5	*l = 3* *h = 3,4*	**1**
250	FF	l = 3 h = 3	*l = 3* *h = 3,1* D	**2**
290	FF	l = 5 h = 3	*l = 5,1* *h = 3* D	**3**
470	FP	l = 10 h = 5	*l = 11* *h = 4,4*	**4**
570	FF	l = 7 h = 5	*l = 7,3* *h = 5,1* E	**5**
615	FP	l = 5 h = 5	*l = 5,3* *h = 3,2*	**6**
Quantidade de defeitos	***6***			

SOLDA 17

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Número do defeito
70	FF	l = 1,5 h = 1,5	*l = 1,85* *h = 2,2* D	**1**
600	FF	l = 7 h = 3	*l = 7,1* *h = 3,1* D	**2**
675	FF	l = 3 h = 2	*l = 3* *h = 2* D	**3**
775	FF	l = 3 h = 3	*l = 4* *h = 3* E	**4**
Quantidade de defeitos	***4***			

SOLDA 18

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Número do defeito
60	FF	l = 5 h = 5	*l = 5,2* *h = 5* E	**1**
110	FP	l = 7 h = 5	*l = 7,2* *h = 4,7*	**2**
180	FP	l = 7 h = 2	*l = 7,2* *h = 2,1*	**3**
380	FF	l = 5 h = 2	*l = 5,1* *h = 2,4* E	**4**
450	FP	l = 10 h = 2	*l = 10,2* *h = 1,5*	**5**
500	FP	l = 5 h = 2	*l = 5,1* *h = 1,8*	**6**
750	FP	l = 10 h = 2	*l = 10,2* *h = 2*	**7**
800	FP	l = 5 h = 3	*l = 5,1* *h = 2,2*	**8**
850	FP	l = 10 h = 3	*l = 10,1* *h = 2,8*	**9**
Quantidade de defeitos	***9***			

SOLDA 19

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
35	FF	l = 3 h = 5	*l = 3* *h = 6*	D	**1**
90	FP	l = 3 h = 3	*l = 3* *h = 2,3*		**2**
150	FF	l = 7 h = 2	*l = 7,2* *h = 2*	E	**3**
300	FP	l = 3 h = 5	*l = 2,9* *h = 3*		**4**
350	FF	l = 10 h = 3	*l = 9* *h = 3*	D	**5**
390	FF	l = 10 h = 5	*l = 9,5* *h = 4,9*	E	**6**
435	FF	l = 10 h = 2	*l = 10* *h = 2,3*	D	**7**
Quantidade de defeitos	***7***				

SOLDA 20

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Número do defeito
10	FP	l = 10 h = 5	*l = 9,5* *h = 4,3*	**1**
60	FP	l = 7 h = 3	*l = 7,8* *h = 2,5*	**2**
200	FP	l = 7 h = 5	*l = 7,3* *h = 4,1*	**3**
265	FP	l = 7 h = 3	*l = 7,3* *h = 3,5*	**4**
320	FP	l = 10 h = 5	*l = 11,5* *h = 4,8*	**5**
420	FP	l = 10 h = 3	*l = 10* *h = 2,9*	**6**
605	FF	l = 7 h = 3	*l = 8,5* *h = 3* E	**7**
665	FF	l = 7 h = 3	*l = 7* *h = 3* D	**8**
710	FF	l = 5 h = 3	*l = 5,8* *h = 3,1* D	**9**
750	FF	l = 5 h = 5	*l = 5* *h = 4,9* E	**10**
Quantidade de defeitos	***10***			

SOLDA 21

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)	Inspetor (mm)
180	FP	l = 7 h = 3	*l = 7,3* *h = 3,3*	**1**
250	FF	l = 1,5 h = 1,5	*l = 2,8* *h = 1,7* D	**2**
810	FP	l = 3 h = 2	*l = 3* *h = 2,5*	**3**
Quantidade de defeitos	***3***			

SOLDA 22

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
100	FP	l = 5 h = 2	*l = 5,3* *h = 1,8*		**1**
160	FF	l = 7 h = 5	*l = 7,5* *h = 5,3*	D	**2**
240	FF	l = 7 h = 2	*l = 7,2* *h = 2,4*	E	**3**
460	FF	l = 7 h = 3	*l = 7,3* *h = 3,6*	D	**4**
535	FF	l = 10 h = 2	*l = 9,5* *h = 2,5*	D	**5**
585	FP	l = 7 h = 2	*l = 7,2* *h = 1,9*		**6**
620	FF	l = 7 h = 5	*l = 7,3* *h = 5,2*	E	**7**
690	FF	l = 10 h = 3	*l = 10,8* *h = 3,9*	D	**8**
710	FP	l = 10 h = 2	*l = 10,3* *h = 2*		**9**
730	FF	l = 10 h = 5	*l = 10* *h = 5,3*	E	**10**
820	FP	l = 5 h = 5	*l = 5,2* *h = 5*		**11**
Quantidade de defeitos	***11***				

SOLDA 23

Posição (mm)	Defeito	Dimensão ideal (mm)	Dimensão real (mm)		Número do defeito
0	FF	l = 1,5 h = 1,5	*l = 1,7* *h = 1,8*	D	**1**
150	FF	l = 1,5 h = 1,5	*l = 1,9* *h = 2,7*	E	**2**
180	FF	l = 1,5 h = 1,5	*l = 2,8* *h = 1,9*	D	**3**
220	FF	l = 1,5 h = 1,5	*l = 2,7* *h = 1,9*	E	**4**
300	FP	l = 20 h = 3	*l = 20,7* *h = 3*		**5**
350	FF	l = 20 h = 3	*l = 19,8* *h = 2,9*	E	**6**
400	FF	l = 1,5 h = 1,5	*l = 2,8* *h = 1,8*	D	**7**
430	FF	l = 20 h = 3	*l = 19,1* *h = 3*	E	**8**
560	FF	l = 1,5 h = 1,5	*l = 2,8* *h = 1,8*	D	**9**
680	FP	l = 20 h = 3	*l = 21* *h = 2,5*		**10**
740	FF	l = 1,5 h = 1,5	*l = 2,7* *h = 2,3*	E	**11**
820	FF	l = 1,5 h = 1,5	*l = 2,6* *h = 1,8*	D	**12**
Quantidade de defeitos	***12***				

Anexo C

Resultados do ensaio de ultra-som pulso-eco automatizado

Ensaios de Ultra-som Pulso-eco Automatizado

Foram empregados na confecção do corpo de prova dutos de especificação API-X70, com diâmetro de 254mm, espessura de parede 19,05mm e comprimento de 3000mm. Neste dutos foram inseridos defeitos artificiais nos cordões de soldas circunferenciais.

Classes de defeitos:
Falta de penetração (FP)
Falta de Fusão (FF)

Os defeitos foram inseridos com 4 comprimentos diferentes e 3 alturas, perfazendo um total de 12 defeitos com dimensões diferentes.

comprimentos: l = 3mm, 5mm, 7mm e 10mm
altura: h = 2mm, 3mm e 5mm

Um defeito com a mesma dimensão será repetido 5 vezes, perfazendo um total de 60 defeitos para cada classe.

Adicionalmente foram inseridos 5 defeitos de FP e 5 defeitos de FF com dimensões: l = 20mm e h = 3mm e ainda foram inseridos 20 defeitos de FF com comprimento e altura inferior a 3mm.

A Tabela a seguir apresenta o total de soldas realizadas e a distribuição de defeitos por solda e em seguida são mostrados os Echogramas do ensaio ultra-sônico de pulso-eco automatizado para todas as soldas.

Tabela 1. Distribuição de defeitos por solda

Nº da Solda	Nº Total de Defeitos	Nº de Defeitos (FP)	Nº de Defeitos (FF)
0	11	2	9
1	0	0	0
2	10	4	6
3	1	1	0
4	6	3	3
5	8	3	5
6	3	0	3
7	2	1	1
8	1	0	1
9	5	3	2
10	8	6	2
11	5	3	2
12	6	1	5
13	7	4	3
14	4	3	1
15	11	5	6
16	6	3	3
17	4	0	4
18	9	7	2
19	7	2	5
20	10	6	4
21	3	2	1
22	11	4	7
23	12	2	10
Total	**150**	**65**	**85**

