DETECÇÃO E CLASSIFICAÇÃO DE DEFEITOS DE SOLDAGEM EM RADIOGRAFIAS UTILIZANDO PERFIL TRANSVERSAL AO CORDÃO DE SOLDA

Germano Xavier de Padua

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

Aprovada por:

Prof. João Marcos Alcoforado Rebello, D.Sc.

Prof. Luiz Pereira Calôba, Dr.Ing.

Prof. Alexandre Pinto Alves da Silva, Ph.D.

Prof. Carlos Novo Gatts, D.Sc.

Prof. Marley Maria Bernardes Rebuzzi Vellasco, PhD.

Prof. Ricardo Tadeu Lopes, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

DEZEMBRO DE 2004

PADUA, GERMANO XAVIER DE

Detecção e Classificação de Defeitos de Soldagem em Radiografias Utilizando Perfil Transversal ao Cordão de Solda [Rio de Janeiro] 2004

VIII, 211 p. 29,7 cm (COPPE/UFRJ, D.Sc., Engenharia Metalúrgica e de Materiais, 2004)

Tese – Universidade Federal do Rio de Janeiro, COPPE

1. Ensaios Não-Destrutivos
2. Inspeção Radiográfica
3. Defeitos de Soldagem
4. Reconhecimento de Padrões
5. Redes Neurais

I. COPPE/UFRJ II. Título (série)

Dedico aos meus pais, irmãos, esposa
e ao meu filho Felipe.

AGRADECIMENTOS

Ao meu orientador, professor João Marcos Alcoforado Rebello, agradeço pela sua orientação ao longo de todo o desenvolvimento da tese, pelo incentivo, inclusive nos momentos em que foi necessário interromper a pesquisa, assim como pelo fornecimento de todo o suporte necessário para a realização e conclusão deste trabalho.

Ao meu orientador, professor Luiz Pereira Calôba, pela sua irretocável contribuição na sua disciplina e pelos fins de semana disponibilizados para minha orientação, participando de forma decisiva na obtenção de resultados satisfatórios.

Agradeço ao grande amigo, engenheiro e doutor Romeu Ricardo da Silva por sua imensa colaboração, e diria orientação, em todas as fases da tese. Sua participação, com amizade e caráter irrefutável, foi imprescindível neste trabalho. Obrigado, Romeu.

Agradeço ao Programa de Engenharia Metalúrgica e de Materiais, à COPPE e à UFRJ por proporcionarem a oportunidade de participar desta comunidade científica do mais alto nível. Sou grato a todos os professores, alunos e funcionários desta Universidade que participaram direta ou indiretamente na realização deste trabalho.

Agradeço aos amigos do Laboend, principalmente aos estagiários Marcos Paulo, Bruno e Fernando José que contribuíram para a obtenção dos resultados nas diversas fases da tese.

Agradeço à PETROBRAS por me liberar para dedicação ao doutorado.

Aos colegas e amigos da PETROBRAS que sempre me incentivaram durante o desenvolvimento da tese.

Agradeço ao CNPq e CAPES pela concessão de bolsas de doutorado e iniciação cientifica.

Agradeço ao IIW e ao BAM por permitir a utilização acadêmica dos padrões radiográficos, bem como a publicação científica destes padrões.

Um agradecimento especial a minha esposa, Aline, e ao meu filho, Felipe, pela dedicação, amor e compreensão diários que sempre me mantiveram motivado a trabalhar na conclusão da tese.

Finalmente, agradeço aos meus pais que me proporcionaram a melhor formação possível, tanto em caráter quanto intelectual, sem deixar de lado o amor que tanto contribuiu e contribui para me motivar em todos os desafios da vida.

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

DETECÇÃO E CLASSIFICAÇÃO DE DEFEITOS DE SOLDAGEM EM RADIOGRAFIAS UTILIZANDO PERFIL TRANSVERSAL AO CORDÃO DE SOLDA

Germano Xavier de Padua

Dezembro/2004

Orientadores: João Marcos Alcoforado Rebello
Luiz Pereira Calôba

Programa: Engenharia Metalúrgica e de Materiais

Em reconhecimento de padrões de defeitos de soldagem em radiografias, há basicamente dois campos de pesquisa: um deles envolve técnicas de segmentação da imagem radiográfica, extração de características e classificação dos defeitos; e o outro envolve métodos baseados na análise dos perfis em níveis de cinza transversais ao cordão de solda. Foi estudado o uso do perfil transversal ao cordão de solda para detecção e classificação de defeitos de soldagem em radiografias. Estes perfis foram pré-processados e agrupados em conjuntos de treinamento e teste, sorteados usando técnicas de amostragem aleatória. Avaliou-se o desempenho dos classificadores lineares e não-lineares de padrões implementados usando redes neurais artificiais do tipo *feedforward* com algoritmo de treinamento supervisionado. Foi avaliada também a utilização de redes neurais semi-supervisionadas na detecção e classificação destes defeitos. A acurácia destes classificadores foi estimada com base nos resultados de cada conjunto. Técnicas de componentes principais de discriminação também foram utilizadas para visualização em duas dimensões do nível de separação entre as classes. As redes neurais supervisionadas proporcionaram sucesso de até 98% na classificação dos defeitos. As redes tipo semi-supervisionada forneceram padrões para cada classe de defeito e não defeito estudadas neste trabalho.

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

DETECTION AND CLASSIFICATION OF WELDING DEFECTS IN RADIOGRAPHIC FILMS USING TRANSVERSAL PROFILE TO THE WELD SEAM

Germano Xavier de Padua

December/2004

Advisors: João Marcos Alcoforado Rebello
Luiz Pereira Calôba

Department: Metallurgical and Materials Engineering

In pattern recognition applied to welding defects in radiographic examination, there are basically two research fields: techniques that involve segmentation of radiographic image, extraction of features and classification of the defects; and methods based on analysis of profiles in gray level traverse to weld seams. In this work, we present the results of a study for detection and classification of welding defects in x-rays using traverse profiles to the weld seam. The resulting profiles were pre-processed and set into input pairs of training and test, selected using techniques of random sampling. The performance of linear and non linear classifiers, which were implemented using feedforward networks with supervised training, was evaluated. Neural Networks implemented by semi-supervised classifier were also evaluated. The accuracy of these classifiers was evaluated based on the results of each set input. Techniques of principal components of nonlinear discrimination were also used for visualization in two-dimensions of the separation among the classes. Supervised neural network (nonlinear classifier) provided up to 98% successful classification of defects. Semi-supervised neural network provided patterns for each class of defect and non defect studied in this work.

ÍNDICE

1 – INTRODUÇÃO 1

2 – REVISÃO BIBLIOGRÁFICA 6

2.1 Pré-Processamento dos Parâmetros Radiográficos 7

2.2 Detecção e Classificação de Defeitos em Juntas Soldadas 15

2.2.1 Utilização de Redes Neurais 15

2.2.2 Outras Metodologias de Detecção e Classificação de Defeitos 21

2.3 Considerações Finais 34

3 – MATERIAIS E MÉTODOS 37

3.1 Filmes Radiográficos 37

3.2 Digitalização dos Filmes Radiográficos 37

3.3 Pré-Processamento das Imagens 38

3.4 Obtenção dos Perfis Transversais a Solda em Níveis de Cinza 38

3.5 Pré-Processamento dos Perfis Transversais 41

3.6 Formação dos Conjuntos de Dados 45

3.7 Redes Neurais Supervisionadas 46

3.7.1 Classificadores Lineares 50

3.7.2 Classificadores Não-Lineares 52

3.7.3 Aplicação dos Classificadores 53

3.8 Componentes Principais de Discriminação 55

3.9 Redes Neurais Semi-Supervisionadas 57

3.9.1 Classificação por Similaridade 58

3.9.2 Distribuição dos Dados 59

3.9.3 Equações e Estrutura da Rede ART Modificada 62

3.9.4 Treinamento da Rede ART Modificada 64

3.9.5 Qualidade do Agrupamento de Cada Classe 65

3.9.6 Rede Completa 68

4 – RESULTADOS E DISCUSSÕES 70

4.1 Obtenção dos Perfis Transversais a Solda em Níveis de Cinza 70

4.2 Conjunto 1 72

4.2.1 Pré-Processamento 72
4.2.2 Componentes Principais de Discriminação Linear 76
4.2.3 Classificadores Lineares 77
4.3 Conjunto 2 78
4.3.1 Pré-Processamento 78
4.3.2 Componentes Principais de Discriminação Não Linear 82
4.3.3 Classificadores Não-Lineares 85
4.4 Conjunto 3 91
4.4.1 Pré-Processamento 91
4.4.2 Classificadores Não-Lineares 95
4.4.2.1 Otimização do Número de Neurônios na Camada Intermediária 95
4.4.2.2 Componentes Principais de Discriminação Não-Linear 98
4.4.2.3 Acurácia do Classificador Não Linear 102
4.4.3 Redes Neurais Tipo ART Modificada 107
4.4.3.1 Obtenção dos Padrões de Classes 107
4.4.3.2 Análise Fenomenológica dos Padrões Gerados 121
4.4.3.3 A Rede ART Modificada como Classificador 127
4.6 Discussão Geral 132

5 – CONCLUSÕES 134

7 – REFERÊNCIAS BIBLIOGRÁFICAS 138

APÊNDICE A – EXEMPLOS DE RADIOGRAFIAS COM E SEM DEFEITOS DE SOLDAGEM 145

APÊNDICE B – ARTIGOS PUBLICADOS E SUBMETIDOS 153
B.1 NDT & E International – submetido em 14-12-2004 154
B.2 16º WCNDT 2004 – Conferência Mundial de Ensaios Não Destrutivos 178
B.3 II Inspeq 2004 – Encontro Técnico de Inspeção de Equipamentos Estáticos 185
B.4 7ª Coteq 2003 – Conferência Sobre Tecnologia de Equipamentos 193
B.5 3º Pan-NDT 2003 – Congresso Pan-americano em Ensaios Não Destrutivos 203

1 – INTRODUÇÃO

Estruturas soldadas, submetidas a condições críticas de operação, são freqüentemente inspecionadas por Ensaios Não Destrutivos, pois uma falha pode acarretar grandes perdas, como vidas humanas, danos ambientais, perdas materiais e lucros cessantes. O ensaio radiográfico é largamente utilizado para inspecionar e assegurar a qualidade das juntas soldadas, sendo as radiografias obtidas em filmes, os quais são examinados visualmente por um inspetor treinado e qualificado utilizando um negatoscópio[a].

Recentes desenvolvimentos chegaram à radioscopia (radiografia em tempo real) e à radiografia digital que utiliza uma tela sensível à radiação, ao invés do filme radiográfico, que é reconhecida em um computador que produz a imagem digital. Contudo estes processos ainda são incipientes e não estão difundidos suficientemente para substituir o processo convencional, implicando em alto custo.

Por outro lado, a interpretação visual da qualidade da solda baseada em imagens radiográficas digitalizadas ou de filmes, obtidas por qualquer que seja o processo, embora seja o único método atual reconhecido legalmente pelas instituições normalizadoras, pode em alguns casos apresentar situações onde o fator subjetivo crie alguma dubiedade na interpretação da natureza das descontinuidades, isto é, sua classificação. Acredita-se que a interpretação radiográfica automatizada, se desenvolvida com sucesso, será uma ferramenta que tornará esta atividade mais objetiva, consistente e produtiva.

Existem alguns sistemas, ainda em fase inicial, que visam a automatização ou semi-automatização do processo de interpretação das radiografias de soldas. Estes

[a] Equipamento utilizado para observação de radiografias, consistindo basicamente de uma lâmina de acrílico, onde é colocada a radiografia, e iluminação por trás da mesma.

sistemas, na maioria das vezes, são divididos em quatro principais etapas, a saber: digitalização da radiografia (aquisição da imagem), extração do cordão de solda, detecção de defeitos e, por fim, sua classificação. A primeira etapa, que consiste da digitalização do filme radiográfico, pode ser realizada em um escâner desenvolvido para este fim com capacidade de proporcionar resolução adequada. A extração do cordão de solda pode ser feita por um algoritmo de tratamento de imagens para extrair desta imagem somente a área de interesse e reduzir o tempo gasto nas etapas subseqüentes, eliminando informações irrelevantes, como as referentes ao metal de base. Na detecção dos defeitos normalmente são aplicados algoritmos para o reconhecimento de anomalias no perfil da imagem, através de sistemas de inteligência artificial (redes neurais ou lógica *fuzzy*) e devem, supostamente, prever a existência de irregularidades ao longo da imagem da solda. Assim, a classificação dos defeitos também pode ser executada por um sistema de reconhecimento de padrões ou utilizando árvores de decisão, de forma que o defeito encontrado anteriormente seja reconhecido dentre os diversos tipos, considerando a sua geometria, localização dentro do cordão e outras particularidades relativas ao sinal. E por fim, o julgamento do defeito quanto à aceitação de acordo com a norma ou código aplicável, como o Código ASME (*American Society of Mechanical Engineers*) [1], destinado a execução de projeto e fabricação de vasos de pressão, caldeiras para geração de vapor, tubulações para transporte de petróleo, gás e combustíveis, etc.

O desenvolvimento de um sistema automático visa minimizar a influência do fator humano na inspeção radiográfica, que implicam em redução da confiabilidade nestes resultados. Exemplos destas limitações são: acuidade visual, subjetividade na interpretação, ambiente de trabalho (ruído, calor, vibração, etc.), tempo da jornada de trabalho, exaustão após longos períodos, experiência do inspetor, etc.

Fucsok[2] relata que dentre um grupo de inspetores com experiência de 6 meses a 35 anos, o desempenho do melhor inspetor é de 90% de acerto nas indicações, sendo a média de acerto 68%. Domech[3] estudou a influência do fator humano na confiabilidade da inspeção por Ultra-som, que por ser executada pelo homem, possui limitações idênticas à interpretação radiográfica, observando na prática a baixa confiabilidade do inspetor durante o ensaio. Tais fatos orientam diversas pesquisas para o desenvolvimento de um sistema que torne a interpretação de radiografias de juntas soldadas automática, garantindo ainda que o desempenho seja no mínimo idêntico ao do inspetor.

O presente trabalho visa contribuir de forma relevante para o desenvolvimento de um sistema automático ou semi-automático de interpretação radiográfica utilizando ferramentas de reconhecimento de padrões. Para tanto foi desenvolvida uma metodologia até o momento não relatada em qualquer publicação anterior, na qual o perfil transversal à solda em níveis de cinza é utilizado como entrada nos classificadores lineares e não lineares, implementados por redes neurais com treinamento supervisionado por retropropagação do erro para a detecção e classificação de defeitos. Foram obtidos ainda, os padrões representativos de cada classe de defeito através das redes neurais tipo ART, que posteriormente, também foi utilizada como classificador.

A qualidade da imagem radiográfica é essencial para a aplicação da metodologia empregada neste trabalho, tanto em termos de digitalização (relação sinal/ruído) quanto à definição e contraste observado nas diferentes regiões da solda, pois os perfis transversais à solda devem ser representativos em relação à classe de defeito a que pertencem ou caso não possua defeitos.

Os perfis transversais devem ser pré-processados antes de serem submetidos aos classificadores de forma a otimizar o desempenho dos classificadores e obter-se um

conjunto de dados homogêneo. Para tanto, foram utilizadas técnicas de normalização, interpolação e suavização, com os devidos cuidados para que não sejam perdidas informações relevantes ao objetivo do trabalho, como por exemplo a suavização excessiva, que levaria ao não reconhecimento de um determinado defeito ou a uma classificação incorreta. A metodologia empregada no pré-processamento foi implementada após algumas proposições, inclusive pelo fato de as publicações não definirem claramente as técnicas utilizadas. Ao fim desta etapa foram obtidos conjuntos de sinais que representam todas as classes de defeitos de soldagem, bem como a inexistência de defeitos.

Na implementação das redes neurais foram utilizadas estruturas do tipo supervisionada e semi-supervisionada. Para as redes neurais supervisionadas, o algoritmo de treinamento utilizado foi o de retropropagação do erro [4], tendo sido aplicado o procedimento de validação como critério de parada do treinamento. Inicialmente, foram utilizados classificadores lineares para avaliar a capacidade de separação entre duas classes (com defeito e sem defeito), bem como a melhoria do desempenho promovido pelo pré-processamento. Após estabelecer o pré-processamento adequado, foram utilizados classificadores não-lineares, que foram avaliados tanto para detecção de defeitos quanto para sua classificação. Foram utilizadas redes neurais tipo *feedforward* com treinamento supervisionado por retropropagação do erro e redes neurais do tipo ART Modificadas com treinamento semi-supervisionado [5, 6].

Os resultados obtidos foram muito satisfatórios, apresentando índice de acerto de até 98% quando se utiliza o classificador não-linear implementado por redes neurais artificiais supervisionadas, com treinamento por retropropagação do erro. Podendo ser considerado um dos melhores resultados obtidos neste tipo de desenvolvimento quando comparado às publicações dos principais pesquisadores nesta área[7, 8, 9, 10].

Utilizando as redes neurais tipo ART Modificada, com treinamento semi-supervisionado, obtivemos um índice de acerto abaixo daquele obtido com as redes supervisionadas, porém considerados viáveis para esta aplicação. Foram obtidos ainda os padrões representativos de cada classe de defeito e não defeito estudadas neste trabalho.

Considerando as abordagens acima, a distribuição do conteúdo deste trabalho foi feita como apresentado abaixo.

No capítulo 2 apresenta-se uma revisão bibliográfica acerca dos processos de automatização da interpretação de radiografias de juntas soldadas digitalizadas, dando maior ênfase ao processo de detecção e classificação de defeitos em perfis transversais ao cordão de solda radiografados, com os classificadores implementados por redes neurais artificiais por se tratar da linha de trabalho para o desenvolvimento da tese. Outras linhas de pesquisa são apresentadas para complementar esta revisão, como a extração do cordão de solda e a utilização de algoritmos *fuzzy*.

No Capítulo 3 é feita uma descrição da metodologia de pesquisa utilizada no desenvolvimento deste trabalho, incluindo uma relação dos padrões radiográficos utilizados e o método de implementação dos classificadores. No capítulo 4, os resultados são apresentados e discutidos. No Capítulo 5 serão apresentadas as conclusões obtidas pela análise dos resultados apresentados, seguidas das sugestões para trabalhos futuros. No capítulo 6 são apresentadas as referências bibliográficas utilizadas na elaboração da tese. Para finalizar, apresenta-se nos apêndices exemplos de imagens radiográficas contendo os defeitos de soldagem mais comuns utilizadas no desenvolvimento desta tese, além dos artigos publicados ao longo do desenvolvimento deste trabalho.

2 – REVISÃO BIBLIOGRÁFICA

Neste capítulo, foi feita uma revisão do estado da arte envolvendo publicações a respeito da automatização das etapas de interpretação de radiografias de soldas, com destaque aos processos de detecção e classificação de defeitos a partir de imagens digitalizadas. Nota-se a necessidade de um tratamento prévio da imagem digitalizada, envolvendo suavização, normalização, redução/eliminação do ruído e realçamento da solda, além de algoritmos aplicados à extração da solda e detecção dos defeitos. Finalmente, os processos de automatização da inspeção envolvendo sistemas de reconhecimento de padrões, principalmente redes neurais artificiais.

É importante ressaltar que o tema desta tese encontra-se em fase inicial de desenvolvimento, inclusive em âmbito mundial, havendo pouca disponibilidade de publicações abrangendo a automatização da inspeção radiográfica.

Kehoe e Parker[11] revisaram as várias técnicas de processamento de imagem para detecção automática de defeitos em imagens radiográficas. Enfatizaram a necessidade de realçamento da imagem radiográfica em um sistema de processamento de imagem e os métodos disponíveis para tal. Os autores incluíram nesta lista, técnicas de redução de ruído, técnicas de realçamento do contraste e métodos de detecção de defeitos. Os resultados do processamento de imagens foram obtidos para imagens digitalizadas a partir de filmes fotográficos, contudo, acredita-se que estas técnicas possam ser igualmente aplicadas a imagens radiográficas digitalizadas. Mery[12] simulou a presença de defeitos na radioscopia de fundidos para a indústria automotiva, onde fica clara a necessidade de um processamento de imagens antes de qualquer inspeção.

Em um levantamento do estado da arte em sistemas de inspeção de juntas soldadas em filmes radiográficos digitalizados verifica-se que até o momento não existe um sistema operando plenamente. As pesquisas nesta área utilizam diversos parâmetros, tanto geométricos, extraídos diretamente da imagem radiográfica, quanto do perfil em níveis de cinza transversal à solda. Pode-se ainda utilizar filtros diretamente na imagem de forma a ressaltar defeitos não muito claros devido ao baixo contraste. Tais parâmetros geralmente são processados em sistemas baseados em redes neurais artificiais, algoritmos *fuzzy* ou ainda árvores de decisão.

2.1 Pré-Processamento dos Parâmetros Radiográficos

O desenvolvimento de um sistema completo para inspeção de radiografias compreende, além do pré-processamento da imagem digitalizada, na maioria das vezes, a extração do cordão de solda como etapa inicial. O objetivo desta etapa é reduzir a quantidade de informações a serem processadas na etapa subseqüente, que é a detecção e classificação dos defeitos.

Liao e Li[7] desenvolveram uma metodologia que compreende quatro principais componentes: o módulo de Pré-processamento (*Preprocessing*), módulo de Ajuste da Curva (*Curve Fitting*), módulo de Detecção do Perfil de Anomalia (*Profile-Anomaly Detection*) e Pós-processamento (*Postprocessing*). Os resultados obtidos dos perfis processados são compilados para gerar um mapa de defeitos em duas dimensões, que corresponde à solda testada. A metodologia de pré-processamento será apresentada a seguir, a parte referente ao ajuste da curva, detecção e pós-processamento é descrita na seção 2.2.2.

O pré-processamento é necessário para remover o fundo da imagem, realçá-la se estiver escura e normalizá-la de forma que todas tenham a mesma intensidade máxima.

Um simples valor de nível de cinza não pode ser aplicado como patamar (*threshold*) para remover o fundo de todas as imagens. Um patamar que remove corretamente o fundo de uma imagem clara pode remover todos os tons de cinza em uma imagem escura. Para possibilitar o uso de um simples patamar alguns ajustes devem ser feitos nas imagens. O balanceamento por média é usado em cada perfil transversal à solda em níveis de cinza de modo que cada perfil tenha aproximadamente o mesmo tamanho. Liao[7] utilizou a denominação "imagem linear" para referenciar o perfil transversal a solda em níveis de cinza.

Após uma imagem linear ser balanceada é aplicado o patamar, cujo valor é escolhido pela observação dos histogramas das imagens balanceadas. O patamar não deve remover nenhum defeito que tenha baixos tons de cinza. Uma vez o fundo removido, a imagem linear é balanceada de volta, retornando à forma inicial para as operações subseqüentes de processamento.

Liao e Li[7] verificaram que a razão sinal/ruído difere consideravelmente dentre as várias imagens lineares (perfil transversal à solda em níveis de cinza), sendo menores em algumas imagens escurecidas do que nas de imagens mais claras. Quando as imagens escurecidas são normalizadas o nível de ruído nessas imagens é amplificado para um grau maior que o de imagens claras. Para prevenir a amplificação do ruído, como aconteceria na normalização direta, os níveis de cinza de uma imagem escurecida são inicialmente acrescidos de um determinado valor.

A figura 2.1.b mostra que o nível de ruído é menor quando o perfil linear original na figura 2.1.a é primeiro realçado, e então normalizado.

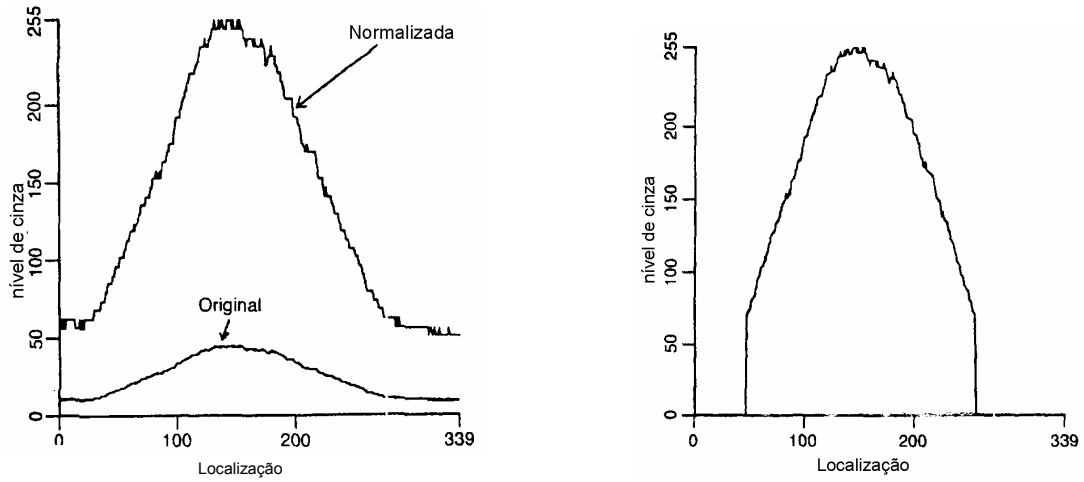

Figura 2.1: (a) Perfil transversal de uma imagem escura e sua versão normalizada; (b) o nível de ruído é menor quando a imagem passa por um realçamento e então é normalizada[7].

Após a remoção do fundo e das operações de realçamento de imagens escurecidas, uma imagem linear é normalizada de forma que seu nível de cinza máximo se torne 255.

Warren Liao e Jiawei Ni[14] desenvolveram um sistema de inspeção que consiste basicamente de duas componentes: uma para extração do cordão de solda e uma outra para detecção dos defeitos presentes neste cordão. A metodologia de extração foi desenvolvida utilizando o software "Khoros"[15] instalado em uma estação de trabalho *Sun SPARC5*. Utilizando imagens já digitalizadas, foi feita conversão do formato "VICOM" para "VIF" para viabilizar o processamento em ambiente "Khoros".

A metodologia de extração do cordão de solda foi desenvolvida baseada na observação de que o perfil transversal à solda em tons de cinza aproxima-se mais de uma curva gaussiana do que os outros objetos da mesma imagem. Pode-se verificar tal fato no gráfico de intensidade da figura 2.3 extraído da figura 2.2.