SOLDA 0 - Defeitos de Falta de Penetração

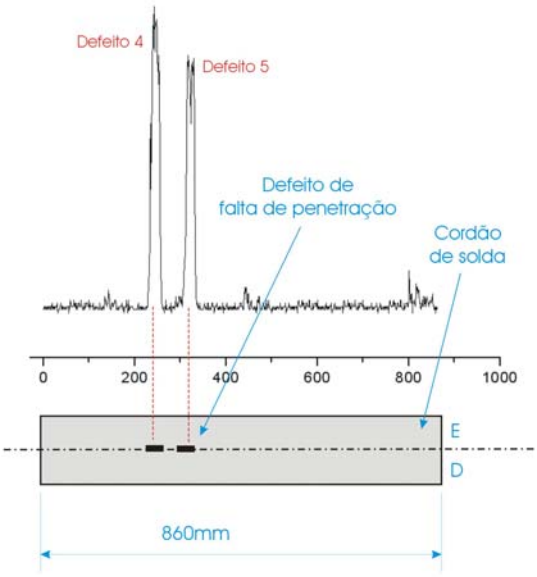

SOLDA 0 - Defeitos de Falta de Fusão

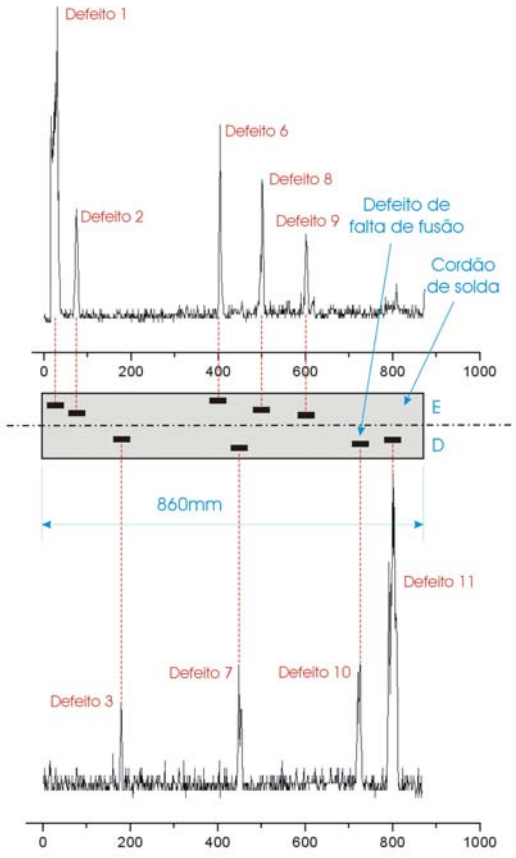

SOLDA 1 - Sem Defeitos

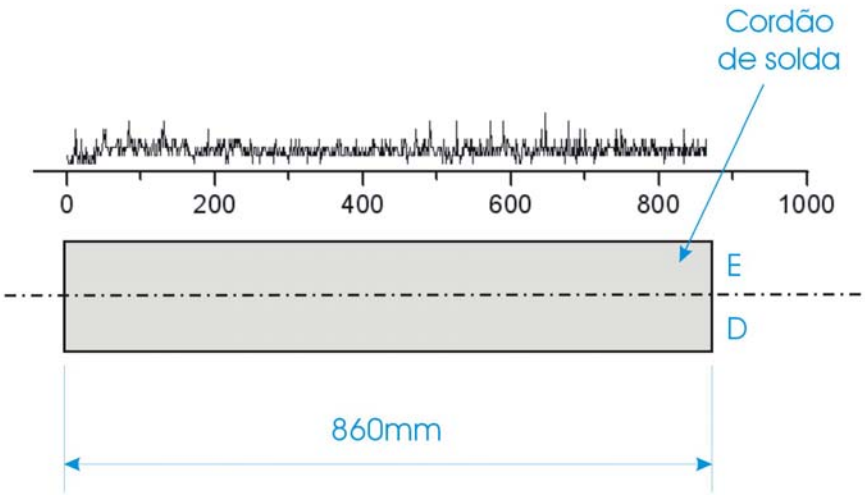

SOLDA 2 - Defeitos de Falta de Penetração

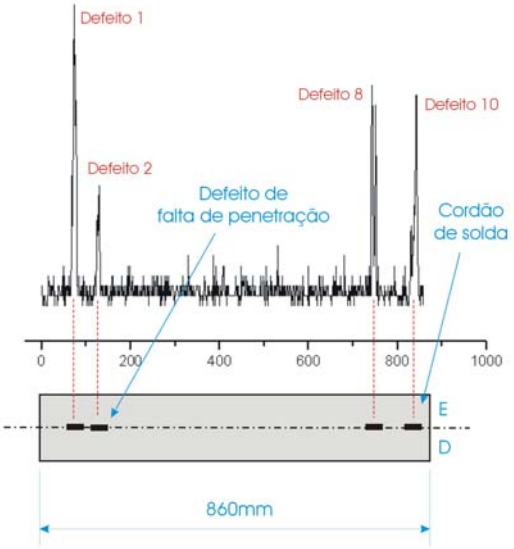

SOLDA 2 - Defeitos de Falta de Fusão

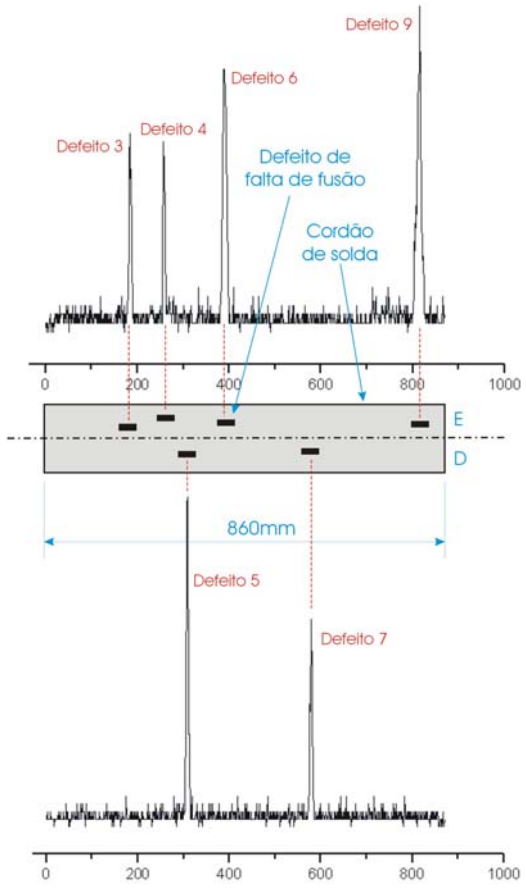

SOLDA 3 - Defeitos de Falta de Penetração

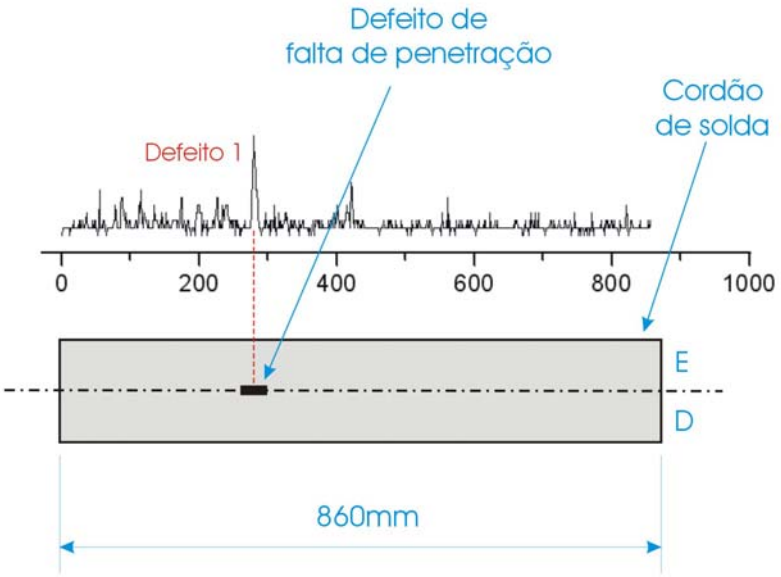

SOLDA 4 - Defeitos de Falta de Penetração

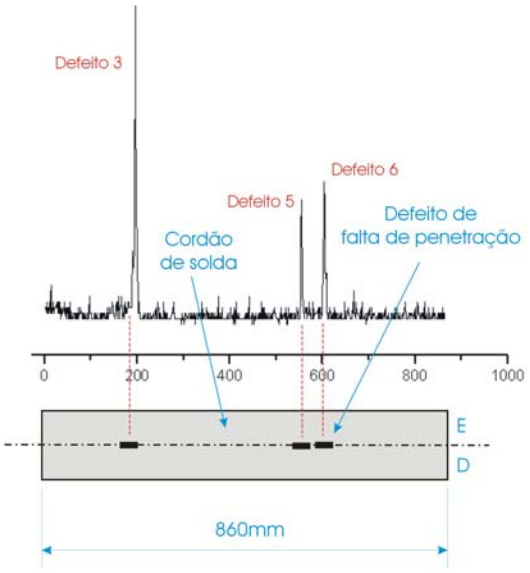

SOLDA 4 - Defeitos de Falta de Fusão

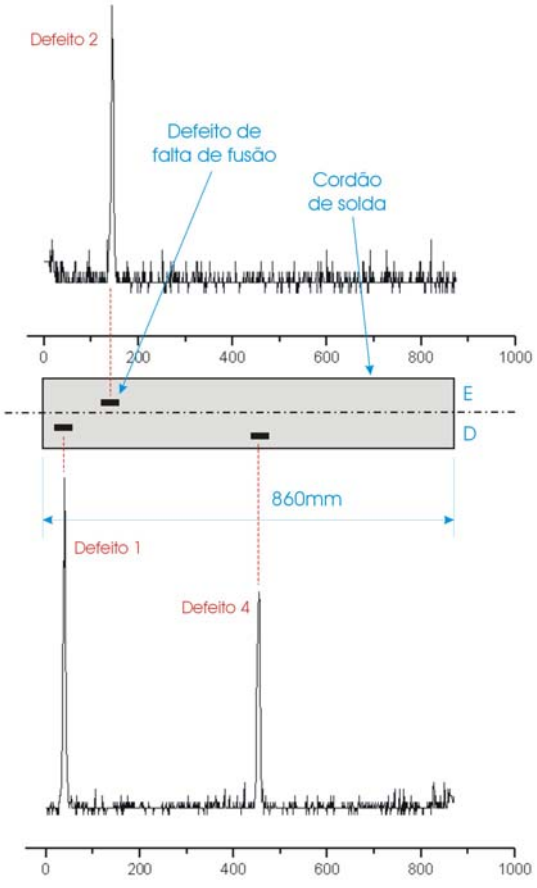

SOLDA 5 - Defeitos de Falta de Penetração

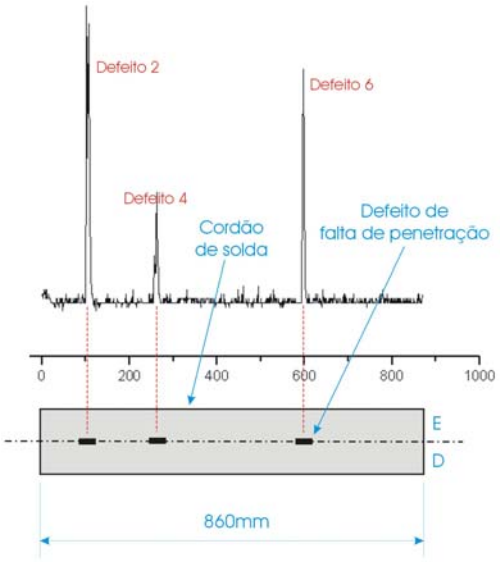

SOLDA 5 - Defeitos de Falta de Fusão

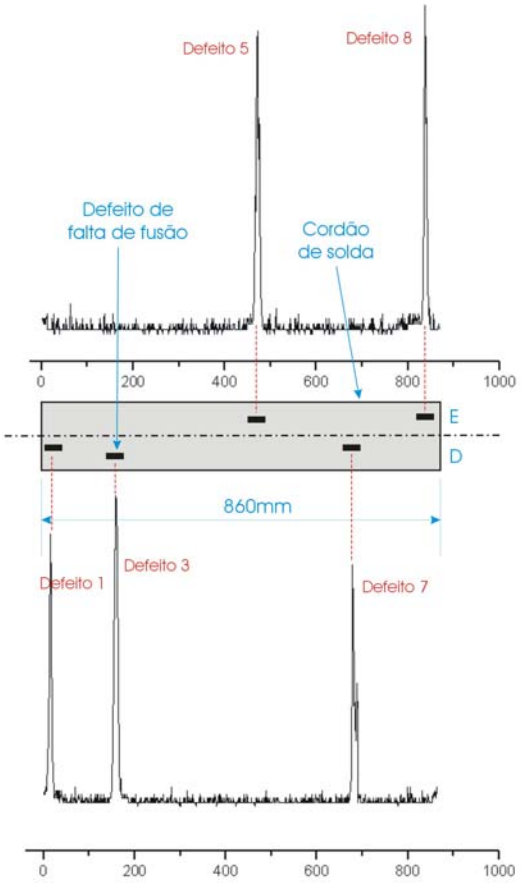

SOLDA 6 - Defeitos de Falta de Fusão

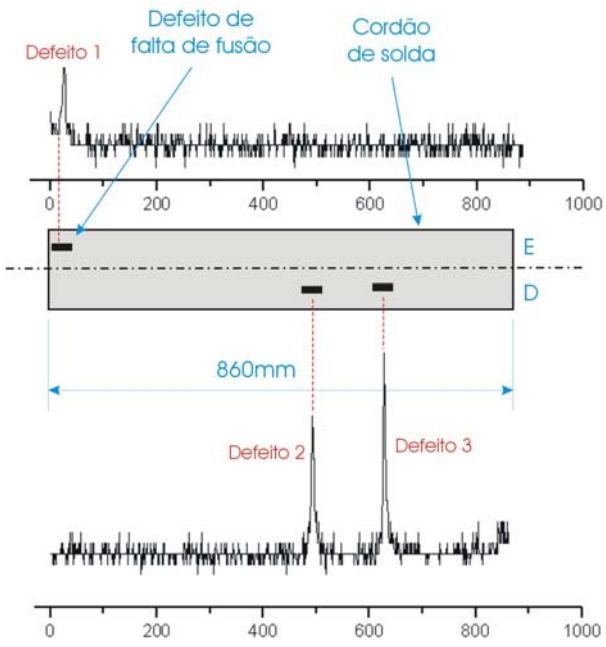

SOLDA 7 - Defeitos de Falta de Penetração

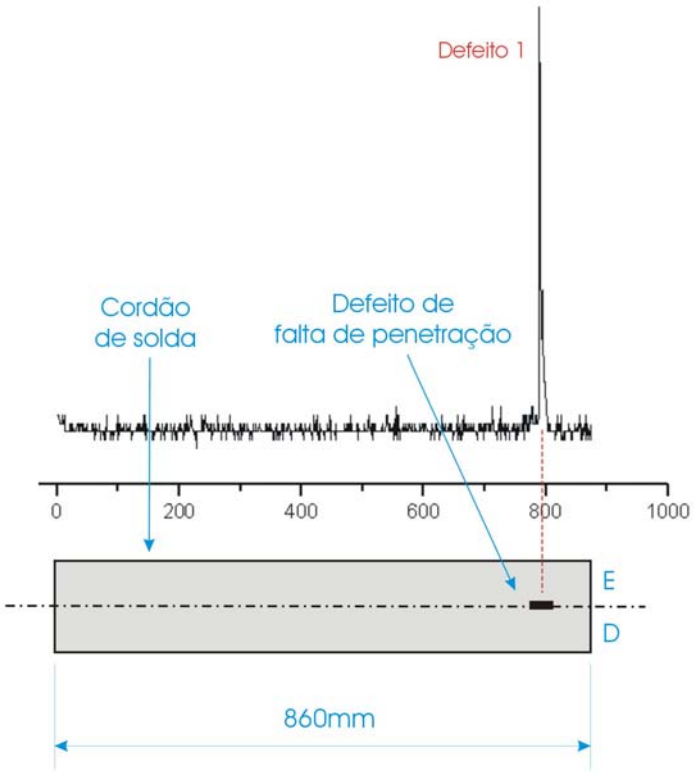

SOLDA 7 - Defeitos de Falta de Fusão

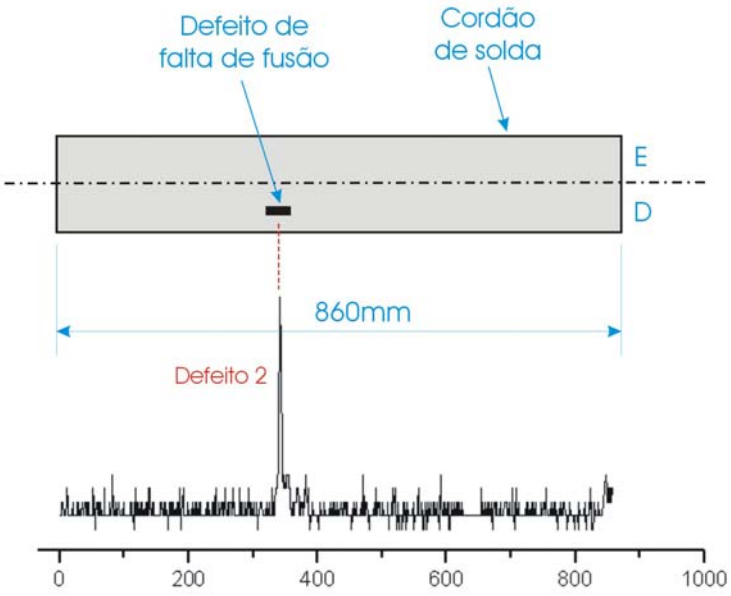

SOLDA 8 - Defeitos de Falta de Fusão

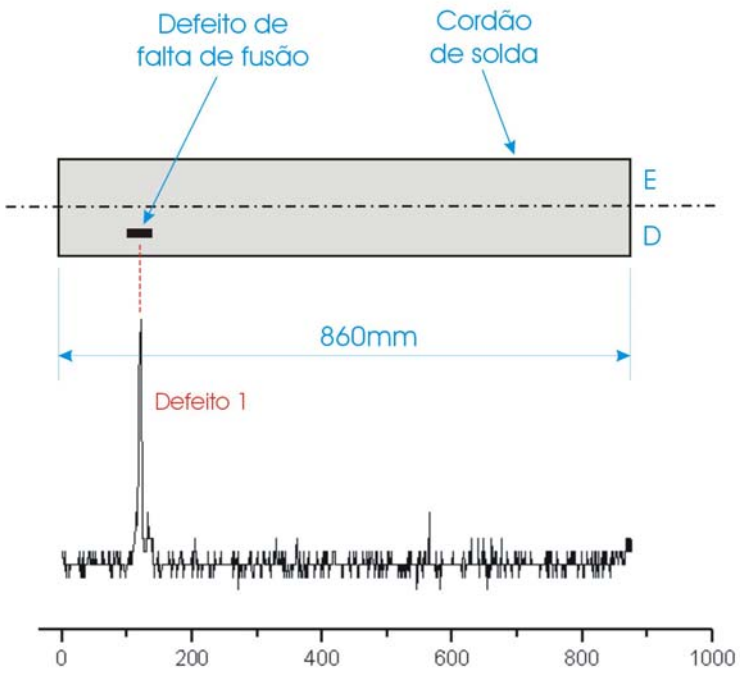

SOLDA 9 - Defeitos de Falta de Penetração

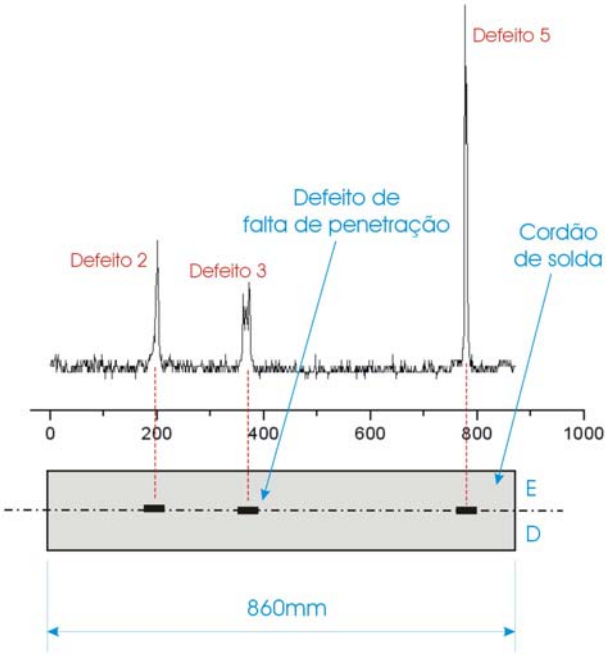

SOLDA 9 - Defeitos de Falta de Fusão

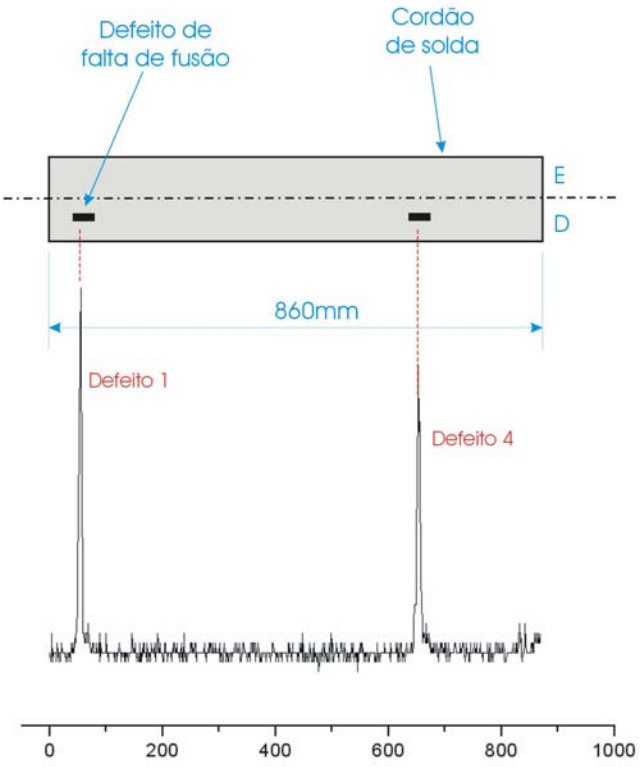

SOLDA 10 - Defeitos de Falta de Penetração

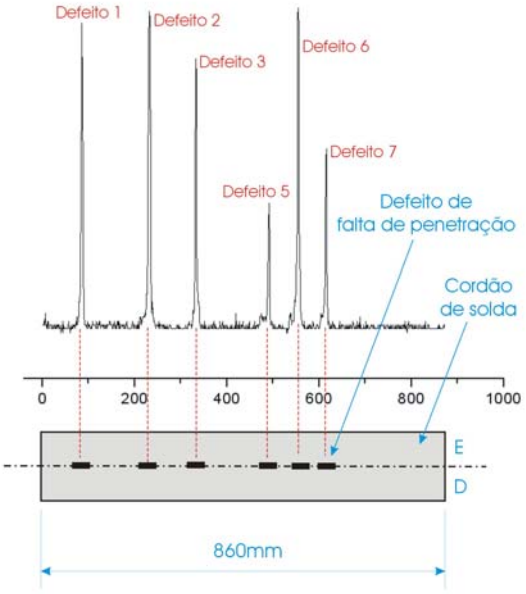

SOLDA 10 - Defeitos de Falta de Fusão

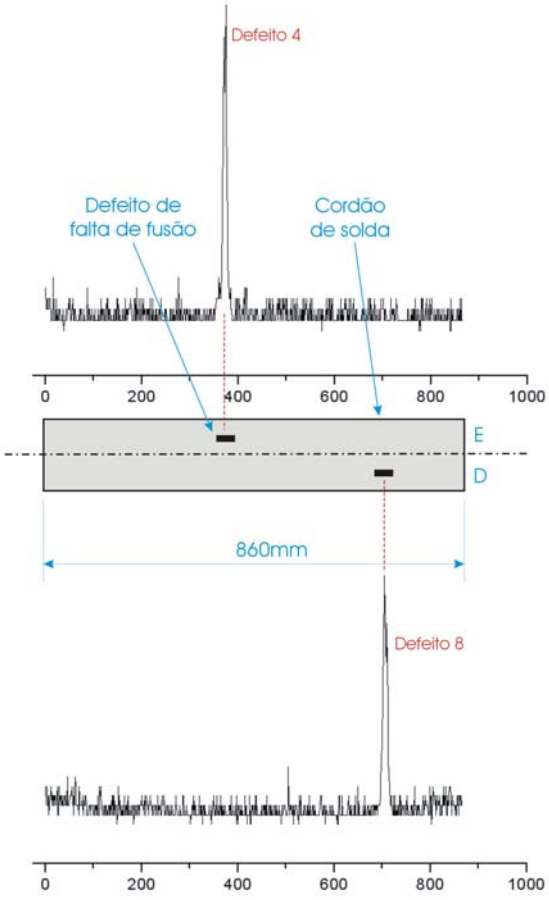

SOLDA 11 - Defeitos de Falta de Penetração

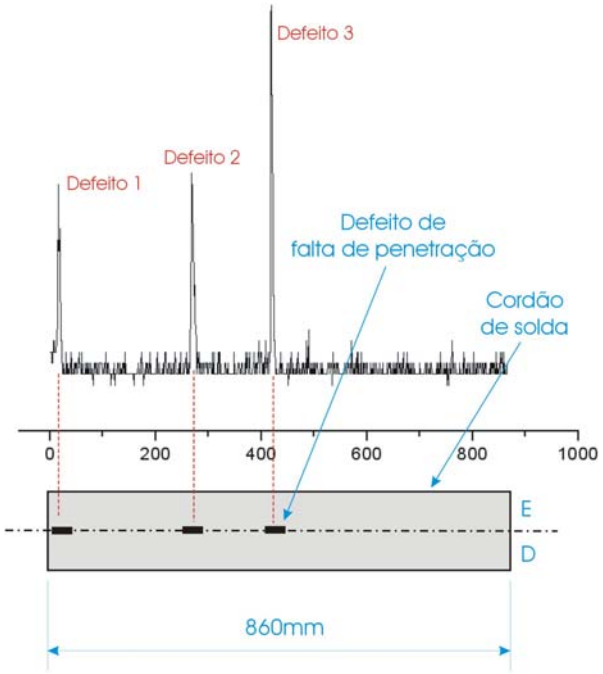

SOLDA 11 - Defeitos de Falta de Fusão

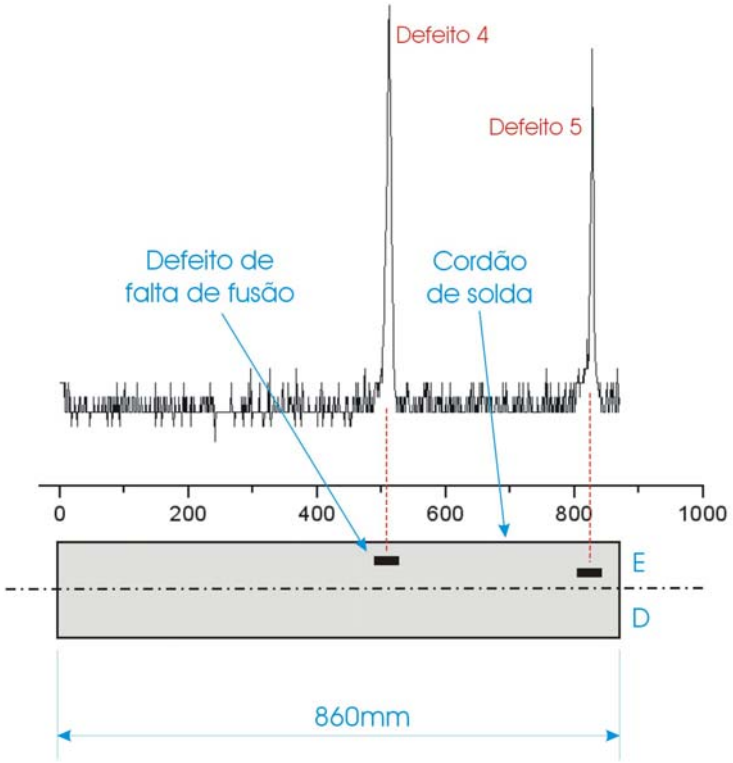

SOLDA 12 - Defeitos de Falta de Penetração

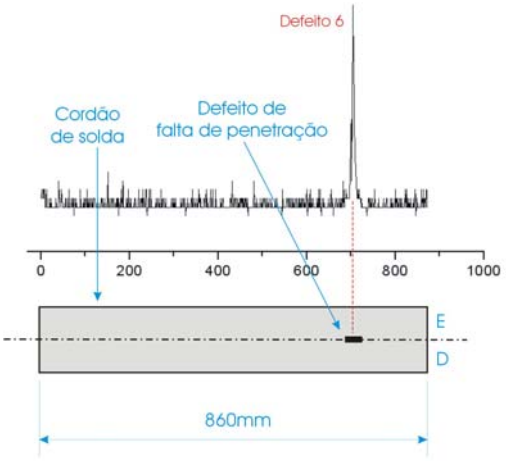

SOLDA 12 - Defeitos de Falta de Fusão

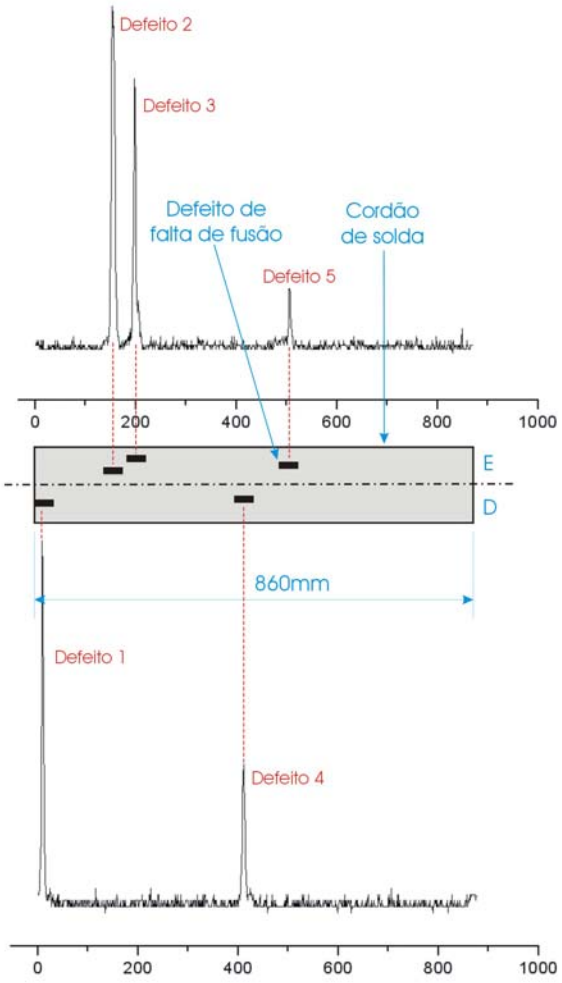

SOLDA 13 - Defeitos de Falta de Penetração

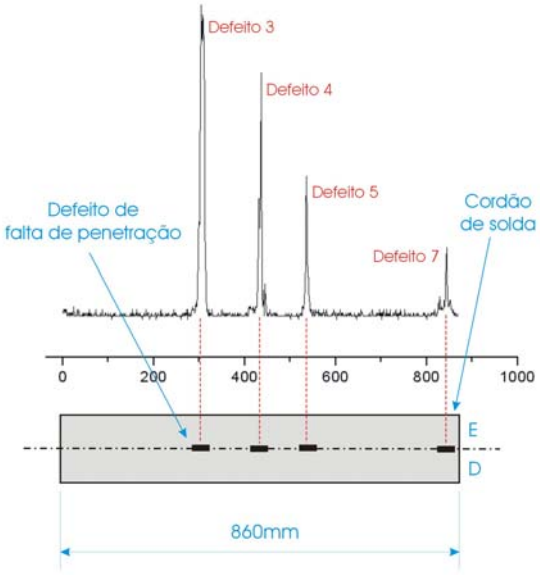

SOLDA 13 - Defeitos de Falta de Fusão

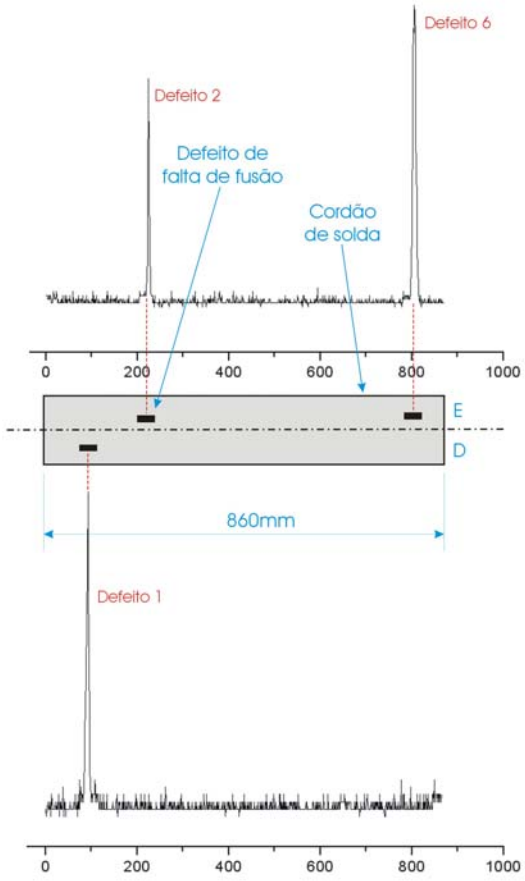

SOLDA 14 - Defeitos de Falta de Penetração

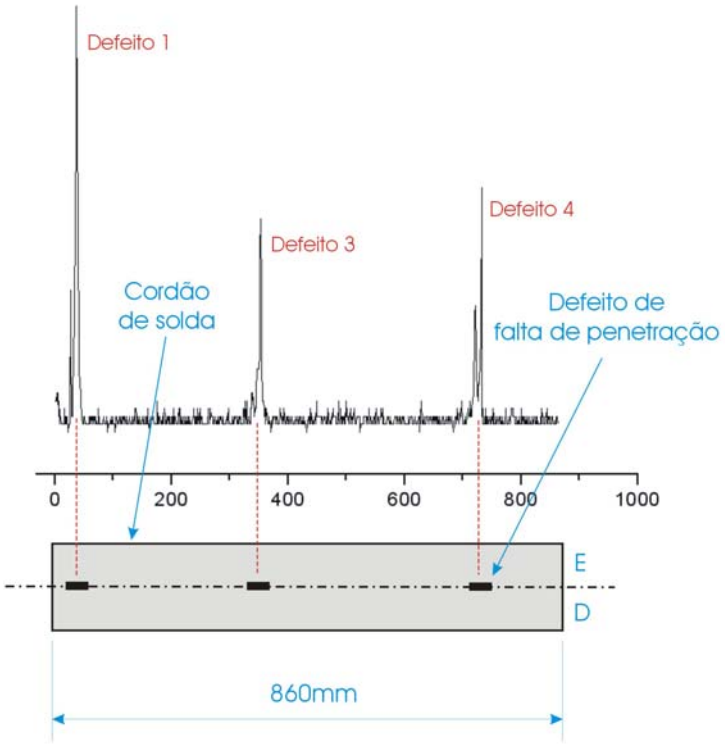

SOLDA 14 - Defeitos de Falta de Fusão

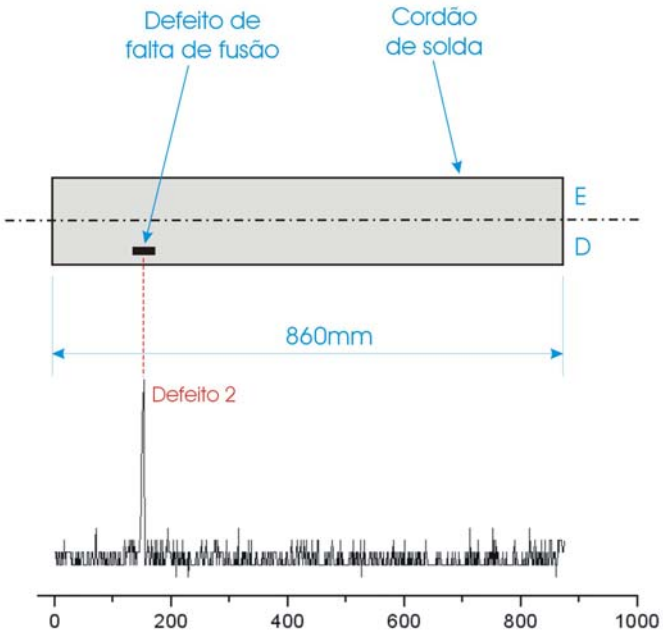

SOLDA 15 - Defeitos de Falta de Penetração

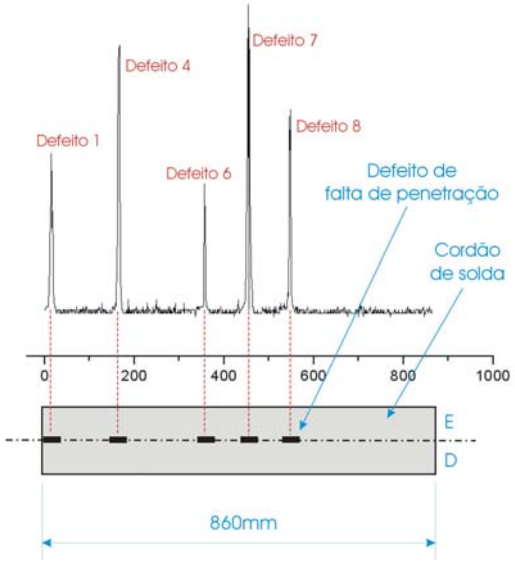

SOLDA 15 - Defeitos de Falta de Fusão

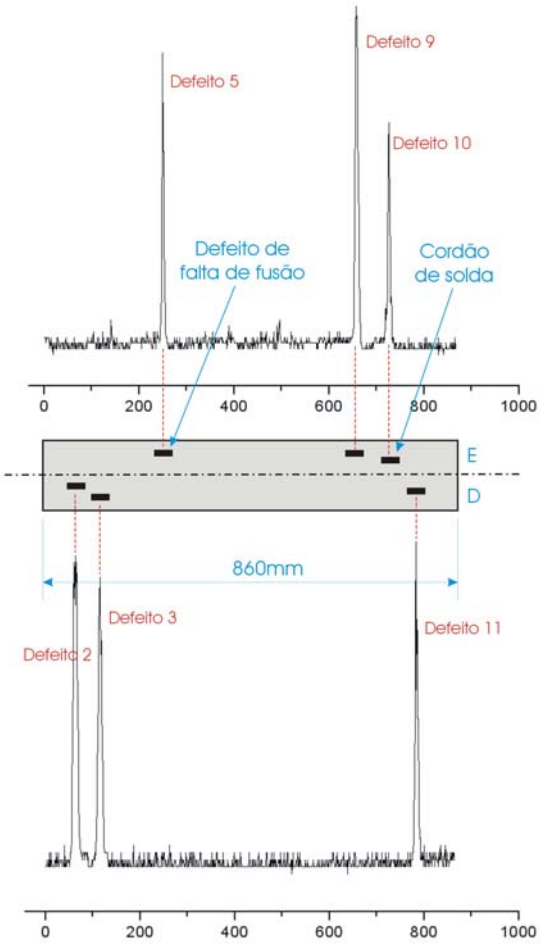

SOLDA 16 - Defeitos de Falta de Penetração

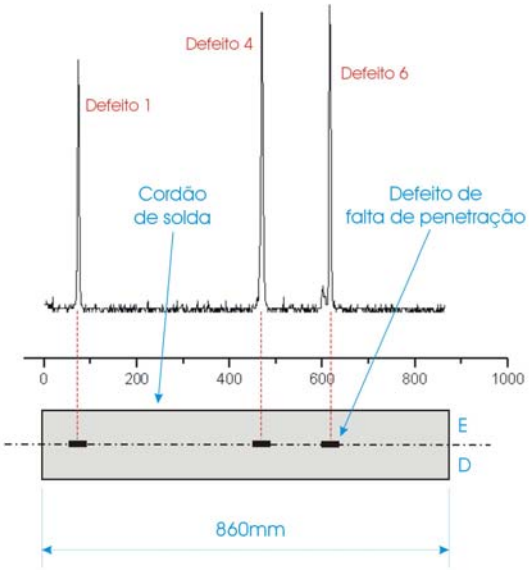

SOLDA 16 - Defeitos de Falta de Fusão

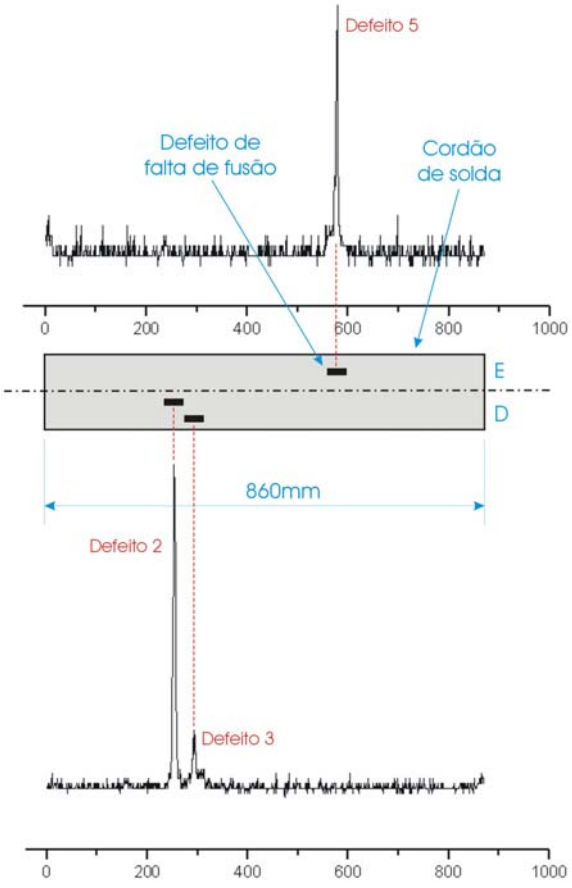

SOLDA 17 - Defeitos de Falta de Fusão

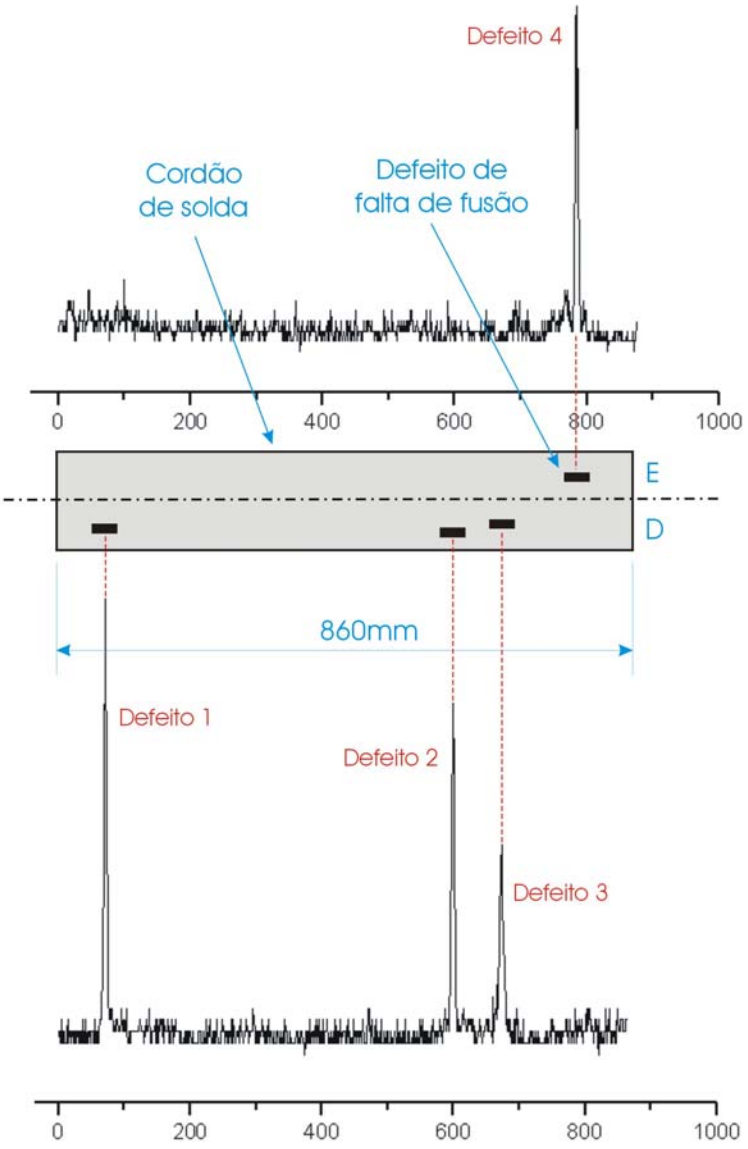

SOLDA 18 - Defeitos de Falta de Penetração

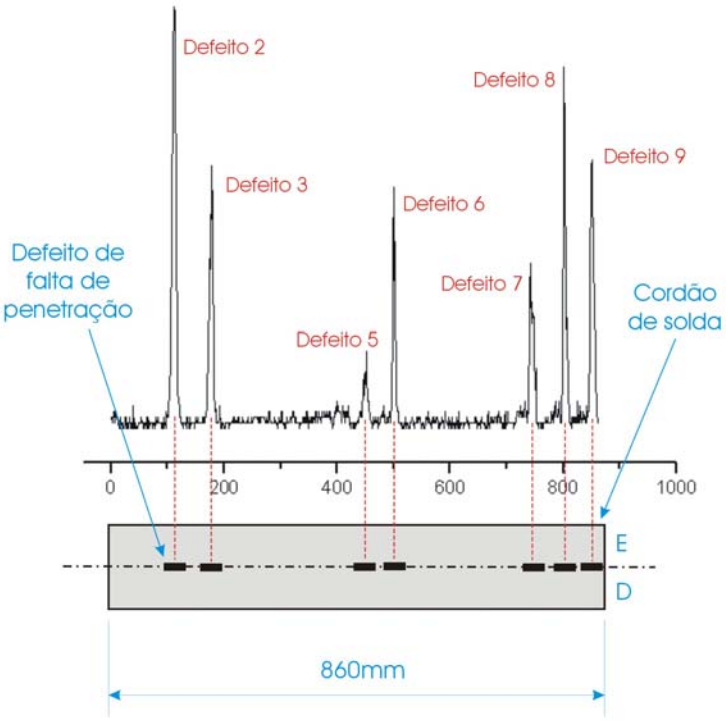

SOLDA 18 - Defeitos de Falta de Fusão

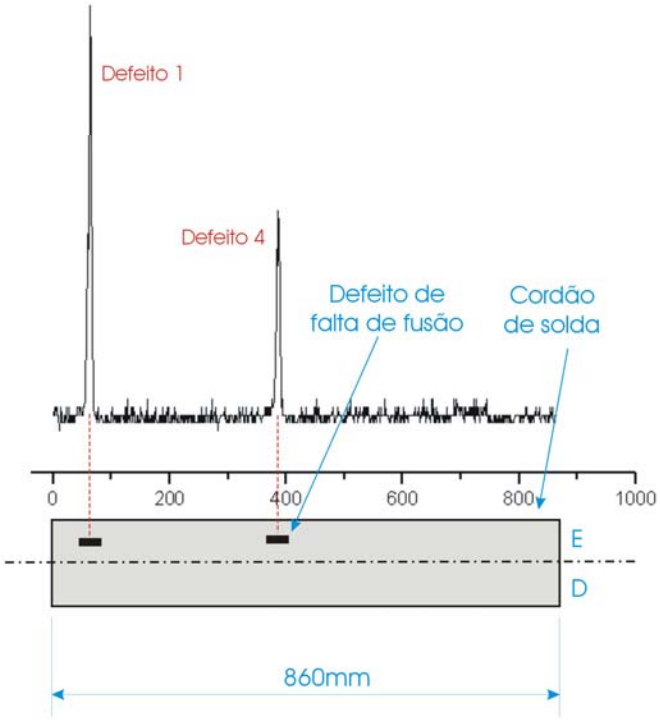