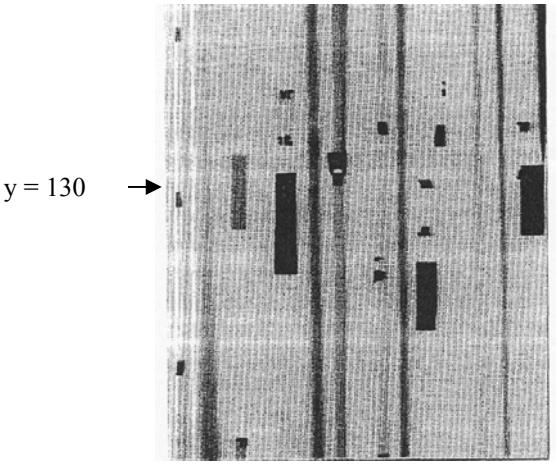

Figura 2.2: Imagem radiográfica de quatro soldas lado a lado[14]. A seta indica a região do perfil transversal mostrado na figura 2.3.

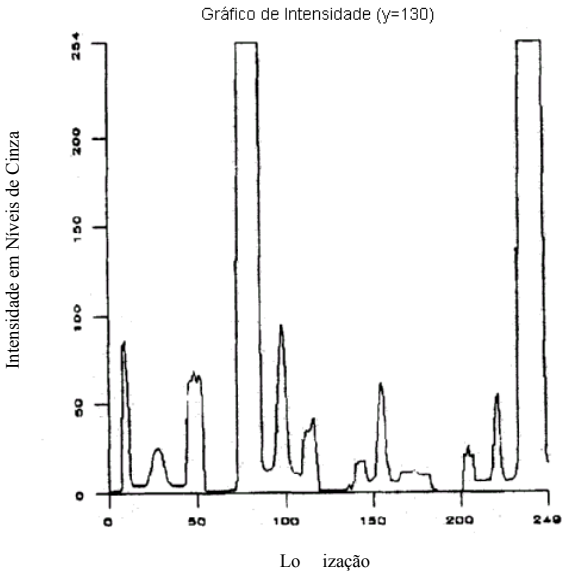

Figura 2.3: Gráfico de intensidade em níveis de cinza da linha y=130, extraída da figura 2.3[14].

A metodologia adotada por Liao[14] consistiu basicamente em:

i. Detectar objetos em cada imagem linear aplicando o algoritmo de detecção de picos.

ii. Computar a similaridade entre o gráfico de intensidade de cada objeto com sua gaussiana em termos do erro médio quadrado (*mean square error* – MSE).

iii. Identificar o objeto com menor MSE que será a solda. Registrar a largura e localização da solda.

iv. Encontrar a largura máxima da solda. Utilizar a inclinação do perfil para determinar a localização do centro das posições inicial e final de toda a solda.

v. Adicionar a metade da largura máxima à localização do centro tendo o maior valor *x* e fazendo dele o limite direito da solda. Subtrair metade da largura máxima da localização do centro tendo o menor valor *x* e fazendo dele o limite esquerdo da solda.

vi. Extrair o cordão de solda baseado nos limites encontrados.

De acordo com Liao e Ni[14] os picos (vales) são detectados quando se observa mudança no sinal, i.e., na inclinação da imagem linear. A detecção de picos é aplicada à identificação de objetos na imagem linear.

A detecção de vales é aplicada para encontrar todos os vales na imagem linear usando o menor tamanho de janela, i.e., a unidade. Para cada pico identificado, um par de vales simétricos ao pico é encontrado.

Para Liao e Ni[14] a similaridade entre o gráfico de intensidade de cada objeto e sua gaussiana é definida em termos do erro médio quadrado (MSE). Assumindo que o objeto é centrado em x = X e seus vales a esquerda e direita estão localizado em x = X – d e x = X+ d, MSE é calculado pela equação 2.1:

$$MSE = \frac{\sum_{x=X-d}^{X+d} f(x) - g(x)}{2d} \tag{2.1}$$

onde d é a distância entre o pico e o seu vale mais próximo, f(x) representa o perfil em níveis de cinza e g(x) a curva gaussiana correspondente.

O objeto com menor MSE é considerado mais similar à gaussiana. Visto que geralmente o gráfico de intensidade de uma solda parece mais gaussiano que outros objetos, o objeto com menor MSE pode ser identificado como a solda. Para comparar os MSE's dos objetos é feita a normalização pela divisão da intensidade de cada *pixel* pelo somatório das intensidades de todos os *pixels* pertencentes ao objeto (limitado pelos seus vales a esquerda e a direita).

Seguindo estas etapas da metodologia de extração da solda, Liao e Ni[14] obtiveram êxito em 100% das 25 imagens processadas, sendo esta metodologia, contudo, destinada a extração de cordões de solda retilíneos, sendo necessárias modificações caso queira aplicá-la a soldas curvas.

T. Warren Liao e K. Tang[16] trataram o procedimento de extração do cordão de solda da imagem radiográfica através da segmentação. Constatou-se que não há nenhum valor de patamar que possa ser selecionado para extrair as soldas com clareza não sendo recomendável, neste caso, utilizar um único nível de cinza para extrair soldas.

Após chegar a esta conclusão, Liao e Tang[16] propuseram usar MLP (*Multilyered Percepton*) na extração da solda ao invés de utilizar toda a imagem, a fim de obter uma imagem linear considerando não somente o nível de cinza, mas também a geometria e a localização dos objetos. O objetivo do classificador é extrair a solda de forma que a maioria dos objetos sejam corretamente reconhecidos, diminuindo assim o número de objetos estranhos à solda, passíveis de serem classificados incorretamente. Um pós-processamento é necessário para remover o ruído e restabelecer a continuidade da linha de solda devido à classificação incorreta. Detalhes da extração de características, classificação baseada em MLP e pós-processamento são dadas a seguir.

Para distinguir objetos da solda de outros estranhos ao cordão, fatores com capacidade de discriminação devem ser identificados, isto é, deve ser feita uma seleção

de parâmetros característicos. Liao e Tang[16] utilizaram a técnica "*eyeball*" para determinar estes fatores, baseados na observação dos gráficos de intensidade das imagens lineares. Esta técnica consiste em definir quatro parâmetros para cada objeto na imagem: a posição do pico, a largura, o erro médio quadrado (MSE) entre o objeto e a gaussiana do seu gráfico de intensidade e a intensidade do pico.

O programa para extração consiste de três etapas, similares ao utilizado em [14]: primeiro, um algoritmo de detecção de pico é usado para detectar objetos em uma imagem linear. Para cada objeto detectado, a intensidade do pico e sua posição são obtidas. Segundo, um algoritmo de detecção de vale é aplicado para encontrar os vales associados a cada objeto detectado anteriormente. Após encontrar os vales, a largura dos objetos é calculada. Terceiro, o MSE entre o gráfico de intensidade de cada objeto e sua gaussiana é computado.

Segundo Liao e Tang[16] a similaridade entre o gráfico de intensidade de cada objeto e sua gaussiana é definida em termos do MSE. Quanto menor o MSE, mais gaussiana é a curva do objeto. Visto que o gráfico de intensidade é mais gaussiano que os outros objetos, o objeto com menor MSE é identificado por tentativa como sendo a solda. O procedimento de cálculo do MSE e determinação da intensidade máxima do pico do objeto utilizada por Liao e Tang[16] é idêntica ao de Liao e Ni[14].

Liao e Tang[16] utilizaram redes neurais MLP para reconhecimento de padrões, isto é, distinguir perfis que representam soldas de qualquer objeto que não seja um cordão soldado, baseado nos quatro parâmetros definidos anteriormente (intensidade e posição do pico, largura dos objetos e MSE). Foram usadas 100 soldas em 25 imagens. A figura 2.4.a mostra exemplos de extração do cordão de solda utilizando o algoritmo descrito, sendo a imagem original a apresentada na figura 2.2. Verificou-se que a detecção foi perfeita para soldas retilíneas (figura 2.4.a) e quase perfeita para soldas

curvas (figura 2.4.b). O percentual de alarme falso variou entre 2 e 12%. Este procedimento foi desenvolvido para extrair os cordões de solda antes de aplicar um algoritmo ou rotina para detecção de defeitos na solda.

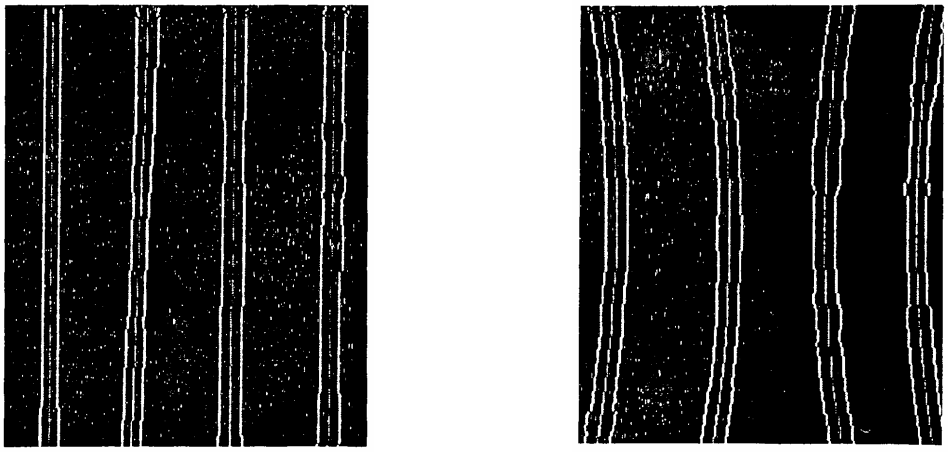

(a) (b)

Figura 2.4: (a) Exemplo de soldas retilíneas extraídas da figura 2.3; (b) soldas curvas com os contornos definidos[16].

Cheng et al[17] utilizaram o treinamento de redes neurais com três camadas para avaliar testes de fadiga em ligas de magnésio, introduzindo os dados da propagação de trincas de fadiga (variação da tensão, número de ciclos e abertura da trinca) de forma a estabelecer uma relação entre a propagação das microtrincas e o número de ciclos até a ruptura do material. Foi utilizado o algoritmo de retropropagação do erro (*error backpropagation*) para o treinamento da rede. Os resultados obtidos são encorajadores com relação ao desenvolvimento da técnica, revelando a possibilidade potencial da utilização das redes neurais para automatização dos ensaios, auxiliando na determinação dos parâmetros dos ensaios e na avaliação dos resultados.

Li e Liao[18] desenvolveram algoritmos *fuzzy* para identificação das soldas nas imagens radiográficas, compreendendo dois componentes: extração de parâmetros e classificação *fuzzy* de padrões. Os parâmetros a serem extraídos são a largura, erro

médio quadrado entre o objeto e sua gaussiana e a intensidade do pico, idênticos aos relatados em [16]. Os resultados indicam que o procedimento desenvolvido fornece um alto percentual de correção no reconhecimento, porém não menciona valores.

Liao et al[19] apresentaram uma metodologia para extrair a solda (retilínea ou curva) de imagens radiográficas digitalizadas. Esta metodologia consiste de três principais etapas: extração dos parâmetros, classificação dos padrões e pós-processamento. Cada imagem é processada linha por linha para extrair os parâmetros (largura, erro médio quadrado entre o objeto e sua gaussiana e intensidade do pico – nível de cinza) de cada objeto na imagem linear. Os algoritmos *fuzzy "K-NN* e *c-means*" foram usados na classificação dos padrões para reconhecer cada objeto como solda ou não. O pós-processamento é usado para remover ruído gerado por alarmes falsos e para conectar linhas de solda descontinuas. Ambos os classificadores podem extrair a solda corretamente, contudo, o classificador *fuzzy "K-NN*" mostrou-se mais eficiente, fornecendo menor número de alarmes falsos, tornando o pós-processamento mais fácil.

2.2 Detecção e Classificação de Defeitos em Juntas Soldadas

2.2.1 Utilização de Redes Neurais

Nafaâ et al[8] utilizaram redes neurais para delimitar a região em torno do defeito de soldagem em imagens radiográficas. Inicialmente, os resultados dependem das condições de contraste da imagem, que influenciam na delimitação do contorno da imagem do defeito; neste caso, uma operação de realçamento da imagem é recomendada. A classificação dos defeitos é feita também pela utilização de redes

neurais, utilizando para isso parâmetros geométricos de forma para o treinamento da rede.

Jacobsen et al[20] compararam empiricamente o desempenho de redes neurais e árvores de decisão para a detecção de defeitos em cordões de solda baseado em uma série de imagens radiográficas digitalizadas. Os procedimentos de processamento são voltados para a detecção de trincas paralelas à direção da solda. Os operadores de detecção foram desenvolvidos para encontrar as bordas e contornos dos objetos, baseado em descontinuidades locais nos valores de nível de cinza. Região do fundo, trinca e mordedura das imagens foram extraídas por redes neurais e árvores de decisão, e seus parâmetros calculados. Foram utilizados outros critérios de comparação entre os métodos de detecção, além do normalmente aplicado, que é o percentual de erro. A utilização de redes neural proporcionou um desempenho levemente melhor que árvores de decisão.

De Padua et al[21] comprovaram o melhor desempenho de classificadores lineares quando os sinais de entrada recebem um pré-processamento, incluindo aplicação do filtro Savitzky-Golay[22] e normalização dos sinais em relação ao contraste, obtendo assim um conjunto de dados homogêneo, onde a amplitude de cada sinal varia de zero a um. Foram utilizadas redes neurais supervisionadas com uma camada oculta e neurônio tipo tangente hiperbólica, cujo treinamento foi executado por retropropagação do erro, possuindo duas possíveis respostas: sinal com defeito ou sem defeito. O percentual de sucesso na detecção de defeitos em imagens radiográficas a partir do perfil transversal em níveis de cinza foi consideravelmente superior quando o mesmo recebeu um pré-processamento visando, principalmente, reduzir o nível de ruído. Foi proposto, ainda, um algoritmo para extração do cordão de solda do perfil como um todo. Para tanto se valeram da verificação de que tais perfis transversais à

solda possuem comportamento gaussiano[14, 16, 7] devido ao reforço da solda, característica esta não verificada em soldas reparadas ou esmerilhadas. O algoritmo consiste em uma regressão gaussiana no sinal, identificação da mediana desta gaussiana e a partir deste ponto truncar o sinal em 1,5 vezes o desvio-padrão para cada lado, perfazendo uma largura de três vezes o desvio-padrão em todos os sinais. Este procedimento mostrou-se eficiente para a maioria dos tipos de sinais, exceto para aqueles que continham defeitos tipo mordedura, o que é plenamente compreensível devido à localização deste tipo de defeito, na borda do cordão de solda (vide exemplos de defeitos em radiografias no Apêndice A).

Da Silva et al[9] avaliou o desempenho de classificadores lineares hierárquicos e não-hierárquicos, implementados por redes neurais, para classificação de defeitos de soldagem (falta de penetração, mordedura, porosidade e inclusões de escória - subdividida em inclusão linear e não-linear – trinca e falta de fusão não foram estudados) em imagens radiográficas digitalizadas. Foi efetuado um pré-processamento das imagens digitalizadas visando reduzir/eliminar ruído e melhorar o contraste. Os parâmetros característicos dos defeitos foram definidos com base na forma de interpretação do inspetor, i.e., de acordo com características visuais como localização, forma, densidade (nível de cinza), razão de aspecto, etc., além da observação das condições de soldagem.

Da Silva[9] utilizou discriminadores lineares, cuja entrada é representada por um vetor composto pelos seis parâmetros característicos. Um discriminador ótimo é aquele que maximiza a probabilidade de sucesso na classificação dos vetores de entrada. O uso do discriminador linear ótimo é uma técnica conhecida denominada “discriminadores de Fisher” em estatística. Uma forma prática de implementá-los é pela utilização de redes neurais com uma camada e um neurônio por classe, conforme descrito por Haykin[4].

Foram utilizados discriminadores lineares hierárquicos e não-hierárquicos[23] e a acurácia dos discriminadores foi avaliada antes e depois de ser aplicado um critério de reclassificação dos vetores cuja saída não "excitou" nenhum dos neurônios referentes às seis classes, este critério é baseado no maior valor de saída. Os classificadores hierárquicos, ao contrário dos não-hierárquicos, iniciam o processo de discriminação das classes pelas mais facilmente separáveis. Os algoritmos de classificação dos discriminadores hierárquicos e não-hierárquicos são comparados quanto ao seu desempenho.

Os discriminadores não-hierárquicos sem reclassificação identificaram com sucesso 62% dos vetores de entrada, 6% foram erroneamente classificados e 32% não foram classificados. Ao aplicar o critério de reclassificação o percentual de acerto atingido foi de 80%, com 20% das entradas erroneamente classificadas, sendo que tais erros concentraram-se nas classes inclusão linear e não linear de escória. Porém, ao se tratar estas classes como uma única, o percentual de acerto é de 90% para o caso com reclassificação.

O critério de reclassificação é utilizado quando todas as saídas são negativas ou existe mais de uma saída positiva. Sua aplicação consiste em alocar aquele vetor entrada na classe cujo neurônio possui o maior valor interno de excitação.

Ao se utilizar os discriminadores hierárquicos nota-se sensível melhora nos resultados. No caso sem reclassificação identificaram com sucesso 85% dos vetores de entrada, 13% foram erroneamente classificados e 2% não foram classificados. Ao aplicar o critério de reclassificação o percentual de acerto atingido foi mantido em 85%, com 15% das entradas erroneamente classificadas. Assim como nos discriminadores não-hierárquicos, os erros concentraram-se nas classes inclusão linear e não linear de

escória. Ao se tratar estas classes como uma única o percentual de acerto é de 94% para o classificador sem aplicar reclassificação e 96% para aquele com reclassificação.

Da Silva et al[24], em trabalho subseqüente ao [9], onde utilizou classificadores lineares, introduziu a utilização de classificadores não-lineares implementados por redes neurais com duas camadas (intermediária e saída – que corresponde ao número de classes estudadas) para a classificação de defeitos de soldagem a partir de parâmetros geométricos obtidos em radiografias digitalizadas. Foi utilizado o algoritmo de retropropagação do erro para o treinamento das redes neurais. Foi feito estudo variando o número de neurônios na camada intermediária, até atingir o número ótimo, i.e., melhor desempenho dos classificadores.

Da Silva[24] buscou a classificação de quatro tipos de defeitos: porosidade, falta de penetração, mordedura e inclusão de escória. Esta última foi tratada de duas formas, como um único tipo de defeito ou subdividida em linear e não linear, quando a saída de rede possui cinco classes.

O fato do desempenho dos classificadores dependerem fortemente da relevância dos parâmetros de entrada, Da Silva[24] utilizou um critério de relevância não-linear para avaliar o quanto a utilização de cada parâmetro influencia na resposta do sistema. Tal critério é baseado na busca de mudanças nas respostas da rede quando um parâmetro é substituído pelo seu valor médio. Foram utilizados quatro parâmetros de entrada: posição, razão de aspecto, razão entre menor eixo e área do defeito (e/A) e arredondamento. Em seu trabalho anterior [9], Da Silva verificou que dois dos seis parâmetros utilizados (razão entre o contraste do defeito e o contraste da radiografia e razão entre comprimento e área do defeito) não possuíam relevância significativa comparados aos demais. Através de um critério de relevância não-linear, provou que os

dois parâmetros podem realmente ser desprezados. Esta constatação permitiu a redução na dimensão dos dados de entrada, sem prejuízo ao desempenho do classificador.

Para encontrar o número ideal de neurônios na camada intermediária, foi utilizado o critério empírico de aumentar gradualmente este número de neurônios e observar o desempenho e os erros de classificação. No primeiro caso, com cinco classes, o melhor desempenho (92%) foi obtido com 17 e 18 neurônios, para quatro classes foi obtido desempenho máximo (100%) com 10 neurônios, ambos com o conjunto de teste.

Diferentes combinações entre parâmetros de entrada foram testadas neste classificador, de onde Da Silva[24] concluiu que o número de parâmetros de entrada ainda pode ser reduzido a três, ao contrário de outras publicações [25, 26], onde foram utilizados dez parâmetros, obtendo desempenho inferior.

Da Silva[24] testou ainda a utilização de componentes principais de discriminação não-linear e verificou que a utilização de somente uma componente fornece um índice de acerto de 92% no treinamento com quatro classes; contudo este índice cai para 66, 4% ao utilizar cinco classes. Ao utilizar duas componentes, o índice de acerto é próximo ao obtido com três ou quatro parâmetros, comprovando a eficiência das componentes principais na redução da dimensão dos dados de entrada.

O critério de reclassificação foi o mesmo utilizado em [9], porém adaptações geométricas foram necessárias pelo fato de estar sendo utilizado um classificador não-linear.

Da Silva[27] detalha todos os estudos publicados em [9, 24] envolvendo relevância de características, classificadores lineares e não-lineares, hierárquicos e não hierárquicos para a discriminação de defeitos de soldagem. Contudo, neste trabalho foram introduzidos dois novos tipos de defeitos (falta de fusão e trinca), além dos cinco apresentados anteriormente (inclusão de escória linear e não linear, porosidade, falta de

penetração e mordedura). Da Silva[24, 27] fez ainda uma estimativa da acurácia dos classificadores não-lineares valendo-se de métodos de amostragem aleatória para não favorecer nenhuma classe envolvida, obtendo resultados satisfatórios, inclusive nos métodos mais simples.

Foi verificado que as classes mordedura e falta de penetração podem ser identificadas por um classificador linear, enquanto porosidade, falta de fusão e, principalmente, inclusão de escória demandam classificadores não-lineares para sua correta discriminação.

2.2.2 Outras Metodologias para Detecção e Classificação de Defeitos

T. Warren Liao e Yueming Li[7] desenvolveram uma metodologia para automatizar a detecção de defeitos de soldagem em uma imagem radiográfica digitalizada. Esta metodologia baseou-se na observação de que o perfil de uma solda de boa qualidade possui a forma de um "sino" (perpendicular à direção de soldagem) com algumas variações locais; um defeito de soldagem resulta em um desvio desta forma. O perfil das anomalias causadas pelos defeitos pode ser classificado em três tipos: pico, vale e inclinação. Exemplos de perfis com estas anomalias são mostrados na figura 2.5, na qual se destaca a região onde é interessante obter uma imagem isenta de ruídos.

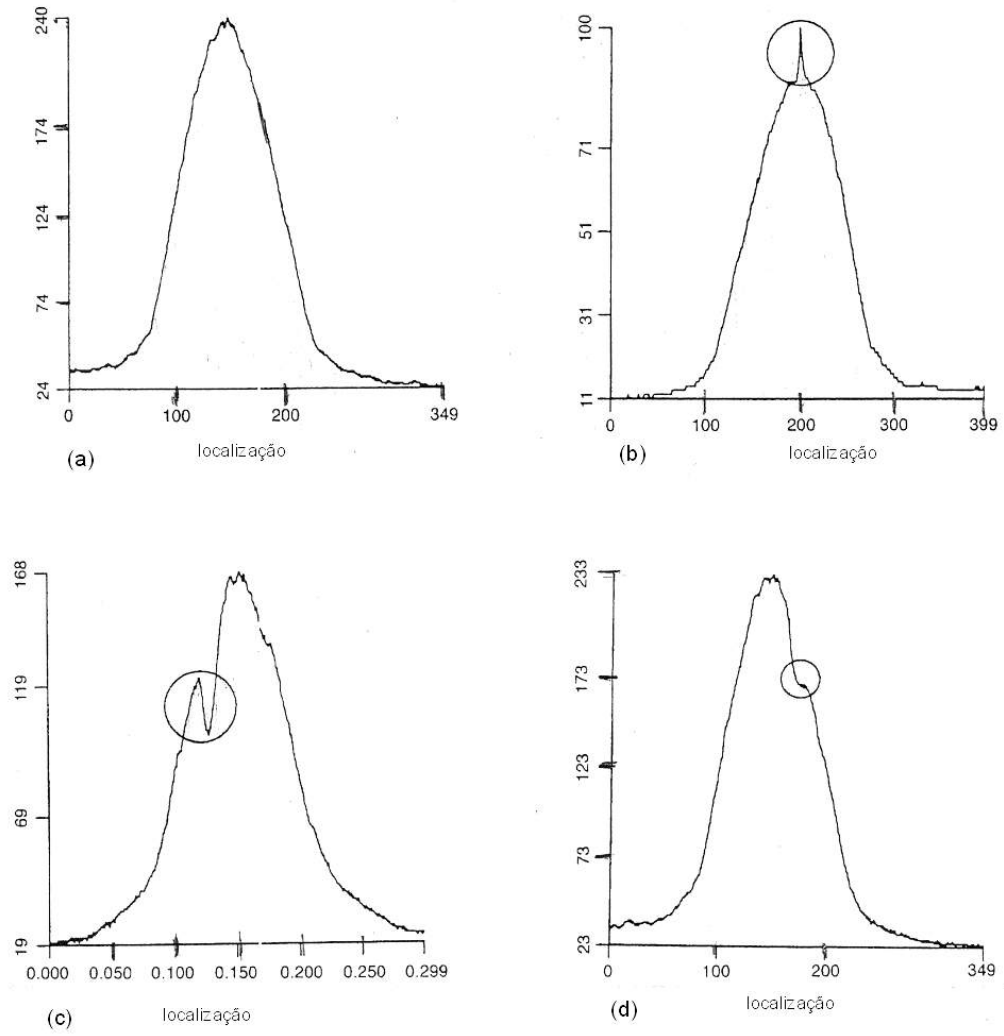

Figura 2.5: Perfis típicos: (a) solda de boa qualidade com forma gaussiana; (b) defeito tipo pico; (c) defeito tipo vale e (d) defeito tipo inclinação[7].

A metodologia de Liao e Li[7] compreende quatro principais componentes: o módulo de Pré-processamento, descrita na seção 2.1, módulo de Ajuste da Curva (*Curve Fitting*), módulo de Detecção do Perfil de Anomalia (*Profile-Anomaly Detection*) e Pós-processamento (*Postprocessing*), que são descritas abaixo.

O algoritmo de ajuste da curva funciona como uma técnica de redução de ruído para alisar os perfis lineares. A suavização das curvas ajustadas pode ser controlada pelo ajuste de um fator de suavização, tornando esta forma de controle uma técnica de

redução de ruído. A técnica "*spline*" de ajuste da curva pode ser aplicada, detalhes da aplicação da função "*spline*" podem ser encontrados em Dierckx[13].

O objetivo de Liao[7] é encontrar um fator de suavização, S, apropriado, que funcione para toda a série de imagens de soldas, sendo este fator determinado por tentativa e erro. Idealmente, o fator de suavização escolhido deve alisar todos os ruídos enquanto mantêm, no perfil, as anomalias causadas pelos defeitos de soldagem intactos. Visto que as condições de imagens de soldas diferem consideravelmente, torna-se quase impossível encontrar um fator de suavização fixo que funcione bem para todas as imagens. É, portanto, desejável que se tenha um fator de suavização adaptável cujo valor seja variável de acordo com a condição da imagem linear a ser testada, especificamente a largura e o grau de ruído.

O conceito de "rugosidade" é introduzido para refletir o grau de ruído de um perfil linear. A relação entre a "rugosidade" e o fator de suavização é então estabelecida e posteriormente utilizada para determinar o fator de suavização para um perfil linear em particular[7].

Nota-se que a variação na amplitude da imagem linear induzida por um defeito em um perfil menos ruidoso em alguns casos pode ser menor que aquela induzida por ruído em um perfil muito mais ruidoso. Isto é inerente a algumas das imagens e é o maior responsável por alarmes falsos e detecções mal sucedidas[7].

Liao e Li[7] selecionaram cem perfis lineares para o estabelecimento de uma relação entre S (fator de suavização) e R (rugosidade). Os fatores de suavização apropriados para estes perfis foram determinados por tentativa e erro. Um fator de suavização é dito apropriado se todo ruído for filtrado e todas as anomalias forem mantidas.

Para a detecção das anomalias, dois tipos de ajustes – "*tight-fitting*" e "*loose-fitting*" – são executados para cada perfil linear. Uma constante que é relativamente grande comparada aos valores calculados acima é usada como fator de suavização para "*loose-fitting*". O propósito do ajuste "*tight-fitting*" é filtrar todo o ruído e manter as anomalias, enquanto o "*loose-fitting*" é usado para filtrar ambos. A forma ideal de uma curva "*loose-fitting*" deve ser a forma de um sino sem nenhuma flutuação local. A figura 2.6.a mostra as curvas ajustadas por "*tight*" e "*loose-fitting*" do perfil linear da figura 2.5.d. As anomalias pico e vale podem ser identificadas pelo uso da curva ajustada pelo "*tight-fitting*" somente. Por exemplo, a curva "*tight-fitting*" da figura 2.6.b do perfil linear da figura 2.5.c é suficiente para identificar a anomalia vale. Para a identificação da anomalia tipo inclinação, a comparação das curvas ajustadas por "*loose-fitting*" e "*tight-fitting*" é necessária.

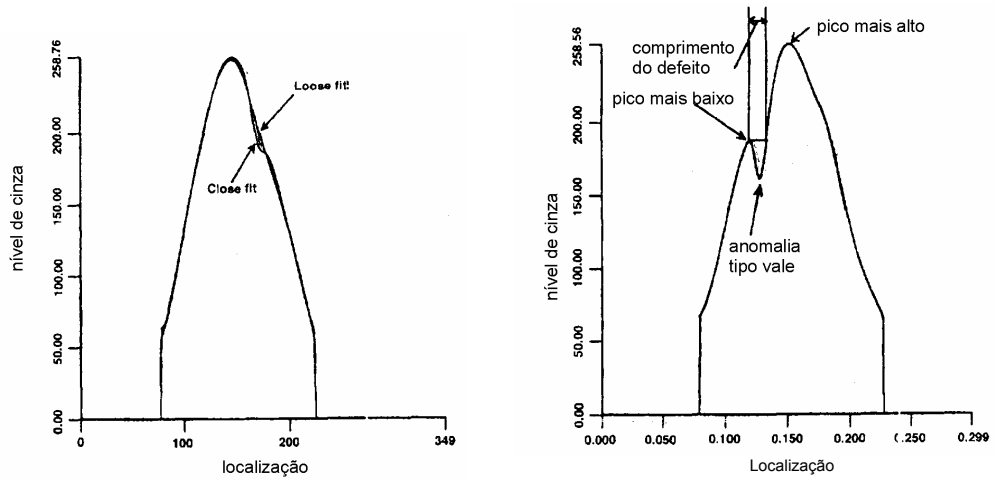

(a) (b)

Figura 2.6: Curvas do perfil transversal, (a) anomalia tipo inclinação "*tightly fitted*" e "*loosely fitted*"; (b) anomalia tipo vale que pode ser identificada pela curva "*tightly fitted"*[7].

De acordo com Liao e Li[7], existem três tipos de perfil de anomalia: pico, vale e inclinação. Os algoritmos de detecção destas anomalias são detalhados a seguir.

Um defeito tipo inclusão de escória geralmente causa um ponto claro na imagem da solda. Um perfil linear que atravesse o ponto claro terá uma anomalia pico correspondente ao ponto claro. A anomalia pico poderia aparecer em qualquer lugar do perfil. Note que a anomalia vale poderia gerar falsos picos no perfil. Por exemplo, os dois picos que delimitam a anomalia tipo vale na figura 2.6.b não devem ser detectados como anomalia pico. Portanto, distinções devem ser feitas entre uma verdadeira anomalia pico e outra falsa. Felizmente, a verdadeira anomalia pico causada por um defeito de inclusão tem algumas características especiais. Para ajudar a descrever estas características, os seguintes termos são definidos, como mostra a figura 2.7.

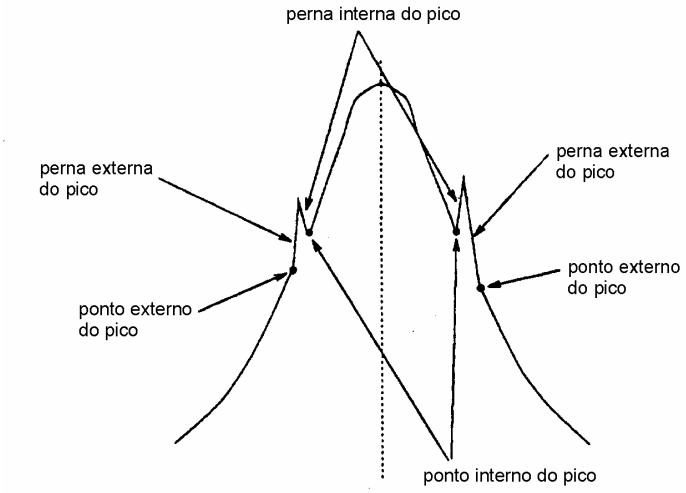

Figura 2.7: Típica anomalia pico e suas partes[7].

- Perna interna e perna externa do pico;
- Ângulo do pico – ângulo entre as duas pernas do pico;

- Pico apontado – se o ângulo do pico é menor que um dado limite, o pico é considerado apontado. Um pico é duplamente apontado se seu ângulo é menor que metade do limite;
- Ponto interno e externo do pico – o ponto de onde a perna externa (interna) junta-se a curva sino é chamada ponto externo (interno) do pico. Ambos os pontos são caracterizados pelo fato de que a primeira derivada da sua vizinhança a esquerda difere consideravelmente daquela à direita.

Utilizando as definições anteriores, uma verdadeira anomalia tipo pico possui, normalmente, as seguintes características:

a) Se um pico é duplamente apontado, é definitivamente uma anomalia pico, ou seja, é um defeito.
b) Um pico apontado pode ser ou não um verdadeiro defeito. Outras informações são necessárias para confirmar ou não.
c) Uma verdadeira anomalia pico não tem o limite esquerdo do perfil como seu ponto externo.
d) A maior perna de uma anomalia pico geralmente não é maior que duas vezes o tamanho da menor.
e) A inclinação da perna externa de uma anomalia pico é grande.
f) Se um pico é apontado e seu nível de cinza correspondente é o máximo do perfil linear, este pico é, geralmente, uma anomalia pico.

Baseado nestas características, Liao e Li[7] desenvolveram o algoritmo de identificação. O comprimento de uma anomalia pico detectada é computada como a diferença entre a posição do *pixel* do seu ponto externo e posição do *pixel* do seu ponto interno.

Uma anomalia tipo pico pode induzir a um falso vale, assim como anomalias tipo vale podem incorrer em falsos picos. Se todas as anomalias tipo pico são identificadas corretamente, a detecção de vales é trivial. Para minimizar alarmes falsos, um patamar é utilizado. Se a profundidade de um vale detectado for maior que o patamar, este é classificado como um verdadeiro vale, caso contrário não é. Devido à distribuição não uniforme dos ruídos no perfil linear, especificamente mais ruidoso no topo que nas laterais do "sino", dois patamares diferentes são usados. Um patamar maior é usado para a região central e um menor para as regiões em ambos os lados.

Para computar o comprimento de um vale detectado, o menor pico que delimita o vale é encontrado primeiro, o qual define o final da anomalia. O nível de cinza do menor pico é então usado para encontrar a outra extremidade da anomalia. Considerando que cada vale tem duas paredes, a posição da parede oposta que possui o mesmo nível de cinza que o menor pico define a outra extremidade da anomalia, como mostra a figura 2.7.

A anomalia tipo inclinação é a mais difícil de identificar. Ambos ajustes, "*tight-fitting"* e *"loose-fitting*", são requeridos para esta identificação. A figura 2.6.a mostra um exemplo de anomalia tipo inclinação. Na faixa onde é possível ocorrer esta anomalia, três parâmetros são verificados: a distância vertical máxima entre as duas curvas, a distância horizontal máxima entre as duas curvas e a segunda derivada máxima. Se os três parâmetros são maiores que os seus patamares correspondentes, pode-se afirmar que é uma anomalia tipo inclinação.

O comprimento de uma anomalia tipo inclinação é calculado como sendo a diferença entre os dois pontos que delimitam a faixa de inclinação. A distância vertical entre as curvas de ajuste, "*tight-fitting"* e "*loose-fitting"*, em cada um destes dois pontos é próximo de zero.

O algoritmo de detecção da anomalia inclinação é desativado quando a "rugosidade" do perfil linear é maior que um valor de patamar. Isto se deve ao fato de que em um perfil muito ruidoso, o algoritmo de detecção pode captar muitos alarmes falsos, o que não é desejável. O valor de patamar é escolhido baseado em um processo de tentativa e erro relativo à taxa de detecção executada corretamente e de alarmes falsos.

Visto que a imagem da solda é processada linha por linha usando os algoritmos de detecção supracitados, e projetados para ter uma alta taxa de detecção correta, é inevitável que alguns arranhões isolados ou marcas de alarme falso estarão presentes no mapa de defeitos. Estes arranhões ou marcas são removidos pelo ajustamento de um patamar para suas áreas. Dois patamares diferentes são usados, um para defeitos de inclusão que requer um pequeno patamar e o outro destinado aos outros defeitos que deve ser maior.

Liao e Li[7] testaram 24 imagens contendo 75 defeitos de diversas naturezas. Cinco defeitos, consistindo principalmente de porosidades e que seriam aceitos pelos códigos para vasos de pressão, não foram detectados. A taxa de defeitos corretamente detectados foi de 93.3%. A taxa de alarmes falsos é calculada como a razão entre o número de perfis lineares sem anomalias mas erroneamente julgados como tendo anomalias e o número total de perfis testados livres de anomalias. A taxa de alarmes falsos total foi de 4,2%, que foi principalmente causada pelos defeitos de "falta de fusão" ou perfis muito ruidosos com características não gaussianas.

Soldas reparadas e/ou esmerilhadas freqüentemente não fornecem características gaussianas. A alta taxa de alarmes falsos para perfis não gaussianos é compreensível devido à metodologia aplicada, baseada em características gaussianas. Isto implica que uma outra metodologia é necessária para processar soldas reparadas e/ou esmerilhadas.

Os resultados de Liao e Li[7] mostraram sucesso da sua metodologia de detecção de defeitos, fornecendo uma taxa alta de detecções feitas corretamente (93,3%) e uma taxa de alarmes falsos aceitável (4,2%). Contudo, é necessário esforço contínuo no sentido de generalizar a metodologia de extração da solda para cordões curvos e para que soldas reparadas e/ou esmerilhadas possam ser processadas com alta taxa de detecção e baixa taxa de alarmes falsos.

K. Murakami[28] desenvolveu um sistema de processamento de imagem que detecta e classifica defeitos internos às soldas automaticamente. O software deste sistema consiste basicamente de três partes: pré-processamento, detecção de defeito e classificação de defeitos. O fluxograma deste procedimento é mostrado na figura 2.8.

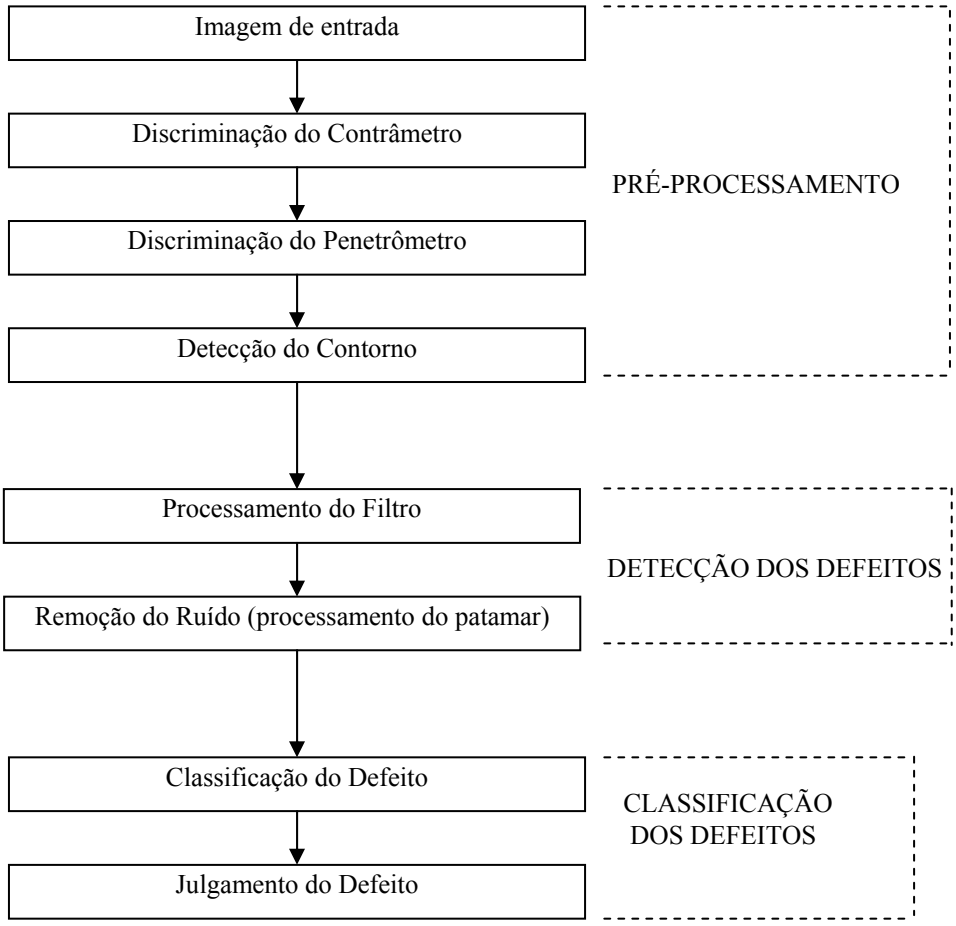

Figura 2.8: Fluxograma para detecção e classificação automática de defeitos na solda [28].

O pré-processamento inclui a discriminação da parte a ser inspecionada, decisão da sua conveniência como uma parte a ser inspecionada e extração da região a ser inspecionada.

No início da inspeção, os processos de discriminação são realizados pelo penetrômetro (IQI - Indicador de Qualidade de Imagem) para corrigir sua resolução espacial (poder de resolução) e também pelo contrâmetro para verificar seu contraste de forma que sua qualidade fotográfica possa ser julgada se é boa suficiente para ser inspecionada. Filmes com qualidade insuficiente são rejeitados.

Após um filme com boa qualidade fotográfica ser selecionado, uma linha que forma um contorno entre a parte soldada e o metal de base é extraída. Isto corresponde ao pré-processamento da determinação de uma região para detecção de defeitos. Inicialmente, um processo de suavização é aplicado na direção horizontal para reduzir o efeito do ruído. Após buscar o contorno linha por linha do topo até a base, é fixada a linha de contorno da solda.

Candidatos a defeito são detectados nesta região pelo uso de uma operação aritmética local e processamento de patamar. Além disso, um pré-janelamento é realizado para excluir defeitos tipo mordeduras e ondulações no cordão, por causarem redução na confiabilidade para detecção de defeitos de soldagem.

Para detectar defeitos, a imagem é realçada por uma operação aritmética local em uma região limitada, conforme exemplo na figura 2.9, e então um defeito padrão é detectado pela operação de patamar. Uma lista de operadores aritméticos locais para detecção de defeitos é disponibilizada no sistema, conforme tabela 2.1, estes operadores consistem de filtros aplicados à imagem, cada um deles possui um objetivo específico, detalhes destes operadores podem ser encontrados em [28].

Tabela 2.1: Lista de operadores para detecção de defeitos[28].

Número	Filtro[b]	Número	Filtro[b]
1	SMOOT4	11	LEGRB1
2	BRG41	12	LEGRS1
3	LEGFC1	13	LEGRS2
4	LRGKS1	14	LEGRS3
5	LEGKS2	15	LEGSB1
6	LEGLP1	16	LEGSB2
7	LEGPW1	17	CNTRF1
8	LEGPW2	18	CNTRF2
9	LEGPW3	19	CNTRF3
10	LEGPW4		

[b] Filtros descritos em [28].

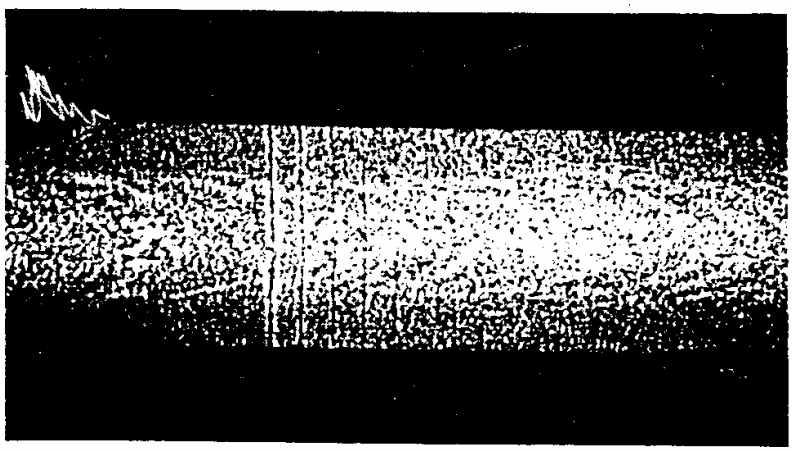

Figura 2.9: Imagem realçada pelo filtro SMOOT 4[28].

A imagem realçada desta forma é fornecida processando o patamar de nível de cinza. Então, possíveis defeitos localizados fora desta região são removidos dos candidatos, e somente aqueles que existem entre ambos os lados da linha de contorno da solda são transferidos ao próximo processo. No sistema de Murakami[28] a detecção de porosidade é relativamente fácil, mas a detecção de trincas torna-se mais difícil. Este

sistema ainda necessita de melhorias. O resultado do processamento patamar é mostrado na figura 2.10 com aqueles da discriminação do penetrômetro e discriminação do contorno.

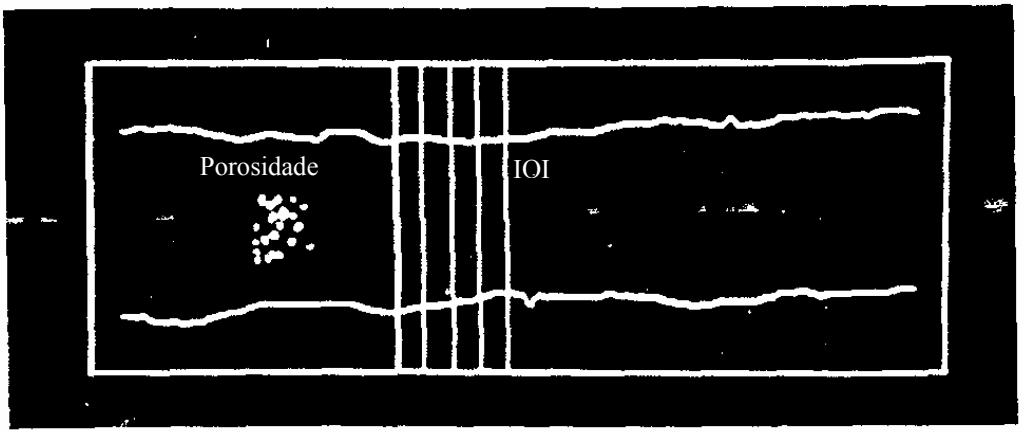

Figura 2.10: Exemplo de resultado na detecção de defeito, mostrando o contorno da solda, discriminação do penetrômetro (IQI) e defeitos tipo porosidade[28].

Alekseychuk e Zscherpel[29] desenvolveram um algoritmo para detecção de trincas e/ou descontinuidades de geometria similar em radiografias. O algoritmo é baseado somente nas duas características mais óbvias destes defeitos, que são bruscas mudanças na intensidade (contraste) na direção ortogonal a direção do defeito e a forma alongada deste tipo de defeito. O procedimento consiste em um tratamento de imagem baseado na razão sinal/ruído, posterior suavização da imagem pelo seu histograma e subtração do fundo da imagem. Os resultados de detecção do sistema desenvolvido foi comparado ao desempenho de inspetores treinados, utilizando as mesmas imagens, o sistema apresentou grande variância na taxa de detecção correta, mas de uma forma geral 50% dos seus resultados ficaram aquém do obtido pelos inspetores.

Shafeek et al[30, 31] relataram a utilização de processos seqüenciais de equalização de histograma aplicado ao filme radiográfico de juntas soldadas, digitalizados por uma câmera CCD (*Charged Couple Device*). Foram desenvolvidos

dois programas que executam um pré-processamento das imagens para detecção de defeitos, quando são extraídos parâmetros de forma, orientação e localização destes defeitos. A partir destes parâmetros é feita a classificação e julgamento de cada defeito de acordo com as normas internacionais. Contudo, a operação dos programas exige treinamento específico, funcionando como um sistema semi-automático.

Liao et al[10] desenvolveram uma metodologia na qual a imagem é processada linha por linha, 25 parâmetros são extraídos de cada imagem linear, sendo que estes parâmetros são obtidos por um procedimento de tentativa e erro. O sistema de detecção de defeitos de Liao et al é baseado em lógica *fuzzy*, onde foi feita comparação entre dois classificadores, "*K-NN*" e "*c-means*". O sistema ainda deve ser melhorado, visto que os melhores resultados fornecem 18,68% de alarmes falsos e 6,01% de defeitos perdidos.

Lashkia[32] propõe um método mais efetivo de detecção de defeitos baseado na teoria *fuzzy*, no qual as imagens são filtradas usando características locais da imagem, e um algoritmo é aplicado para detectar defeitos internos de soldagem. Os resultados mostram eficiência na detecção de defeitos pequenos e de baixo contraste a um nível similar a visão humana, verificada pela comparação entre os resultados dos dois métodos. A lógica *fuzzy* permite um reconhecimento de defeitos confiável e flexível em imagens radiográficas.

Zhang e Basart[33] propõem um sistema automático de inspeção radiográfica. Inicialmente, são extraídos parâmetros locais de uma imagem e então a classificação é executada por um classificador lógico *fuzzy*. Como o classificador é construído para uma aplicação específica, a adaptação para determinadas aplicações é estabelecida pelo treinamento de protótipos. Comparado a redes neurais convencionais, que é uma "caixa preta" e possui estágio de treinamento muito lento, o processo de treinamento do classificador *fuzzy* é muito mais rápido porque é estabelecido diretamente do

treinamento de arquivo de dados. O desempenho do sistema depende da base de conhecimento. A figura 2.11 mostra um diagrama simplificado deste sistema de inspeção automatizado.

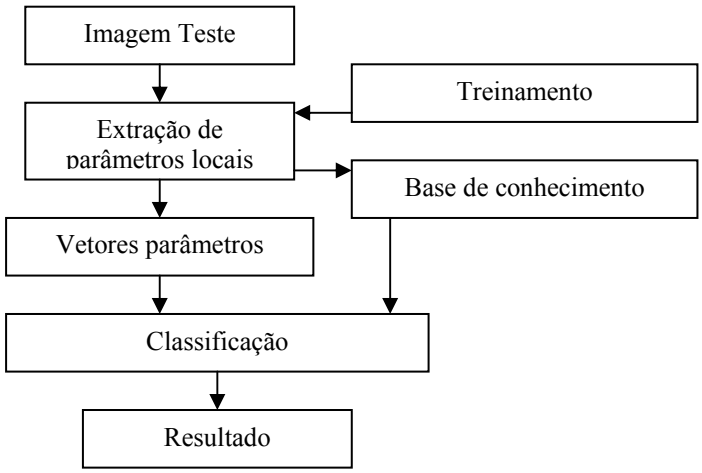

Figura 2.11: Diagrama simplificado do sistema automático de detecção[33].

2.3 Considerações Finais

As publicações voltadas para a automatização da interpretação de imagens radiográficas de juntas soldadas são muito restritas, onde a maioria dos pesquisadores ainda mantém sigilo sobre o detalhamento dos principais passos do processo pelo fato de não existir um sistema comercialmente funcionando, apesar de ser objeto de estudo nos maiores centros de pesquisa em Ensaios Não Destrutivos do mundo, como o TWI (*The Welding Institute* – Reino Unido) e o BAM (*Federal Institute for Materials Research and Testing* – Berlim).

Verificou-se que podem ser aplicadas diferentes rotinas, algoritmos e técnicas para extração do cordão de solda, detecção e classificação de defeitos de soldagem em

radiografias. De uma forma geral, os autores efetuaram previamente um tratamento da imagem digitalizada, visando melhorar o contraste e reduzir o ruído, executando posteriormente as etapas de extração da solda, detecção e classificação dos defeitos com maior eficiência.

O processamento da imagem é feito, em geral, em um programa adquirido no mercado, porém as etapas subseqüentes exigem a elaboração de rotinas de programação específicas, utilizando árvores de decisão ou mais comumente técnicas de inteligência artificial, como redes neurais e lógica *fuzzy*, ambos fornecendo bons resultados, atingindo seus objetivos, porém ainda necessitando de aperfeiçoamentos.

As imagens são tratadas como uma matriz, onde o perfil de cinza é utilizado para extrair o cordão de solda e o histograma transversal é utilizado dentro da rotina de detecção de defeitos.

De uma forma geral, existem duas linhas de pesquisa para detecção e classificação de defeitos de soldagem em radiografias digitalizadas. Uma delas utiliza o perfil transversal à solda em níveis de cinza e posteriormente a extração de parâmetros deste perfil, como erro médio quadrado em relação a sua gaussiana, entre outros parâmetros de forma para utilização como entrada dos sistemas de reconhecimento de padrões. Esta metodologia inspirou o desenvolvimento deste trabalho, porém restringiu-se somente a utilização do perfil transversal à solda em níveis de cinza, não tendo sido utilizado parâmetros, mas o perfil completo como entrada dos classificadores. A segunda linha de pesquisa trabalha com a extração de parâmetros dos defeitos previamente detectados, entre eles pode-se citar características geométricas, de intensidade ou texturais do defeito dentro da imagem radiográfica. Estes parâmetros formam os vetores de entrada para os classificadores, tendo como objetivo somente a classificação dos defeitos, não abrangendo a detecção como na metodologia anterior.