SOLDA 19 - Defeitos de Falta de Penetração

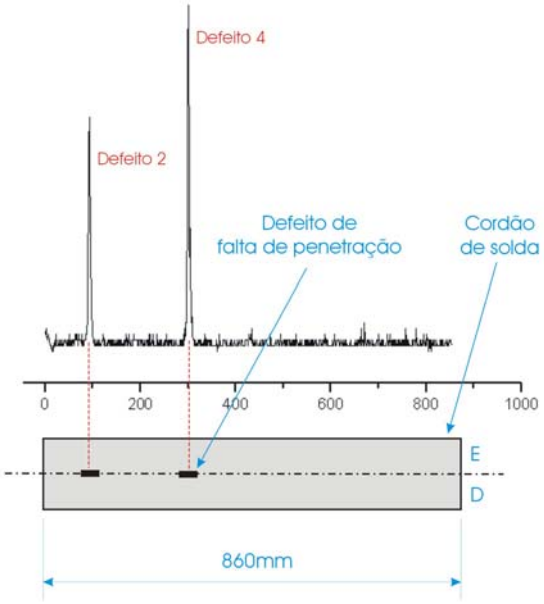

SOLDA 19 - Defeitos de Falta de Fusão

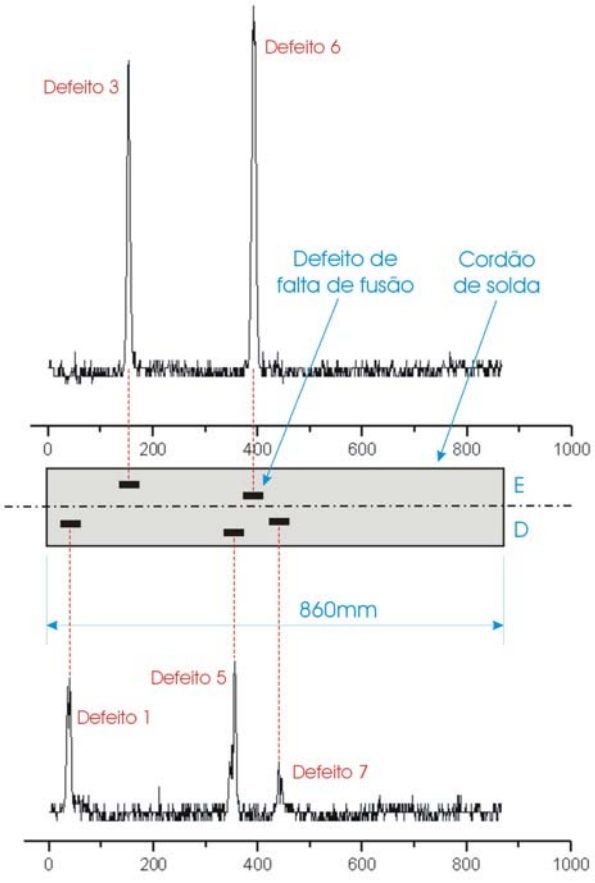

SOLDA 20 - Defeitos de Falta de Penetração

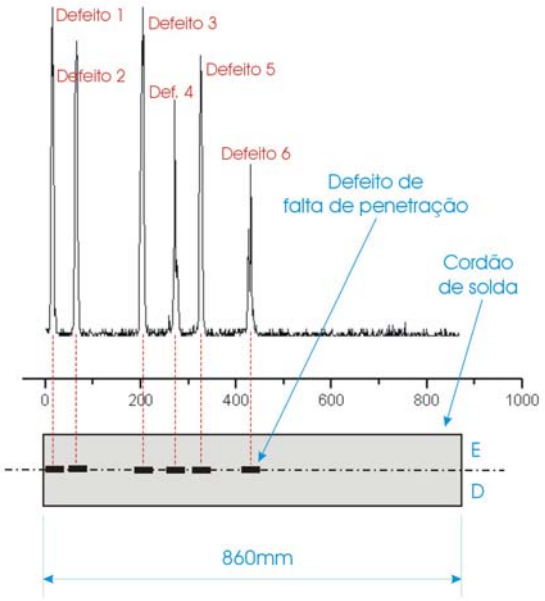

SOLDA 20 - Defeitos de Falta de Fusão

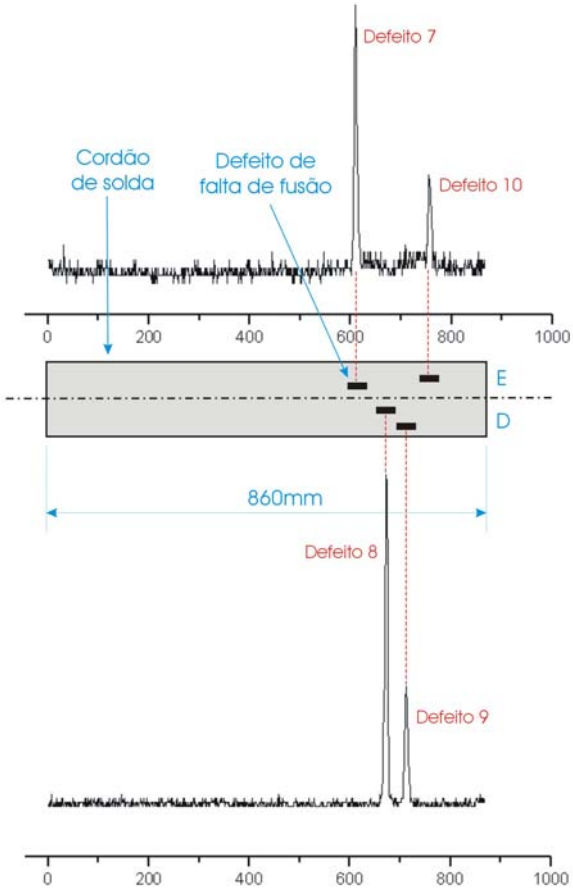

SOLDA 21 - Defeitos de Falta de Penetração

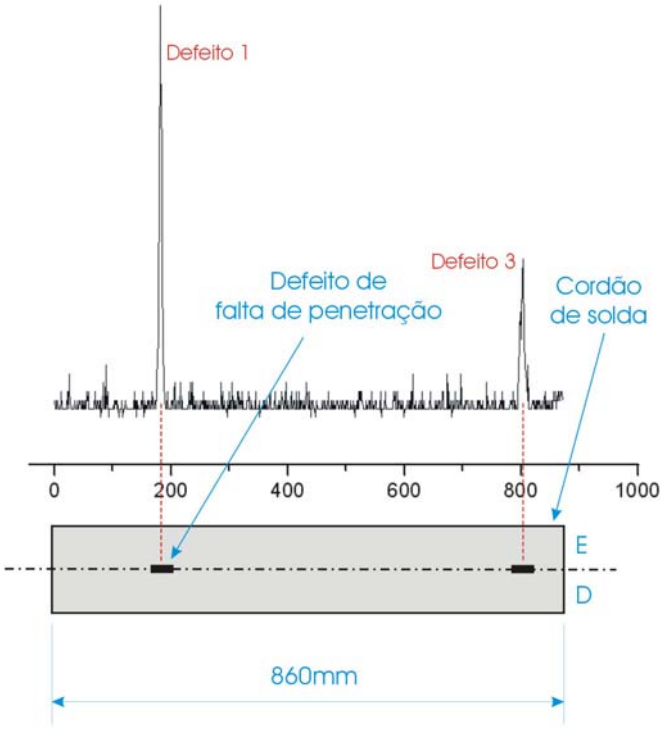

SOLDA 21 - Defeitos de Falta de Fusão

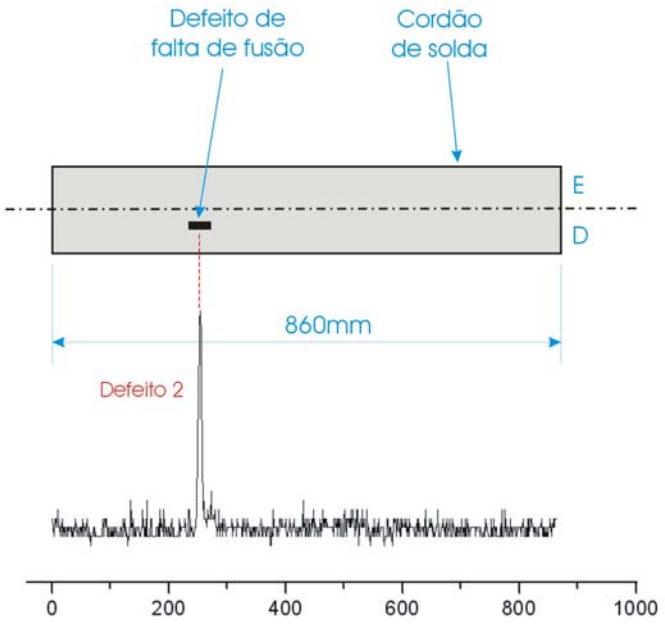

SOLDA 22 - Defeitos de Falta de Penetração

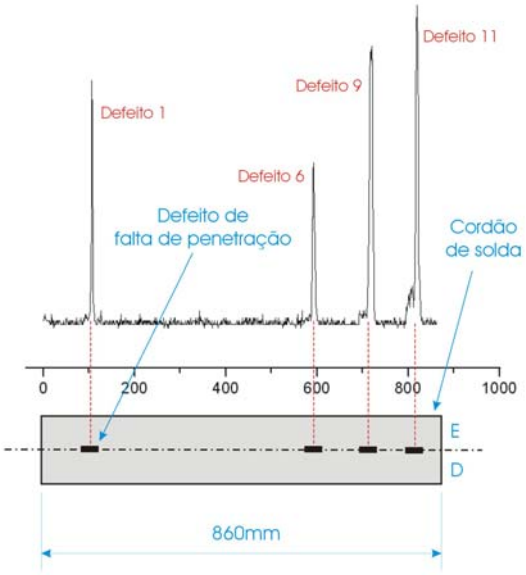

SOLDA 22 - Defeitos de Falta de Fusão

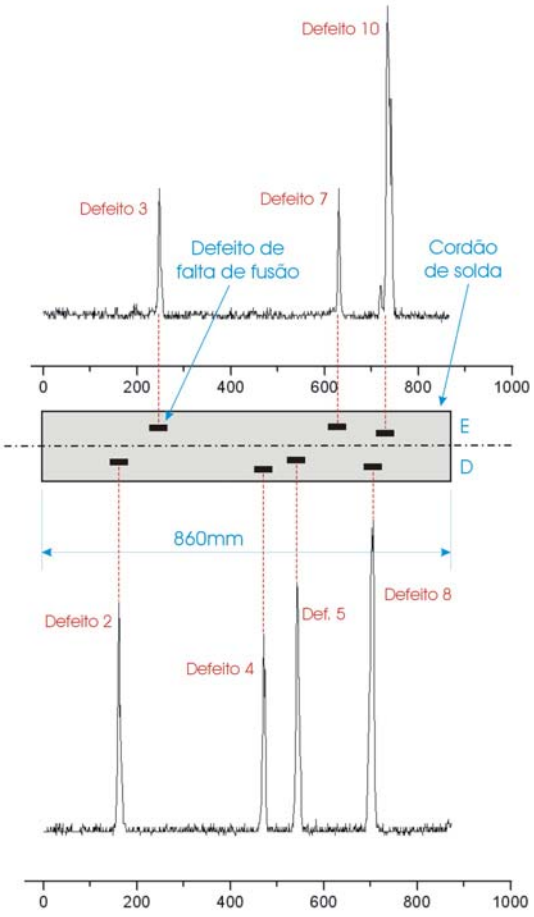

SOLDA 23 - Defeitos de Falta de Penetração

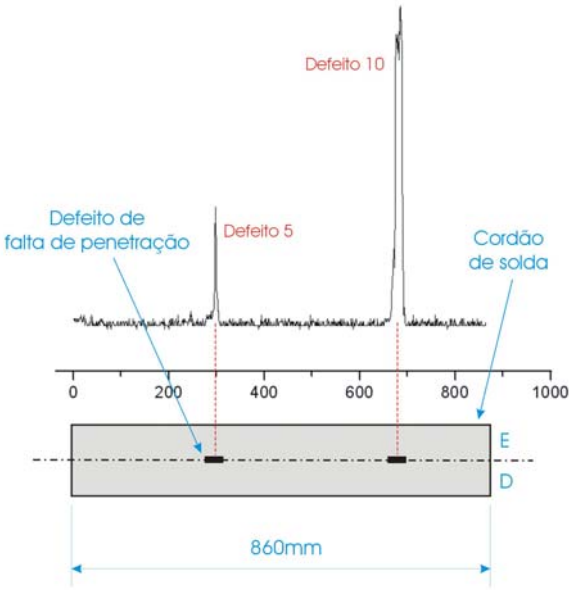

SOLDA 23 - Defeitos de Falta de Fusão

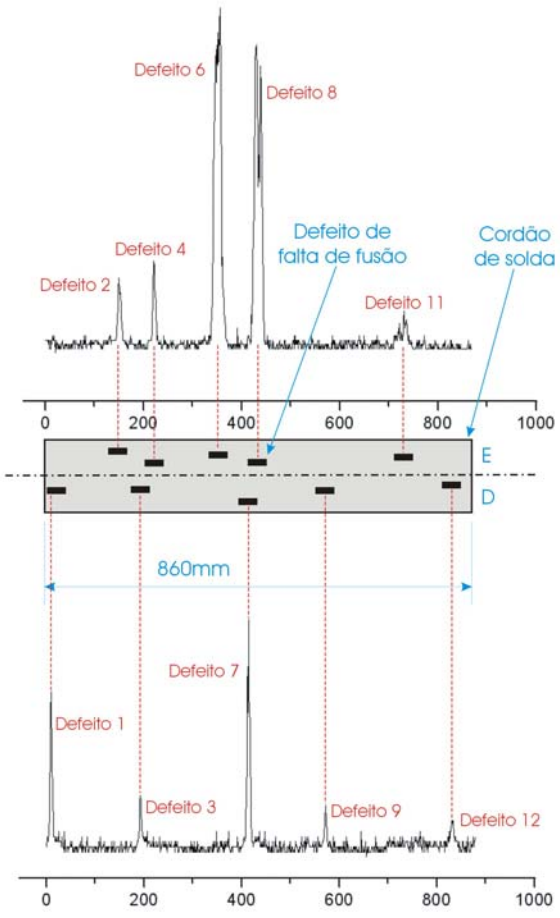

Anexo D

Resultados do ensaio de ultra-som por TOFD automatizado

Ensaios de ultra-som automatizado por *TOFD*

Foram empregados na confecção dos corpos de prova dutos de especificação API-X70, com diâmetro de 254mm, espessura de parede 19,05mm e comprimento de 3000mm. Nestes dutos foram inseridos defeitos artificiais nos cordões de soldas circunferenciais.

Classes de defeitos:

Falta de penetração (FP)

Falta de Fusão (FF)

Os defeitos foram inseridos com 4 comprimentos diferentes e 3 alturas, perfazendo um total de 12 defeitos com dimensões diferentes.

comprimentos: l = 3mm, 5mm, 7mm e 10mm

altura: h = 2mm, 3mm e 5mm

Um defeito com mesma dimensão foi repetido 5 vezes, perfazendo um total de 60 defeitos para cada classe.

Adicionalmente foram inseridos 5 defeitos de FP e 5 defeitos de FF com dimensões: l = 20mm e h = 3mm e ainda foram inseridos 20 defeitos de FF com comprimento e altura inferior a 3mm.

A Tabela a seguir mostra o total de soldas realizadas e a distribuição de defeitos por solda e em seguida são apresentadas as imagens D-scan obtidas através de varreduras destas soldas utilizando a técnica ultra-sônica automatizada de TOFD.

Tabela 1. Distribuição de defeitos por solda

Nº da Solda	**Nº Total de Defeitos**	**Nº de Defeitos (FP)**	**Nº de Defeitos (FF)**
0	11	2	9
1	0	0	0
2	10	4	6
3	1	1	0
4	6	3	3
5	8	3	5
6	3	0	3
7	2	1	1
8	1	0	1
9	5	3	2
10	8	6	2
11	5	3	2
12	6	1	5
13	7	4	3
14	4	3	1
15	11	5	6
16	6	3	3
17	4	0	4
18	9	7	2
19	7	2	5
20	10	6	4
21	3	2	1
22	11	4	7
23	12	2	10
Total	**150**	**65**	**85**

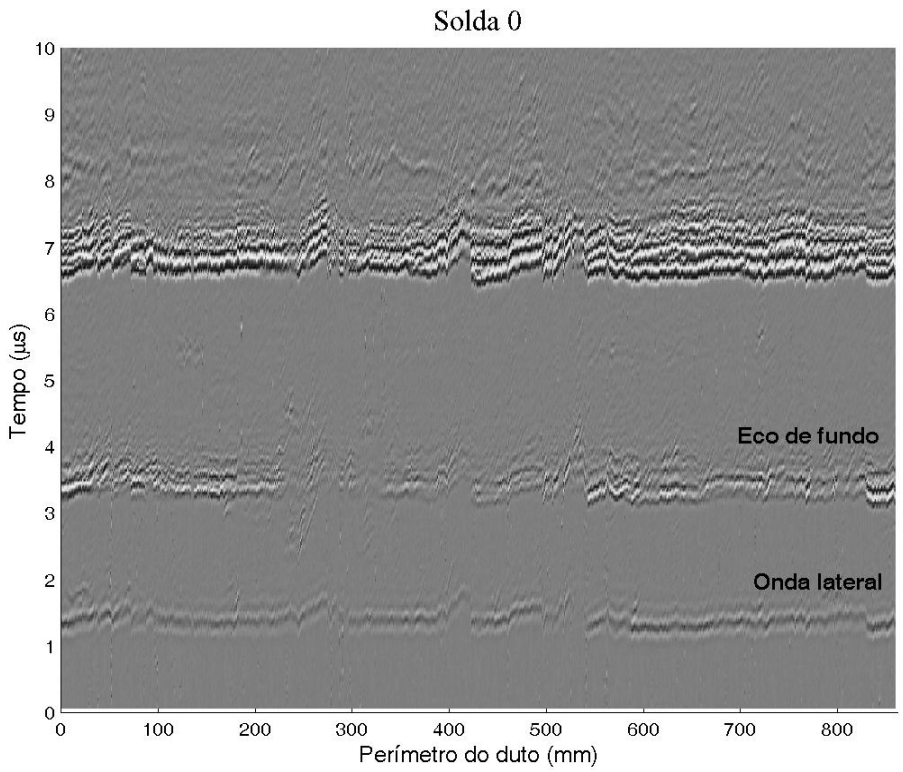
Solda 0
Tempo (µs)
Perímetro do duto (mm)
Eco de fundo
Onda lateral
0
1
2
3
4
5
6
7
8
9
10
0
100
200
300
400
500
600
700
800

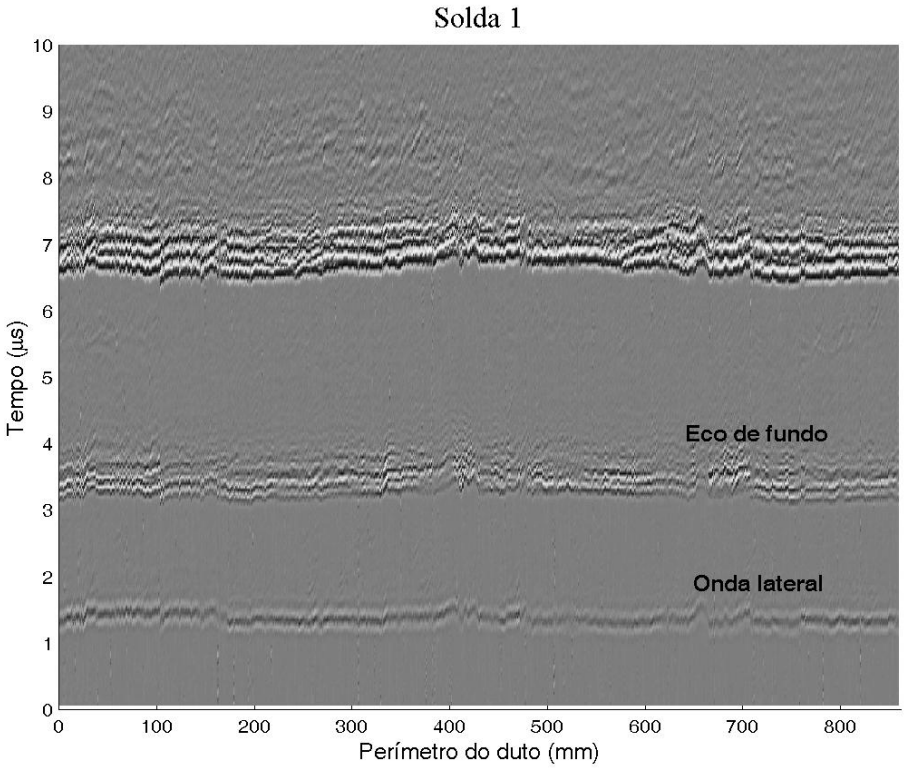
Solda 1
Tempo (µs)
Perímetro do duto (mm)
Eco de fundo
Onda lateral
0
1
2
3
4
5
6
7
8
9
10
0
100
200
300
400
500
600
700
800