Outras linhas de pesquisa foram mostradas, como a utilização do tratamento de imagens e segmentação, para determinar os limites da solda e detectar os defeitos, porém a utilização desta metodologia mostrou-se limitada, pois os resultados satisfatórios restringem-se a somente um ou no máximo dois tipos de defeitos corretamente classificados.

3 – MATERIAIS E MÉTODOS

Neste capítulo, a metodologia e os materiais empregados na tese serão apresentados. Para tanto, este capítulo divide-se nas seções: filmes radiográficos, digitalização dos filmes, pré-processamento das imagens radiográficas, obtenção dos perfis transversais à solda em níveis de cinza, pré-processamento dos perfis transversais, formação dos conjuntos de dados, componentes principais de discriminação, redes neurais supervisionadas e redes neurais semi-supervisionadas.

3.1 Filmes Radiográficos

Os filmes radiográficos utilizados no desenvolvimento desta tese são padrões radiográficos do IIW (*International Institute of Welding*) e do BAM (*Bundesanstalt fü Materialforschung und-prüfung – Federal Institute for Materials Research and Testing – Berlin*). Estes padrões são radiografias de juntas soldadas em aço carbono, cujos defeitos de soldagem são atestados pelos respectivos centros de pesquisa. Por serem padrões, estas imagens possuem maior confiabilidade em relação ao tipo de defeito presente, principalmente: falta de penetração, falta de fusão, porosidade, inclusão de escória, mordedura e trinca.

3.2 Digitalização dos Filmes Radiográficos

Os primeiros padrões radiográficos do IIW (TC5 – ano 1952) utilizados no trabalho de tese foram digitalizados em um escâner do tipo Flatbed UMAX Mirage II

com resolução espacial de 500 pixels por polegada (dpi) e 256 níveis de cinza. A segunda coleção de padrões (IIW 1290 – ano 1995), recentemente adquirida, foi digitalizada usando um escâner da marca Microtek de modelo ScanMaker 9800 XL. Neste caso, foi utilizada a resolução máxima disponível de 2000 dpi. As imagens do BAM foram digitalizadas com resolução de 600 dpi e 256 níveis de cinza no escâner LS 85 SDR Lumisys/Kodak.

3.3 Pré-Processamento das Imagens

O pré-processamento consistiu, principalmente, da aplicação de dois procedimentos de melhoramento da imagem. Conforme proposto por [11, 7, 14, 16, 19], inicialmente deve-se reduzir, e se possível eliminar, o ruído decorrente da digitalização da imagem, e posteriormente fazer um realçamento da imagem, isto é, melhorar o contraste. As operações de otimização da imagem foram executadas em software adequado (*Image Pro Plus 4.0 - Media Cybernetcs*).

3.4 Obtenção dos Perfis Transversais a Solda em Níveis de Cinza

Os perfis transversais ao cordão de solda foram obtidos conforme indicado na figura 3.1. Porém, as imagens radiográficas contêm diversas informações irrelevantes à qualidade da solda, como a parte do metal de base junto à solda e a identificação da mesma, sendo necessário um procedimento de extração do cordão de solda para retirar tais informações do perfil antes do seu processamento. O que além de reduzir o esforço computacional no processamento destes sinais, também melhora o desempenho do

sistema de reconhecimento de padrões, pois minimiza os erros induzidos por informações desnecessárias.

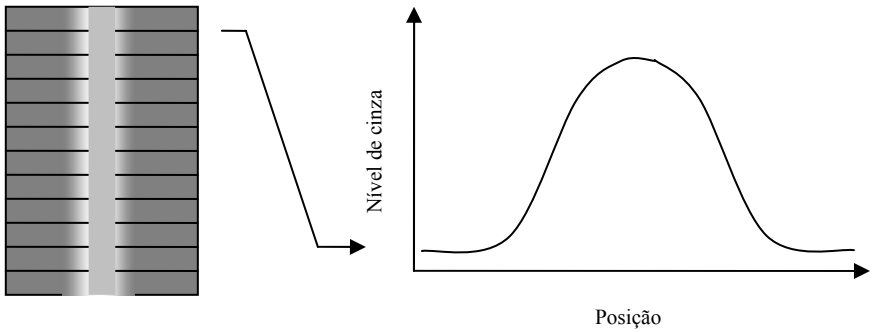

Figura 3.1: Distribuição em níveis de cinza no perfil transversal a solda.

Para que se tenha uma posição espacial precisa dos defeitos de soldagem, assim como da largura da solda, as imagens devem ser previamente calibradas. Para tanto se utilizou a escala de calibração existente no filme radiográfico, esta calibração foi feita no próprio programa *Image Pro Plus 4.0*.

Aos perfis obtidos, inicialmente, foi aplicado um procedimento de extração do cordão de solda, de forma que as informações irrelevantes referentes ao metal de base pudessem ser extraídas. Este procedimento é baseado na constatação de Liao [7, 14, 16], de que o perfil em níveis de cinza transversal a solda aproxima-se mais de uma curva gaussiana do que outros objetos neste perfil, e consistindo em fazer uma regressão não-linear do perfil segundo a curva de Gauss, sabendo-se que os perfis transversais às juntas soldadas com reforço têm um comportamento gaussiano. Posteriormente, os parâmetros média e desvio-padrão dos perfis gaussianos obtidos foram utilizados para definir o limite de corte para a extração do cordão de solda, sem perda de informações da solda, e retirando do sinal informações irrelevantes do metal de base. O procedimento consiste em truncar o perfil na largura três vezes o desvio-padrão, centralizado na mediana. O que estiver dentro desta largura é considerado como

referente à solda, o restante é excluído do perfil. A figura 3.2 exemplifica este procedimento, aplicado a um perfil já processado, cuja aplicação será apresentada na próxima seção.

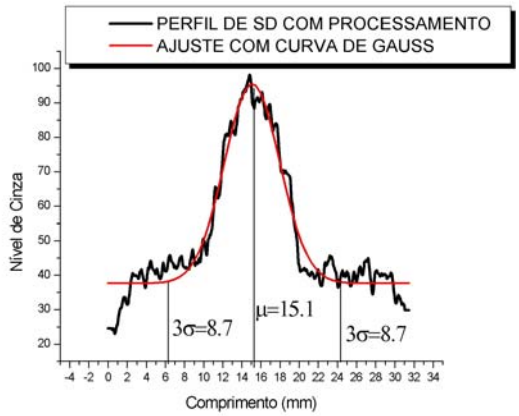

Figura 3.2: Extração da solda segundo regressão gaussiana.

Devido aos resultados desfavoráveis obtidos pelo procedimento acima, que serão apresentados e discutidos no próximo capítulo, fez-se necessário extrair visualmente da imagem radiográfica a parte referente somente à junta soldada utilizando o mesmo programa *Image Pro Plus 4.0*, conforme exemplo da figura 3.3.

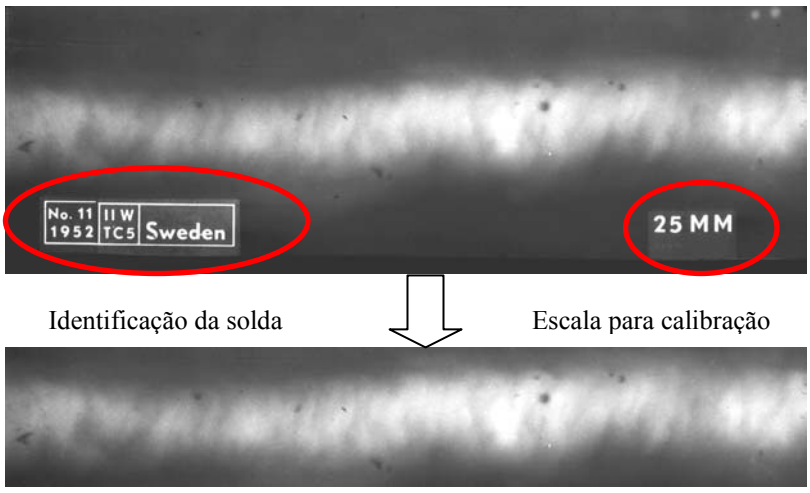

Figura 3.3: Extração visual da solda.

Portanto, os perfis transversais ao cordão de solda foram obtidos em duas condições: (a) com extração visual, executada diretamente na imagem radiográfica, e (b) sem a extração visual, que foram submetidos ao procedimento de extração utilizando a regressão gaussiana. Os perfis foram exportados a partir do programa *Image Pro Plus 4.0* no formato *ASCII* .

3.5 Pré-processamento dos Perfis Transversais

O pré-processamento dos perfis transversais ao cordão de solda obtidos na etapa anterior consistiu, inicialmente, em aplicar um filtro passa-baixa para suavização. O filtro utilizado foi o Savitzky-Golay[22, 34], cuja característica principal é a redução do ruído, porém sem prejuízo ao conteúdo de alta freqüência do sinal, o que, caso acontecesse, implicaria em uma brusca diminuição da amplitude do sinal, a exemplo do média móvel padrão. Após a aplicação do filtro Savitzky-Golay foi feita uma normalização da amplitude dos perfis processados a partir da divisão de cada ponto do sinal pelo valor da máxima amplitude do mesmo. Com isso, permitiu-se que todos os perfis tivessem escalas similares de amplitude.

A efetividade deste pré-processamento, incluindo suavização e normalização, foi verificada através da utilização de classificadores lineares para detecção de defeitos de soldagem [35] e serão detalhados adiante.

Devido à diversidade das características das soldas utilizadas para formar os conjuntos de dados, assim como da resolução espacial das imagens, fez-se necessário proceder uma interpolação nos perfis, de forma que obtivéssemos todos os perfis com mesma quantidade de pontos. O procedimento de interpolação foi executado segundo a

Transformada Rápida de Fourier (FFT)[34], dentro da rotina de pré-processamento descrita a seguir. Assim, a interpolação foi executada com base no perfil de menor dimensão, i.e., menor número de pontos. Este número de pontos variou de acordo com o conjunto de dados.

No último estágio de pré-processamento, foi feita uma nova normalização dos sinais em função da posição do defeito em relação ao pico da curva gaussiana obtida na regressão descrita acima. Neste caso, todos os defeitos deveriam estar posicionados ao lado direito da curva de Gauss, visando melhorar o desempenho dos classificadores. Destacamos que a escolha do lado direito foi meramente aleatória (o lado esquerdo poderia ter sido usado também). Os sinais cujo defeito se localizasse no lado esquerdo foram invertidos, considerada a imagem especular, conforme exemplifica a figura 3.4. Caso o defeito se localizasse na área central do perfil seu posicionamento era mantido.

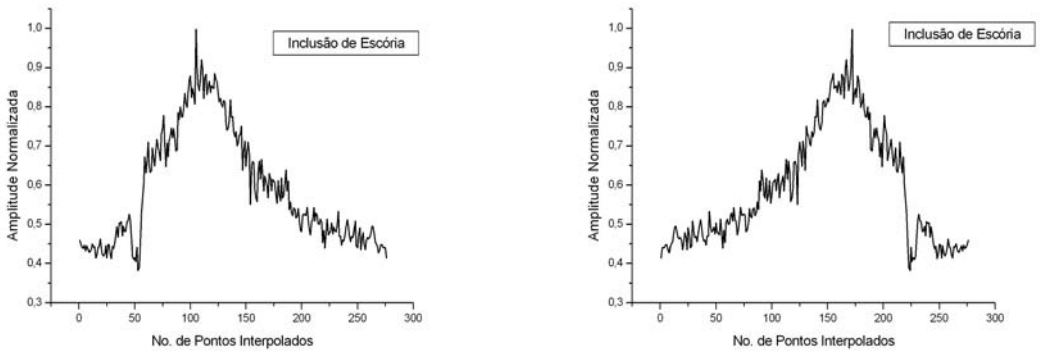

(a) (b)

Figura 3.4: Exemplo de perfil (a) antes e (b) depois da normalização da posição do defeito para o lado direito do ponto de máxima amplitude.

Cada estágio do pré-processamento descrito acima foi testado em classificadores lineares e não-lineares, isto é, foram formados conjuntos de dados que foram implementados no treinamento, validação e teste destes classificadores nas duas

situações, com e sem o pré-processamento, visando uma comparação dos resultados obtidos. Deste ponto em diante, os perfis em níveis de cinza transversais ao cordão de solda podem ser chamados de sinais.

Foi desenvolvida uma rotina no programa Matlab 6.0 para implementar as etapas do pré-processamento estabelecidas após estudo adequado; assim, ao final do trabalho todas as etapas estavam contidas dentro da mesma rotina, onde é possível variar diversos parâmetros do pré-processamento:

a) os perfis de entrada são aqueles obtidos no programa de processamento de imagens *Image Pro Plus 4.0* no formado ASCII e o seu número de pontos varia de acordo com a imagem de origem e sua amplitude varia de 0 a 255 (tons de cinza); posteriormente foi implementada nesta rotina uma opção de abrir a imagem e obter o perfil transversal diretamente, sem necessidade de utilizar um programa de processamento de imagens;
b) o número de pontos na janela do filtro Savitzky-Golay e o grau desta função[22]: após avaliação das condições de suavização do perfil foi utilizada uma função do segundo grau e uma janela de oito pontos para cada lado;
c) o número de pontos do sinal a ser obtido ao final da interpolação: foi definido em função do perfil com menor número de pontos e foi executada segundo a Transformada Rápida de Fourier (FFT)[34], cuja aplicação consiste em operar esta transformada ao sinal e posteriormente sua regressão de acordo com o número de pontos desejado;
d) normalização da amplitude: As componentes de cada perfil foram divididas pelo seu valor máximo, assim, os valores não mais variam de 0 a 255, mas de 0 a 1;

e) regressão não-linear segundo a curva de Gauss: esta regressão pode ser operada segundo funções do primeiro ao quinto grau; foi utilizada função do primeiro grau, de forma que se obtenha somente um pico nesta curva;

f) subtração do perfil processado da sua gaussiana: esta operação tem o objetivo de avaliar a utilização do sinal subtraído como entrada nos classificadores; os resultados preliminares inviabilizaram esta utilização;

g) exportação: no formato *ASCII* dos sinais obtidos, as condições destes sinais são: original e interpolado, suavizado e interpolado, suavizado, interpolado e subtraído.

A figura 3.5 mostra a janela de operação desta rotina. Para a normalização da posição do defeito foi elaborada uma rotina em separado, que consiste, simplesmente, em visualizar o sinal e caso a indicação de defeito esteja localizada ao lado esquerdo do pico da gaussiana é dado comando para inverter o sinal, caso contrário, a distribuição de pontos no sinal é mantida.

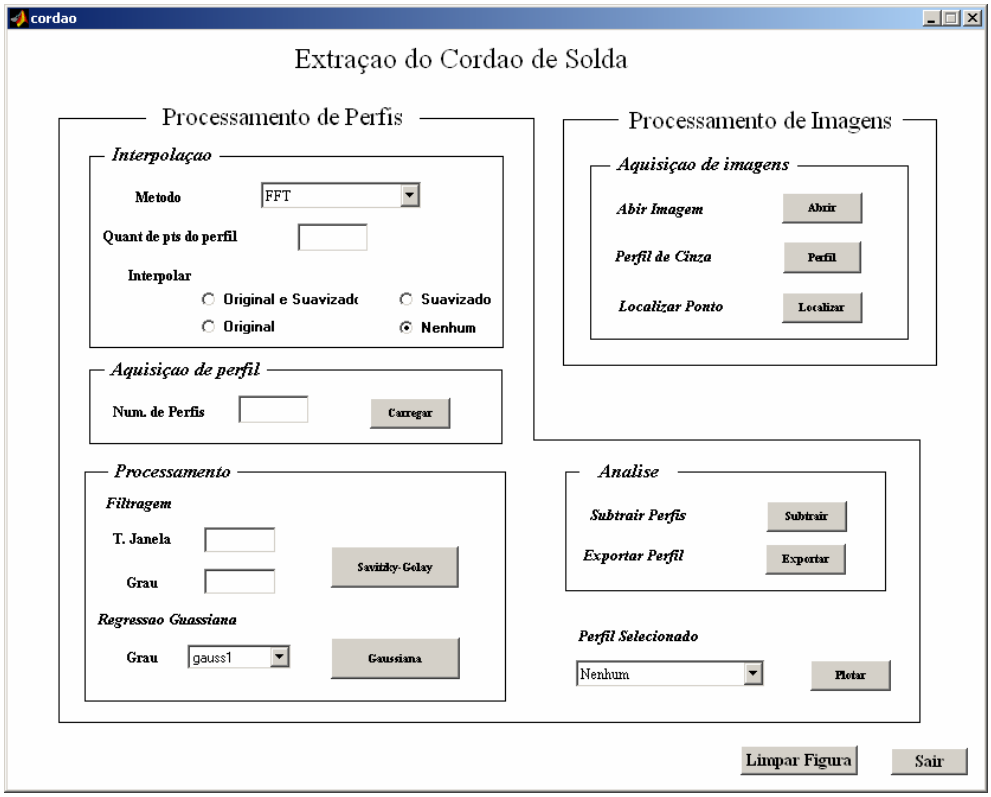

Figura 3.5: Janela de operação da rotina de pré-processamento.

3.6 Formação dos Conjuntos de Dados

Foram formados, basicamente, três conjuntos de dados ao longo do trabalho, de acordo com as necessidades e disponibilidade de amostras (imagens radiográficas). Os mesmos são descritos a seguir:

a) O primeiro conjunto de dados foi formado a partir de padrões radiográficos do IIW (ano 1952); este conjunto foi formado por 200 sinais, sendo metade deles representando a classe sem defeito (SD) e a outra metade contendo defeitos (CD) de diversos tipos e distribuídos aleatoriamente, sem diferenciação. Este conjunto de dados foi formado para avaliar a efetividade do primeiro pré-processamento (suavização com o filtro Savitzky-Golay e normalização da amplitude) e do procedimento de extração da solda segundo a curva de Gauss. O procedimento de extração foi aplicado de forma que todos os sinais possuíssem 500 pontos, não tendo sido aplicada qualquer tipo de interpolação. Este conjunto de dados será referenciado neste trabalho como conjunto 1.

b) Um segundo conjunto de dados foi formado com 1400 sinais, também a partir de padrões radiográficos do IIW (ano 1952), composto de 200 sinais de cada classe. Neste caso têm-se sete classes: sem defeito (SD) e seis tipos de defeito, falta de fusão (FF), falta de penetração (FP), inclusão de escória (IE), mordedura (MO), porosidade (PO) e trinca (TR). Entre parênteses estão indicadas as siglas utilizadas para designar os respectivos tipos de defeito; ao longo deste trabalho serão utilizadas estas siglas para referenciá-los. A este conjunto foi aplicado o mesmo pré-processamento do conjunto 1, contudo acrescenta-se aqui a interpolação executada segundo a transformada rápida de Fourier (FFT)[34]. Este conjunto de dados será referenciado neste trabalho como conjunto 2.

c) O terceiro conjunto foi formado a partir de padrões radiográficos IIW (ano 1995) e BAM, contendo as mesmas sete classes do conjunto 2 (SD, FF, FP, IE, MO, PO e TR), porém em quantidades variadas para cada rótulo de classe. A este conjunto foi aplicado o mesmo pré-processamento do conjunto 2, porém incluiu-se neste caso a normalização da posição do defeito conforme rotina descrita na seção 3.5. A quantidade de sinais para cada classe foi: SD – 467, FF – 64, FP – 181, IE – 154, MO – 95, PO – 412 e TR – 265. Este conjunto de dados será referenciado neste trabalho como conjunto 3.

3.7 Redes Neurais Supervisionadas

Normalmente, quando se trabalha com reconhecimento de padrões, avalia-se primeiro a possibilidade de separação entre as classes estudadas por um processo de classificação linear, visto ser este o processo mais simples, rápido e de fácil implementação. Conforme descreve Haykin [4], e também Bishop [36], uma rede neural de uma única camada pode ser usada para implementação de um classificador linear de padrões, para então partir para a implementação de classificadores não-lineares, caso os lineares não apresentem a melhor solução para a separação das classes envolvidas. Desenvolveu-se para este trabalho, primeiramente, os classificadores lineares implementados por redes neurais supervisionadas, compostas por neurônios do tipo tangente hiperbólica. Para estimar os parâmetros da rede, suas sinapses e bias, recorreu-se ao algoritmo de treinamento por retropropagação do erro, usando momento e taxa de aprendizado variável. Uma descrição detalhada destes parâmetros de treinamento é encontrada em uma vasta literatura, como bons exemplos temos Haykin[4] e Bishop[36].

Em Silva[9], encontra-se uma descrição aprofundada do estudo de classificadores lineares e não lineares de padrões usados para separar defeitos de soldagem típicos como: mordedura, falta de penetração, porosidade e inclusão de escória, mas neste caso, os dados eram compostos por características geométricas extraídas dos defeitos após o processamento das imagens.

Para um melhor entendimento apresentamos na figura 3.6 o modelo de neurônio artificial utilizado, tipo tangente hiperbólica, onde são indicados os elementos que o compõem.

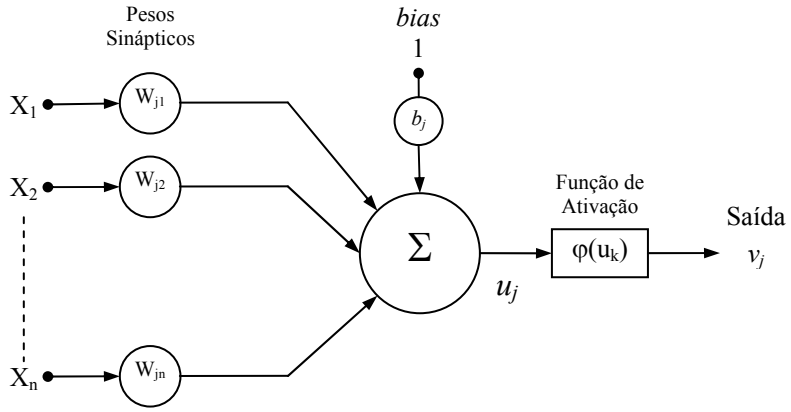

Figura 3.6: Modelo de um neurônio artificial índice *j* [4].

Observando a figura 3.6 temos os seguintes elementos que formam um neurônio:

a) Um conjunto de sinapses, cada qual tendo o seu próprio peso ou peso sináptico. Cada entrada X_n, conectada ao neurônio *j* através da sinapse w_{jn}, é multiplicada pelo peso sináptico w_{jn}. O índice *j* se refere ao neurônio em questão e o *n* se refere à entrada que o peso conecta. É importante ressaltar que um peso sináptico pode ter valores positivos ou negativos.

b) Um somador, que soma os sinais de entrada da rede ponderados pelos respectivos pesos sinápticos do neurônio, executando uma combinação linear dos mesmos com um sinal de polarização b_j e gerando a variável de excitação interna u_i.

c) Uma função de ativação, que é usada para restringir a amplitude da saída de um neurônio. Normalmente, uma saída de um neurônio está contida no intervalo [0, 1] ou [-1, 1]. No caso do neurônio linear a função de ativação é a identidade, para neurônios não lineares utilizou-se a função tangente hiperbólica.

O modelo apresentado acima inclui uma polarização (ou *bias* b_j) aplicada ao neurônio que pode ser representado por uma sinapse *bj* conectada a uma entrada de sinal fixa unitária. Este *bias* tem o efeito de aumentar ou diminuir a função de excitação, dependendo de ser ele positivo ou negativo, e mudar a região de operação da função de ativação.

Usando a formulação matemática, o neurônio *j* e a saída *v* podem ser descritos funcionalmente por:

$$u_j = \sum_{i=q}^{n} w_{jn} x_n + b_j \tag{3.1}$$

e

$$v_j = \varphi(u_j) \tag{3.2}$$

A função de ativação utilizada foi a função tangente hiperbólica, definida por:

$$v = \varphi(u) = \tanh(u) \tag{3.3}$$

Esta função possui várias vantagens nesta utilização, entre elas destaca-se a propriedade de ser diferenciável em todo o domínio, fator importante quando se aplica o treinamento do tipo retropropagação do erro.

O algoritmo de treinamento empregado foi de retropropagação do erro via gradiente descendente. Por tratar-se de um treinamento supervisionado, têm-se as respostas desejadas para os neurônios de saída da rede, sendo direto o cálculo dos ajustes dos pesos das sinapses ligadas a estes neurônios. Entretanto, o mesmo não ocorre para os neurônios das camadas intermediárias. Neste caso, todos os neurônios da

rede compartilham a responsabilidade pelos erros cometidos em todas as saídas da rede. A dificuldade é saber como recompensar ou penalizar estes neurônios pela sua parcela de responsabilidade[4]. A figura 3.7 mostra um exemplo da estrutura deste tipo de rede.

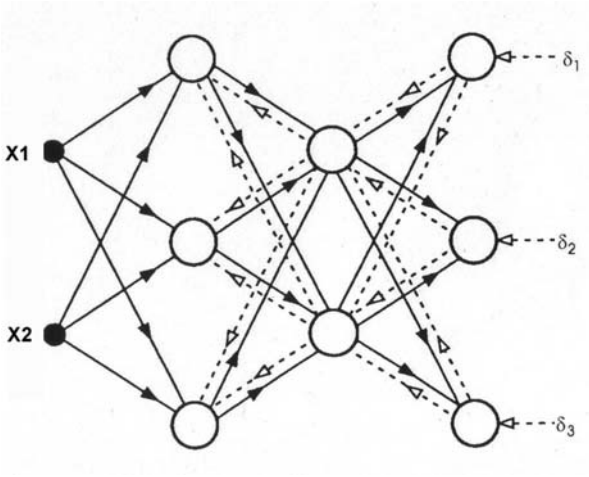

Figura 3.7: Estrutura de redes neurais supervisionadas com 3 camadas e treinamento por retropropagação do erro. Linhas cheias representam fluxo do sinal *feedforward*, linhas tracejadas a retropropagação do erro[27].

O erro encontrado para os neurônios das camadas intermediárias é determinado recursivamente, em termos dos erros de todos os neurônios de camada de saída, aos quais o neurônio intermediário está diretamente conectado[37, 4].