Solda 2

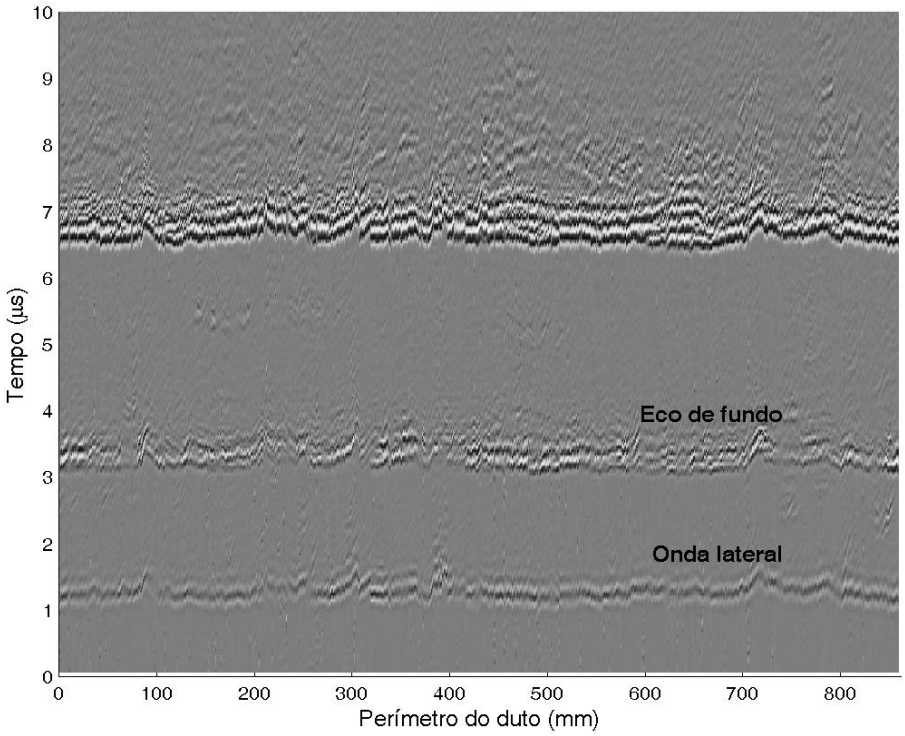

Solda 3

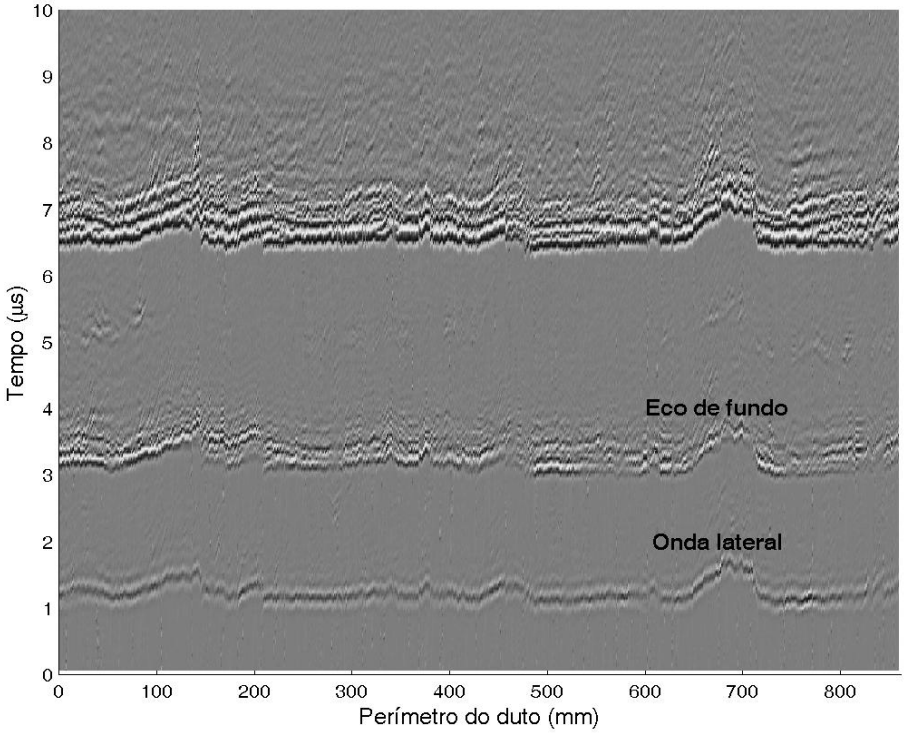

Solda 4

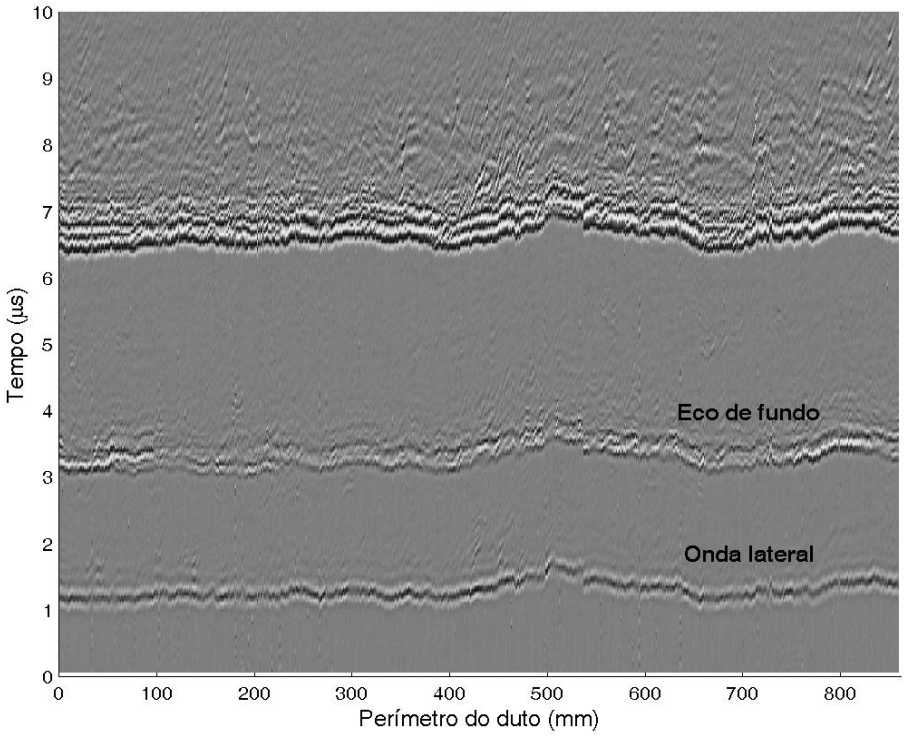

Solda 5

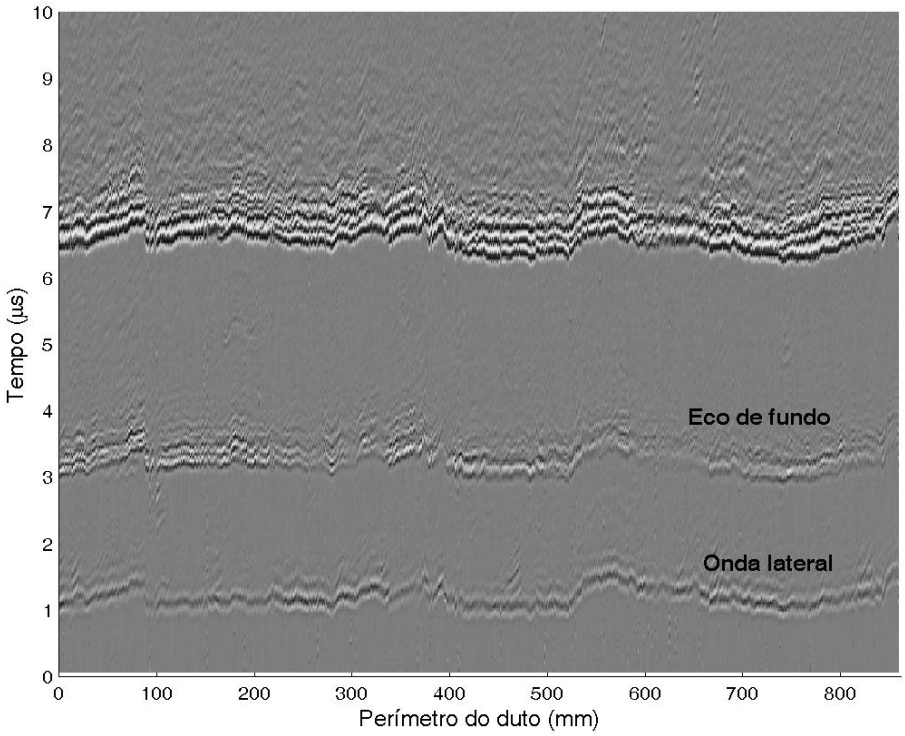

Solda 6

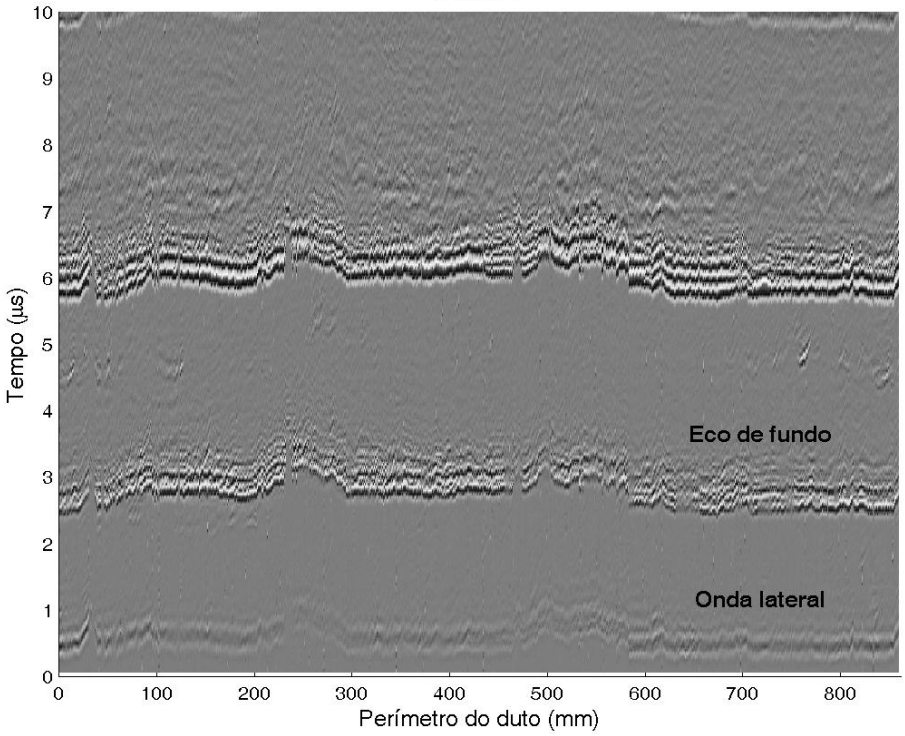

Solda 7

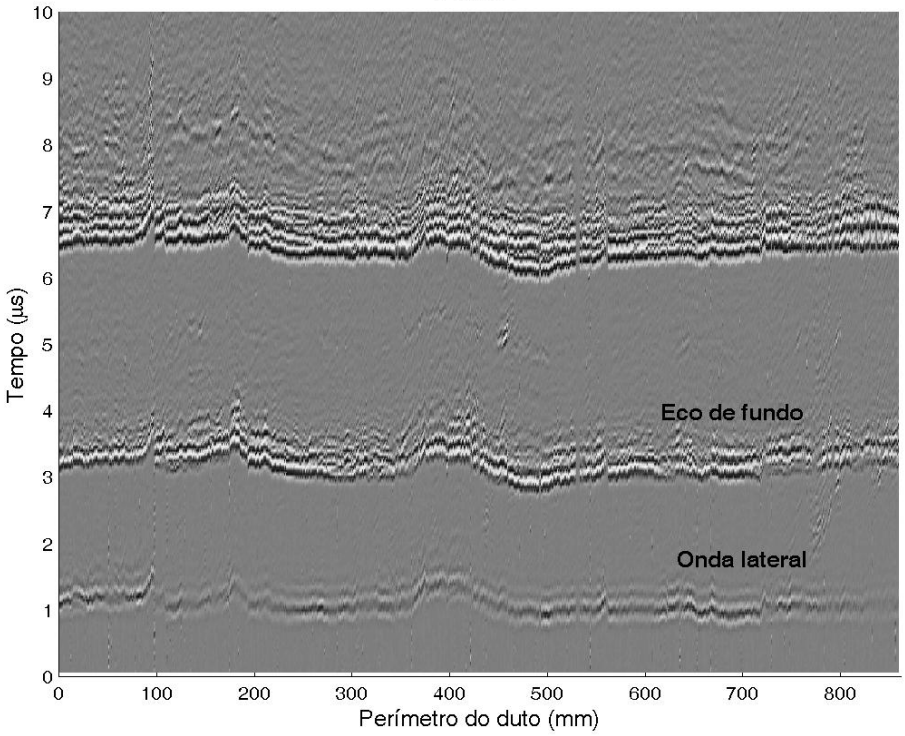

Solda 8

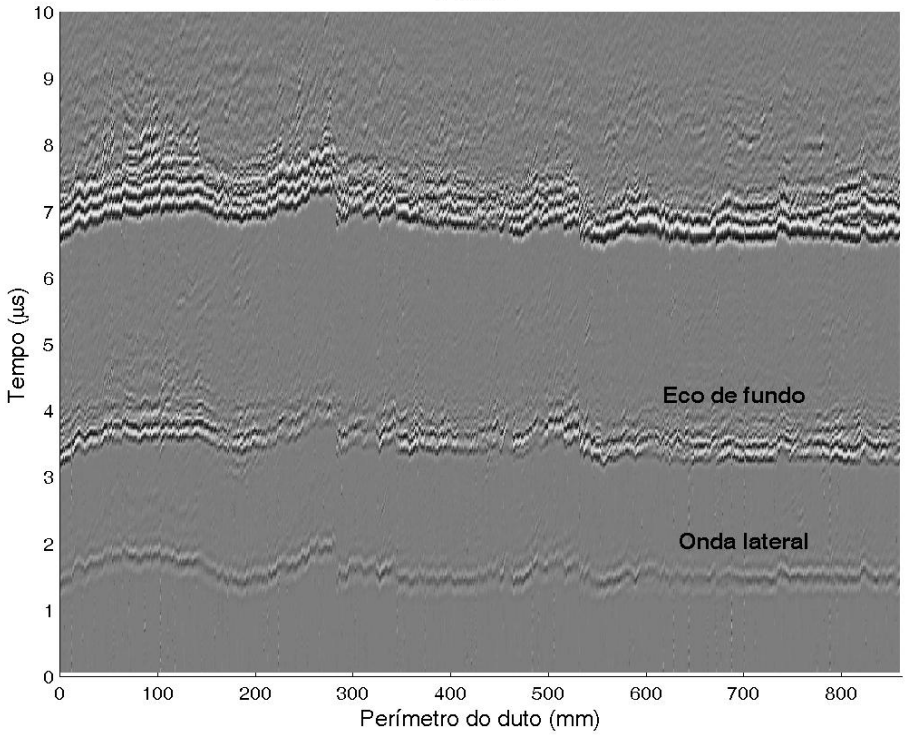

Solda 9

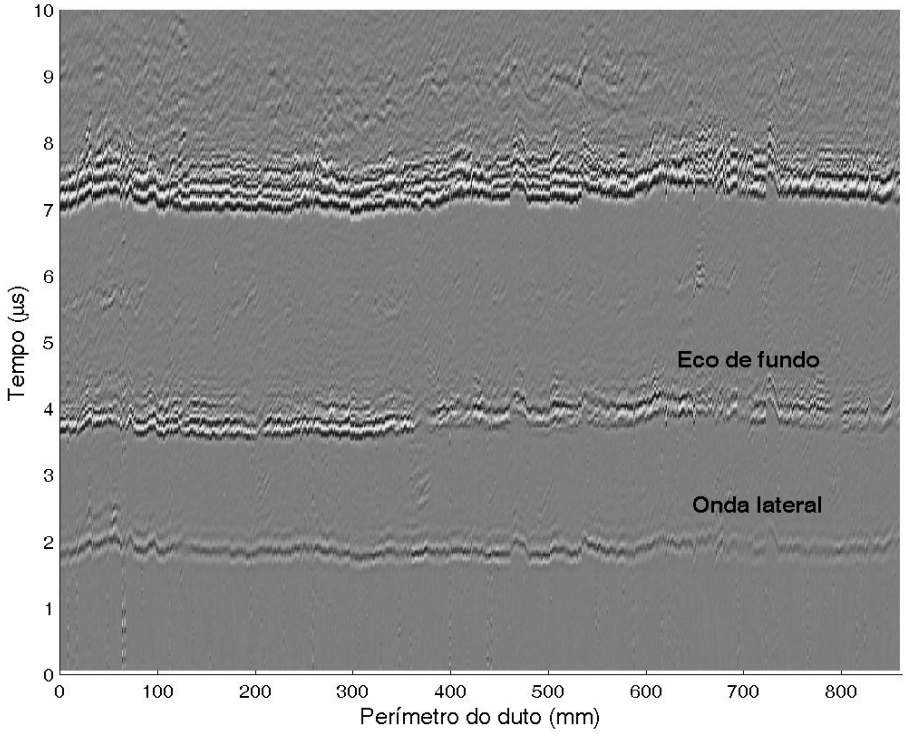

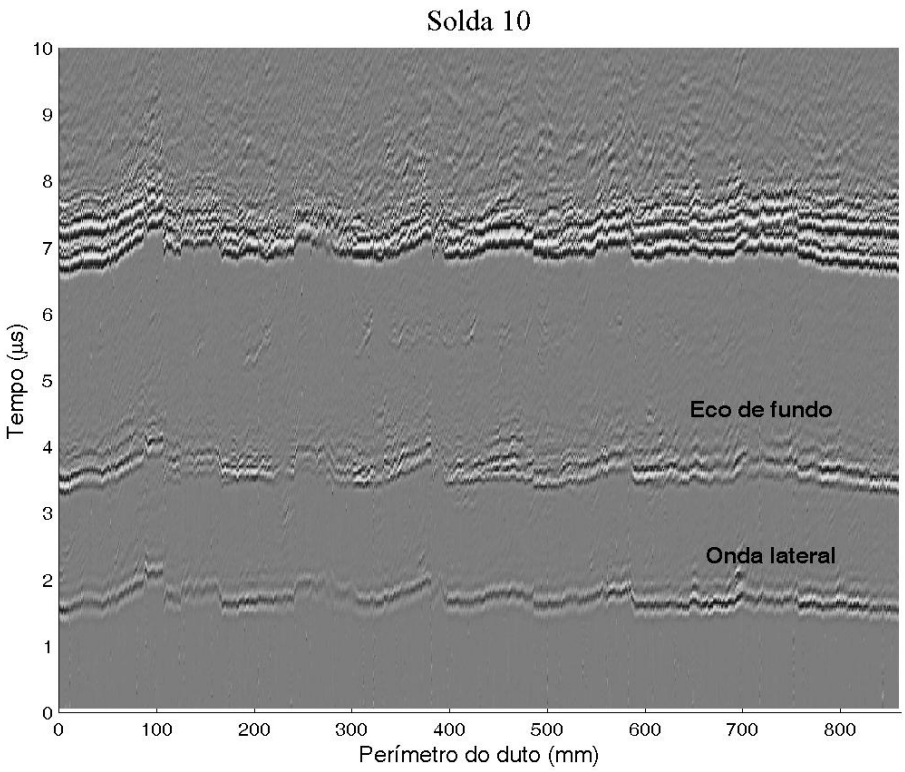
Solda 10
Tempo (µs)
Perímetro do duto (mm)
Eco de fundo
Onda lateral
0
1
2
3
4
5
6
7
8
9
10
0
100
200
300
400
500
600
700
800

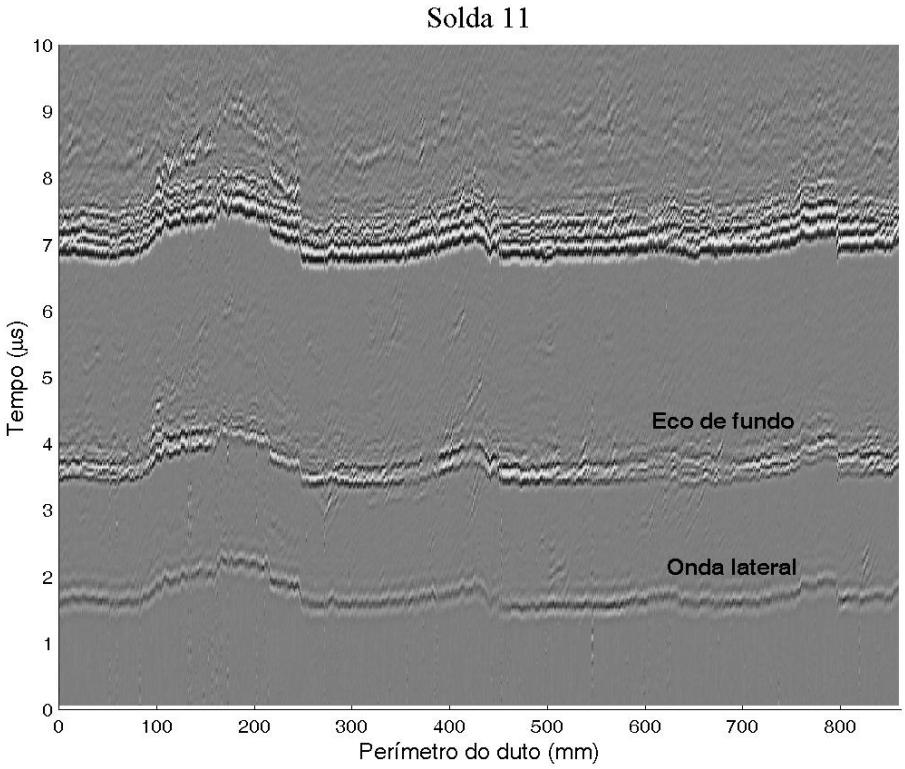
Solda 11
Tempo (µs)
Perímetro do duto (mm)
Eco de fundo
Onda lateral
0
1
2
3
4
5
6
7
8
9
10
0
100
200
300
400
500
600
700
800