O algoritmo de retropropagação do erro pode ser resumido nas seguintes etapas:

a) Inicializar os pesos sinápticos, inclusive o *bias*, de forma aleatória e estabelecer os parâmetros da rede;

b) Repetir até que um critério de parada, previamente estabelecido, seja atingido (erro mínimo, número de passos, etc.);

b.1) Para cada padrão de treinamento:

- Propagar a entrada através da rede e calcular a saída na fase de propagação;

- Comparar as saídas produzidas com as saídas desejadas e determinar o erro em cada saída;

- Retropropagar o erro através da rede;

- Calcular o acréscimo a ser aplicado em cada sinapse baseado nas informações da propagação do sinal e do erro (conforme fórmula que utiliza gradiente descendente);

b.2) Atualizar os pesos sinápticos pela média dos valores de delta (δ) calculados.

O algoritmo de retropropagação do erro apresenta algumas desvantagens, como por exemplo: lentidão de treinamento para superfícies de erro mais complexas e possível convergência para mínimos locais. Porém, existem técnicas alternativas de treinamento, como utilização de passo e momento variáveis, para minimizar estes problemas, como nos algoritmos utilizados neste trabalho.

3.7.1 Classificadores Lineares

As entradas dos discriminadores são os perfis transversais à solda em níveis de cinza pré-processados, onde cada perfil representa um vetor $\underline{x}$, cuja dimensão é dada pelo seu número de pontos, portanto varia de acordo com o conjunto de dados. Um discriminador linear para classe C_j separa as entradas desta classe das demais através de uma inequação linear de primeira ordem:

$$\underline{x} \in C_j \Leftrightarrow u_j > 0 \tag{3.4}$$

onde,

$$u_j = \sum_{i=1}^{7} \underline{w}_{ij}\, \underline{x}_i + b_j = \underline{w}_j^T\, \underline{x} + b_j \tag{3.5}$$

Cada classe C_j tem seu discriminador próprio, definido por $\underline{w_j}$ e b_j.

No domínio da entrada o separador da classe C_j, isto é, o lugar geométrico dos pontos que satisfazem $u_j = 0$, é um plano perpendicular ao vetor $\underline{w_j}$ e distante da origem $-b_j / |\underline{w}_j|$, distância medida no sentido de $\underline{w}_j$. É prático normalizar-se $|\underline{w}_j| = 1$, mudando-se o valor de b_j para $b_j/|\underline{w}_j|$ de modo a não alterar a inequação 3.4. Neste caso, u_j mede a distância da entrada $\underline{x}$ ao separador, e é uma medida não linear da probabilidade de acerto da classificação para aquela entrada específica.

Um discriminador ótimo é aquele que maximiza a probabilidade de acerto da classificação. Os discriminadores lineares ótimos são uma técnica bem conhecida em estatística denominada discriminadores de Fisher[38]. Uma forma prática de implementá-los é através de uma rede neural de uma camada e, nesta camada, um único neurônio por classe, técnica utilizada neste trabalho.

A visualização geométrica dos separadores é impraticável neste caso, devido à dimensão dos vetores de entrada. Supondo um espaço de duas dimensões, cada separador S_j divide o espaço de entrada em dois semi-espaços (semiplanos), onde $u_j > 0$ e $u_j < 0$. Entradas que pertencem à classe C_j e que são corretamente classificadas, são representadas por pontos no semiplano onde u_j é positivo. Note que podem existir regiões onde o semiplano de dois ou mais separadores é positivo, por outro lado podem existir regiões situadas no semiplano negativo para todos os separadores. Nesta situação, pode-se valer do fato que u_j é a medida de probabilidade de uma determinada entrada pertencer à classe C_j e assim tomar a classe com maior valor de u_j como a mais provável e considerá-la como a saída. Este é um exemplo de critério de reclassificação, aplicável quando nenhum neurônio é excitado.

Para os classificadores não-hierárquicos encontra-se o vetor discriminador $\underline{w}_j$ e a polarização b_j para cada uma das classes C_j em relação as restantes. Ambos são normalizados para um vetor $\underline{w_j}$ de módulo unitário. Neste caso, visa-se a obtenção do

melhor discriminador possível para que uma classe seja separada das restantes, não alterando o conjunto de entrada para o treinamento da rede. Os vetores entrada são multiplicados pelos vetores $\underline{w_j}$ de cada classe e somado ao deslocador b_j (bias) correspondente, gerando u_j. O resultado desta operação que for maior que zero corresponde à classe, defeito (CD) ou sem defeito (SD). Pelo fato de existirem somente duas classes possíveis, não há o risco de ocorrer mais de uma indicação, caso contrário poderia ser utilizado um critério de reclassificação, onde o maior valor de u_j indica a classe mais provável.

3.7.2 Classificadores Não-Lineares

Os classificadores não-lineares foram desenvolvidos usando redes neurais com duas camadas, uma intermediária e outra de saída. Para encontrar o número de neurônios ótimo na camada intermediária, variou-se o número de neurônios nesta camada, acompanhando o desempenho de treinamento e teste, e os erros obtidos após treinamento em função do número de neurônios utilizados. Com isso, chegou-se ao número de neurônios ótimos para obter o melhor desempenho de classificação com os dados utilizados no aprendizado da rede. O número ótimo foi considerado como o menor número de neurônios acima do qual a taxa de acerto não melhora significativamente. Ao fim de cada passo do treinamento são introduzidos sinais que não participaram deste para avaliar a capacidade de generalização do classificador ao longo do treinamento e acompanhar a evolução do aprendizado da rede, possibilitando parar o treinamento no momento mais apropriado. Este procedimento é chamado de validação. Este número fornece o máximo acerto, minimizando os problemas de supertreinamento (*overtraining*). Os resultados encontrados são dispostos em tabelas,

onde se indica o número de neurônios e o desempenho da rede no treinamento e validação. Tratando-se de uma rede de classificação de padrões, o número de neurônios da camada de saída corresponde ao número de classes estudadas, portanto 2 ou 7 neurônios na camada de saída, dependendo do objetivo. Todas as funções de ativação adotadas, como já mencionado, foram do tipo tangente hiperbólica e com presença de bias. O sucesso na utilização de classificadores não lineares na detecção de defeitos nos perfis transversais a solda foi relatado em [39]. A figura 3.8 ilustra a aplicação dos classificadores lineares e não lineares.

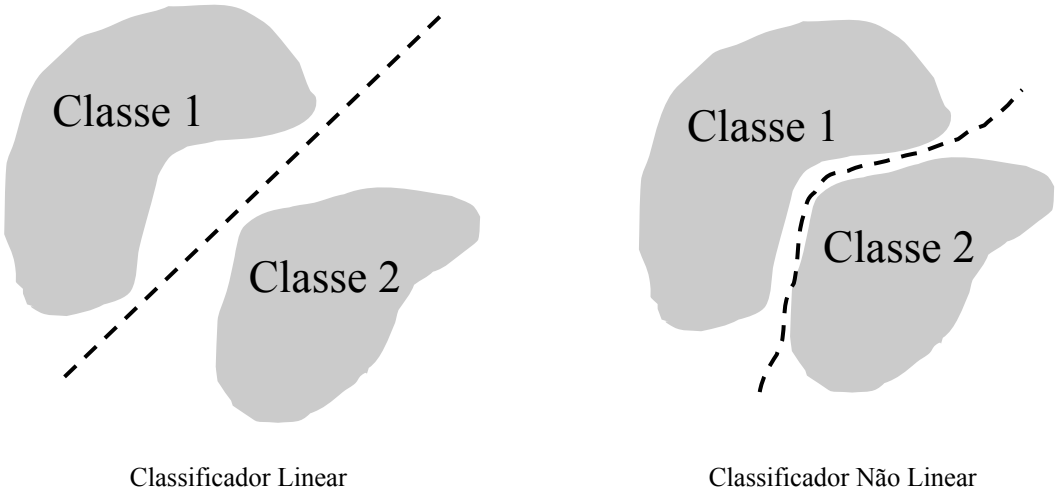

Figura 3.8: Classes separáveis linearmente e não linearmente[27].

3.7.3 Aplicação dos Classificadores

a) Conjunto 1

Conforme informado anteriormente, este conjunto continha 200 sinais, sendo 100 deles com defeito (CD) e os outros 100 sem defeito (SD). Este conjunto foi utilizado para avaliar a capacidade de separação entre as duas classes utilizando classificadores lineares e os mesmos sinais nas condições com e sem pré-processamento. Desta forma pôde-se avaliar também a melhoria no desempenho dos

classificadores na discriminação de sinais contendo defeitos daqueles sem defeitos, após aplicação do filtro Savitzky-Golay.

b) Conjunto 2

Este conjunto possui sete classes distribuídas em 1400 sinais, sendo 200 sinais de cada classe. Neste caso foi avaliada a implementação dos classificadores não-lineares na detecção de defeitos, isto é, na discriminação das classes CD e SD.

c) Conjunto 3

Este conjunto possui 1638 sinais distribuídos dentre as sete classes já conhecidas. Foram utilizados classificadores não-lineares para a detecção e classificação destes defeitos, isto é, inicialmente foi feita discriminação somente entre as classes CD e SD, e posteriormente sua classificação dentre as sete classes conhecidas. Este conjunto foi utilizado para avaliar o quanto à normalização da posição do defeito melhora o desempenho dos classificadores não-lineares. Como as classes possuíam números diferentes de quantidade de dados, diferenças acentuadas inclusive, de forma a não favorecer o treinamento da rede para uma classe mais populosa, algumas replicações aleatórias foram feitas para igualar o número de dados presentes em cada classe. Porém, para que não houvesse dados usados para testar os classificadores que também tivessem sido usados em seus treinamentos, procedeu-se primeiramente com sorteios aleatórios de dados para teste em cada classe, com um percentual fixo para todas as classes, e, em seguida, estes dados foram replicados aleatoriamente nas classes menos populosas até que as mesmas contivessem a mesma quantidade de dados da classe com maior número de sinais de entrada. O mesmo foi realizado com os dados de treinamento. Desta forma, os pares de conjuntos de treinamento e teste usados na estimação da acurácia [24, 40] do

classificador continham a mesma quantidade de dados em cada classe, sem que a rede fosse testada com dados que foram utilizados anteriormente no treinamento, e vice-versa. Este critério elimina o efeito das diferentes populações das classes e é fundamental para otimizar a probabilidade de acerto em função de cada entrada, considerando cada classe igualmente provável.

3.8 Componentes Principais de Discriminação (CPD)

O cálculo das componentes principais de discriminação é bastante útil, pois este cálculo 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. Supondo um vetor $\underline{x}$ de dimensão n como entrada, deseja-se então reduzir a dimensão de $\underline{x}$ para um vetor $\underline{z}$ de dimensão m, $m < n$, contendo somente as informações mais relevantes, temos a representação: $\underline{x}(\dim\, n) \rightarrow \underline{z}(\dim\, m)$, $m < n$. O vetor $\underline{z}$ é composto pelas m componentes principais de discriminação, sendo a primeira componente formada pela projeção ortogonal de $\underline{x}$ na direção $\underline{w}_1(|\underline{w}_1|=1)$.

Assim, a componente principal p_1 é a projeção ortogonal de $\underline{x}$ em $\underline{w}_1$ e pode ser representada como $p_1 = \underline{x}^t\underline{w}_1$, onde $\underline{w}_1$ representa a direção principal de discriminação. A representação de $\underline{x}$ em uma única componente é $\underline{x} \cong p_1\underline{w}_1$ e o erro de representação $\underline{x}_1$ é tal que $\underline{x} = p_1\underline{w}_1 + \underline{x}_1$. O vetor $\underline{x}_1$ representa a informação não projetada de $\underline{x}$ na direção $\underline{w}_1$. Decompondo o vetor $\underline{x}$ em m componentes, temos: $\underline{x} = p_1\underline{w}_1 + p_2\underline{w}_2 + ... + p_m\underline{w}_m + \underline{\varepsilon}$, onde $\underline{\varepsilon}$ é o vetor erro residual para a representação usando m componentes.

Para avaliar a capacidade de separação entre as classes de perfis recorreu-se à técnica de componentes principais de discriminação linear e não-linear, também implementada por redes neurais. Gráficos bidimensionais compostos pelas duas

componentes principais de discriminação linear e não linear foram construídos, permitindo a visualização otimizada do problema proposto. Em Silva [41], detalha-se a implementação desta metodologia.

Neste trabalho, foram utilizadas as componentes principais de discriminação linear e não-linear, obtidas por redes neurais de duas (linear) ou três (não-linear) camadas. O ajuste dos vetores sinápticos das 3 camada é feito pelo método gradiente descendente usando a função do erro médio quadrático como função objetivo, na qual a primeira camada contém apenas um neurônio por vez, após o treinamento, o vetor $\underline{w}_1$ representa a direção principal de discriminação não linear das classes estudadas, conforme descrito em [24, 41] e exemplificado na figura 3.9.

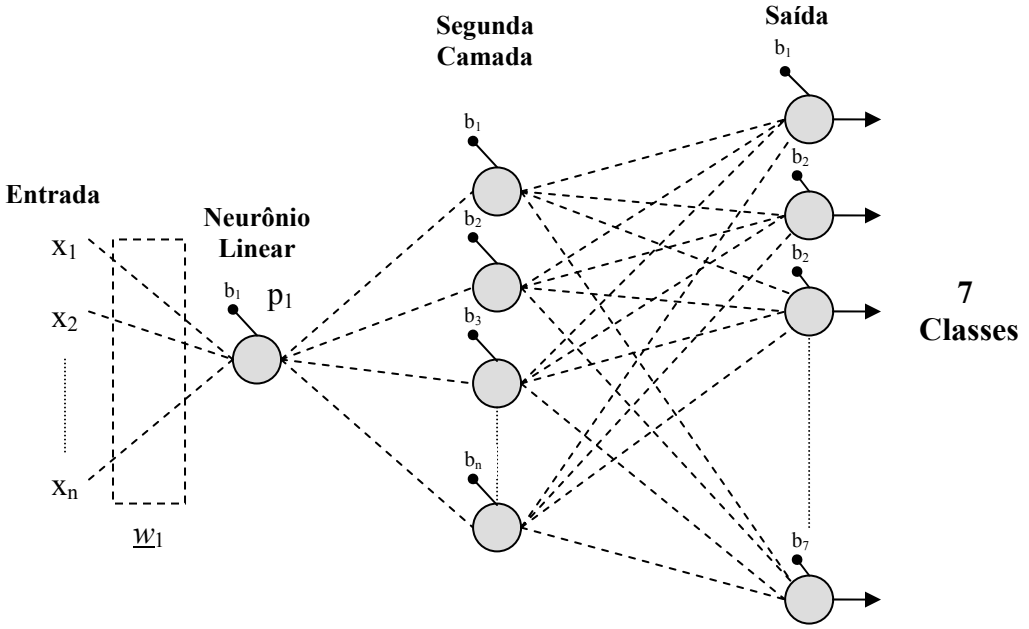

Figura 3.9: Rede para implementação da primeira componente principal de discriminação não linear[27].

O desenvolvimento das demais componentes consiste em torná-las ortogonais, ou seja $\underline{w}_1 \perp \underline{w}_2 \perp \underline{w}_3 \perp \ldots \perp \underline{w}_m$. Para tanto, a rede é novamente treinada após a obtenção

de $\underline{w}_1$ da mesma maneira, contudo utilizando $\underline{x}_1$ como nova entrada, onde $\underline{x} = p_1\underline{w}_1 + \underline{x}_1$, procede-se desta forma sucessivamente até a componente m. Denominamos estas como componentes principais de atuação independente, uma vez que cada componente é obtida com o ruído $\underline{x}_j$ da informação não utilizada pelas anteriores $x_j = \underline{x} - \sum_{k=1}^{j-1} p_k \underline{w}_k$.

Gráficos bidimensionais foram obtidos para cada um dos três conjuntos de dados descritos na seção anterior. Tais gráficos são constituídos pelas duas componentes principais de discriminação, representadas por P_1 e P_2, e foram obtidos para os 3 diferentes conjuntos de dados descritos na seção 3.6.

O fato de estes gráficos serem bidimensionais deve ser considerado, pois os vetores de entrada dos conjuntos 1, 2 e 3 possuem 500, 268 e 276 pontos, respectivamente, o que representa a sua dimensão. Esta é uma ótima ferramenta para avaliar os conjuntos de dados disponíveis quanto à complexidade de classificação esperada, contudo deve-se considerar a diferença entre as dimensões dos vetores e dos gráficos, além da utilização de classificadores lineares e não-lineares, de forma a não basear somente nestes resultados a avaliação da viabilidade do trabalho.

3.9 Redes Neurais Semi-Supervisionadas

Além do aprendizado supervisionado, redes neurais são capazes também de receber o aprendizado não supervisionado ou semi-supervisionado. Este tipo de aprendizado, que será discutido nesta seção, permite, além de realizar a classificação dos eventos, levantar os padrões das classes.

Foram utilizadas redes neurais tipo ART modificadas para obtenção dos padrões de cada classe e posteriormente foi utilizada como classificador, a metodologia será apresentada a seguir.

3.9.1 Classificação por Similaridade

Uma classificação ou agrupamento é dito por similaridade quando entradas "semelhantes" são alocadas ao mesmo agrupamento. Dois vetores entrada $\underline{x}_i$ e $\underline{x}_j$ são ditos semelhantes se a distância Euclidiana entre eles $d_{ij} = | \underline{x}_i - \underline{x}_j |$ é pequena se comparada com a distância média dos vetores de uma dada população. Este critério normalmente corresponde à similaridade física das entradas no mundo real. Portanto, d_{ij} é uma medida de dissimilaridade entre $\underline{x}_i$ e $\underline{x}_j$.

Consideremos,

$$s_{ij} = 1 - \frac{d_{ij}^2}{M} \tag{3.6}$$

onde,

$$M = \frac{1}{2} Max(d_{ij}^2) \tag{3.7}$$

s_{ij} é agora uma medida de similaridade entre $\underline{x}_i$ e $\underline{x}_j$, variando de 1, para máxima similaridade ($d_{ij} = 0$), até -1, para máxima dissimilaridade (d_{ij} máximo). Se as entradas estiverem normalizadas para $| \underline{x}_i | = 1 \ \forall$ i, isto é, todo $\underline{x}_i$ está sobre uma hiperesfera de raio unitário, então é fácil demonstrar que[42]

$$s_{ij} = 1 - \frac{d_{ij}^2}{2} = \underline{x}_i^t \underline{x}_j \tag{3.8}$$

Um aspecto muito interessante da classificação por similaridade é que ela pode ser feita de forma não supervisionada. Um treinamento não supervisionado é aquele em que conhecer a saída desejada não é necessário para que a rede se adapte e produza a resposta esperada. É o caso da Camada de Kohonen e das redes ART[4, 37, 38, 42].

Classificadores por similaridade, em especial aqueles por redes neurais, apresentam propriedades interessantes, algumas das quais nos são muito úteis:

a) O treinamento é usualmente muito mais rápido que o supervisionado;
b) A rede pode ser treinada e operada simultaneamente. Claro que o desempenho na operação depende da quantidade de treinamento já realizado;
c) Cada classe é treinada de forma razoavelmente independente das demais. Isto torna a rede plástica: classes existentes podem ser alteradas ou removidas, ou mesmo novas classes introduzidas, sem alterar o comportamento das demais classes já "aprendidas". Esta característica é muito importante no nosso caso;
d) Sua arquitetura é simples e aberta, permitindo fácil hibridização com outras redes e conceitos, como ocorre neste trabalho. Permite uma fácil interpretação geométrica do *modus operandi* do classificador, ao contrário da rede *feedforward* treinada por retropropagação do erro;
e) A rede gera "padrões" para as classes, o que permite estender o conhecimento sobre a fenomenologia do caso[42].

3.9.2 Distribuição dos Dados

Considerando um caso muito comum, no qual nosso problema pode ser enquadrado, onde cada entrada $\underline{x}$ pode ser vista como um padrão $\underline{w}$ ao qual um ruído $\underline{r}$ foi adicionado: $\underline{x} = \underline{w} + \underline{r}$.

Supondo que o ruído é branco gaussiano, isto é, o ruído de cada componente de $\underline{r}$ tem média nula, mesma variância σ^2, distribuição gaussiana e não são correlatos.

As entradas $\underline{x}$ se distribuirão em uma hiperesfera centrada em $\underline{w}$. Sem perda de generalidade e para facilidade de visualização, consideremos $\underline{x}$ bidimensional e relaxemos a condição $| \underline{x} | = 1$ (apenas para visualização). A figura 3.10 mostra o

domínio de diferentes classes com diferentes ruídos e, inclusive, com regiões de superposição.

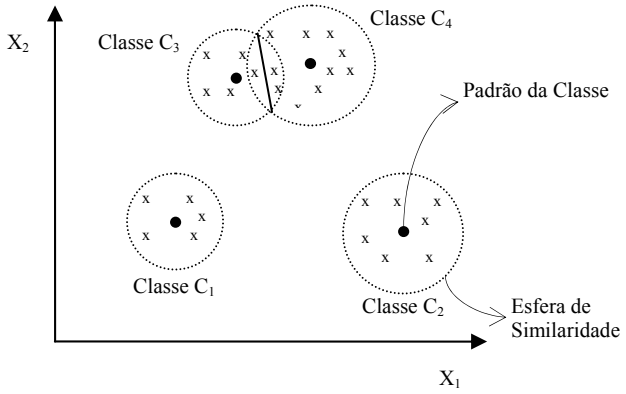

Figura 3.10: Ilustração da uma classificação de vetores segundo quatro padrões e esferas de similaridade[42].

Existem casos onde uma classe pode ser melhor representada por mais de um padrão, perdendo assim a característica esférica. Neste caso, pode-se utilizar várias esferas (padrões) para representar esta classe, conforme exemplificado na figura 3.11.

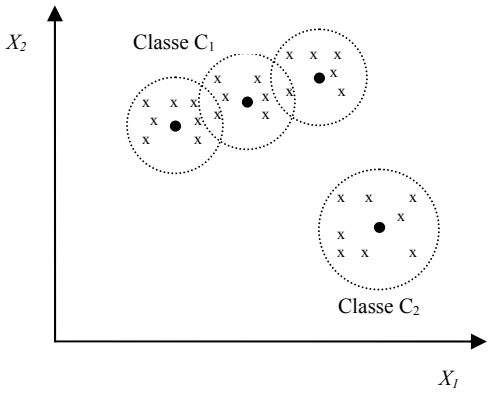

Figura 3.11: Ilustração de uma distribuição da classe C_1 não esférica e C_2 esférica[42].

Estes tipos de dados sugerem que o domínio das classes seja delimitado por hiperesferas. Para que o agrupamento seja bem sucedido é fundamental que o raio da hiperesfera de cada classe seja bem escolhido; hiperesferas com raios muito grandes delimitam domínios muito maiores que os da classe, inclusive podendo englobar

entradas que pertencem a outras classes de defeitos; raios muito pequenos exigirão um grande número de padrões para representar a classe.

A distribuição das distâncias d_i das entradas $\underline{x_i}$ aos respectivos padrões $\underline{w}$ é a distribuição de $|\ \underline{r}\ |$. É o lado positivo de uma gaussiana com variância $n\sigma^2$ onde n é a dimensão de $\underline{x}$ e σ^2 a variância de cada uma de suas componentes. A figura 3.12 esboça a forma desta distribuição em linha cheia.

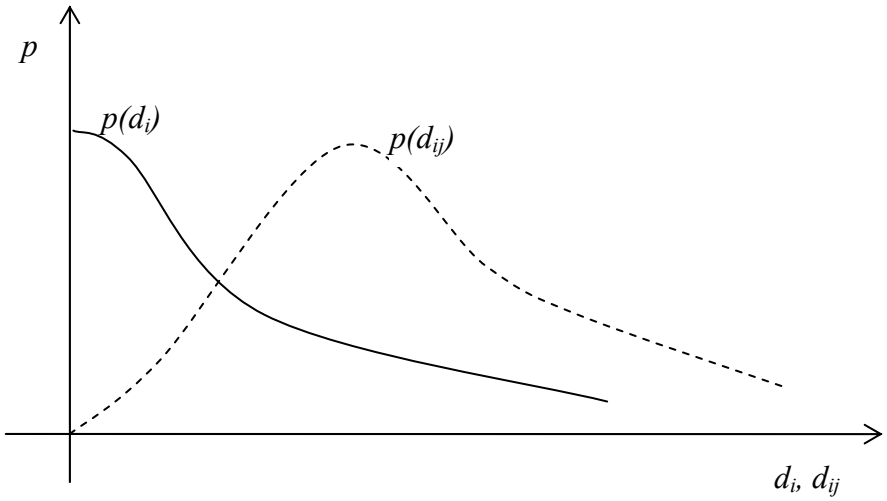

Figura 3.12: Esquema de distribuição de $p(d_i)$ e $p(d_{ij})$ [42].

Considerando a distribuição $p(d_{ij})$ normal, um valor razoável para o raio da hiperesfera que contém esta classe é, portanto,

$$r \cong 2{,}5\sqrt{n}\sigma \tag{3.9}$$

onde, a constante 2,5 estatisticamente engloba 90% das amostras.

Normalmente não é prático calcular este valor em classes mais complexas, com vários padrões.

A distribuição das distâncias d_{ij} entre as duas entradas $\underline{x_i}$ e $\underline{x_j}$ associadas ao mesmo padrão $\underline{w}$ responde por uma distribuição, conforme esquema da figura 3.12, com média (e moda, aproximadamente) igual a

$$m \cong \sqrt{2n}\sigma \tag{3.10}$$

No caso de uma classe complexa, com vários padrões $\underline{w}$, m pode ser identificado como a menor moda da distribuição de d_{ij}, e pode ser facilmente determinado.

Se considerarmos que o menor diâmetro de uma classe é igual ou maior que o diâmetro das hiperesferas que determinam seu domínio, então, das equações 3.9 e 3.10:

$$r \cong \frac{2{,}5}{\sqrt{2}} m \cong 1{,}5m \tag{3.11}$$

onde r é o maior raio de similaridade recomendado para a classe.

3.9.3 Equações e Estrutura da Rede ART Modificada

Considerando o descrito anteriormente, no caso de várias classes C_i com diferentes padrões $\underline{w}_i$, a classe mais provável para uma entrada $\underline{x}$ formada por um padrão corrompido por ruído branco é aquela cujo padrão $\underline{w}$ é o mais similar à entrada $\underline{x}$, isto é

$$x \in C_i \Leftrightarrow s_i > s_j \forall j \neq i \tag{3.12}$$

onde,

$$s_i = \underline{x}^t \underline{w}_i ; \; |\underline{x}| = 1 \tag{3.13}$$

este é o chamado casamento com o padrão, "*template matching*". Mas, além disto podemos querer também que haja similaridade suficiente entre a entrada e o padrão mais similar a ela, isto é, que

$$s_i \geq \rho_i = 1 - \frac{r_i^2}{2} \tag{3.14}$$

onde ρ_i é o parâmetro de vigilância, r_i é chamado raio de similaridade. O domínio da classe C_i é, portanto, uma hiperesfera de centro $\underline{w}_i$ e raio $\underline{r}_i$.