Solda 12

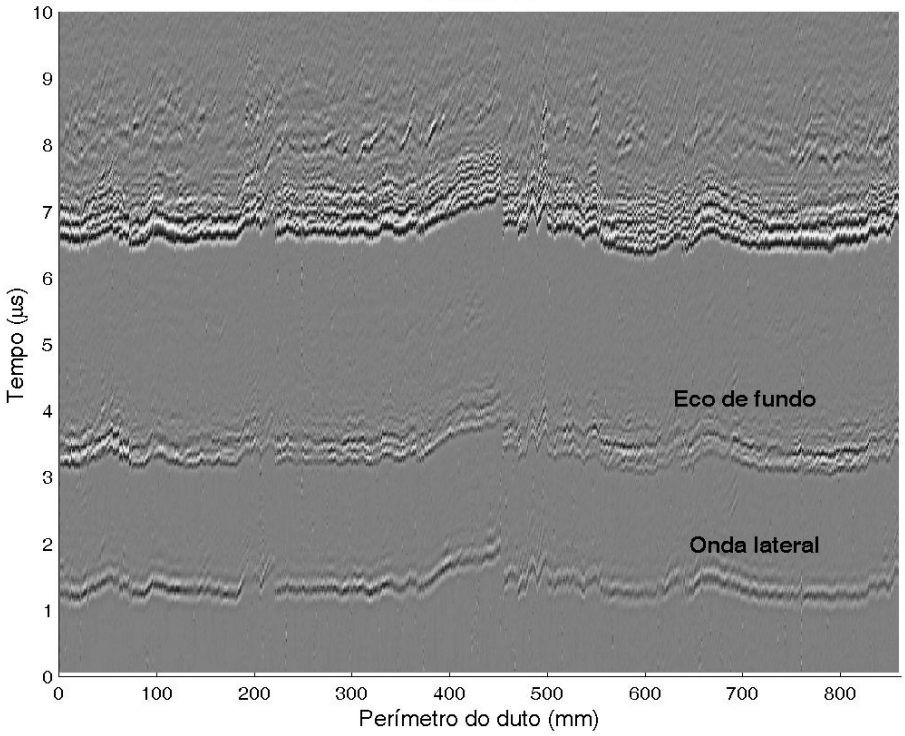

Solda 13

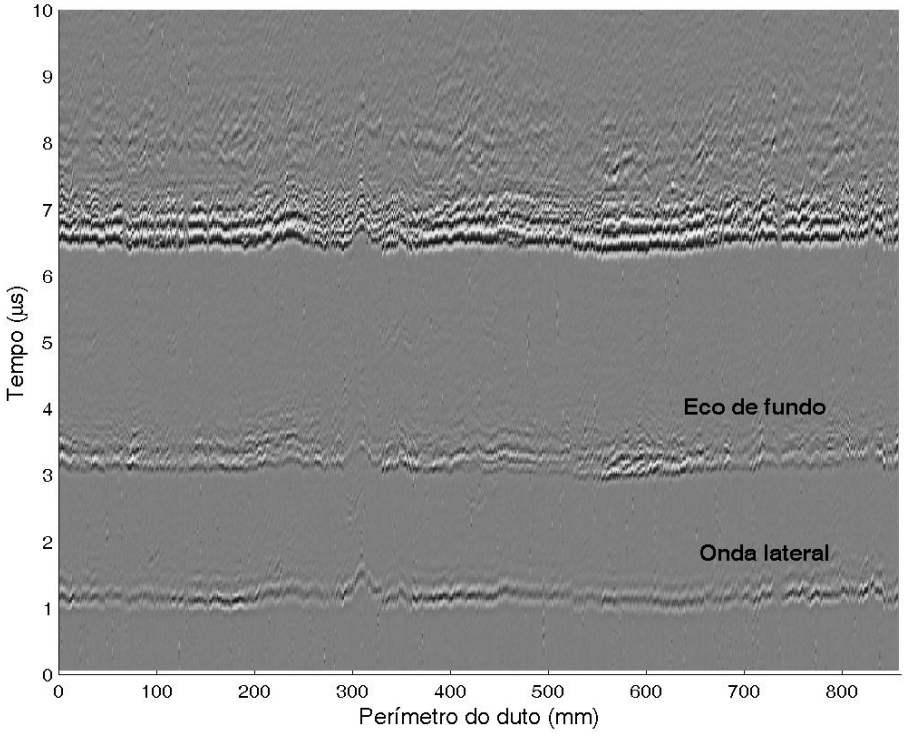

Solda 14

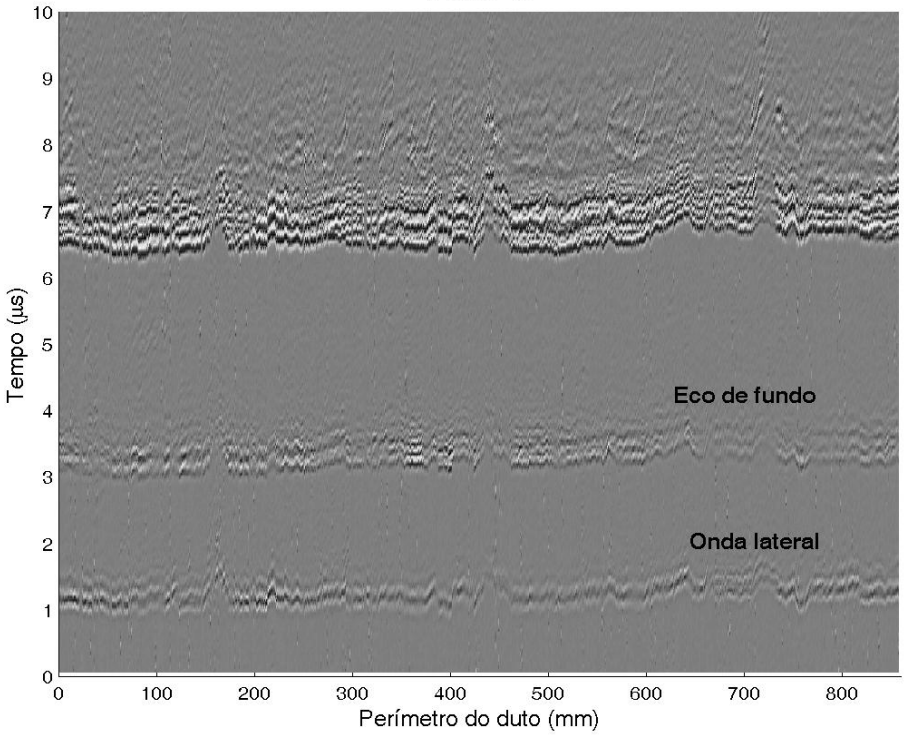

Solda 15

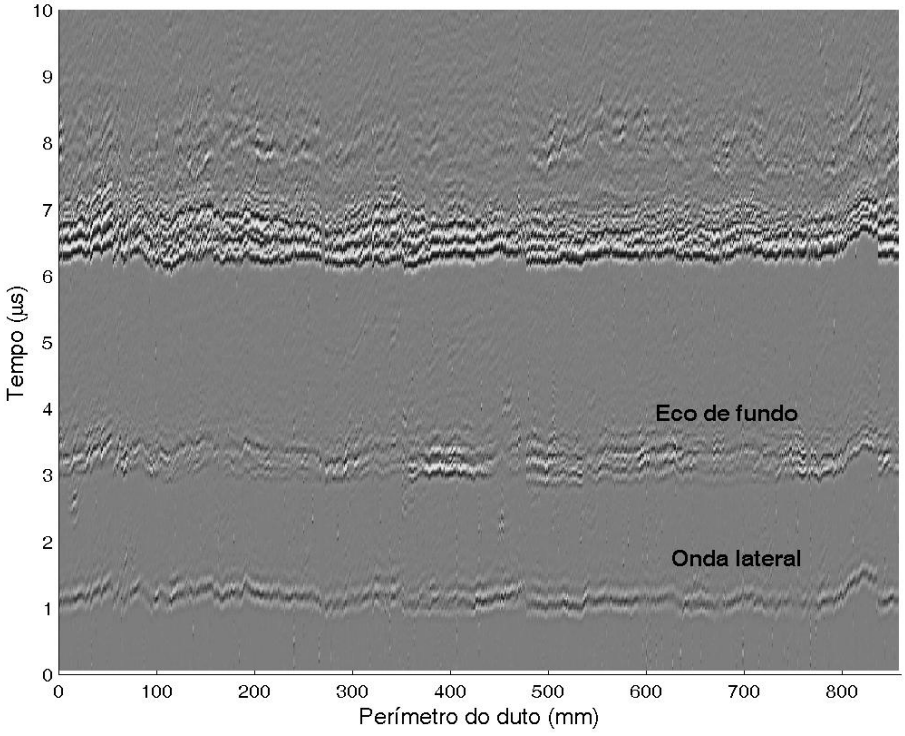

Solda 16

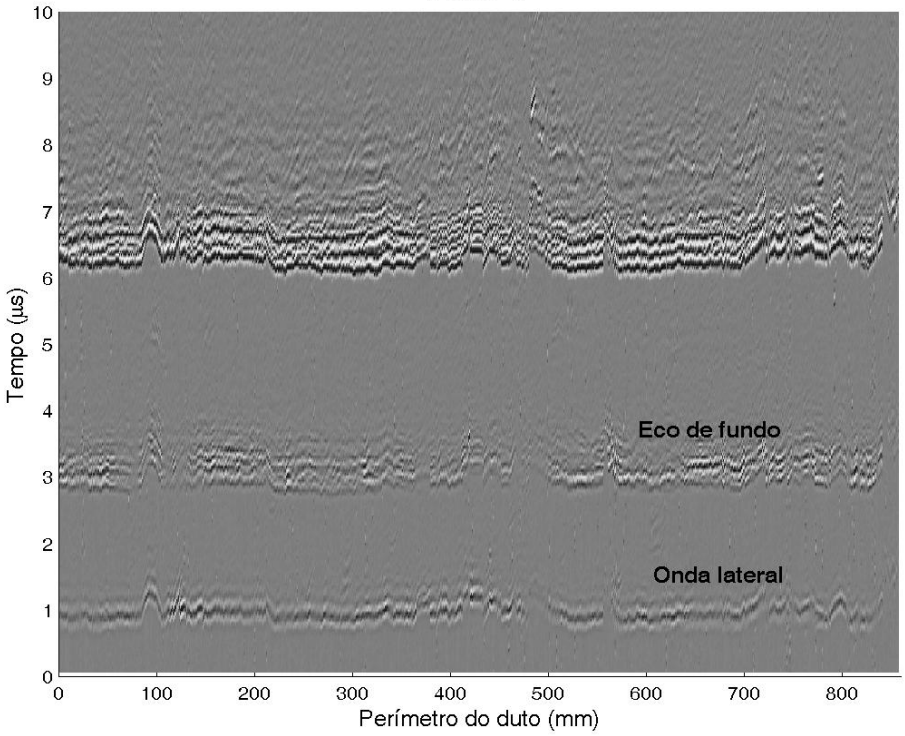

Solda 17

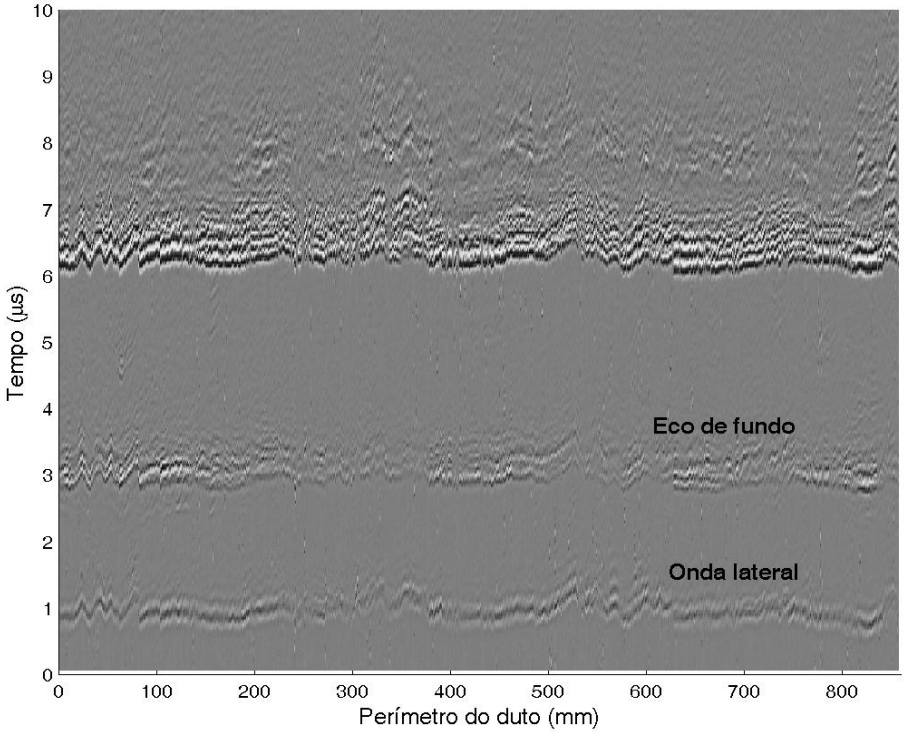

Solda 18

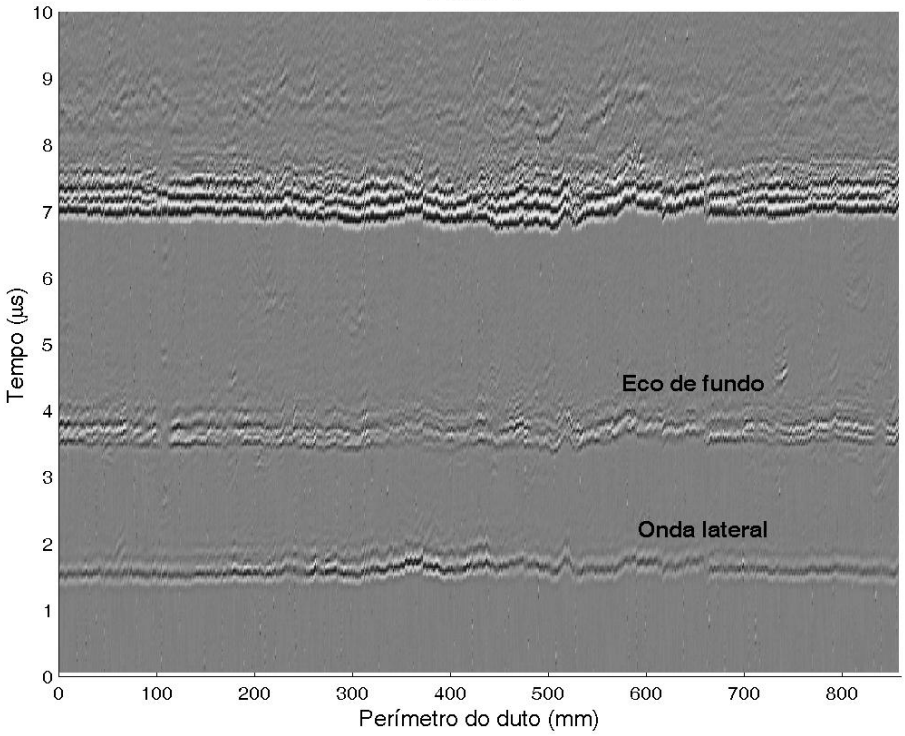

Solda 19

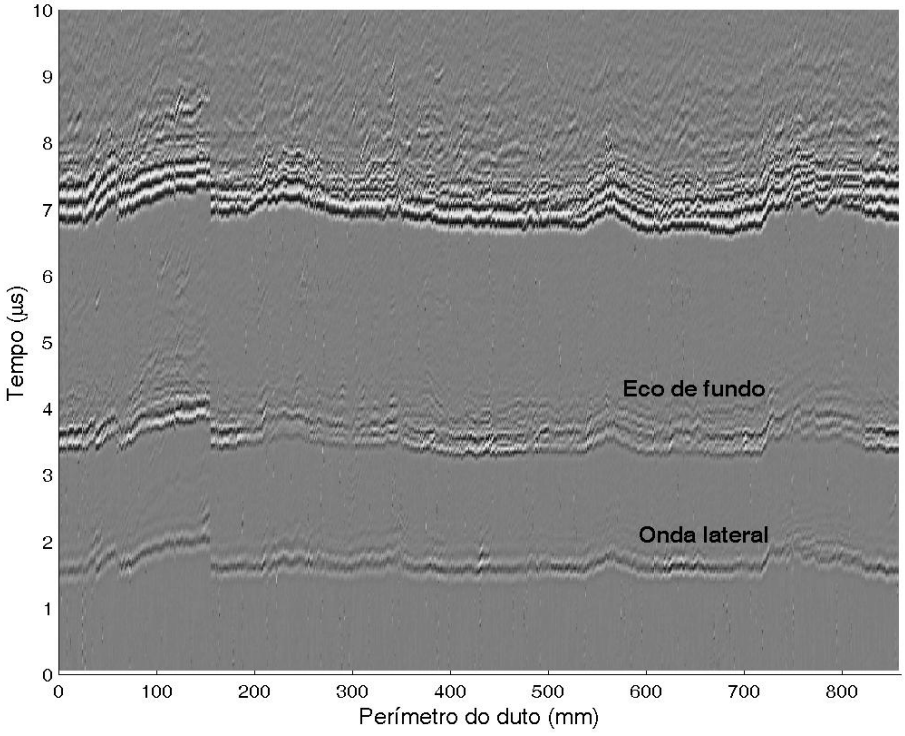

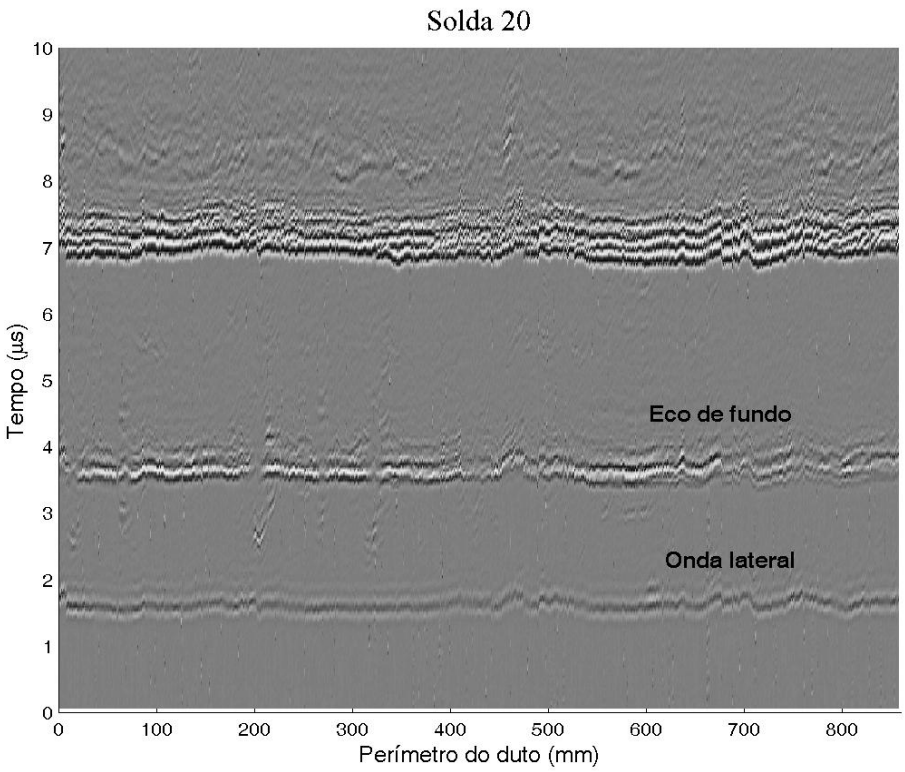
Solda 20
Tempo (µs)
Perímetro do duto (mm)
Eco de fundo
Onda lateral
0
1
2
3
4
5
6
7
8
9
10
0
100
200
300
400
500
600
700
800

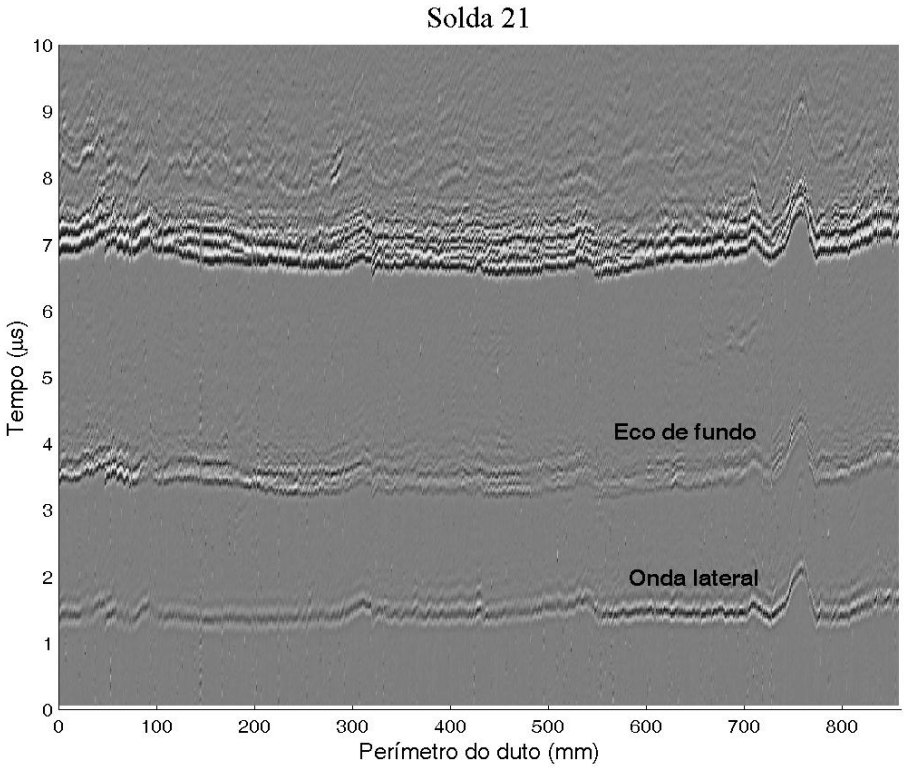
Solda 21
Tempo (µs)
Perímetro do duto (mm)
Eco de fundo
Onda lateral
0
1
2
3
4
5
6
7
8
9
10
0
100
200
300
400
500
600
700
800

Solda 22

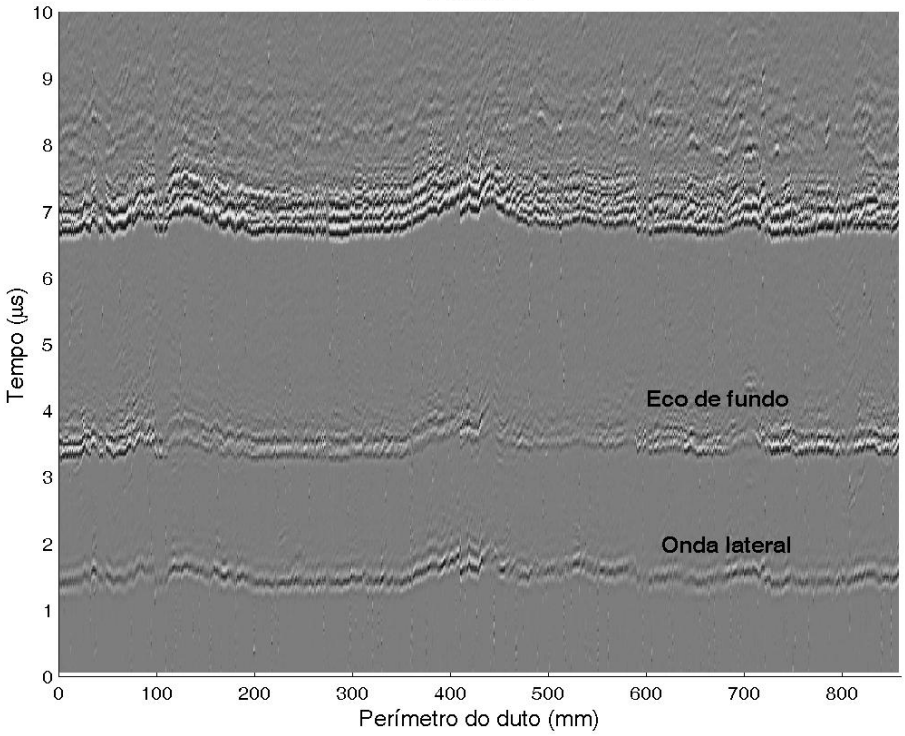

Solda 23

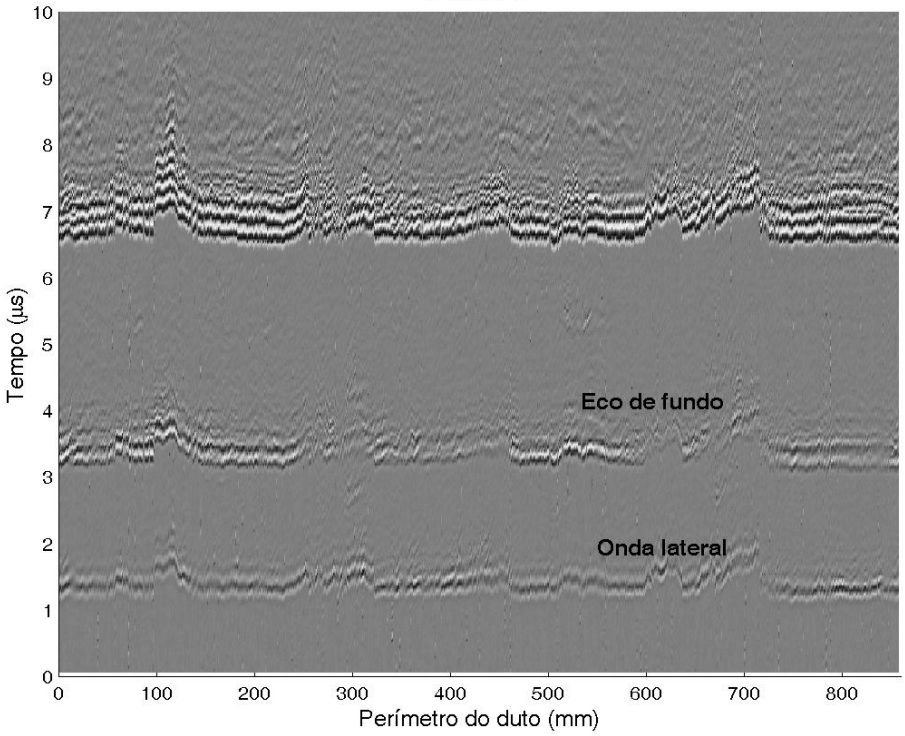

Anexo E

Artigos publicados

ARTICLE IN PRESS

Available online at www.sciencedirect.com

SCIENCE DIRECT

ELSEVIER

NDT&E International ▮ (▮▮▮▮) ▮▮▮–▮▮▮

NDT&E international

www.elsevier.com/locate/ndteint

MFL signals and artificial neural networks applied to detection and classification of pipe weld defects

A.A. Carvalho[a,*], J.M.A. Rebello[a], L.V.S. Sagrilo[b], C.S. Camerini[c], I.V.J. Miranda[d]

[a]*Department of Metallurgical and Materials Engineering, COPPE/UFRJ-Federal University of Rio de Janeiro, P.O. Box 68505, CEP 21941-972, Rio de Janeiro RJ, Brazil*

[b]*Department of Civil Engineering, COPPE/UFRJ-Federal University of Rio de Janeiro, P.O. Box 68505, CEP 21941-972, Rio de Janeiro RJ, Brazil*

[c]*PETROBRAS Research and Development Center (CENPES), Cidade Universitária, Q. 7, Ilha do Fundão, CEP 21949-900, Rio de Janeiro RJ, Brazil*

[d]*Pipe Way Engineering, Praça Mario Nazaré, 40 São Cristovão, CEP 20940-080, Rio de Janeiro RJ, Brazil*

Received 20 January 2006; received in revised form 7 April 2006; accepted 10 April 2006

Abstract

This work evaluates the use of artificial neural networks (ANNs) for pattern recognition of magnetic flux leakage (MFL) signals in weld joints of pipelines obtained by intelligent pig. Initially the ANNs were used to distinguish the pattern signals with non-defect (ND) and signals with defects (D) along of the weld bead. In the next step the ANNs were applied to classify signal patterns with three types of defects in the weld joint: external corrosion (EC), internal corrosion (IC) and lack of penetration (LP). The defects were intentionally inserted in the weld bead of a pipeline of API 5L-X65 steel with an outer diameter of 304.8 mm. In this way, the MFL signal itself, digitized with 1025 points, was used as the ANN input. Initially the signals were used as inputs for the neural network without any type of pre-processing, later four types of pre-processing were applied to the signals: Fourier analysis, Moving-average filter, Wavelet analysis and Savitzky–Golay filter. Signal processing techniques were employed to improve the performance of the neural networks in distinguishing between the defect classes.

The results showed that it is possible to classify signals of classes D and ND using ANN with very efficient results (94.2%), as well as for corrosion (CO) and LP signals (92.5%). Also it is possible to classify the defect pattern signals: EC, IC and LP using neural networks with an average rate of success of 71.7% for the validation set.

© 2006 Elsevier Ltd. All rights reserved.

Keywords: Non-destructive inspection; Pig; MFL; Neural network; Pattern recognition

1. Introduction

Pipelines are considered the most efficient way of transferring fluids (oil and gas) over long distances. However, despite this high-efficiency, there has been reasons for concern over the last years, principally because a large part of the existing pipeline networks are coming to the end of their useful life. Consequently it is necessary to be able to monitor, evaluate and to guarantee their structure as a whole, taking precautions against leaks and consequently protecting the environment and the population. Non-destructive tests (NDT) coupled with signal processing techniques and artificial intelligence, such as artificial neural network (ANN), have contributed positively to evaluate the structural integrity of the pipelines used by the petroleum industry.

The non-destructive inspection of pipelines for fluid transport is based principally on the magnetic flux leakage (MFL) technique, for the detection of discontinuities and loss of thickness due to corrosion (CO) of the pipeline walls, permitting a quantitative evaluation of the size of the defect [1–3]. The MFL technique uses a tool known as intelligent pig to inspect pipelines. The pig is propelled inside the pipe under the pressure of the fluid and it is equipped with various sensors to gather information on the state of the pipeline, Fig. 1. For pipelines that are buried, offshore or of difficult access this pig method is the only

*Corresponding author. Tel.: +55 21 8146 1794; fax: +55 21 2290 1544.
E-mail address: alves@metalmat.ufrj.br (A.A. Carvalho).

0963-8695/$ - see front matter © 2006 Elsevier Ltd. All rights reserved.
doi:10.1016/j.ndteint.2006.04.003

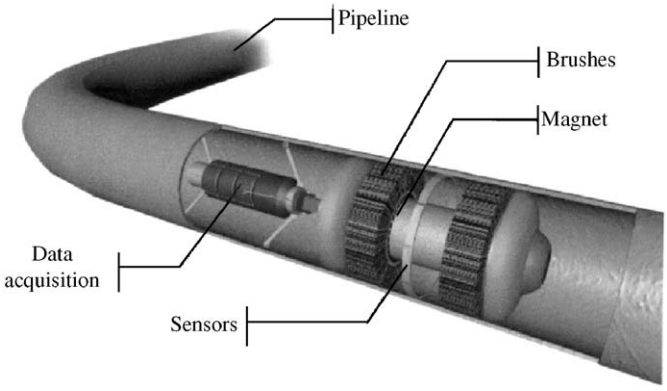

Fig. 1. Sketch of a magnetic pig.

possible option for inspection. Today there are two well-known techniques for pig inspection: ultrasonic and MFL, however approximately 90% of the inspections via pig are carried out using the MFL magnetic pig [1].

The MFL technique, if on the one hand, has a high probability of detecting defects, on the other, its ability to classify these defects is still questionable, since it is difficult to correlate the signal characteristics to the type of defect. Normally the classification of the signal is carried out visually; and so this basically depends on the ability and knowledge of the operator. However, the correct classification of the type of discontinuity on the pipeline wall would allow a faster and more precise decision to be made in terms of repairing the damage, reducing the risk of failures and consequently any temporary production loss or negative environmental impact.

The innovative growth of computational techniques, mainly in sciences related to artificial intelligence, like neural networks, has given a great impulse in the development of automatic inspection and classification systems of defect patterns [4–7]. In this work, the pattern classifiers used ANNs to recognize the classes of the MFL signals from intelligent pig inspection of weld joints. The performance of these classifiers was initially evaluated for the signal classification of defects (D) and non-defects (ND) and later for three types of defects of weld joints—external corrosion (EC), internal corrosion (IC) and lack of penetration (LP)—which were artificially introduced in the weld bead. Pre-processing techniques, such as Fourier analysis [8,9], wavelets transform [10,11] and Savitzky–Golay filter [12,13], were applied to the network input signals in an attempt to facilitate the automatic classification.

2. Methodology

2.1. Specimens

For the present study four specimens were prepared (S1, S2, S3 and S4) from seamless steel pipes with the specification API 5L-X65, having a length of 9100 mm, nominal outer diameter of 304.8 mm and wall thickness of 7.1 mm. On these specimens 12 circumferential welds were made with defects artificially inserted during the welding process (Fig. 2). Three classes of defects were simulated in the weld bead: EC, IC and LP. The defects were inserted at each 90° along the weld bead resulting in a total of four defects per bead, as seen in Fig. 2. The LP defect was introduced during the welding of the bead while the EC and IC defects were simulated with shallow groves inserted manually by machining (Fig. 3). The defects had depths varying between 3 and 5 mm and lengths varying between 10 and 50 mm.

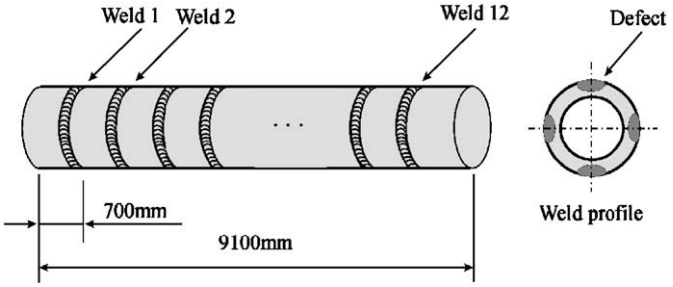

Fig. 2. Specimen used in the tests.

2.2. Tests with MFL pig

Intelligent pigs have electronic instrumentation adequate for each method of inspection for the measurement or recording of parameters to appraise the state of the pipeline. The use of intelligent pigs enables access to underground and subsea pipelines, which would be impossible using conventional inspection methods. An additional advantage of using pigs is that the inspection can be carried out during normal pipeline operation without causing any stoppages. Besides the sensors, pigs are equipped with units for acquisition, data processing and energy sources, and are able to travel for hundreds of kilometers while submitted to high pressures and in contact with the pipeline fluid [14–17].

The principle of MFL pig inspection is based on the application of a known external magnetic field onto a ferromagnetic material and measuring the response via appropriate sensors (Hall sensors or coil). If the material presents any discontinuity on its surface or interior, the external magnetic field will be disturbed, being the type of disturbance dependent on various factors, such as the intensity of the magnetic field applied, the geometry of the defect, the type of material, etc. [18,19], as shown in Fig. 4.

In this work it was used an MFL pig with 136 Hall sensors and a ring of coil type sensors, used to discriminate between internal and external defects.

2.3. Artificial neural networks

An ANN is a simple mathematical model whose purpose is to represent the human brain behavior in different situations [21]. This mathematical model consists of a generic interpolation equation that is function of the

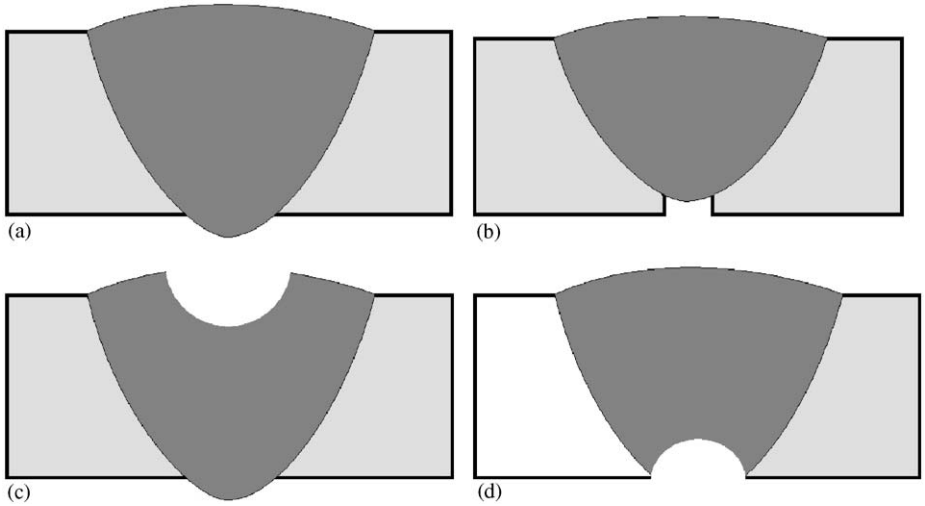

Fig. 3. Sketch of the four studied conditions of the weld bead: (a) non-defect; (b) lack of penetration; (c) external corrosion; and (d) internal corrosion.

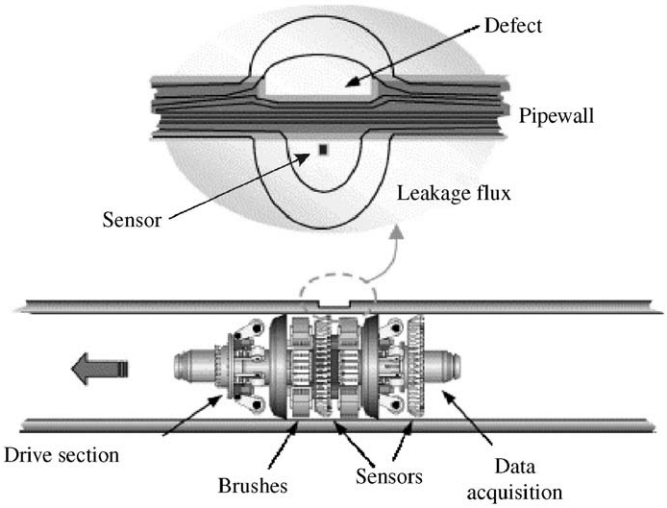

Fig. 4. MFL inspection [20].

components exciting the system (human neurons) and its associated response. This equation contains unknown constant coefficients (synaptic weights) that must be evaluated on the basis of known excitations (inputs) and responses (outputs). In the context of the ANNs this calculation is called training. In order to certify whether the model is working properly or not others known excitations and responses, not employed in the training, should be tested with the model.

Nowadays neural networks can be trained in order to help human beings to solve difficult problems. In this work an ANN is used with aims, (i) to improve the diagnostic of experts in the classification of the patterns of defects in weld bead and (ii) to obtain a reliable and fast tool for automatic classification of weld defects.

The use of neural networks in NDT is relatively recent, and has been applied mainly for the detection of discontinuities and pattern recognition. In this work, the ANN was used for the recognition of MFL signal classes. The neural network here works like a specialist in analyzing the MFL signals. An MFL specialist analyzes the signal and its relevant characteristics and then using his knowledge and experience decides whether there is ND or D and in the latter case infers on the type of defect. A neural network, like a specialist, extracts information from the signal to check if there is ND or D and in the latter case classify the defect; however since the neural network was set up by computational algorithms, it is much more precise in its results, being able to 'see' details that the human eye (a specialist) cannot.

In this work nonlinear pattern classifiers were implemented using ANNs of the supervised type using the error backpropagation algorithm and two layers, one hidden layer and one output layer [21]. Varying the number of neurons in the hidden layer and observing the performance of the classifier and the error at the end of the training it was possible to obtain the most adequate number of neurons for this layer in this study. The best configuration found was 15 neurons in the hidden layer. In an ANN for pattern classification the number of neurons in the output layer corresponded to the number of classes studied. Initially, in this work, two neurons were used to discriminate between D and ND classes and later three neurons were used to discriminate between the defect classes EC, IC and LP. In this way, the MFL signal itself, digitalized with 1025 points, was used as the ANN input, of which each point corresponded to an input of the network, while the output indicated one of the classes, as shown in Fig. 5.