O uso simultâneo das duas condições acima com classes C_i, com padrões $\underline{w_i}$ e raio de similaridade r_i diferentes pode ser implementado usando a variável u_i:

$$x \in C_i \Leftrightarrow u_i > u_j \forall j \neq i \tag{3.15}$$

onde

$$u_i = \underline{x}^t \underline{w}_i - \rho_i \tag{3.16}$$

e

$$\rho_i = 1 - \frac{r_i^2}{2} \tag{3.17}$$

A rede que implementa esta classificação é a "*winner-takes-all*" na figura 3.13.

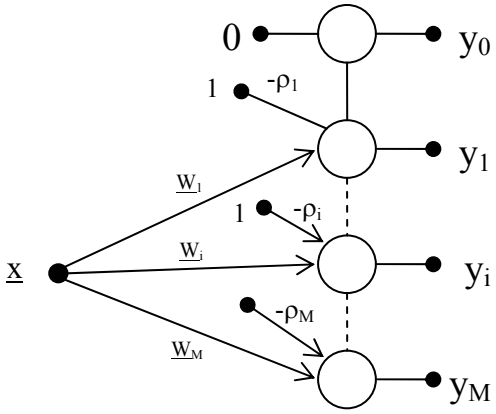

Figura 3.13: Estrutura da rede ART implementada[43, 42, 44].

O neurônio ganhador indica o padrão mais similar à entrada e que satisfaz a condição de similaridade mínima. No caso do neurônio y_o ganhar nenhum padrão existente satisfaz a condição de similaridade mínima.

A figura 3.10 apresenta o centro das classes e o domínio das mesmas, conforme estabelecido pela rede. No caso das classes com superposição, o separador na região pertencente a ambas hiperesferas (círculos, neste exemplo) de similaridade é o hiperplano (reta, neste exemplo) que contém a intersecção das hiperesferas, como seria

natural esperar. Na figura 3.11 uma classe não esférica é representada por três padrões. Uma entrada que ative qualquer um destes três neurônios pertence à classe. Esta condição pode ser implementada utilizando um neurônio que recebe como entrada as saídas dos três neurônios, implementa com elas um "ou" lógico e fornece em sua saída a informação da pertinência da entrada à classe. Se as saídas dos neurônios $y_i \in \{0, 1\}$ o "ou" lógico pode ser implementado conforme a esquema na figura 3.14, onde

$$C_j = \begin{cases} 0 \text{ se } u_j < 0 \\ 1 \text{ se } u_j \geq 0 \end{cases} \tag{3.18}$$

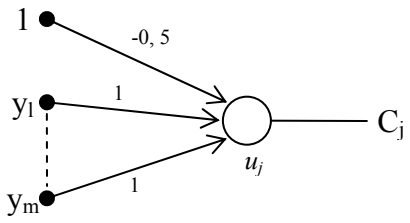

Figura 3.14: Esquema de implementação do "OU" lógico[42].

3.9.4 Treinamento da Rede ART Modificada

Este tipo de rede denominada rede ART Modificada[23], reúne conceitos da Camada de Kohonen unidimensional, das redes ART 1 e 2 de Grossberg [37] e das redes *Counterpropagation* de Hecht-Nielsen [37]. O treinamento é chamado semi-supervisionado porque inicialmente uma rede ART é treinada para cada classe de forma independente, para diferentes raios de similaridade. Cada uma destas redes é dita "especializada" em sua classe. O treinamento das redes ART utiliza dois passos alternativos. Se um neurônio y_i é vencedor, a entrada se situa dentro da esfera de similaridade deste neurônio i, e o vetor sinapse do mesmo sofre um deslocamento na direção da entrada

$$\Delta \underline{w}_i = \alpha(\underline{x} - \underline{w}_i) \tag{3.19}$$

onde o passo de treinamento α é tipicamente 0,1. Esta operação visa conduzir o padrão $\underline{w_i}$ para a média das entradas por ele representadas[42].

Se o neurônio y_o é vencedor, isto significa que nenhum padrão existente representa a entrada com similaridade suficiente, e é necessário criar um novo padrão para isto. Um novo neurônio é, então, criado com vetor sinapse $\underline{w}_{M+1} = \underline{x}$. O critério de parada do treinamento deve ser definido previamente; o mais comum é estabelecer a parada após um determinado número de passos sem criar novos padrões.

Após o treinamento, todos os padrões $\underline{w_i}$ encontrados devem ter seu módulo normalizado para 1. O fato de $|\underline{x}| = 1$ não implica em que $|\underline{w}| = 1$.

Uma questão importante neste tipo de rede é o equilíbrio entre o tamanho do raio de similaridade e o número de padrões, pois o raio de similaridade excessivamente grande pode não discriminar diferentes classes e a criação de muitos padrões implica em uma indefinição dentre as classes envolvidas[42].

Assim, para cada classe são treinadas várias redes especialistas ART, cada uma com um parâmetro de vigilância, ρ, diferente, $\rho = 1 - \frac{r^2}{2}$, em especial com aqueles obtidos com r no entorno de r_{min} dado pela equação 3.9. Cada rede tem um número, N, diferente de padrões. É feita, então, a crítica dos diferentes agrupamentos (diferentes redes) obtidos conforme a seção a seguir.

3.9.5 Qualidade do Agrupamento de Cada Classe

Um bom agrupamento deve apresentar uma pequena dissimilaridade intra-classe e uma grande dissimilaridade inter-classes[38].

A dissimilaridade intra-classe, para a classe C_j, pode ser medida por:

$$D_j^2 = \frac{1}{N_j} \sum_{\forall \underline{x} \in C_j} | \underline{x} - \underline{w}_j |^2 \tag{3.20}$$

e a dissimilaridade intra-classe total, a ser minimizada, pode ser representada por:

$$D^2 = \sum_{\forall j} N_j D_j^2 = \sum_{\forall j} \sum_{\forall \underline{x} \in C_j} | \underline{x} - \underline{w}_j |^2 \tag{3.21}$$

Por outro lado o agrupamento deve ser tal que maximize a dissimilaridade inter-classes, que pode ser medida por:

$$D_{out}^2 = \sum_{\forall j} N_j \, | \underline{w}_j - \underline{w}_o |^2 \tag{3.22}$$

onde $\underline{w}_o$ é o baricentro de todas as entradas:

$$\underline{w}_o = \frac{1}{N} \sum_{\forall \underline{x}} \underline{x} \tag{3.23}$$

Otimizar duas funções objetivo é usualmente complicado. Felizmente, em nosso caso é possível demonstrar que a soma $D^2 + D^2_{out}$ é constante, ou seja, basta minimizar D^2 que estaremos automaticamente maximizando D^2_{out}.

Consideremos a minimização de D^2. À medida que aumentamos o número, N, de padrões, $\underline{w}$, usados no agrupamento, D^2 decresce, entretanto, os padrões passam a não ser representativos. Iniciando com um padrão, N = 1, a cada padrão acrescentado D^2 decresce, inicialmente de forma significativa e em seguida em pequenos passos. É usualmente aceito que o maior N que ainda produz um decréscimo significativo é o que corresponde a um bom agrupamento "natural" [38]. Como o número de padrões depende do raio de similaridade escolhido, este é um segundo critério para determinar o raio de similaridade.

O ponto de inflexão de D indica apenas a região no entorno da qual o número ótimo de agrupamentos deve estar, mas a escolha de N, número de padrões de classes, necessita ser complementada por uma análise fenomenológica e/ou numérica. A razão

disto é que uma região com elevada população pode apresentar uma queda considerável em D se representada por dois padrões bastante similares, e uma região com baixa população pode estar empregando um único padrão para representar entradas pouco similares. Fenomenologicamente, o primeiro caso pode ser evidenciado por padrões muito semelhantes, e o segundo por padrões estranhos, inesperados, resultado apenas da média de dois padrões e sem significado físico[38, 42].

Numericamente, o problema pode ser analisado calculando a população N_i atendida por cada padrão $\underline{w}_i$, isto é, as entradas $\underline{x}$ para as quais $\underline{w}_i$ é o padrão vencedor, e o valor de D_i^2 para esta população, dado por:

$$D_i^{\,2} = \frac{1}{N_i} \sum_{\forall \underline{x} \in C_{\underline{W}_i}} |\, \underline{x} - \underline{w}_i \,|^2 \tag{3.24}$$

onde $C_{\underline{W}_i}$ é o conjunto dos vetores $\underline{x}$ tais que $\underline{w}_i$ é o neurônio vencedor. O cálculo da média das distâncias entre os diversos padrões $\underline{w}_i$, $p(d_{ij}, \forall i \neq j)$, onde $d_{ij} = \left[\underline{w}_i - \underline{w}_j\right]^{1/2}$ também fornece informação essencial[38, 42].

Dois padrões $\underline{w}_i$ e $\underline{w}_j$, cuja distância d_{ij} é consideravelmente menor que a média, e cujos D_i^2 e D_j^2 também são consideravelmente menores que a média, são fortes candidatos a serem compactados em um único padrão.

Um padrão $\underline{w}_k$ com baixa população N_k e alto D_k^2 é candidato a ser particionado em dois ou mais padrões distintos.

O resultado da análise da qualidade dos agrupamentos é a escolha da rede ART que representará cada classe.

3.9.6 Rede Completa

Para cada rede especialista em cada classe os neurônios que representam os diferentes padrões de classe têm suas saídas conectadas em um neurônio de uma próxima camada, que implementa um "ou" lógico e cuja saída indica a pertinência da entrada à classe, como mencionado anteriormente. Na figura 3.15, a seguir, a classe 1 é composta pelos padrões $\underline{w}_1$ a $\underline{w}_5$, a classe 2 pelos padrões $\underline{w}_6$ a $\underline{w}_9$ e a classe 3 pelos padrões $\underline{w}_{10}$ a $\underline{w}_{11}$. Todas as redes especialistas são, então, conectadas em um único "*winner takes all*"[42].

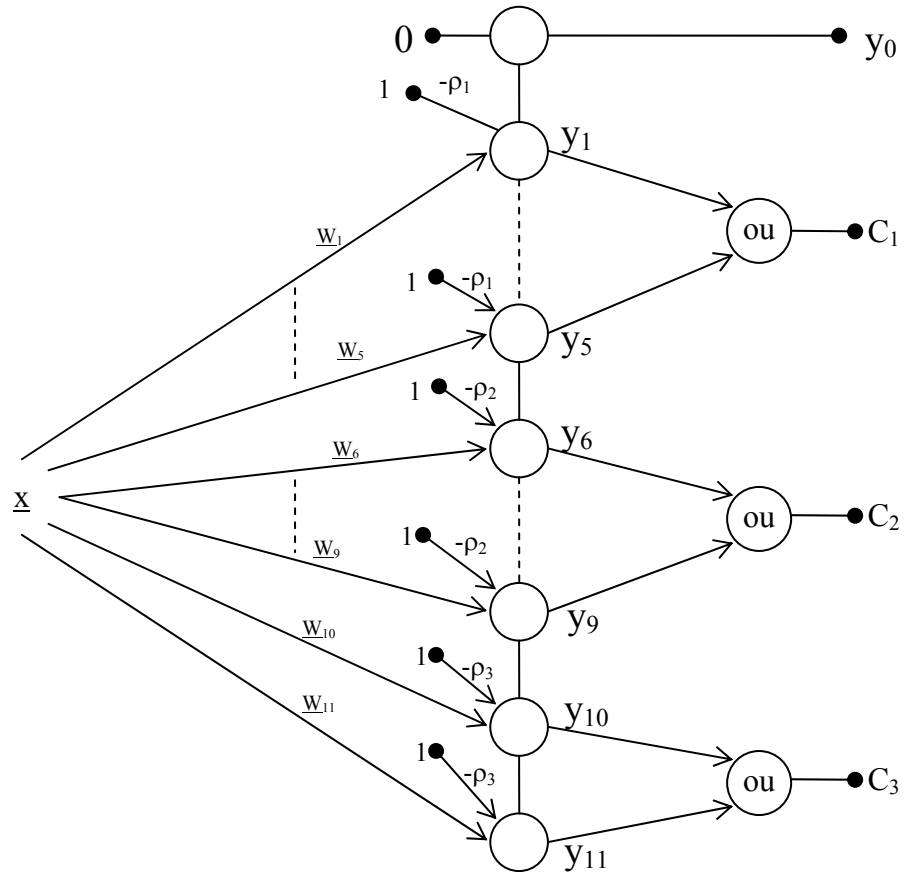

Figura 3.15: Esquema da rede ART Modificada completa.

Na rede completa uma saída C_j ativa indica que a entrada pertence à classe C_j, e a saída y_o ativa indica que a entrada não apresenta suficiente similaridade com nenhum dos padrões estabelecidos. Se o neurônio y_o for eliminado, a rede sempre apresentará uma classificação; isto é análogo ao processo de reclassificação que usamos nas redes *feedforward*. Neste caso a classe indicada é aquela que contem o padrão cuja superfície da hiperesfera de similaridade mínima está mais próxima da entrada.

Obtida a rede final, esta deve ser testada com os conjuntos de treinamento e teste.

Classificações errôneas são chamadas "invasões" porque significam que um padrão, com sua esfera de similaridade, invadiu o domínio de uma outra classe. Para corrigir o problema o raio de similaridade do neurônio responsável pela classificação errada deve ser reduzido até que a classificação fique correta. Isto implicará, porém, na recomposição da rede especialista que continha o neurônio, porque seu domínio foi reduzido; talvez seja necessário incluir novos padrões para que ela continue a abranger o domínio de sua classe[42].

Um número elevado de classificações errôneas poderá requerer a correção das redes.

4 – RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentados os resultados obtidos ao longo do desenvolvimento do trabalho segundo a metodologia apresentada no capítulo anterior. Os seguintes tópicos serão abordados: obtenção dos perfis transversais à solda, o pré-processamento aplicado a estes perfis, determinação das componentes principais de discriminação linear e não-linear dos perfis e finalmente a utilização das redes neurais com treinamento do tipo supervisionado e semi-supervisionado, bem como o estudo da sua acurácia.

Paralelamente, serão feitas as respectivas discussões a respeito destes resultados e comparações com trabalhos de pesquisa de outros autores.

4.1 Obtenção dos Perfis Transversais às Soldas em Níveis de Cinza

Foram formados três conjuntos de dados ao longo do desenvolvimento deste trabalho. Esta criação aconteceu de acordo com as necessidades e disponibilidade de amostras (imagens radiográficas). Conforme descrito na seção 3.6, cada um destes conjuntos foi utilizado com determinados objetivos e suas características foram aprimoradas ao longo do trabalho de pesquisa de tese. Os dois primeiros conjuntos (conjuntos 1 e 2) foram conjuntos preliminares, utilizados para fazer testes e ajustes na metodologia deste trabalho. Os resultados de cada etapa da pesquisa serão apresentados e discutidos para cada conjunto de dados. Reapresenta-se e detalha-se abaixo, em ordem cronológica de obtenção e utilização, as principais características destes conjuntos de dados:

a) Conjunto 1: O primeiro conjunto de dados foi formado a partir de padrões radiográficos do IIW (ano 1952), sendo este conjunto formado por 200 sinais, com metade deles representando a classe sem defeito (SD) e a outra metade contendo defeitos (CD) de diversos tipos e distribuídos aleatoriamente. Este conjunto de dados foi formado para avaliar a efetividade do primeiro pré-processamento (suavização com o filtro Savitzky-Golay e normalização da amplitude), bem como seus parâmetros, além do procedimento de extração da solda segundo a curva de Gauss.

b) Conjunto 2: Um segundo conjunto de dados foi formado com 1400 sinais, também a partir de padrões radiográficos do IIW (ano 1952), composto de 200 sinais de cada classe. Conforme informado no capítulo anterior, este conjunto, continha sete classes: sem defeito (SD), falta de fusão (FF), falta de penetração (FP), inclusão de escória (IE), mordedura (MO), porosidade (PO) e trinca (TR). Entre parênteses estão indicadas as siglas utilizadas para designar os respectivos tipos de defeito, ao longo deste trabalho serão utilizadas estas siglas para referenciá-los. A este conjunto foi aplicado o mesmo pré-processamento utilizado no conjunto 1, tendo-se aqui acrescentado a interpolação, executada segundo a transformada rápida de Fourier (FFT)[34].

c) Conjunto 3: o terceiro conjunto foi formado a partir de padrões radiográficos IIW, incluindo as duas coleções (ano 1952 e 1995), e BAM, contendo as mesmas sete classes do conjunto 2 (SD, FF, FP, IE, MO, PO e TR), porém em quantidades variadas. A este conjunto foi aplicado o mesmo pré-processamento do conjunto 2, porém incluiu-se aí a normalização da posição do defeito, que se apresenta em forma de uma descontinuidade no perfil gaussiano do sinal, conforme rotina descrita na

seção 3.5. A quantidade de sinais para cada classe foi: SD – 467, FF – 64, FP – 181, IE – 154, MO – 95, PO – 412 e TR – 265, formando um total de 1638 sinais.

4.2 Conjunto 1

4.2.1 Pré-Processamento

O pré-processamento dos perfis foi efetuado visando a redução na quantidade de informações a serem processadas quando da implementação das redes neurais, principalmente daquelas referentes ao metal de base da junta, bem como a redução do ruído normalmente contido nestes sinais, sem causar, contudo, prejuízo às informações contidas nestes sinais e relevantes para o desenvolvimento dos classificadores, melhorando desta forma o seu desempenho.

A extração do cordão de solda visava eliminar a parte do sinal referente ao metal de base, cujo conteúdo não traz nenhuma informação relevante ao nosso objetivo; a suavização teve como objetivo eliminar o ruído presente no sinal, decorrente do próprio processo radiográfico e da digitalização; a normalização dos sinais de entrada é importante em qualquer processamento, pois visa homogeneizar a faixa de amplitude dos sinais, ressaltando, desta forma, as diferenças inerentes à classe a que pertencem, o que irá impactar na sua correta classificação.

O procedimento de extração do cordão de solda, descrito na seção 3.4, foi aplicado ao conjunto 1 de forma que todos os sinais possuíssem 500 pontos. Para definir parâmetros de suavização através do filtro Savitzky-Golay[22, 34] (número de pontos na janela de aplicação do filtro e grau da função polinomial de suavização) os perfis

foram avaliados visualmente, utilizando a experiência em processamento de sinais, até se concluir que, para suavizar o perfil sem perda de informações relevantes, sem queda acentuada da amplitude do sinal, consistia em uma janela de 10 x 10 pontos com polinômio do segundo grau. A justificativa para presença de ruído em radiografias de materiais é muito discutida e diversos fatores são relacionados na literatura [11, 27, 28]. Sabe-se, entretanto, que o ruído eletrônico aleatório provocado pelo processo de digitalização é quase sempre presente[27].

A figura 4.1 apresenta exemplos de perfis deste conjunto para uma solda sem defeito e com defeito neste grupo, antes e depois do pré-processamento sendo que a figura 4.1.a mostra um exemplo de perfil obtido no trabalho para um cordão de solda sem a presença de defeitos (SD), neste caso sem processamento com o filtro de Savitzky-Golay. Fica claro, como se pode observar, a existência de ruído no sinal. A figura 4.1.b representa o perfil resultante obtido pela aplicação do filtro no perfil da figura 4.1.a, evidenciando uma considerável suavização do ruído e mantendo a forma original do perfil. Na mesma figura 4.1.b, tem-se uma linha contínua representando a curva de Gauss obtida para o perfil processado. Observa-se que, distante da média três desvios padrões simetricamente para os dois lados, entramos na região de representação do metal de base, portanto, fora do interesse do trabalho proposto. O mesmo foi verificado para todos os outros perfis (num total de 100) referentes a condição sem defeito (SD). Isto permitiu chegar a conclusão que, com uma boa margem de segurança, pode-se definir o limite de três desvios-padrão (3σ) para extração do cordão de solda para esta classe (SD). Tais resultados das extrações automáticas dos cordões para os perfis estudados pelo algoritmo desenvolvido mostraram que esta metodologia, quase sempre, é eficiente e menos complexa do que a proposta por Liao[7], por exemplo. Apenas a figura 4.1 é mostrada porque todas as demais obtidas nos sinais restantes são

similares em resultados e observações a respeito do filtro aplicado e da técnica de extração do cordão. Vale destacar que esta técnica destina-se somente às condições em que há ocorrência de reforço de cordão de solda, onde o comportamento gaussiano é evidente. Para outras condições, possivelmente outros tipos de ajustes terão que ser feitos.

A figura 4.1.c mostra um perfil original contendo o defeito trinca no cordão de solda, visualizado no "vale" acentuado próximo ao centro do cordão. A figura 4.1.d representa o resultado da aplicação do filtro no perfil original, mostrando que o ruído foi claramente alisado, mas a amplitude do "vale" referente ao defeito sofreu uma redução notável, mesmo com as características de preservação de altas freqüências que o filtro possui. O ajuste com curva de Gauss, na figura 4.1.d, também ilustra a constatação de que, com três desvios padrões distantes da média (centro da curva gaussiana), simetricamente, eliminou-se a parte do perfil referente ao metal de base somente no lado direito do sinal, restando dúvidas quanto ao ponto de corte que deve ser aplicado ao lado esquerdo devido às irregularidades nesta região do sinal. Esta situação foi verificada para a maioria dos sinais contendo defeitos naquela região e nos sinais com perfil irregular (não gaussiano), o que impossibilitou a implementação desta metodologia, pois sua aplicação se limitaria somente a poucas classes, o que implicaria em um conjunto de dados não homogêneo.

A mesma metodologia foi aplicada aos 100 perfis com existência de defeito (CD). É importante destacar que os 100 perfis contendo defeitos possuíam as classes porosidade, trinca, falta de penetração, falta de fusão e inclusão de escória conforme indicação do IIW. A classe mordedura, também muito freqüente em cordões de solda, não foi analisada por se tratar de uma classe que normalmente ocorre na borda do cordão, o que cria um fator complicador para a extração do cordão sem eliminação da

parte do perfil referente ao defeito. Inclusive pelo fato desta classe ser facilmente detectada por métodos convencionais.

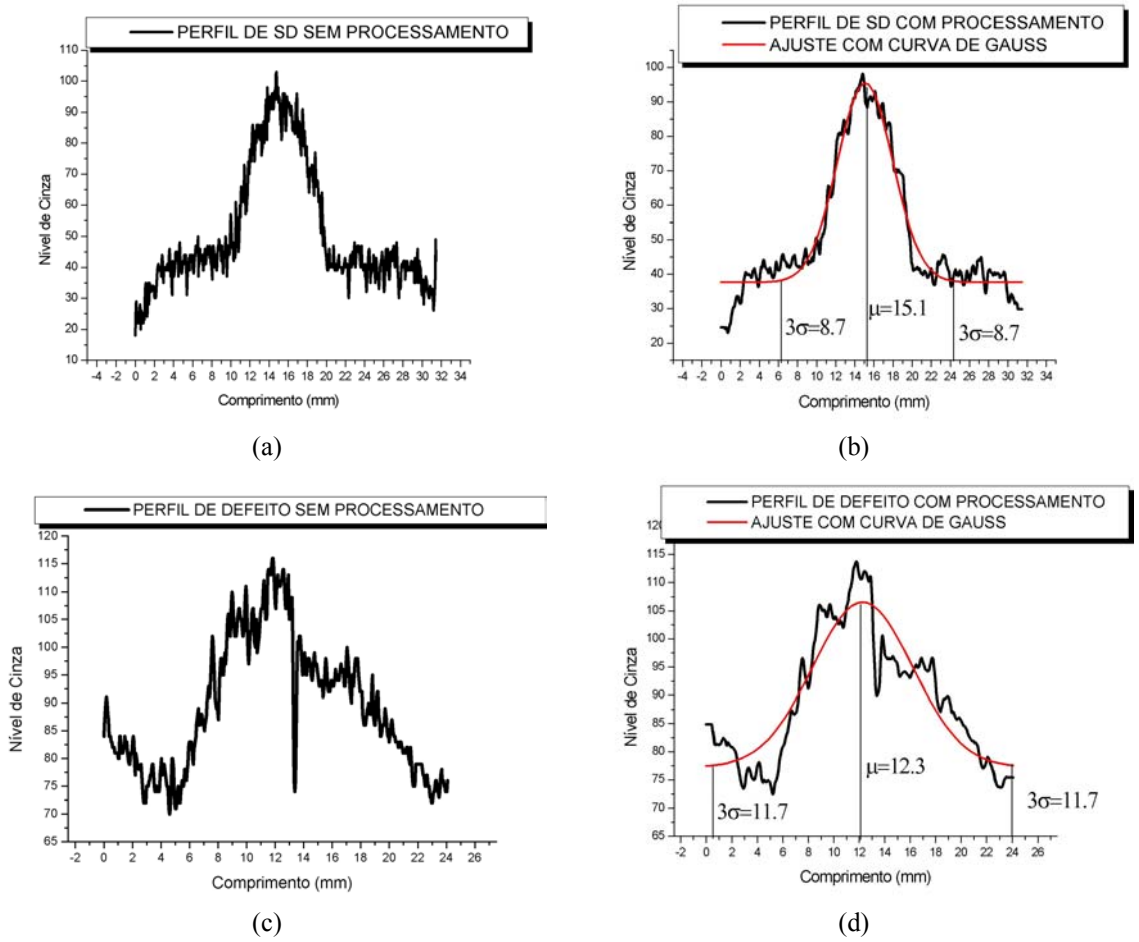

Figura 4.1: Exemplos de perfis do conjunto 1, antes e depois do pré-processamento, indicando a gaussiana, o seu pico e o ponto de corte, em 3σ**:** (a) perfil obtido diretamente da imagem radiográfica de uma solda sem defeito na condição sem processamento, onde a presença de ruído é visível; (b) mesmo perfil com processamento com filtro Savitzky-Golay, e o resultado de um ajuste gaussiano; (c) perfil de uma radiografia na região de ocorrência de um defeito, sem processamento; (d) perfil anterior com processamento e ajuste gaussiano.

A metodologia proposta para extração do cordão de solda a partir da regressão gaussiana e do desvio-padrão não foi implementada para o restante dos conjuntos de

dados (conjuntos 2 e 3) por não proporcionar a confiabilidade necessária no ponto de corte ocorrendo interferência com alguns tipos de defeitos, que são objeto deste trabalho, e pelo fato de existir grande variação no nível de ruído dos perfis utilizados, tendo sido necessária a extração visual do cordão de solda da imagem original, conforme mostrado na seção 3.4. A implementação de uma metodologia de processamento de imagens para automatizar esta extração exige um estudo aprofundado, o que deixamos como sugestão para trabalhos futuros.

4.2.2 Componentes Principais de Discriminação Linear (CPDL)

Foram utilizados classificadores lineares para discriminar duas classes, com e sem defeito (CD e SD) no conjunto 1, o que permitiu obter as duas componentes principais de discriminação linear (P_1 e P_2) como mostrado na figura 4.2. Verifica-se que as duas classes de perfis estudadas CD e SD têm regiões distintas no gráfico e são linearmente separáveis, não sendo necessária, neste caso, a utilização de um classificador não linear.

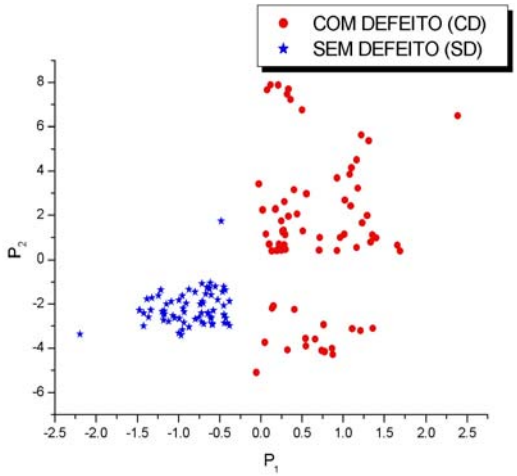

Figura 4.2: Gráfico das componentes principais de discriminação linear, referente ao conjunto 1, para as classe defeito e sem defeito.

4.2.3 Classificadores Lineares

Para ratificar a decisão pelos parâmetros de pré-processamento acima foram utilizados classificadores lineares, nos quais os mesmos sinais foram inseridos nas condições com e sem pré-processamento, visando nesta etapa inicial avaliar a capacidade deste algoritmo discriminar perfis transversais em níveis de cinza provenientes de soldas com e sem defeito. A tabela 4.1 mostra a acurácia dos classificadores lineares para discriminação das classes com e sem defeito aplicados a 100 sinais, sendo 70 para treinamento e 30 para teste.

Tabela 4.1: Índices de acerto numérico e percentual para os conjuntos de dados usados para treinamento e teste dos classificadores lineares.

	SEM PROCESSAMENTO		**COM PROCESSAMENTO**	
	Treinamento	**Teste**	**Treinamento**	**Teste**
Com Defeito (CD)	70 (100%)	16 (53,3%)	70 (100%)	19 (63,3%)
Sem Defeito (SD)	70 (100%)	30 (100%)	70 (100%)	30 (100%)
Índice Geral de Acerto	140 (100%)	46 (76,7%)	140 (100%)	49 (81,7%)

Os classificadores lineares desenvolvidos com treinamento por retropropagação do erro, em batelada e usando apenas um neurônio, proporcionaram 100% de acerto geral para os dados de treinamento (70 perfis de cada classe) nas condições de perfis: com e sem processamento com filtro, comprovando o que havia sido constatado no gráfico das CPDL. Com os dados de teste (30 perfis de cada classe), os sinais sem processamento resultaram em 100% de acerto para os perfis da classe SD

e 53,3% de acerto para a classe CD, o que resulta em um índice geral de acerto de 76,7% (46 em um total de 60 perfis). Este índice é razoavelmente bom tendo em vista a simplicidade do classificador e as características complexas de informações que estão presentes em perfis de cinza de cordões de solda, que normalmente contêm ruídos de origem variada, oscilações intensas de distribuição de cinza e contraste, espessuras não uniformes na seção transversal à imagem e etc.

Com os sinais processados, obteve-se também 100% de acerto para os dados de treinamento. Porém, para este caso, o índice de acerto para a classe CD aumentou para 63,3%, mostrando certa melhora em relação aos perfis sem processamento para esta classe, mantendo os 100% de acerto para a classe SD. O índice geral de acerto para esta condição foi de 81,7% (49 acertos em um total de 60), ratificando a necessidade de se executar o pré-processamento destes sinais e que aquele proposto é adequado ao objetivo do trabalho.

4.3 Conjunto 2

4.3.1 Pré-Processamento

Os perfis deste conjunto tiveram a solda extraída visualmente do metal de base, feita diretamente na imagem, conforme descrito na seção 3.4. No pré-processamento deste conjunto de amostras foi aplicado filtro idêntico ao Conjunto 1, haja vista a melhoria nos resultados proporcionados naquele conjunto. Contudo, o tamanho da janela de processamento do filtro Savitzky-Golay[22, 34] foi reduzida de 10x10 para 8x8, objetivando uma menor perda de amplitude nas indicações de defeito, conforme verificada na figura 4.1.d.

Foi executada ainda a normalização da amplitude em relação ao contraste, isto é, todos os pontos foram divididos pelo maior valor de nível de cinza no perfil, de forma que esta variasse entre 0 e 1. Por fim foi feita a interpolação de todos os perfis de acordo com aquele que possuía o menor número de pontos no conjunto (268 pontos).

As figuras 4.2 a 4.8 apresentam exemplos de perfis do conjunto 2 para uma solda sem defeito e para cada tipo de defeito neste grupo, antes e depois do pré-processamento.

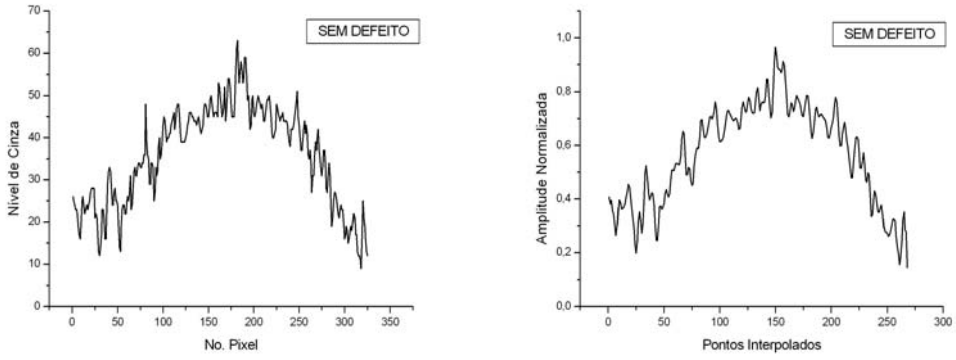

(a) (b)

Figura 4.2: Exemplo de perfil de uma solda sem defeito; (a) antes e (b) depois do pré-processamento (aplicação do filtro Savitzky-Golay).

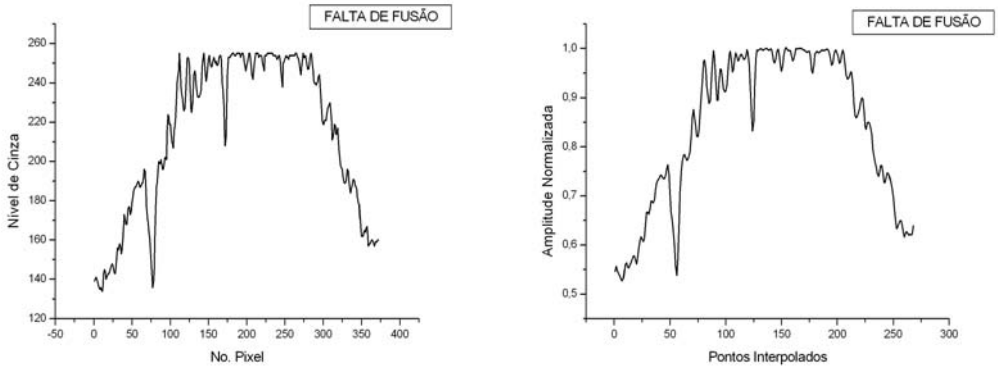

(a) (b)

Figura 4.3: Exemplo de perfil de uma solda com defeito tipo FF; (a) antes e (b) depois do pré-processamento (aplicação do filtro Savitzky-Golay).

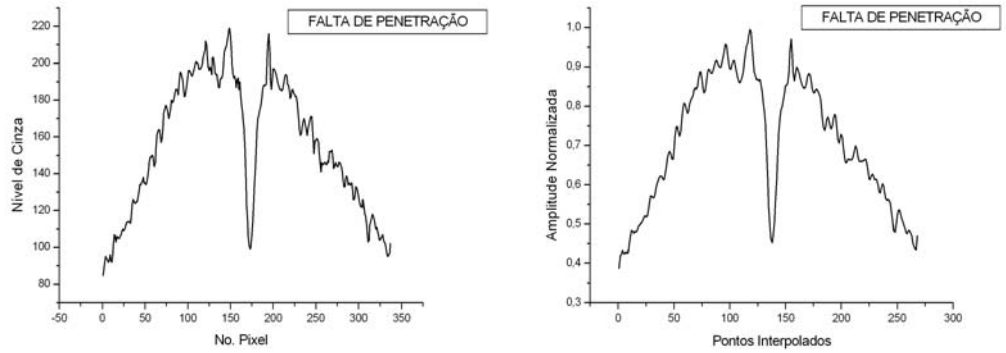

(a) (b)

Figura 4.4: Exemplo de perfil de uma solda com defeito tipo FP; (a) antes e (b) depois do pré-processamento (aplicação do filtro Savitzky-Golay).

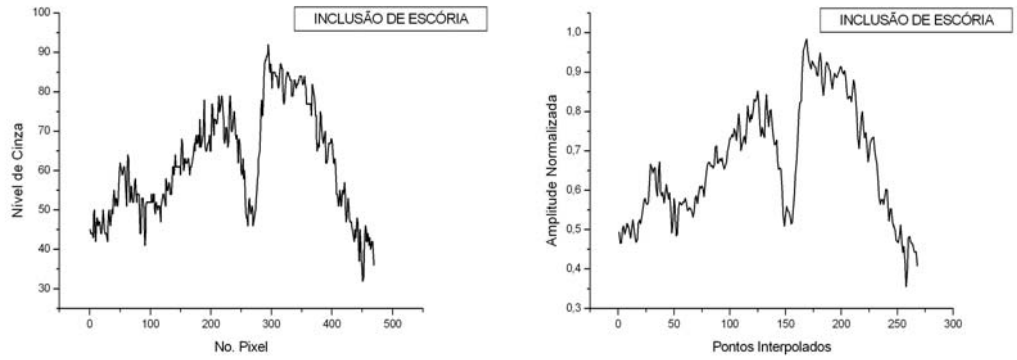

(a) (b)

Figura 4.5: Exemplo de perfil de uma solda com defeito tipo IE; (a) antes e (b) depois do pré-processamento (aplicação do filtro Savitzky-Golay).

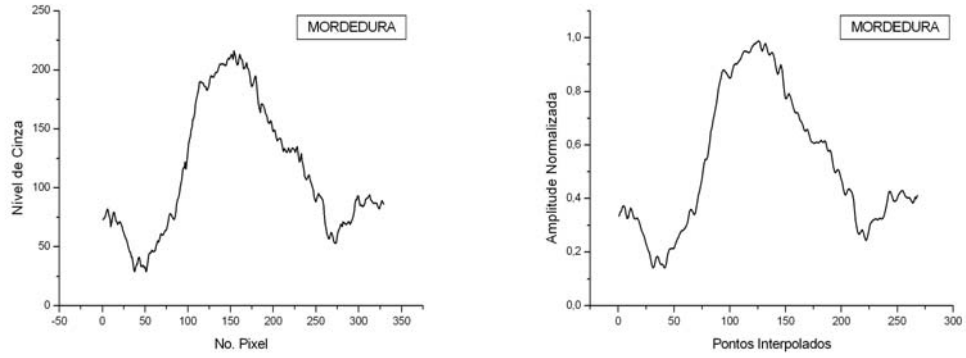

(a) (b)

Figura 4.6: Exemplo de perfil de uma solda com defeito tipo MO; (a) antes e (b) depois do pré-processamento (aplicação do filtro Savitzky-Golay).

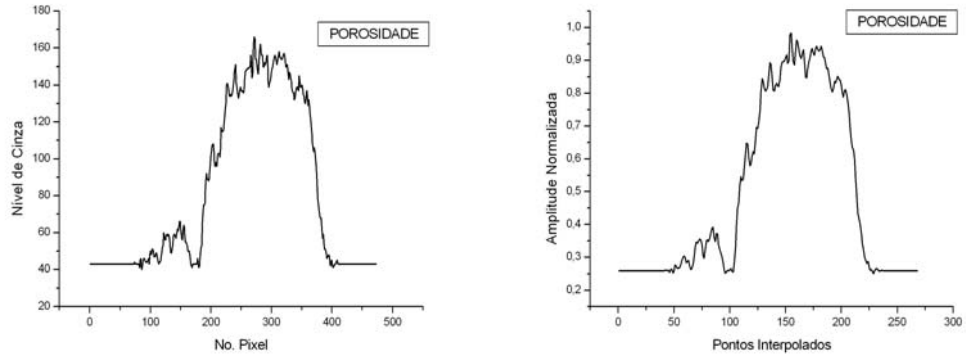

(a) (b)

Figura 4.7: Exemplo de perfil de uma solda com defeito tipo PO; (a) antes e (b) depois do pré-processamento (aplicação do filtro Savitzky-Golay).

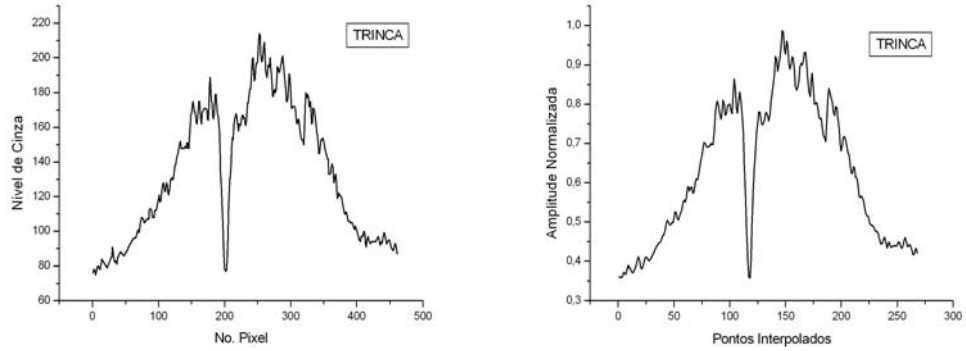

(a) (b)

Figura 4.8: Exemplo de perfil de uma solda com defeito tipo TR; (a) antes e (b) depois do pré-processamento (aplicação do filtro Savitzky-Golay).

Nota-se que o pré-processamento não modificou as indicações de defeitos, mantendo suas características de amplitude e localização, por exemplo, e, sobretudo, amenizou o nível de ruído presente no sinal original. Embora as diferenças entre os perfis não sejam tão marcantes, este pré-processamento permitiu redução na dimensão das entradas dos classificadores, bem como melhorou o desempenho dos mesmos.

4.3.2 Componentes Principais de Discriminação Não Linear (CPDNL)

O gráfico das componentes principais de discriminação não-linear é mostrado na figura 4.9. Foram obtidos ainda os gráficos para cada classe de defeito contra as demais, apresentados na figuras 4.10. A manutenção das características dos sinais é essencial para se obter um bom desempenho no reconhecimento de padrões, quando se deseja classificar estes sinais de acordo com as informações contidas neles. Estes gráficos são construídos após a obtenção das componentes principais de discriminação P_1 e P_2 de cada amostra, que correspondem aos eixos horizontal e vertical, permitindo desta forma visualizar a distribuição destas amostras num espaço bidimensional.

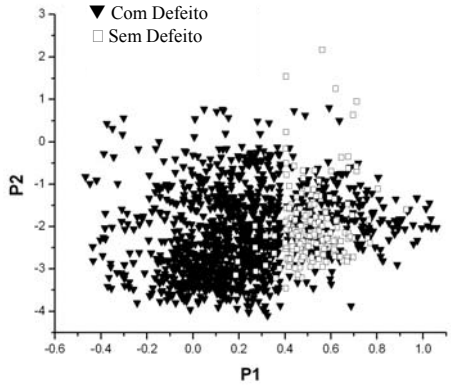

Figura 4.9: Gráfico das componentes principais de discriminação não linear referente ao conjunto 2, para as classes com defeito (CD) e sem defeito (SD).

A figura 4.9 mostra um gráfico de componentes principais de discriminação não linear obtido por um classificador não linear, implementado por uma rede neural de 3 camadas. A primeira camada contém somente um neurônio tipo linear ativo por vez, as outras são formadas por neurônios do tipo tangente hiperbólica. O gráfico de componentes principais permite visualizar de forma otimizada, em duas dimensões, o nível de separação entre as classes CD e SD. Estas classes apresentam um considerável nível de separação no espaço bidimensional, mesmo considerando os erros de classificação para as duas classes. Na prática, mais de duas componentes de discriminação podem ser utilizadas para identificar ambas as classes. Contudo, neste trabalho, estas componentes não foram utilizadas como entrada dos classificadores, servindo como sugestão para trabalhos futuros, tendo em vista que a implementação deste procedimento exige um estudo mais profundo na sua metodologia. Nota-se ainda que as classes não são linearmente separáveis, como no conjunto 1, devido ao aumento considerável na quantidade de amostras.

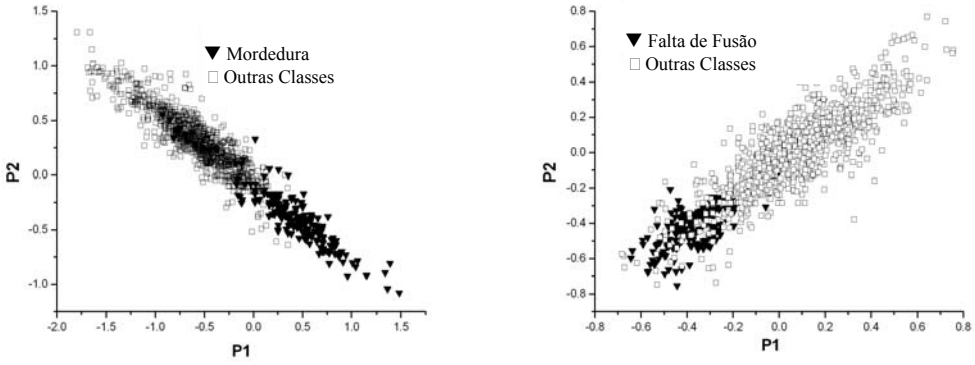

(a)

(b)

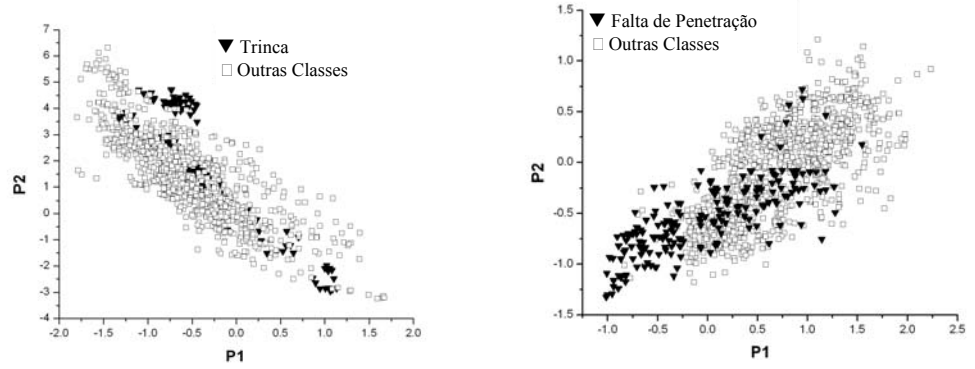

(c)

(d)

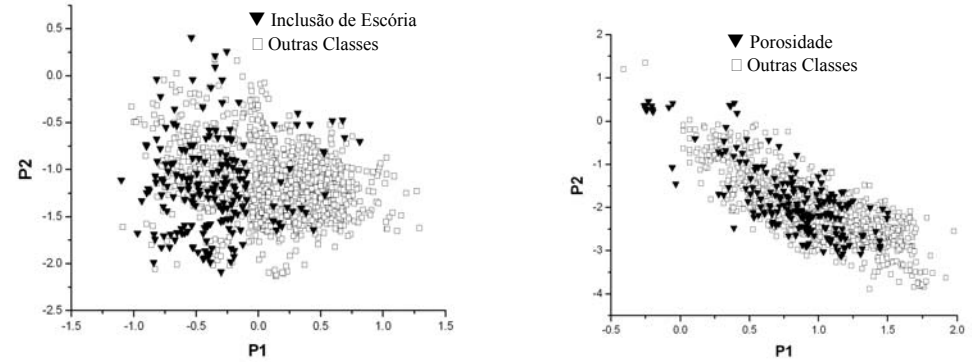

(e)

(f)

Figura 4.10: Gráficos das componentes principais de discriminação não linear referentes ao conjunto 2, para as 6 classes de defeito contra as demais; (a) Mordedura, (b) Falta de Fusão, (c) Trinca, (d) Falta de Penetração, (e) Inclusão de Escória e (f) Porosidade.

Pela análise dos gráficos das CPDNL apresentados acima, nota-se que existem classes onde não se visualiza nenhuma separação, como PO, IE, MO e FP e outras, como TR e FF, onde fica claro o agrupamento de amostras de classes distintas em determinada região. Contudo, esta ferramenta não deve ser definitiva na decisão de proceder esta separação, pois devemos considerar que estamos utilizando somente duas componentes principais, enquanto os vetores de entrada possuem dimensão 268.

4.3.3 Classificadores Não-Lineares

A figura 4.11 mostra a curva de erro do classificador durante o treinamento, onde se pode visualizar a evolução do erro de treinamento e validação da rede e o seu critério de parada, critério este baseado no erro mínimo de validação, possibilitando o controle de "supertreinamento" do classificador. Portanto, o treinamento pára quando o erro de validação se estabiliza ou cresce durante um dado número de épocas, sendo tomados os parâmetros (sinapses) que proporcionaram o menor erro de validação.

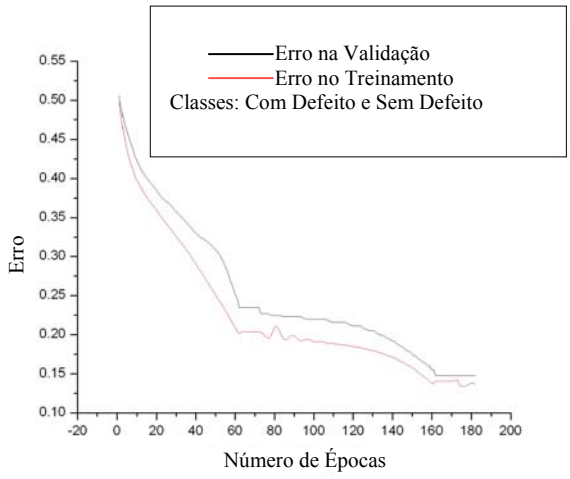

Figura 4.11: Curva de erro, demonstração do critério de parada no treinamento.

As escolhas dos conjuntos de treinamento e teste foram feitas por um algoritmo de sorteio aleatório, de forma a garantir que o mesmo percentual de perfis com e sem defeito seja utilizado no treinamento e teste. Portanto, de um total de 1200 perfis da classe CD e 200 da classe SD, 80% destes perfis foram utilizados aleatoriamente no treinamento, dos quais 10% foram utilizados na validação, e os 20% restantes foram inseridos na fase de teste. A figura 4.12 mostra um esquema de como foi feito o estudo de acurácia destes classificadores.

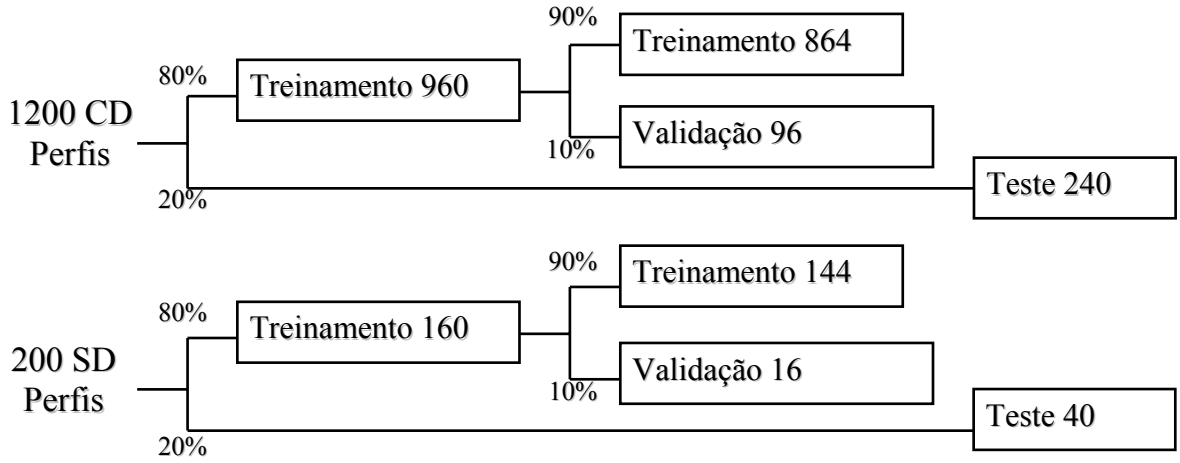

Figura 4.12: Estudo da acurácia dos classificadores não lineares.

A tabela 4.2 apresenta o resultado do estudo da influência do número de neurônios na camada intermediária sobre o desempenho da rede nas etapas de treinamento e teste. Este estudo, que visa otimizar o desempenho do classificador, foi feito para a detecção de defeitos, isto é, discriminação de duas classes, CD e SD, utilizando os sinais suavizados. A classificação dentre os 6 possíveis tipos de defeitos foi feita com o conjunto 3, após consolidação de todo a metodologia de pré-processamento e obtenção dos parâmetros da rede.

Tabela 4.2: Variação no número de neurônios na camada intermediária e os desempenhos obtidos para o treinamento e teste dos subconjuntos na detecção de defeitos (perfis suavizados; duas classes: CD e SD).

Número de Neurônios	**Treinamento (%)**	**Teste (%)**
5	99,5	91,0
7	99,9	93,6
9	99,2	91,4
11	99,5	95,0
13	99,6	93,2
15	**99,8**	**96,1**
17	100,0	93,2
19	99,4	94,3
Máximo	100,0	96,1
Mínimo	99,2	91,1

Nota-se que o melhor desempenho desta rede ocorre com 15 neurônios na camada intermediária, definido pelo melhor índice de acerto obtido com os dados de teste e menor diferença percentual entre treinamento e teste. Cabe notar aqui que atribuímos o aumento do erro no conjunto de teste quando se utiliza mais de 15 neurônios a maior suscetibilidade destas redes ao supertreinamento. A tabela 4.3 mostra o resultado final do desempenho dos classificadores não lineares na detecção de defeitos com 15 neurônios na camada intermediária com 10 conjuntos de treinamento e teste formados aleatoriamente a partir das entradas disponíveis.