2.4. Pre-processing of signals

Initially the signals were used as inputs for the neural network without any type of pre-processing, later the

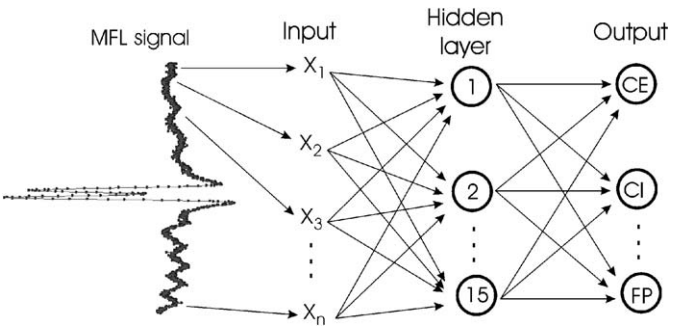

Fig. 5. Neural network used in the tests.

following four types of pre-processing were applied to the signals:

- Fourier analysis [8,9];
- moving-average filter [12];
- wavelet analysis [10,11];
- Savitzky–Golay filter [12,13].

Fourier analysis consists in decomposing a signal into its constituent sinusoids of different frequencies. Another way to think of Fourier analysis is as a mathematical technique for transforming the signal from the time domain to the frequency domain [8,9].

For many signals, the Fourier analysis is extremely useful because the frequency component contains very important information. There is, however, a serious inconvenience as, when the signal is transformed to the frequency domain, the time information is lost and so with the Fourier transform (FFT) of a signal it is impossible, in the present context, to say when the specific event occurred along the pipe length.

If the characteristics of the signal do not vary with time, that is, if the signal is what is called a stationary signal, this inconvenience is not very important. However, many signals contain numerous transitory or non-stationary characteristics, such as abrupt changes, fluctuations, discontinuities, etc. Often these characteristics are the most important part of the signal and in this case the Fourier analysis is not appropriate.

Wavelet transform was specifically developed to overcome the limitations of the Fourier analysis. The wavelet transform represents a type of compromise between a view based on the time and on the frequency of the signal. This technique supplies information on when and in which frequencies the event occurred [10,11]. Similarly to the FFT, that consists in the decomposition of the signals in harmonic functions of various frequencies, the wavelet transform is the decomposition of a signal in components (wavelets) that vary in scale (extended or compressed) and in positions (shifting wavelets) in relation to the original wavelet or ''mother wavelet''. In general a wavelet can be defined as a wave of limited duration that has an average value of zero and whose form tends to be irregular and asymmetric, contrary to harmonic components, that varying between $\pm\infty$ and are smooth and regular. However, a signal of the variable form can relate to the wavelet analysis better than to the Fourier analysis [22].

A moving average filter is a numerical procedure that smoothes data by replacing each original signal data point with the average of the neighboring points defined within a given span length.

Savitzky–Golay smoothing filter [12,13], also known as digital smoothing polynomial filter or least-squares smoothing filter, is typically used to smooth signals with noise and with large frequency intervals. This filter is less sensitive to width of interval since the new point, that is, the point of the signal just smoothed, is obtained by the adjustment of the points of the interval by a polynomial and not by the simple average of the neighboring points, as occurs with the standard moving-average filter, that tends to eliminate an important part of the contents of high-frequency of the signal together with the noise. This characteristic allows the Savitzky–Golay filter to be applied to analytical signals with thin peaks, presenting improved results to those obtained with the moving-average filter [12].

3. Results

Initially the performance of the ANN was evaluated for the recognition of signal patterns of classes D and ND. Consequently the signals of the specimens S1, S2 and S4 were grouped together in a single set of data and then randomly separated into a training set (70% of data) and test set (30% of data) and the signals of the specimen S3 were used only for network validation. The training set is the set of inputs and outputs employed just to train the neural network. The test set is another independent set of known inputs and outputs used in order to ensure that the results predicted by the ANN correspond to the correct ones, i.e., this set is employed to certify that the ANN is able to answer correctly to situations not experienced in the training phase. The validation set, as used in this paper, works like a second test set and provides another measure of how well the ANN is performing on data not used to train it.

Table 1 shows the results of the neural network in classifying the classes D and ND without any type of pre-processing for the training, test and validation sets. For this 300 signals were used for training, 120 for test and 120 for validation, for each class. The table shows that the ANN presented an average rate of success of 100% for the

Table 1
Classification D × ND—training, test and validation

Samples	Rate of success (%)	Errors (%)
Training 300	100	0
Test 120	100	0
Validation 120	94.2	D(10) and ND(1.7)

training and tests sets and 94.2% for the validation set. For the validation set, the ANN confused 10% of the D class signals with ND class signals and 1.7% of the ND class signals with D class signals. Therefore, the D class presented a rate of success of 90%, while the ND class presented a rate of success of 98.3%, giving an average of rate of success in identifying D and ND classes of about 94.2%. A possible explanation for this confusion is that the defects were inserted in the pipeline with different depths and as defects with small depths generate signals with very low amplitudes they are easily confused with the signals of the ND class. Also it should be taken into consideration that the variation of thickness due to the reinforcement of the weld bead had an influence on the signal. However, this is the most critical situation, since the ANN would transmit a diagnostic of false security in relation to the real conditions.

Table 2
Classification EC × IC × LP—training, test and validation

Samples	Rate of success (%)	Errors (%)	Confusion with (%)
Training 100	100	0	—
Test 40	95.8	EC (7.5)	IC (2.5) and LP (5)
		IC (2.5)	EC (2.5)
		LP (2.5)	EC (2.5)
Validation 40	66.7	EC (57.5)	IC (47.5) and LP (10)
		IC (35)	EC (20) and LP (15)
		LP (7.5)	EC (5) and IC (2.5)

Table 2 presents the results for training, test and validation sets in classifying the defect classes EC, IC and LP. One hundred signals of each class were used for training, 40 for test and 40 for validation. The ANN presented a very satisfactory performance for training and test sets giving an average rate of success for training of 100% and for tests 95.8%. For the validation set there was a large drop with an average rate of success of 66.7%. The greatest amount of confusion occurred between the classes EC and IC, which was expected since the signals are very similar. The class LP presented a high rate of success equal to 92.5%.

Due to the low success rate obtained by the ANN for the validation set (66.7%), it was decided to pre-process the input signals of the network to try to eliminate irrelevant

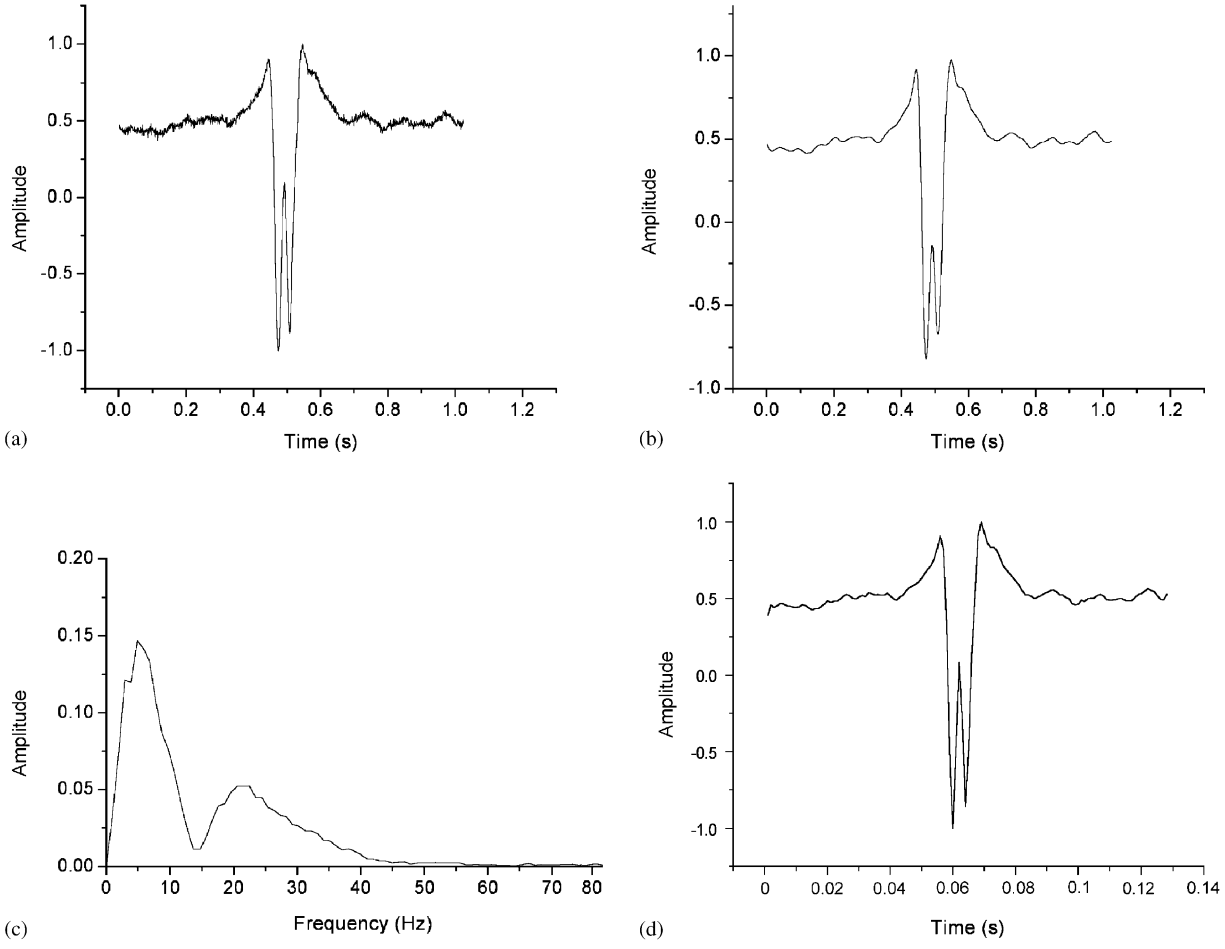

Fig. 6. Signal of class EC: (a) original signal; (b) Savitzky–Golay filter; (c) Fourier transform (FFT); and (d) wavelet coefficients. Amplitudes were normalized.

characteristics that could hinder the classification of the defect classes and so improve the performance for the validation set. The neural network inputs were pre-processed by the methods described above: FFT, wavelet transform, moving-average filter and Savitzky–Golay filter, of which the wavelet transform was used in a continuous and discrete form [10,11]. Fig. 6 shows examples of these processing for an EC class signal.

Tables 3–7 show the results of the output of the network for the pre-processed signals. These tables showed that there was no significant improvement in the performance of the ANN for the validation data set. The best result being obtained by using coefficients of continuous wavelet as input for the neural network (71.7%) and the worst was when the FFT (61.7%) was used. This means that the details are not preponderant for the classification of the signal, that is, the difference between classes is more in the form of the signal than in its details. However, the pre-processing considerably reduced the time of training of the ANN, since the original signal contained 1025 points and in some cases, when the signal was pre-processed, this number was reduced to 128 points. Since this procedure will be applied for pig training, where an inspection run is several kilometers long, the processing time is an important factor.

Concerning the CO defects, according to the standards, only the maximum depth of CO "*d*" is taken into consideration without considering its location, that is, the standards give the same treatment for the loss of pipeline wall thickness due to CO not taking into account whether it is internal or external. Therefore, as EC and IC are equally hazardous for the physical integrity of the pipeline and for a specific amount of area corroded corrective measures should be taken to avoid an accident, independent of being internal or external, the two types of CO could be joined into only a single class. Consequently, the classification of the classes of defects falls into only two classes: CO and LP. A computational test using these criteria was carried out on 100 signals of class CO and 100 of class LP for training and 40 signals of each class for test. The results in Table 8, obtained without any pre-processing approach, show a considerable increase in the performance of the ANN for the classification of the validation set in relation to the previous trials. The rate of success for the signals of the validation set, which now was 92.5%, can be

Table 3
Classification EC × IC × LP—training, test and validation—FFT

Samples	Rate of success (%)	Errors (%)	Confusion with (%)
Training 100	100	0	—
Test 40	97.5	EC (5)	
		IC (2.5)	
		—	
Validation 40	61.7	EC (67.5)	IC (47.5) and LP (20)
		IC (37.5)	EC (37.5)
		LP (10)	EC (7.5) and IC (2.5)

Table 4
Classification EC × IC × LP—training, test and validation—moving-average

Samples	Rate of success (%)	Errors (%)	Confusion with (%)
Training 100	100	0	—
Test 40	95.8	EC (2.5)	IC (2.5)
		IC (5)	EC (2.5) and LP (2.5)
		LP (5)	EC (2.5) and IC (2.5)
Validation 40	67.5	EC (67.5)	IC (60) and LP (7.5)
		IC (20)	EC (15) and LP (5)
		LP (10)	EC (7.5) and IC (2.5)

Table 5
Classification EC × IC × LP—training, test and validation—Savitzky–-Golay

Samples	Rate of success (%)	Errors (%)	Confusion with (%)
Training 100	100	0	—
Test 40	95.8	—	—
		IC (7.5)	EC (2.5) and LP (5)
		LP (5)	EC (2.5) and IC (2.5)
Validation 40	67.5	EC (57.5)	IC (50) and LP (7.5)
		IC (32.5)	EC (27.5) and LP (5)
		LP (7.5)	EC (5) and IC (2.5)

Table 6
Classification EC × IC × LP—training, test and validation—continuous wavelet

Samples	Rate of success (%)	Errors (%)	Confusion with (%)
Training 100	100	0	—
Test 40	95	EC (5)	IC (5)
		IC (2.5)	EC (2.5)
		LP (7.5)	EC (2.5) and IC (5)
Validation 40	71.7	EC (60)	IC (45) and LP (15)
		IC (15)	EC (7.5) and LP (7.5)
		LP (10)	EC (7.5) and IC (2.5)

Table 7
Classification EC × IC × LP—training, test and validation—discrete wavelet

Samples	Rate of success (%)	Errors (%)	Confusion with (%)
Training 100	100	0	—
Test 40	95.8	EC (2.5)	LP (2.5)
		IC (7.5)	EC (2.5) and LP (5)
		LP (2.5)	IC (2.5)
Validation 40	69.2	EC (60)	IC (50) and LP (10)
		IC (30)	EC (25) and LP (5)
		LP (2.5)	IC (2.5)

Table 8
Classification CO × LP—training, test and validation

Samples	Rate of success (%)	Errors (%)
Training 100	100	0
Test 40	95	— and LP (10)
Validation 40	92.5	CO (10) and LP (5)

considered high since the data of this sample did not enter in the training of the ANN and was close to the result obtained by the test sample signals that were given training (95%).

It is worth mentioning that the ANN results obtained in this paper for LP defects are expected to be very similar to real defects, since the simulated defects are the same obtained in the pipeline welding process. On the other hand, for the class of CO defect, probably, the results for real defects should be inferior because the defects were simulated with regular shape and real defects have irregular ones as, for instance, can be observed in pitting CO.

4. Final comments

The results of this work show that it is possible to classify MFL pattern signals with defects and with ND using ANNs. Also it is possible to classify the defect pattern signals: LP, EC and IC using neural networks with high efficiency. However it should be noted that the same pipelines where the patterns for training were taken should be used for the test signals to avoid confusion between the IC and EC pattern signals, which in fact is not a problem, since the procedures to analyze the effect of CO in pipelines applies the same treatment whether its is internal or external.

The ANNs distinguish with high-efficiency MFL signals for the LP and CO signals.

The pre-processing techniques employed have not produced significant improvement in the rate of success of the ANN. However, they can be very advantageous since they reduce the time of ANN training considerably.

Acknowledgment

The first author, A.A. Carvalho, gratefully acknowledges sponsorship by FAPERJ (State of Rio de Janeiro Research Support Foundation).

References

[1] Bai Y. Pipelines and risers. USA: Elsevier Ocean Engineering Series Editors; 2001.
[2] Cordell J, Vanzant H. All about pigging. USA: On-stream Systems Limited and Hershel Vanzant & Associates; 2000.
[3] Tiratsoo JNH. Pipeline pigging technology. England: Gulf Publishing Company; 1992.
[4] Masnata A, Sunseri M. Neural network classification of flaws detected by ultrasonic means. NDT and E Int. 1996;29(2):87–93.
[5] Margrave FW, Rigas K, Bradley DA, Barrowcliffe P. The use of neural networks in ultrasonic flaw detection. Measurement 1999;25:143–54.
[6] Santos JB, Perdigão F. Automatic defects classification—a contribution. NDT and E Int. 2001;34(5):313–8.
[7] Obaidat MS, Suhail MA, Sadoun B. An intelligent simulation methodology to characterize defects in materials. Inf. Sci. 2001;137:33–41.
[8] Oppenheim AV, Schafer RW. Discrete-time signal processing. Englewood Cliffs, NJ: Prentice-Hall; 1989.
[9] Lathi BP. Communication systems. New York: Wiley; 1968.
[10] Misiti M, Misiti Y, Oppenheim G, Poggi JM. Wavelet toolbox for use with MATLAB, user's guide, version 1. Natick, MA: The MathWorks Inc.; 1996.
[11] Graps AL. An introduction to wavelets. IEEE Comput. Sci. Eng. 1995;2(2):50–61.
[12] Signal processing toolbox for use with MATLAB, user's guide, version 4. Natick, MA: The Math Works Inc.; 1999.
[13] Sophocles JO. Introduction to signal processing. Englewood Cliffs, NJ: Prentice-Hall; 1999.
[14] Kershaw R. Innovative pigging solutions for pipelines. Pipeline Gas J 2002:56–7.
[15] Share J. Pigging: increasing appreciation of an industry truly come of age. Pipeline Gas J. 2002;48–51 (PPSA special section).
[16] Moreno P, Lauer G. The synergy of combined technologies: the most comprehensive method of pipeline integrity evaluation. Available in internet: 〈http://www.tuboscope-pipeline.com/〉.
[17] Porter TR, Parsons J, Martin M. Pipeline integrity: enhanced decision support with GIS. Available in internet: 〈http://www.tuboscope-pipeline.com/〉.
[18] Nondestructive testing handbook. USA: American Society for Nondestructive Testing; 1986.
[19] Jiles DC. Review of magnetic methods for nondestructive evaluation (Part 2). NDT Int. 1990;23(2):83–92.
[20] Afzal M, Udpa S. Advanced signal processing of magnetic flux leakage data obtained from seamless gas pipeline. NDT and E Int. 2002;35:449–57.
[21] Haykin S. Neural networks—a comprehensive foundation. USA: Macmillan College Publishing Inc.; 1994.
[22] Mukhopadhyay S, Srivastava GP. Characterization of metal loss defects from magnetic flux leakage signals with discrete wavelet transform. NDT and E Int. 2000;33:57–65.

ELSEVIER

Applied Ocean Research 25 (2003) 235–241

Applied Ocean Research

www.elsevier.com/locate/apor

On the reliability of an automated ultrasonic system for hull inspection in ship-based oil production units

A.A. Carvalho[a], L.V.S. Sagrilo[b,*], I.C. Silva[a], J.M.A. Rebello[a], R.O. Carneval[c]

[a]*Laboratory of Non-Destructive Testing (LABOEND), Department of Metallurgical and Materials Engineering, COPPE-Federal University of Rio de Janeiro, P O Box 68505, Rio de Janeiro, RJ 21941-972, Brazil*

[b]*Laboratory of Computational Methods in Engineering (LAMCE), Department of Civil Engineering, COPPE-Federal University of Rio de Janeiro, P O Box 68552, Rio de Janeiro, RJ 21945-970, Brazil*

[c]*PETROBRAS Research and Development Center (CENPES), Cidade Universitária Quadra 7 Ilha do Fundão, Rio de Janeiro, RJ 21949-900, Brazil*

Received 1 August 2003; revised 4 December 2003; accepted 19 February 2004

Abstract

This paper first describes an automated ultrasound-based system developed for underwater nondestructive inspection of superficial defects caused by corrosion in hulls of ship-based floating units employed in offshore oil production. The main advantage of the system is that neither the production needs to be stopped nor the oil tanks need to be emptied during the hull inspection process. Afterwards a special focus is given to the system reliability by investigating some aspects of its probability of detection (PoD) curve.
© 2004 Elsevier Ltd. All rights reserved.

Keywords: Nondestructive inspection; Floating, production, storage and offloading; Floating, storage and offloading; Ultrasonic test; Probability of detection; Monte Carlo simulation

1. Introduction

The use of ship-based floating units as Floating, Production, Storage and Offloading (FPSOs) and Floating, Storage and Offloading (FSOs) for oil production, mainly in deep waters, has increased quickly all over the world because their technical and economical features. Only in Campos Basin offshore Brazil there are nowadays fourteen of such units in operation and others are planned to be installed soon [1].

Usually, an FPSO/FSO consists of an old single hull oil tanker that has been adequately transformed (or converted) in order to store and produce oil as a stationary floating unit at a given location. After starting its operation, the continuous loading and offloading process, variable wave-induced loads, saline marine environment and other effects cause the exposition of an FPSO/FSO to fatigue degradation and corrosion process. Hence, a unit like this shall be periodically inspected in order to assure its structural integrity, minimizing risks for the environment and workers.

Because the difficulty of docking an FPSO/FSO in a shipyard and to avoid stopping the oil production the inspections are usually performed offshore at the unit location. These inspections disturb the production process (e.g. the oil tanks need to be emptied, etc.) and are difficult to be performed (the walls need to be very well cleaned, etc). The inspection of the whole unit is a slowly and costly process. The use of divers to visually inspect the external part of the hull may be inappropriate because it is impossible to guarantee that the whole external surface has been examined. All these problems have been motivating engineers and researchers to develop new technologies to inspect such units.

This paper presents the prototype of an ultrasound-based automatic system developed for detection of corrosion-induced superficial (inner or outer) defects in FPSO/FSO hulls. The inspection system is composed by a mobile vehicle having four magnetic wheels that fix it to the ship hull. The movements of the vehicle are remotely controlled by means of a TCP/IP protocol. The ultrasound inspection is performed by a multi-channel equipment using up to eight

* Corresponding author.
E-mail address: sagrilo@lamce.ufrj.br (L.V.S. Sagrilo).

0141-1187/$ - see front matter © 2004 Elsevier Ltd. All rights reserved.
doi:10.1016/j.apor.2004.02.004

standard ultrasound transducers. The system has been designed to operate underwater and its performance has been extensively verified through laboratory [2,3] and field tests [4]. Other details about the system can be found in Ref. [5]

The probability of detection (PoD) curve for any inspection system is always of interest. For the present system this curve depends on various sources of uncertainties such as: inspection environment (in air or underwater), equipment reliability, operators experience and inspection grid (distance between two consecutive measurements versus distance between transducers). The contribution of the last of these items to the overall system PoD is basically a geometric problem associated to the inspection grid geometry and ultrasound beam diameter. A numerical procedure to evaluate this contribution is developed in this work.

In what follows the automated ultrasound system and the parcel of its PoD curve associated to the grid of inspection will be described in more details.

2. Ultrasound-based automatic inspection system

The main function of the vehicle is to move the ultrasound transducers over the hull aiming at locating defects in the inspected area. The inspection system has been designed to operate in a maximum water depth of 40 m and is controlled by means of an umbilical cable connected to a computer. It weighs approximately 1.7 kN in air and its buoyancy approximately equilibrates its self-weight. The vehicle main dimensions are 1.7 m in length, 1 m in breadth and 0.40 m in height. A general view of the system is shown in Fig. 1.

The system has an aluminum chassis offering flexibility enough to cross over irregularities on the surface being inspected such as weld bead, etc. Four magnetic wheels keep the system connected to the hull during inspections and their attraction forces have been experimentally tested [3,4] to take into account the dynamic ship motions. The motion of the system over the inspected area is driven by two electronically controlled motors, each one giving power for two wheels. In case of any accidental departure from the planned inspection route a corrective action is automatically activated by means of the electronic apparatus. On-board cameras are also installed in the vehicle to help the system operator during inspections. A more detailed view of the vehicle is given in Fig. 2.

Besides the control of the inspection system motions the computer is also responsible by the ultrasound system data acquisition. All ultrasound signals are online registered and stored in the computer in the format of A-scan images as show in Fig. 3. A schematic sketch of how the system works is presented in Fig. 4.

The time spent to inspect a given area and the amount of data to be stored in the computer are directly related to

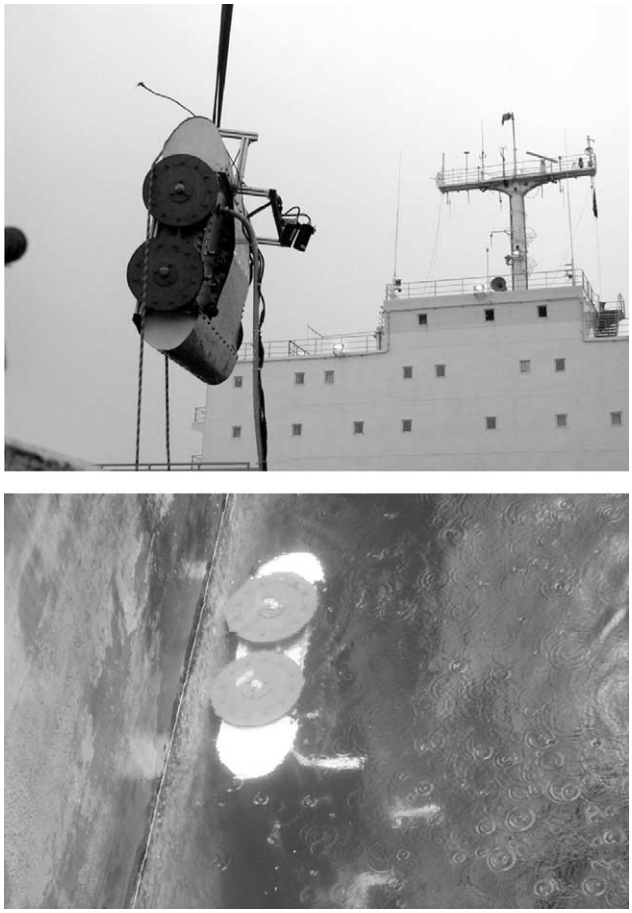

Fig. 1. A general view of the vehicle in air (top) and underwater (bottom).

the distance between the ultrasound transducers l_t and the distance between signal acquisitions l_a, i.e. the inspection grid, as show in Figs. 4 and 5. The smaller the inspection grid the higher is the probability that the ultrasound beams from the transducers overlap defects of small size. On the other hand, for a small inspection grid the inspection time increases and so the inspection costs. Depending on the inspection grid important defects can be missed of being overlapped. It is worth mentioning, as it will be discussed bellow, that the overlapping of a defect is a necessary but not sufficient condition for a defect to be detected by the system.

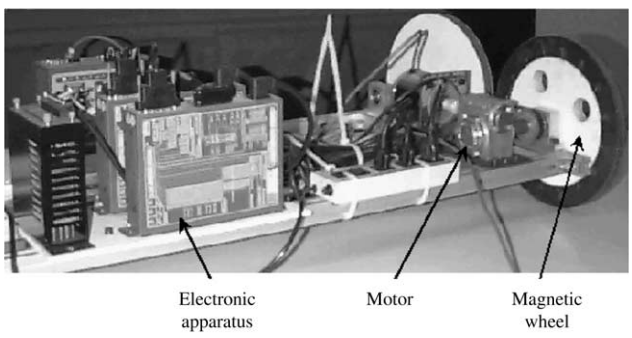

Fig. 2. Details of the inspection vehicle.

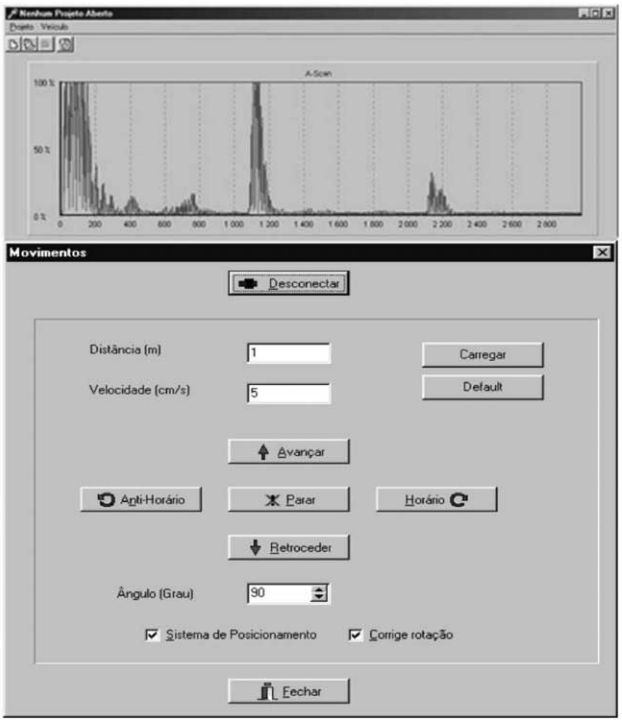

Fig. 3. View of the computer window that controls the inspection system.

An optimum inspection grid, which in practice is problem-dependent, can be developed together with a risk-based approach [6,7] where the PoD curve of the inspection system is extremely important. In Section 3 some aspects involved in the development of the PoD curve for this system will be discussed.

3. PoD curve for the ultrasonic system

The PoD curve of any inspection method gives the probability that it detects an existing defect of known size and shape. For the ultrasonic system described above

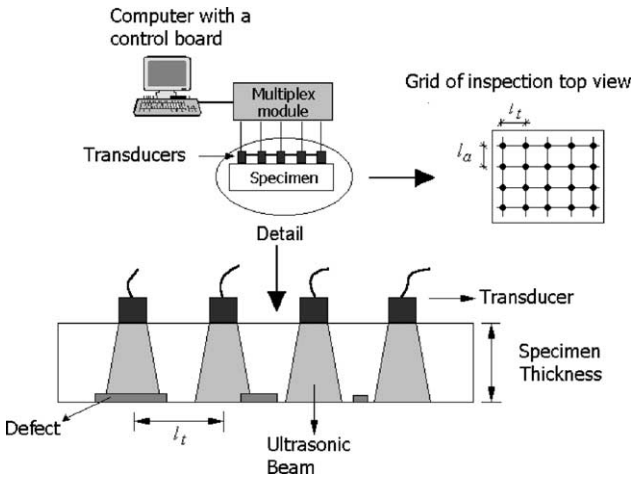

Fig. 4. Schematic diagram of the ultrasonic inspection system.

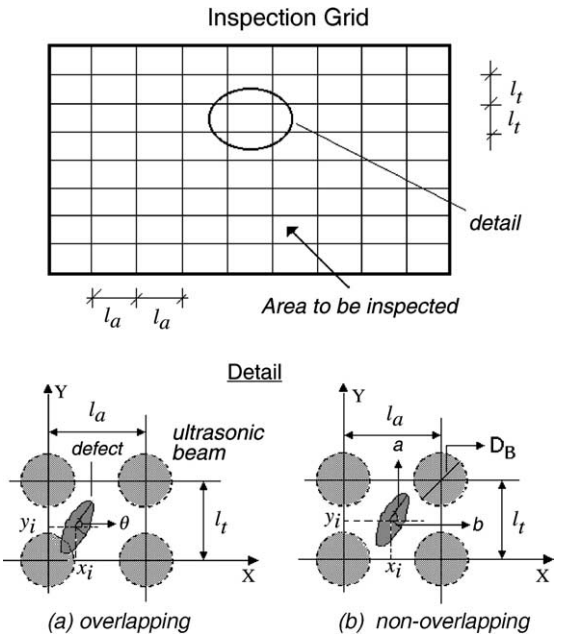

Fig. 5. Ultrasound beam overlapping and non-overlapping of an elliptical defect.

the detection of a defect will depend on whether it is overlapped by at least an ultrasound beam from the transducers and if the equipment and operators can identify its existence. In others words, a defect needs to be overlapped by an ultrasound beam to be detected but this does not mean that its detection is certain because there are other uncertainties involved in the inspection process such as: equipment reliability, operators experience, inspection environment (in air or underwater), etc.

One manner to obtain the PoD is experimentally by testing, with various inspection teams, a large number of specimens having defects with known shape and dimensions. Therefore, the determination of the PoD experimentally can be a very expensive and hard work.

For the ultrasonic system, as it is heavily dependent on the inspection grid, i.e. on the lengths l_t and l_a, a very important parcel of the PoD can be computed numerically as it will be described in what follows.

Mathematically, the PoD(**s**) for a generic defect of size **s**, where **s** is a vector containing the defect and transducers main dimensions, can be described by the following equation:

$$\mathrm{PoD}(\mathbf{s}) = P(O(\mathbf{s}) \cap E(\mathbf{s})) = P(O(\mathbf{s}))P(E(\mathbf{s})|O(\mathbf{s})) \quad (1)$$

where $O(\mathbf{s})$ is the event that the defect is overlapped by at least one ultrasound beam, $E(\mathbf{s})$ is the event that the equipment and the system operators properly identify the existence of the defect and $P(E(\mathbf{s})|O(\mathbf{s}))$ is the probability of occurrence of the event $E(\mathbf{s})$ given that the event $O(\mathbf{s})$ has occurred.

By means of the Eq. (1) the PoD curve is modeled as the product of two parcels: a geometric parcel $P(O(\mathbf{s}))$ which is associated to the grid of inspection and a parcel $P(E(\mathbf{s})|O(\mathbf{s}))$

which is associated to other uncertainties present in the inspection process.

In practice the parcel $P(E(\mathbf{s})|O(\mathbf{s}))$ can assume values between 0 and $1 - P$, where P is the non-zero probability that a defect will not be detected, regardless of its size, and conditioned on overlapping. For defect sizes approaching infinity, the PoD conditioned on overlapping will approach $1 - P$ (rather than 1.0). The equipment's minimum capacity of detection can be accounted for by assigning $P(E(\mathbf{s})|O(\mathbf{s})) = 0$ for $\mathbf{s} \leq \mathbf{s}_{\min}$, where $\mathbf{s}_{\min}$ is the minimum defect the equipment can detect. In practical terms, the parcel $P(E(\mathbf{s})|O(\mathbf{s}))$ should be established based on a large series of experimental results where tests are performed in such a way that the defect is certainly overlapped by one or more ultrasound beams. The environment where the inspection is performed shall be properly accounted for in the test cases.

The geometric parcel $P(O(\mathbf{s}))$, which hereafter will be called *Probability of Overlapping*, can be numerically evaluated as shown bellow.

3.1. Numerical evaluation of the probability of overlapping

The procedure employed in this work to obtain the geometric parcel $P(O(\mathbf{s}))$ of the system PoD curve (see Eq. (1)), i.e. the probability of overlapping, employs artificial simulation of the inspection process using Monte Carlo Simulation Technique [8] and assumes that the defects have an idealized elliptic shape.

Through Monte Carlo Simulation methodology a number N of specimens containing a defect of semi-axes a and b are generated artificially. The center of the defect is located randomly anywhere over the specimen surface. The orientation of the ellipse semi-axis a is also generated randomly. For a given inspection grid each artificial specimen is analyzed numerically in order to verify whether at least one or none of the ultrasonic beams overlaps the defect, as indicated in Fig. 5. The probability of overlapping for the defect with semi-axes a and b, considering an inspection grid l_t by l_a, is then given approximately by the ratio of the number of defects detected by the total number N of artificial specimens.

The diameter of the ultrasonic beam D_B at the level of the defect plays an important role in any ultrasonic-based inspection. It is well known from the ultrasound theory [9] that after leaving the transducer tip the ultrasound beam enlarges conically through the specimen thickness, as illustrated in Fig. 6, and its energy intensity is lower at the borders than at the zone bellow the transducer diameter. Therefore, when the beam area that overlaps a defect gets very close to beam border the intensity of the reflected waves becomes weaker and, consequently, the defect detection likelihood becomes lower but still exists. To take into account this situation and also to consider that the defect can be in the inner or outer surface of the hull, the approach adopted in this work has been to take

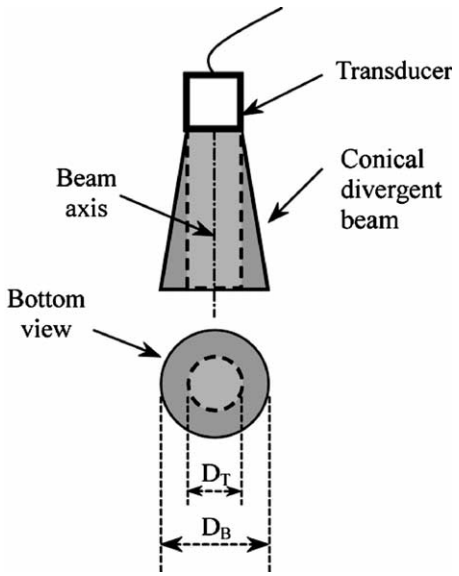

Fig. 6. The main characteristics of the ultrasonic beam.

the ultrasonic beam D_B along the entire specimen thickness as equal to the transducer beam diameter D_T. In this approach, conservatively, the conical divergence of the ultrasound been has been disregarded.

Under the assumptions stated above, the definition of the probability of overlapping through Monte Carlo Simulation can be obtained by considering only one rectangle of the inspection grid, as illustrated in Fig. 5, and is given by the following expression

$$P(O(a,b,D_T)) = E[I(x,y,\theta,a,b,D_T)]$$
$$= \int_0^{\pi}\int_0^{l_a}\int_0^{l_t} I(x,y,\theta,a,b,D_T) f_{X,Y,\Theta}(x,y,\theta)\,\mathrm{d}y\,\mathrm{d}x\,\mathrm{d}\theta \qquad (2)$$

where X and Y are random coordinates that define the center of the elliptical defect, θ is the random orientation of the ellipse semi-axis a, $f_{X,Y,\Theta}(x,y,\theta)$ is the joint probability density function of these three random variables and $E[\cdot]$ stands for expected or mean value. As the center of the defect can be located anywhere inside the rectangle and the direction of the semi-axis a can be anyone, the $f_{X,Y,\Theta}(x,y,\theta)$ is given by the product of three independent uniform distributions, i.e.

$$f_{X,Y,\Theta}(x,y,\theta)$$
$$= \frac{1}{l_t}\frac{1}{l_a}\frac{1}{\pi} \qquad 0 \leq x \leq l_t; 0 \leq y \leq l_a; 0 \leq \theta \leq \pi \qquad (3)$$
$$= 0 \qquad \text{otherwise}$$

The term $I(x,y,\theta,a,b,D_T)$ is the indicator function and it is equal to 1 if the defect is overlapped by the at least one ultrasound beam from the transducers and 0 otherwise. The overlapping occurrence can be verified numerically through standard formulae of analytical geometry. The numerical process of calculating the probability of overlapping

reduces basically to (a) generating of N artificial specimens (or simulations), each one having the center of the defect and its orientation generated randomly according to the distribution given by Eq. (3), and then (b) checking for all of them whether there is overlapping or not. Therefore, the Eq. (2) can be written as

$$P(O(a,b,D_T)) \approx \sum_{i=1}^{N} \frac{I(x_i,y_i,\theta_i,a,b,D_T)}{N} \quad (4)$$

The number of simulations (artificial specimens) N must be large enough in order to get good confidence in the simulated results. A standard measure of error, as given in Refs. [8,10], can be used along the simulation process to determine the number of simulations N needed to attend a desired level of error.

The present development constitutes in an extension of a previous work of the authors [10] where only circular defects have been taken into account. In Ref. [10] it is also shown that when the defect is circular ($2a = 2b = D$) and the inspection grid is square an analytical expression is obtained for the probability of overlapping.

Although the probability of overlapping does not represent the complete system PoD, as modeled in Eq. (1), it is very helpful for specifying the details of an inspection work because certainly there will be no detection if the defect is not overlapped by an ultrasound beam from the transducers.

3.1.1. Some numerical results

The probability of overlapping described earlier is obtained numerically by considering a specified inspection grid, a fixed relation between the ellipse semi-axes a and b, i.e. $a = \alpha b$, and the transducers diameter D_T. However, for further usage, as in the case of a reliability-based inspection planning, an analytical curve can be more helpful. It has been observed through curve fitting using the Kolmogorov-Smirnov test with a significance level of 5% that the four-parameter probability distribution proposed by Ochi [11], among others like Weibull, Lognormal, Frechet and Gumbel, is the one the fits better the numerical results. This distribution is given by

$$P(O(a/b = a\alpha^{-1}, D_B = D_T)) = 1.0 - \exp\left(-c(2a)^m \exp\left(-p(2a)^k\right)\right) \quad (5)$$

where c, m, p and k are the four distribution parameters obtained from the numerical data.

In Figs. 7–9 three examples of numerical probability of overlapping curves are presented together with the corresponding fitted distribution. For a case of circular defect and square inspection grid, shown in Fig. 7, the analytical probability of overlapping is also included. In all these examples the diameter of the transducers D_T has been taken as 10.0 mm. As it can be seen in these examples the probability distribution given by Eq. (5) fits very well to the numerical results. In the case of a circular defect and a square inspection grid (see Fig. 7) the fitted and analytical curves are practically indistinguishable.

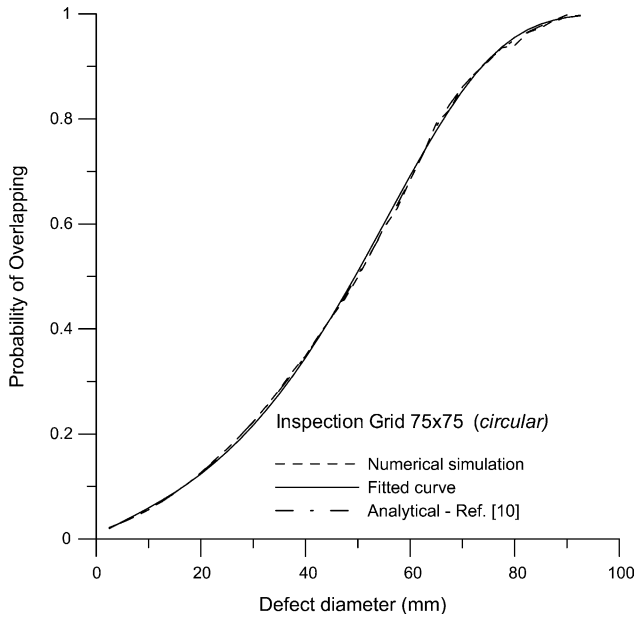

Fig. 7. Probability of overlapping curve for circular defects. Inspection grid 75 × 75 mm and $D_T = 10$ mm.

The results derived for the probability of overlapping can be presented in a form of very practical interest as in Figs. 10 and 11. These figures show the probability of overlapping a defect with known size as a function of the inspection grid and transducer diameter D_T. In practical problems such a type of curve can be employed in order to quickly define the inspection grid for a defect of interest and a desired probability that it will be overlapped.

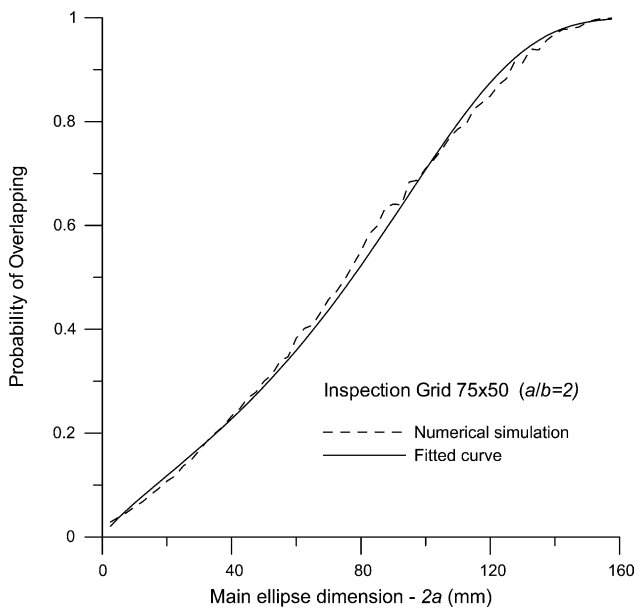

Fig. 8. Probability of overlapping curve for elliptical defects. Inspection grid 75 × 50 mm and $D_T = 10$ mm.

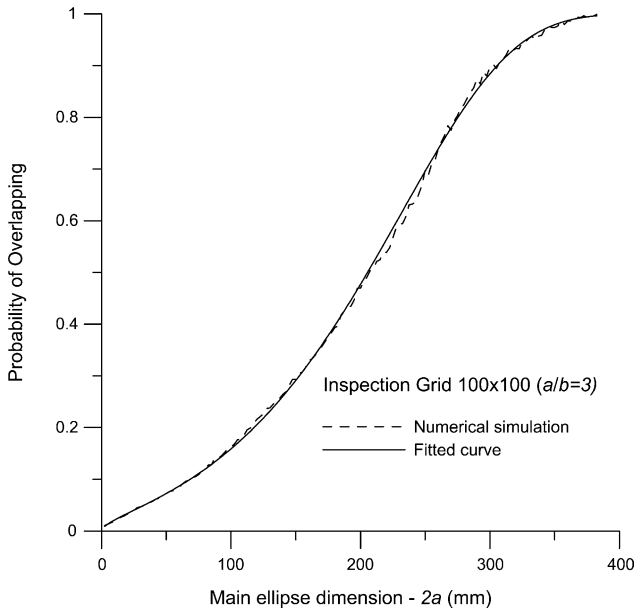

Fig. 9. Probability of overlapping curve for elliptical defects. Inspection grid 100 × 100 mm and $D_T = 10$ mm.

From Figs. 10 and 11 it also can be noticed, as expected, that a circular defect with diameter D has a larger probability of being detected than an elliptical defect with $2a$ equal to D and $2b$ equal to $D/2$.

4. Final comments

This paper described the development (prototype) of an automatic ultrasound-based multichannel system for underwater hull inspection of stationary ship-based floating units.

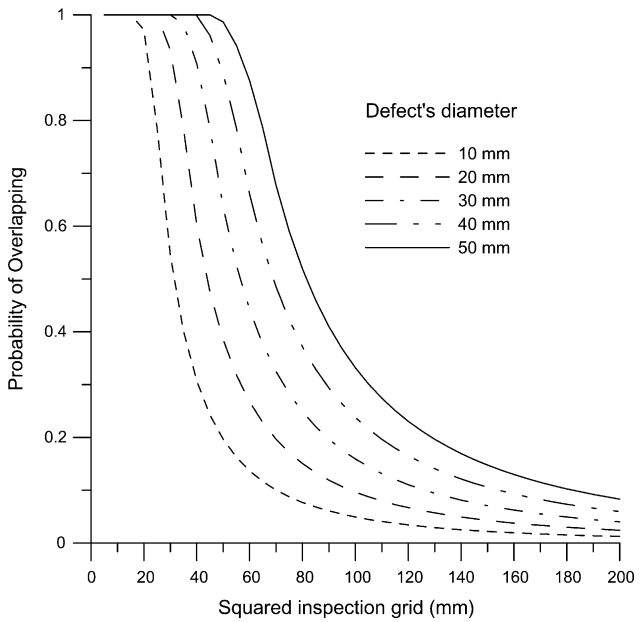

Fig. 10. Square grid size vs. probability of overlapping for $D_T = 10$ mm (circular defects).

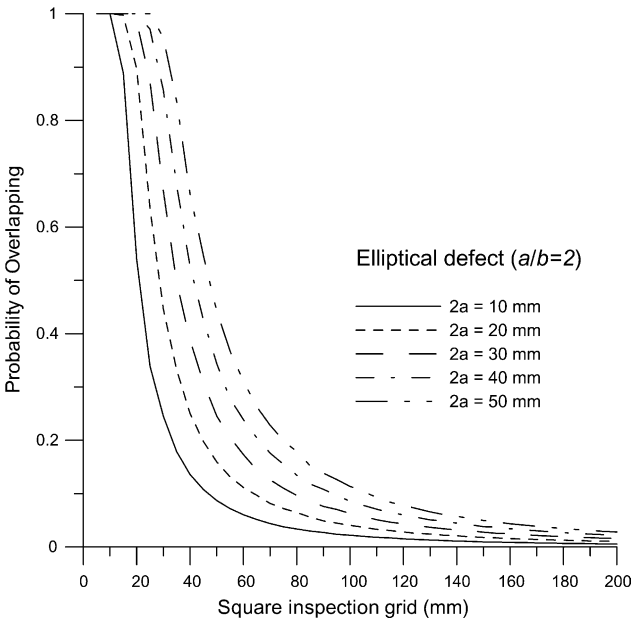

Fig. 11. Square grid size vs. probability of overlapping for $D_T = 10$ mm (elliptical defects).

The system is an improved nondestructive inspection technique aiming at assuring the structural integrity of installed FPSOs or FSOs units.

The system is designed to identify superficial defects induced by corrosion and works without disturbing the unit operation. All data acquisition and movement of the system over the inspected area are computer-controlled. The system capacity for detecting defects is strongly dependent on the inspection grid, which is defined by the distance between two consecutive data acquisitions and the distance between ultrasound transducers.

The PoD curve for this system has been formulated as the product of two parcels: (a) the probability that the defect will be overlapped by at least one ultrasound beam from the transducers and (b) the conditional probability that once the defect is overlapped the equipment and its operators will identify its existence.

It has been shown that the probability of overlapping can be, under some reasonable assumptions, obtained numerically using Monte Carlo Simulation Method. The parcel that depends on all variables but the inspection grid is difficult to be defined analytically. It is a special topic for further research and must be based on a large number of experimental tests taking into account a series of factors such as: the inspection environment, inspectors team experience and equipment reliability.

Acknowledgements

This work is sponsored by FINEP and PETROBRAS through the CTPETRO contract number 6599045600. The authors acknowledge the technical staff of the Submarine

Technology Laboratory at PETROBRAS Research and Development Center for performing the laboratory tests and helping in the field experiments at Angra Bay.

The second author is sponsored by Brazilian Petroleum Agency (Agência Nacional do Petróleo-ANP) through a visiting researcher grant under the contract PRH/ANP/MCT-35. This is gratefully acknowledged.

The authors would like also to acknowledge the valuable comments of two anonymous reviewers on an earlier version of the paper.

References

[1] Souza VVC, Structural analysis for the conversion of a FPSO, MSc thesis, Department of Civil Engineering, COPPE/UFRJ, Brazil, 2002. (In Portuguese).

[2] Carvalho AA, Detection of surface flaws by pulse-echo ultrasonic technique using a multi-channel system, MSc thesis, Department of Metallurgy and Materials Engineering, COPPE/UFRJ, Brazil, 2002. (In Portuguese).

[3] Carvalho AA, Silva IC, Rebello MA. Automated ultrasonic system for fpso hull inspection: report on laboratory tests at CENPES/PETROBRAS, CTPETRO Project No 702, LABOEND/COPPE/UFRJ. 2002. (In Portuguese).

[4] Carvalho AA, Silva IC, Rebello JMA. Automated ultrasonic system for fpso hull inspection: report on field tests at angra bay, CTPETRO Project No 702, LABOEND/COPPE/UFRJ. 2003. (In Portuguese).

[5] Carvalho AA, Silva IC, Sagrilo LVS, Siqueira MHS, Silva RR, Carneval RO. Automated multi-channel system for ultrasound inspection on a FPSO type ship hull. Proceedings of the 8th European Conference on Non-Destructive Testing, Barcelona, Spain; 2002.

[6] Sagrilo LVS, Lima ECP, Enriques CCD, Rodriguez SHR. In: Carneiro FLL, Ferrante AJ, Babista RC, Ebecken NFF, editors. A reliability-based fatigue inspection planning for fixed offshore structures, offshore engineering. Chichester: Computational Mechanics Publications; 1997. p. 303–18.

[7] Moan T, Hovde GO, Blanker AM. Reliability-based fatigue design criteria for offshore structures considering the effect of inspection and repair. Proc. of the Offshore Technology Conference (OTC), Houston, USA; 1993.

[8] Ang AHS, Tang WH, Probability concepts in engineering planning and design, vol. II. New York: Wiley; 1984.

[9] American Society for Nondestructive Testing, 2nd ed. Nondestructive testing handbook, vol. 7.; 1991.

[10] Carvalho AA, Sagrilo LVS, Silva IC, Rebello JMA. The PoD curve for the detection of planar defects using a multi-chanell ultrasonic system. Insight—The Journal of The British Institute of Non-Destructive Testing 2002;44:11.

[11] Ochi MK. Stochastic analysis and probability prediction of random seas. Advances in Hydroscience, vol. 13. New York: Academic Press; 1982.

The PoD curve for the detection of planar defects using a multi-channel ultrasonic system

A A Carvalho, L V S Sagrilo, I C Silva and J M A Rebello

Paper submitted 23 May 2002

This work presents the development of the theoretical probability of detection (PoD) curve for the detection of planar surface defects by using an automated multi-channel ultrasonic system. The defects are modelled as circular ones and the basis for the PoD development is the system's grid of inspection, ie, the distance between the transducers l_t and the distance between two consecutive data acquisitions l_a. The PoD is numerically developed using the Monte Carlo Simulation technique. An analytical PoD is also derived for the particular case where the distances l_t and l_a are equal. Furthermore, the fitting of a known probability distribution to the numerical PoD is discussed. The PoD obtained in this work can be useful in the development of risk-based inspection planning using the multi-channel ultrasonic system.

1. Introduction

Non-destructive inspection systems have been increasingly employed as effective inspection tools in order to guarantee the quality and reliability of products, equipment and structures. Among non-destructive inspection systems the ultrasonic technique is one of the most used in industry to detect and size material defects, evaluate material properties, measure thickness, etc.

Improvements have been made in the ultrasonic inspection technique in order to make it more efficient, mainly in the area of the data acquisition process[4,9]. These improvements are related to inspection systems employing various transducers, such as the automated multi-channel system[3]. As will be described in more detail in the following section, the multi-channel system moves automatically over the surface under inspection and is composed of various transducers in parallel having a computer-controlled data acquisition process. Inspections using the multi-channel system are faster, cheaper and less tedious to the operators and can be used to inspect large surfaces, for example, the hull of ship-based offshore platforms. However, the quality of the inspection results is directly related to the distance between transducers l_t and the distance between two consecutive data acquisitions l_a. Depending on the choice of these two inspection parameters, important flaws can be missed.

An efficient grid of inspection, defined by the lengths l_t and l_a, for a specific application can be determined in connection with risk-based inspection (*RBI*) planning[7,8], where the critical size of the defect also plays an important role. Therefore, in order to develop the connection between RBI and the grid of inspection, an essential parameter is the probability of detection (PoD) curve associated with the inspection method.

This work presents the theoretical PoD curve for a multi-channel ultrasonic system used to detect planar surface defects. The main assumptions made in the PoD development are that the defects are circular-shaped and parallel to the inspection surface, and their depths are such that if an ultrasonic beam is placed over them they will certainly be detected. Hence, the probability of detection associated with a defect size (or diameter) depends basically on the inspection grid.

The PoD curve is firstly developed numerically using the Monte Carlo Simulation technique[2,5]. An analytical curve is also derived for the case when the inspection grid is square, *ie*, when l_t and l_a are equal. Finally, the process of fitting a known probability function to the numerical PoD is also considered. This last topic can be useful in order to simplify the manipulation of the PoD curve in RBI calculations.

2. Multi-channel ultrasonic system

The multi-channel ultrasonic system for the inspection of surface planar defects considered in the present work is illustrated in Figures 1 and 2. In this automatic system, various transducers are placed on a mobile frame and a computer equipped with a multiplex module controls the generation-reception sequence of

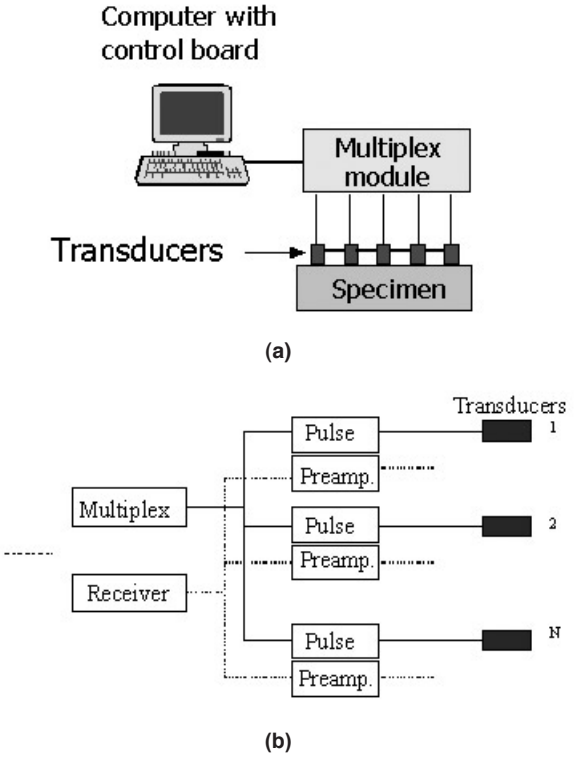

Figure 1. (a) Multi-channel system and (b) its associated schematic functional operation

A A Carvalho, I C Silva and J M A Rebello are in the Laboratory of Non-Destructive Testing, Department of Metallurgical and Materials Engineering, COPPE - Federal University of Rio de Janeiro, PO Box 68505, Code 21945-970 Rio de Janeiro, RJ Brazil. E-mail: jmarcos@metalmat.ufrj.br

L V S Sagrilo is in the Laboratory of Computational Methods in Engineering (LAMCE), Department of Civil Engineering, COPPE - Federal University of Rio de Janeiro, PO Box 68552, Code 21945-970 Rio de Janeiro, RJ Brazil.

ultrasonic signals. The multiplex module has a pulse generator and a pre-amplifier for each channel that are independent, allowing the channels autonomous operation. The system can operate either in the pulse-echo mode or in the transmission-reception mode. In the former, the same transducer sends and receives the pulse; and in the latter a transducer sends the pulse and other receives it.

Figure 2 illustrates the interaction between the ultrasonic beam and the inspected specimen. This Figure also illustrates the inspection grid formed by the geometric distance between the transducers and the positions at which measurements are taken. As can be seen, depending on this grid of inspection the ultrasonic beams may or may not intercept the defects. Assuming that (a) whenever a defect is intercepted by an ultrasonic beam it is identified by the system and (b) the thickness of the inspected specimen is constant, the inspection grid size (l_t and l_a) is the most important parameter for detecting or not detecting an existing defect. The smaller the inspection grid the higher is the probability of detecting defects of small size. On the other hand, for a small inspection grid the inspection time increases and so the inspection costs. An optimum detection grid, which in practice is problem-dependent, can be developed together with a risk-based approach[2,5] where the probability of detection (PoD) curve of the multi-channel system is extremely important. In the next section the development of the PoD curve for this system will be presented.

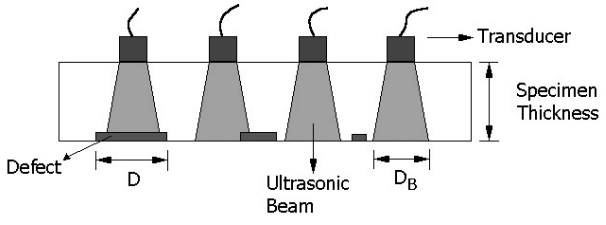

Figure 2. Ultrasonic beams and the surface defects

3. PoD for multi-channel ultrasonic system

The PoD curve gives the probability of detection of an existing defect of a known size as a function of grid inspection lengths l_t and l_a. It can be determined experimentally by considering a large number of specimens having known defects. For each pair of l_t and l_a and the known defect size, which is located randomly over the surface of each specimen, the probability of detection can be evaluated as the number of detections divided by the total number of experiments. It should be noted that the determination of the PoD experimentally could be a very expensive and hard exercise. Another way of obtaining a theoretical PoD curve is numerically by simulating the experimental process artificially. In order to do this, Monte Carlo Simulation[2,5] is employed in this work based on two main assumptions: (a) the defects are modelled as having a circular form parallel to the inspection surface and (b) their depths are such that whenever they are intercepted by an ultrasonic beam their detection is certain.

In what follows the numerical process developed for the definition of the PoD curve is presented. Furthermore, the analytical PoD curve for the particular case when l_t and l_a are equal is also given. Finally, in order to facilitate the use of the PoD in practical applications, the fitting process of a known probability function to the numerical PoD is considered.

3.1 Numerical PoD through Monte Carlo Simulation

By means of the Monte Carlo Simulation methodology, a number N of specimens each containing a defect of diameter D are generated artificially. The centre of the defect is located randomly anywhere over the specimen surface. For a given inspection grid, each artificial specimen is analysed numerically in order to verify whether or not at least one of the ultrasonic beams overlaps the defect. The former situation means the detection of the defect and

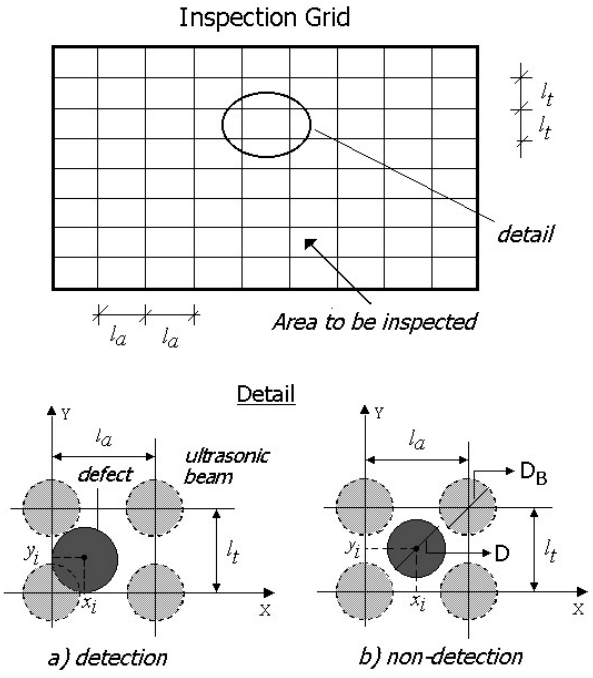

Figure 3. Inspection grid details

the latter the non-detection. As illustrated in Figure 3, the diameter of the ultrasonic beam D_B is that corresponding to the depth of the defect and has to be evaluated taking into account the thickness and material of the inspected body. The probability of detection (PoD) for the defect diameter D and inspection grid l_t by l_a is then given approximately by the ratio of the number of defects detected by the total number N of artificial specimens.

In mathematical terms, the definition of the PoD through Monte Carlo Simulation can be obtained by considering only one rectangle of the inspection grid, as illustrated in Figure 3. The PoD is given by the following expression:

$$PoD = E\left[I(x,y)\right] = \int_0^{l_a}\int_0^{l_t} I(x,y) f_{X,Y}(x,y)\,dy\,dx \quad \text{.....(1)}$$

where X and Y are random variables that define the centre of the circular defect, $f_{X,Y}(x,y)$ is the joint probability density function of these two random variables and $E[.]$ stands for expected or mean value. As the centre of the defect can be located anywhere inside the rectangle, the function $f_{X,Y}(x,y)$ is given by the product of two uniform distributions, one for each coordinate of the central point, *ie*:

$$f_{X,Y}(x,y) = \frac{1}{l_t}\frac{1}{l_a} \quad \text{.....(2)}$$

The term $I(x,y)$ is the indicator function and is equal to 1 if the defect is detected and 0 otherwise. Detection occurs when there is at least one overlapping zone between the defect and the ultrasonic beams from the transducers. Detection or non-detection can be verified numerically through standard formulae of analytical geometry. The N artificial specimens (or simulations) are generated by randomly defining the centre of the defect (x,y) according to the distribution given by Equation (2) and then checking whether there is a detection or non-detection for all of them. Therefore, the Equation (1) can be written as:

$$PoD \approx \sum_{i=1}^{N} \frac{I(x_i,y_i)}{N} \quad \text{.....(3)}$$

The number of simulations (artificial specimens) N must be large in order to get good confidence in the simulated results. According to Ang *et al*[2], the percent error in the result given by

Equation (3) with a 95% confidence level is given by:

$$error = 200\sqrt{\frac{1-PoD}{N\,PoD}}(\%) \quad \text{.....(4)}$$

Through Equation (4) the number of simulations N can be determined for the simulation process to attend a desired level of error.

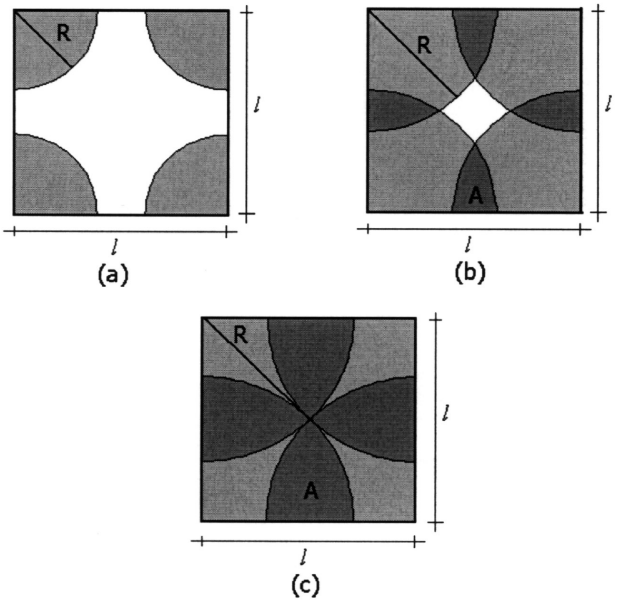

Figure 4. Geometric situations for a square inspection grid. $R = (D + D_B)/2$ and A is given by Eq (7). (a) $R \le l/2$; (b) $l/2 < R \le \sqrt{2}l/2$ and (c) $R > \sqrt{2}l/2$

3.2 Analytical PoD for a squared inspection grid

By considering a square inspection grid, *ie* $l_t = l_a = l$, an analytical PoD can be established. It can be noted that the probability of detection is equal to the probability of the defect centre falling into the shaded area in Figure 4. Hence, this probability is given by the ratio of the shaded area to the total area of the square. As also illustrated in Figure 4, three distinct situations happen:

$$\text{(a) } R = \frac{D + D_B}{2} \le \frac{l}{2}$$

$$\text{(b) } \frac{l}{2} < R = \frac{D + D_B}{2} \le \frac{\sqrt{2}l}{2} \quad \text{.....(5)}$$

$$\text{(c) } R = \frac{D + D_B}{2} > \frac{\sqrt{2}l}{2}$$

Taking into account these three situations and after some mathematical development the PoD curve is given by:

$$PoD = \frac{\pi R^2}{l^2} \qquad \textit{for condition (a)}$$

$$PoD = \frac{\pi R^2 - 4A}{l^2} \qquad \textit{for condition (b)} \quad \text{.....(6)}$$

$$PoD = 1.0 \qquad \textit{for condition (c)}$$

where:

$$A = R^2\, sin^{-1}\left[\sqrt{1-\left(\frac{l}{2R}\right)^2}\right] - \frac{l}{2}\sqrt{R^2 - \left(\frac{l}{2}\right)^2} \quad \text{.....(7)}$$

3.3 Numerical examples

Figures 5 to 8 show the numerical PoDs for the automated multi-channel ultrasonic system for square inspection grids having grid lengths l equal to 50, 100, 150 and 200 mm, respectively. The diameter of the ultrasonic beam at the level of the defects is equal to 10 mm and the error used to define the number of simulations N in Monte Carlo method is 2.5%, according to Equation (4).

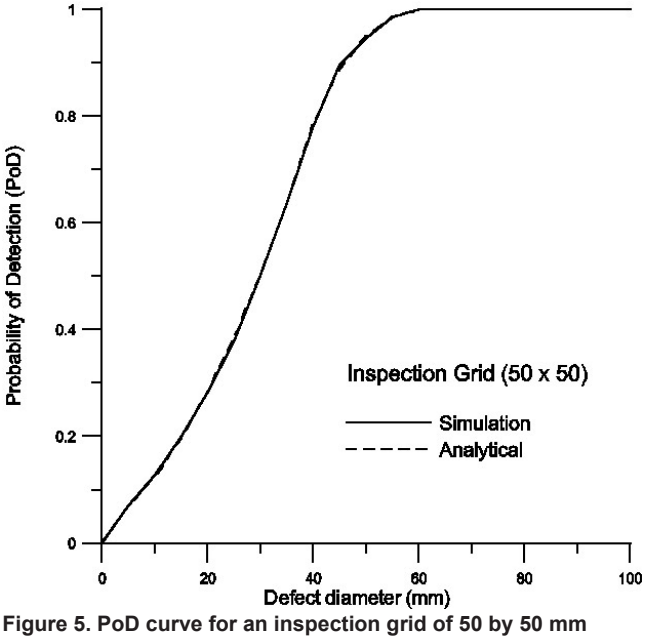

Figure 5. PoD curve for an inspection grid of 50 by 50 mm

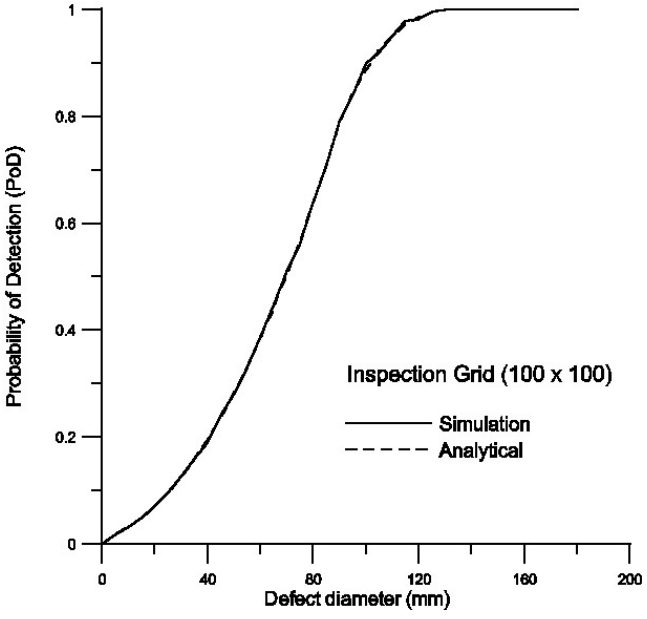

Figure 6. PoD curve for an inspection grid of 100 by 100 mm

According to the assumptions made in this work, it can be seen that the probability of detection is 100% when the condition $\sqrt{2}l = D + D_B$ is reached.

Figures 5 to 8 also include the analytical results given by Eqs (8) to (10). As the results are practically identical, it can be seen that an error level of 2.5% is enough to define the number of trials N for Monte Carlo Simulation technique.

3.4 Fitting a probability distribution to the numerical PoD

In practical applications it is better to use an analytical PoD curve than a numerical one. For a square inspection grid the analytical PoD is derived in Section 3.3. For the other cases an analytical curve can be obtained by fitting a known probability function to the numerical PoD. The process of fitting a probability distribution to numerical data can be found in standard books of statistics[1] and can be summarised in the following steps:

(a) define the candidate probability distributions;

(b) define the parameters of the distributions by least-squares, method of moments, etc;

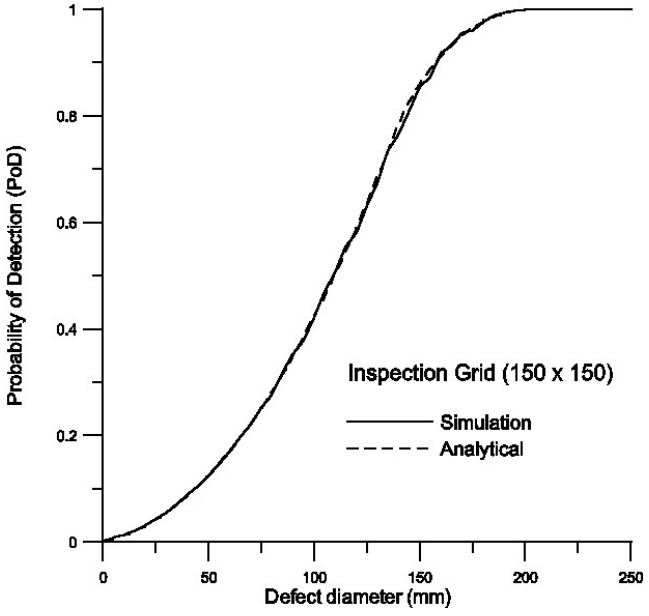

Figure 7. PoD curve for an inspection grid of 150 by 150 mm

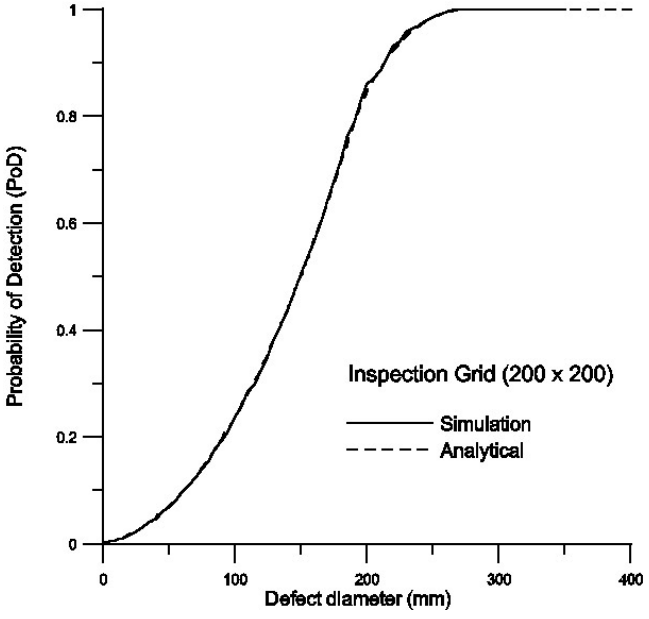

Figure 8. PoD curve for an inspection grid of 200 by 200 mm

(c) choose the distribution that best fits the numerical data by visual inspection or goodness-of-fit tests such as Kolmogorov-Smirnov, chi-square, etc.

For the cases analysed in this work various standard probability functions have been tested, for example Weibull, Frechet, Gumbel, Log Normal, and others. The best fit, based on the Kolmogorov-Smirnov test with a significance level of 5%[1], has always been found to be the four-parameter probability distribution presented by Ochi[6], which is given by:

$$PoD = 1.0 - exp\left[-ad^{m}\, exp\left(-pd^{k}\right)\right] \quad \text{.....(8)}$$

where a, m, p and k are the four distribution parameters obtained from the data and d is the defect size. An approach to obtain the distribution parameters is also indicated by Ochi[6].

In Figures 9 to 12 the numerical PoD and the fitted distributions according to Equation (8) for four non-square different inspection grids are illustrated. As can be seen, the fitted distribution agrees very well with the numerical PoD for all cases presented.

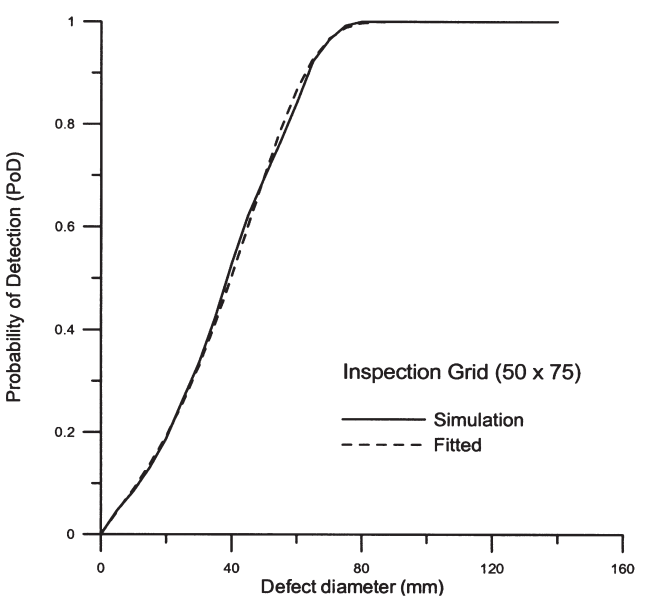

Figure 9. PoD curve for an inspection grid of 50 by 75 mm

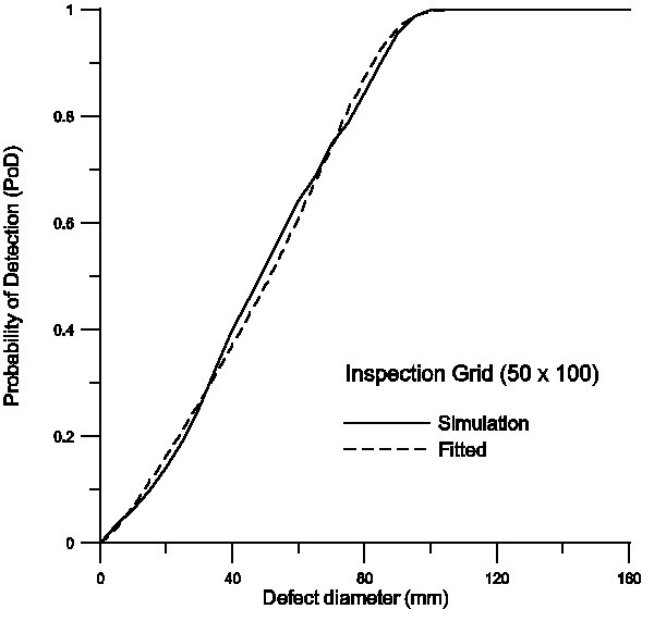

Figure 10. PoD curve for an inspection grid of 50 by 100 mm

4. Conclusions

Multi-channel ultrasonic systems are becoming widely used for inspecting very large surfaces such as ship's hulls. The distance between two consecutive data acquisitions and the distance between the transducers are the parameters that define the inspection grid. The larger the inspection grid the less time-consuming and cheaper is the inspection process. On the other hand, in this case the probability of not detecting an important surface defect can increase too much. In a practical situation, the balance between these two divergent paths can be accomplished by a risk-based approach employing the PoD curve for this inspection method.

In this work the PoD curve for the multi-channel ultrasonic system was obtained. By considering a rectangular inspection grid, *ie* where the distance between transducers is not equal to the distance between two consecutive data acquisitions, the PoD is obtained numerically through Monte Carlo Simulation. For a squared inspection grid the PoD is given analytically. In order to simplify the use of the numerical PoD in practice a fitting process of a known probability distribution was also presented. In this

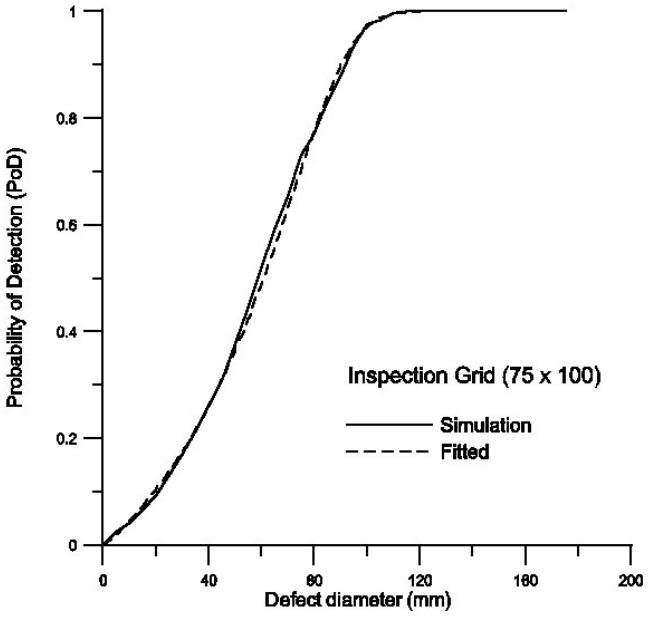

Figure 11. PoD curve for an inspection grid of 75 by 100 mm

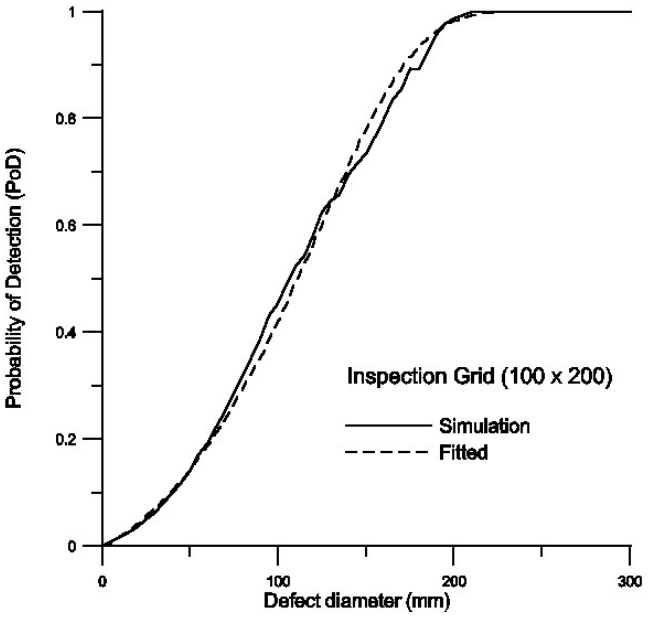

Figure 12. PoD curve for an inspection grid of 100 by 200 mm

latter case the four-parameter probability distribution presented by Ochi[6] turned out to be the best fit in all examples investigated.

The main assumptions made in this work in order to derive the PoD curve were that (a) the defects are of circular form and parallel to the inspection surface and (b) their depths are such that whenever the ultrasonic beam overlaps a defect it is detected. The latter assumption has been supported by some laboratory tests as described by Carvalho[3]. The former assumption can be improved by considering other defect shapes, for example elliptical forms having the main axis oriented randomly over the inspected surface.

Acknowledgements

The second author is sponsored by Brazilian Petroleum Agency (Agência Nacional do Petróleo-ANP) through a visiting researcher grant under the contract PRH/ANP/MCT-35. This is gratefully acknowledged.

References

1. A H S Ang and W H Tang, 'Probability Concepts in Engineering Planning and Design', Vol I, John Willey and Sons, New York, 1975.
2. A H S Ang and W H Tang, 'Probability Concepts in Engineering Planning and Design', Vol II, John Willey and Sons, New York, 1984.
3. A A Carvalho, 'Detection of Surface Flaws by Pulse-echo Ultrasonic Technique Using a Multi-channel System', M.Sc. Thesis, Department of Metallurgy and Materials Engineering, COPPE/UFRJ, Brazil, 2002. (In Portuguese).
4. W A K Deutsch, 'Automated Ultrasonic Inspection', Proceedings of the 15th World Conference on Non-Destructive Testing, Rome, Italy, October 2000.
5. R E Melchers, 'Structural Reliability: Analysis and Prediction', Ellis Horwood Limited, Chichester, 1987.
6. M K Ochi, 'Stochastic Analysis and Probability Prediction of Random Seas', in Advances in Hydroscience, Vol 13, Academic Press, New York, 1982.
7. J R Rudlin and L C Wolstenholme, 'Development of Statistical Probability of Detection Models Using Actual Trial Inspection Data', Insight, Vol 34, No 12, pp 583-589, 1992.
8. L V S Sagrilo, E C P Lima, C C D Enriques, and S H R Rodriguez, 'A Reliability-Based Fatigue Inspection Planning for Fixed Offshore Structures', Offshore Engineering (Carneiro FLL, Ferrante AJ, Batista RC and Ebecken NFF, eds.), Computational Mechanics Publications, Chichester, pp 303-318, 1997.
9. S J Wilson and R A Smith, 'Multi-Element Ultrasonic Scanning of in-Service Airframes', Insight, Vol 40, No 3, pp 154-159, 1998.

CONFERENCE ANNOUNCEMENT AND CALL FOR PAPERS

CONDITION MONITORING 2003

THE NEXT IN THE SERIES OF INTERNATIONAL CONFERENCES ON CONDITION MONITORING

2-4 July 2003 - St Catherine's College, Oxford

For further details contact:
Cindy Bailey, BINDT, 1 Spencer Parade, Northampton, UK NN1 5AA
Fax: (0)1604 231489 or respond via our web site: www.bindt.org/comadit.html