Tabela 4.3: Desempenho do classificador para 10 conjuntos aleatórios (15 neurônios; perfis suavizados; duas classes: CD e SD).

Conjunto	Treinamento (%)	Teste (%)
1	**94,2**	73,8
2	**81,8**	**65,7**
3	90,8	71,9
4	92,2	70,9
5	91,5	71,4
6	92,4	70,9
7	93,1	**78,1**
8	92,8	77,1
9	91,9	77,6
10	91,8	75,2
Media	**91,2**	**73,3**
Desvio-Padrão	**3,5**	**3,8**
Máximo	94,2	78,1
Mínimo	81,8	65,7

Embora os resultados obtidos com os sinais suavizados possam ser considerados razoáveis, é evidente, contudo, a necessidade de melhoria no desempenho da rede. Nota-se uma queda no desempenho deste classificador do estudo de neurônios na camada intermediária, na tabela 4.2, em relação à avaliação do desempenho do classificador pela formação de conjuntos aleatórios, na tabela 4.3. Tal diferença é atribuída à mudança no tipo de sorteio e ao desequilíbrio na população das classes, pois no estudo de neurônios da tabela 4.2 foi utilizado um sorteio ordenado, onde, os pares de treinamento, validação e teste são selecionados na ordem em que são apresentados à rede, sempre respeitando os percentuais de amostragem definidos na figura 4.12, enquanto nos conjuntos apresentados na tabela 4.3 foi utilizado um algoritmo de sorteio aleatório o que favoreceu a classe mais populosa, CD, que possuía 1200 amostras contra

200 da classe SD, pois não foi feita replicação para igualar estas populações, o que foi introduzido no conjunto 3, onde, além da replicação, o sorteio foi feito classe a classe, separadamente.

Visando melhorar o desempenho deste classificador procedeu-se a normalização da posição do defeito em todos os sinais de entrada da rede, conforme descrito na seção 3.4. Sendo necessário um novo estudo de neurônios na camada intermediária para este conjunto, como mostrado na tabela 4.4.

Tabela 4.4: Variação no número de neurônios na camada intermediária e os desempenhos obtidos para o treinamento e teste dos subconjuntos na detecção de defeitos (perfis suavizados e invertidos; duas classes: CD e SD).

Número de Neurônios	**Treinamento (%)**	**Teste(%)**
5	99,7	95,0
7	99,9	95,7
9	99,9	94,6
11	99,8	93,6
13	**99,5**	**96,4**
15	100,0	95,0
17	99,7	96,4
19	99,5	95,7
21	99,7	94,3
Máximo	100,0	96,4
Mínimo	99,20	91,1

De acordo com a tabela 4.4, o estudo do número de neurônios na camada intermediária variou de 5 a 21, onde o melhor desempenho ocorre com 13 neurônios, quando se obteve o menor erro com o conjunto de teste. O controle no número de neurônios na camada intermediária permite reduzir a probabilidade de

"supertreinamento" dos parâmetros da rede. A redução no número de neurônios na camada intermediária, de 15 para 13, foi possível após a normalização da posição do defeito. Esta normalização proporcionou ainda uma grande melhora no desempenho da rede (percentual de acerto), o que pode ser constatado na tabela 4.5, onde se apresenta o desempenho do classificador com 13 neurônios na camada intermediária, utilizando os vetores entrada suavizados e invertidos quando necessário.

Tabela 4.5: Desempenho do classificador para 10 subconjuntos aleatórios (13 neurônios; perfis suavizados e invertidos; duas classes: CD e SD).

Conjunto	**Treinamento (%)**	**Teste(%)**
1	99,7	**94,6**
2	99,5	87,9
3	99,5	93,2
4	99,7	89,6
5	99,0	**78,9**
6	**85,9**	85,7
7	**100,0**	86,1
8	98,2	86,4
9	99,8	88,9
10	99,9	88,6
Media	98,1	88,0
Desvio-Padrão	4,3	4,3
Máximo	100,0	94,6
Mínimo	85,9	78,9

Verificou-se considerável melhoria no desempenho do classificador após a normalização da posição do defeito ao comparar a tabela 4.3 com a 4.5. O desvio-padrão, em ambos os casos, se manteve baixo o suficiente para garantir o bom resultado do sistema de detecção de defeitos de soldagem, visto que entre os 10 subconjuntos

formados aleatoriamente, somente em um o percentual de acerto esteve abaixo de 98% no treinamento e 85% no teste.

4.4 Conjunto 3

Este conjunto de dados caracteriza-se por ser mais abrangente, pois reúne perfis de duas coletâneas de radiografias do IIW e outra do BAM, tornando-o mais variado, e portanto, mais realista e significativo do ponto de vista estatístico dos dados.

Para este terceiro conjunto de dados, também foram utilizados classificadores não-lineares, inicialmente para detectar a presença de defeitos, isto é, classificar os vetores de entrada em duas classes, com e sem defeito (CD e SD), e posteriormente para discriminar os sinais de entrada dentre as sete classes possíveis. Como para os outros conjuntos, as componentes principais de discriminação não-linear foram igualmente obtidas tanto para as sete classes de padrões de sinais, assim como para o caso de duas classes: uma classe contra as demais classes. As redes neurais semi-supervisionadas do tipo ART foram implementadas utilizando este conjunto de dados, cujos resultados são apresentados e discutidos nesta seção.

4.4.1 Pré-Processamento

Neste conjunto de dados, o procedimento de pré-processamento encontra-se consolidado, considerando os resultados obtidos anteriormente para os conjuntos 1 e 2. Consistindo, portanto, em:

a) Extração visual do cordão de solda na imagem radiográfica;

b) Obtenção do perfil transversal ao cordão de solda;

c) Suavização com o filtro Savitzky-Golay, função de 2ª ordem e janela 8x8;

d) Normalização da amplitude;

e) Interpolação para 276 pontos;

f) Normalização da posição do defeito à direita do pico da curva gaussiana.

As figuras 4.13 a 4.19 apresentam exemplos de perfil do conjunto 3 para uma solda sem defeito e para cada tipo de defeito neste grupo, antes e depois do pré-processamento.

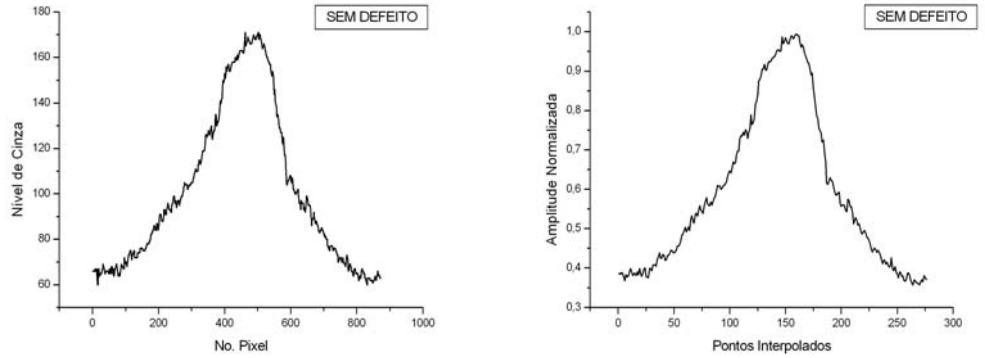

(a) (b)

Figura 4.13: Exemplo de perfil de uma solda sem defeito; (a) antes e (b) depois do pré-processamento.

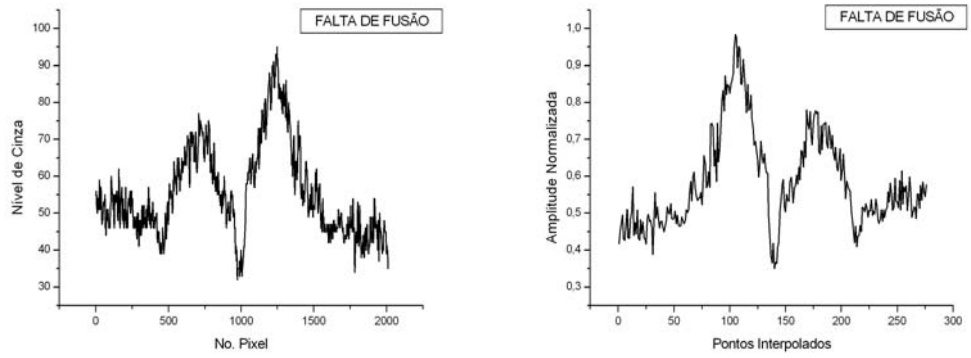

(a) (b)

Figura 4.14: Exemplo de perfil de uma solda com defeito tipo FF; (a) antes e (b) depois do pré-processamento.

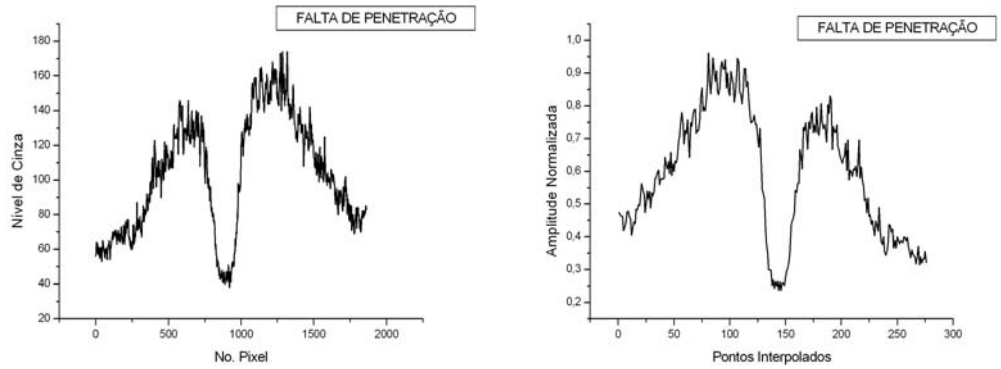

(a) (b)

Figura 4.15: Exemplo de perfil de uma solda com defeito tipo FP; (a) antes e (b) depois do pré-processamento.

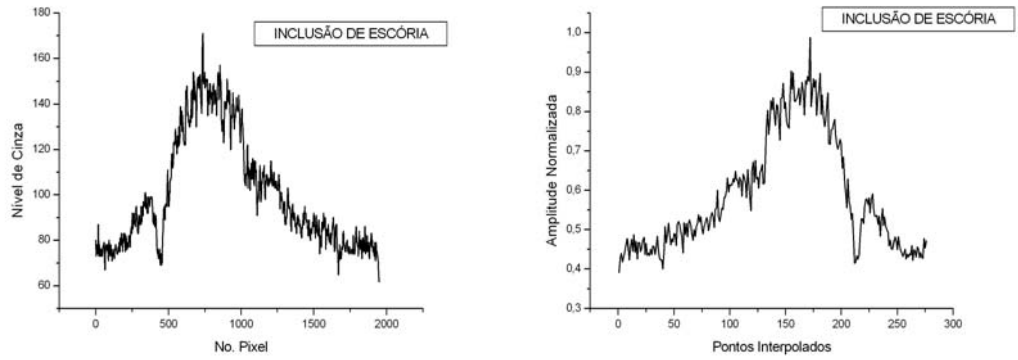

(a) (b)

Figura 4.16: Exemplo de perfil de uma solda com defeito tipo IE; (a) antes e (b) depois do pré-processamento.

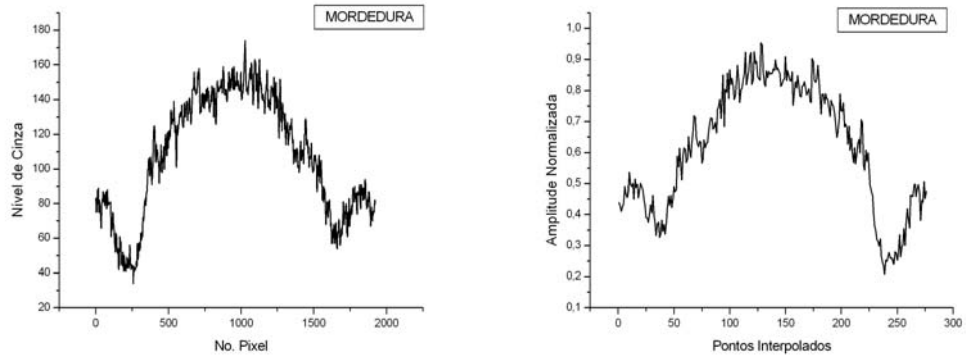

(a) (b)

Figura 4.17: Exemplo de perfil de uma solda com defeito tipo MO; (a) antes e (b) depois do pré-processamento.

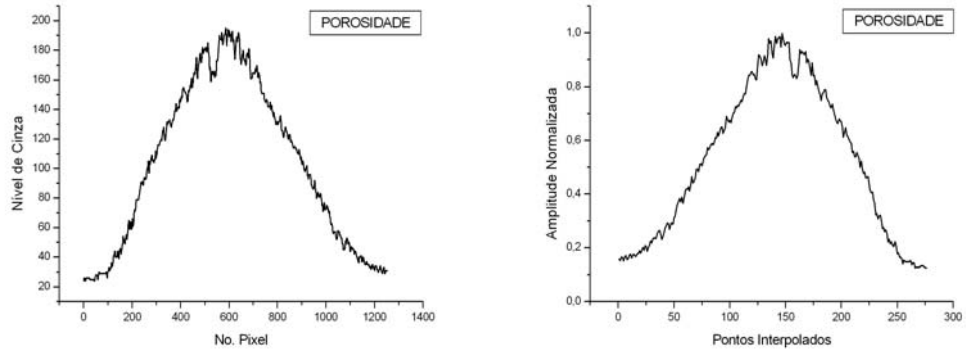

(a) (b)

Figura 4.18: Exemplo de perfil de uma solda com defeito tipo PO; (a) antes e (b) depois do pré-processamento.

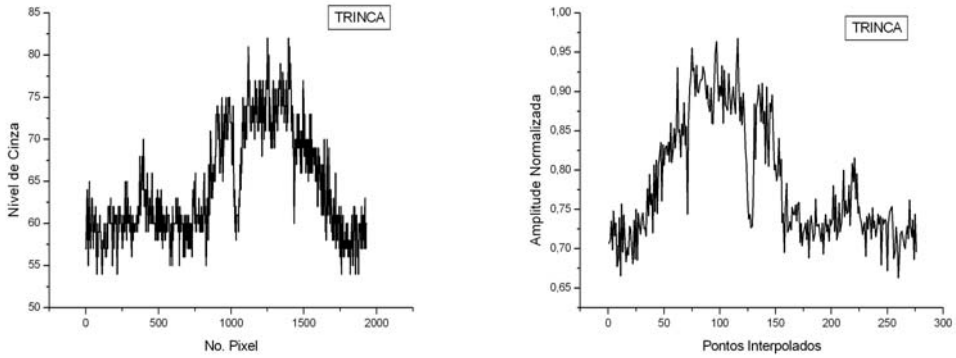

(a) (b)

Figura 4.19: Exemplo de perfil de uma solda com defeito tipo TR; (a) antes e (b) depois do pré-processamento.

Nota-se uma grande diversidade no nível de ruído dentre o conjunto de sinais obtidos. Esta característica é inerente ao processo radiográfico e de digitalização do filme, sendo esta última atenuada pela qualidade do equipamento utilizado e pelo tratamento de imagens aplicado. Portanto, o nível de ruído não pode ser controlado, tendo sido razoavelmente amenizado nesta etapa pelo pré-processamento.

4.4.2 Classificadores Não-Lineares

4.4.2.1 Otimização do Número de Neurônios na Camada Intermediária

Até o presente momento do trabalho, todos os treinamentos e testes dos classificadores foram feitos mantendo-se as quantidades desproporcionais de amostras, o que em termos do algoritmo de treinamento por retropropagação do erro pode ocasionar o favorecimento de acerto de classificação das classes com maior quantidade de amostras, já que essas tendem a influenciar mais significativamente no cálculo do

erro de treinamento. Neste caso, uma solução que na maioria das vezes proporciona bons resultados e equilibra as populações das classes é replicar os dados das classes com menor quantidade de dados até que estas atinjam o número de dados da classe mais favorecida[39]. Com o conjunto 3 de dados, composto por todas as coleções de radiografias do IIW e do BAM, e formado pelos perfis após todos os pré-processamentos (inclusive a inversão de posição de defeito – quando aplicável), realizaram-se novos sorteios aleatórios, neste caso, da seguinte maneira: tendo a classe SD (Sem Defeito) a maior quantidade de dados (467), extraiu-se 15% deste total para formar o conjunto de teste, ou seja, 69 dados foram sorteados para teste e os demais sobraram para formar o conjunto de treinamento (398 amostras). O mesmo foi feito com as demais classes, entretanto, seus dados foram "replicados" até que atingissem o número de dados de teste e de treinamento da classe SD, ou seja, todas classes passaram a ter 69 dados para teste e 398 dados para treinamento. É importante ressaltar que o sorteio dos conjuntos de treinamento e teste foi feito antes da "replicação", pois com esse tipo de procedimento garantiu-se que os dados sorteados para teste não fossem usados no treinamento e que todas as classes tivessem a mesma população para treinamento e teste.

Após a realização de um sorteio aleatório com o procedimento descrito, realizou-se um estudo do número de neurônios ótimos a serem usados na camada intermediária do classificador não-linear com estes novos conjuntos. Para controlar o "supertreinamento" e garantir a generalização do classificador, extraiu-se 15% dos dados de treinamento para formar um conjunto de validação. A tabela 4.6 a seguir mostra os resultados obtidos no estudo do número de neurônios na camada intermediária para a discriminação das 7 classes envolvidas.

Tabela 4.6: Otimização do número de neurônios na camada intermediária do classificador não-linear (Perfis Suavizados e Invertidos – Replicação após sorteio).

Número de neurônios na camada intermediária	**Treinamento (%)**		**Teste (%)**	
	R	**SR**	**R**	**SR**
10	100,0	99,9	97,7	96,0
20*	100,0	100,0	99,4	97,7
30	100,0	100,0	98,9	97,1
40	100,0	100,0	98,1	95,5

*Melhor resultado com os dados de teste.

Pela análise da tabela 4.6 fica evidente que com apenas 20 neurônios na camada intermediária obteve-se o desempenho máximo, com 100% de acerto para os dados de treinamento e 97,7% para os dados de teste na condição mais conservadora, isto é, sem reclassificação (SR), e 99,4% de acerto com reclassificação (R), obtendo os melhores índices de acerto com o conjunto de teste. A figura 4.20.a mostra a curva de erro na fase de treinamento da rede com 20 neurônios na camada intermediária para os dados de treinamento e teste e a figura 4.20.b mostra o detalhamento da região de maior interesse, evidenciando que o treinamento foi interrompido com menos de 1000 épocas devido ao controle de validação.

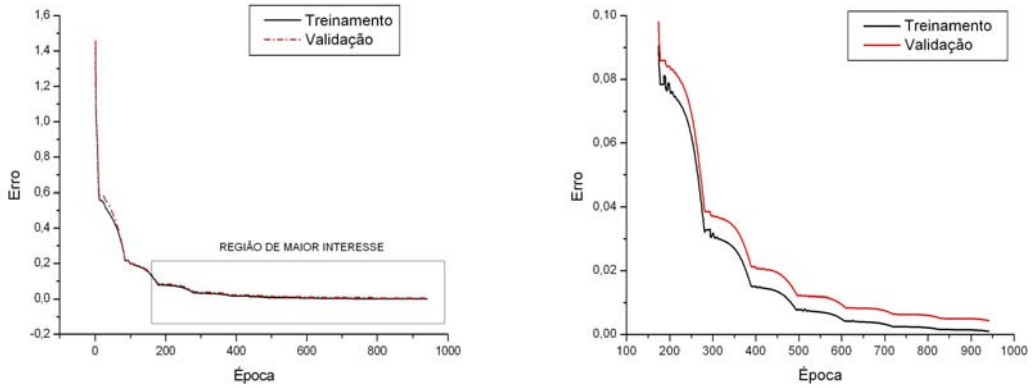

(a) (b)

Figura 4.20: (a) Curvas de erro de treinamento e validação utilizando 20 neurônios na camada intermediária; (b) detalhamento referente à área em destaque em (a). Perfis Suavizados e Invertidos – Replicação após Sorteio.

4.4.2.2 Componentes Principais de Discriminação Não-Linear

Após a otimização do número de neurônios a ser usado na camada intermediária do classificador não-linear, foram obtidas as duas Componentes Principais de Discriminação Não-linear (CPDNL) para estes novos dados, para que se pudesse visualizar em um espaço de representação bidimensional a distribuição dos dados das classes de forma otimizada, conforme descrito na seção 3.7 do capítulo 3. Obtiveram-se, primeiramente, as duas principais componentes para a situação de classificação envolvendo as sete classes (SD, FF, FP, IE, MO, PO, e TR), apresentadas na figura 4.21, e posteriormente, para o caso de classificação envolvendo duas classes: uma das sete classes contra as outras classes juntas, apresentadas nas figuras 4.22 a 4.25.

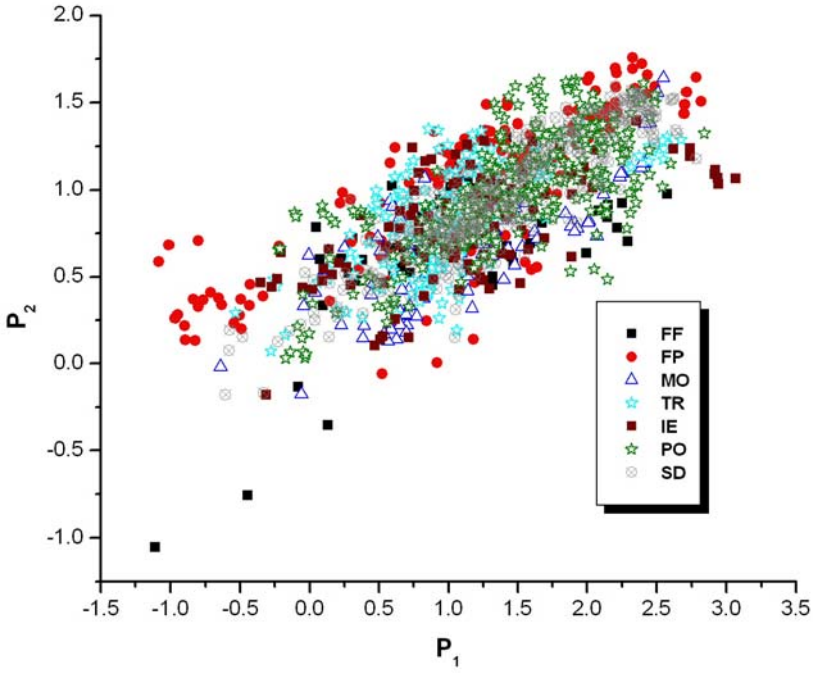

Figura 4.21: Gráfico das componentes principais de discriminação não linear para as sete classes.

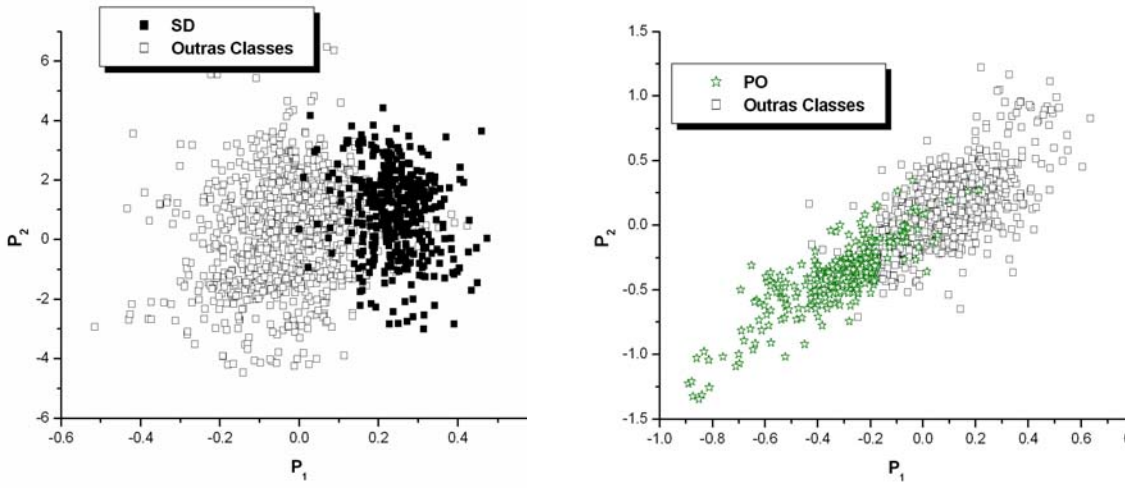

(a) (b)

Figura 4.22: Gráfico das componentes principais de discriminação não linear para as classes: (a) SD e (b) PO contra as demais.

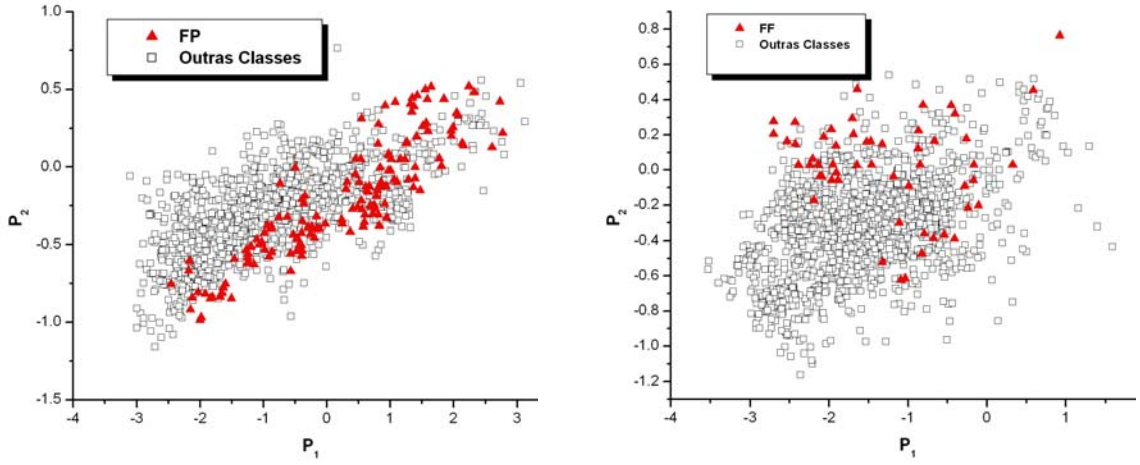

(a) (b)

Figura 4.23: Gráfico das componentes principais de discriminação não linear para as classes: (a) FP e (b) FF contra as demais.

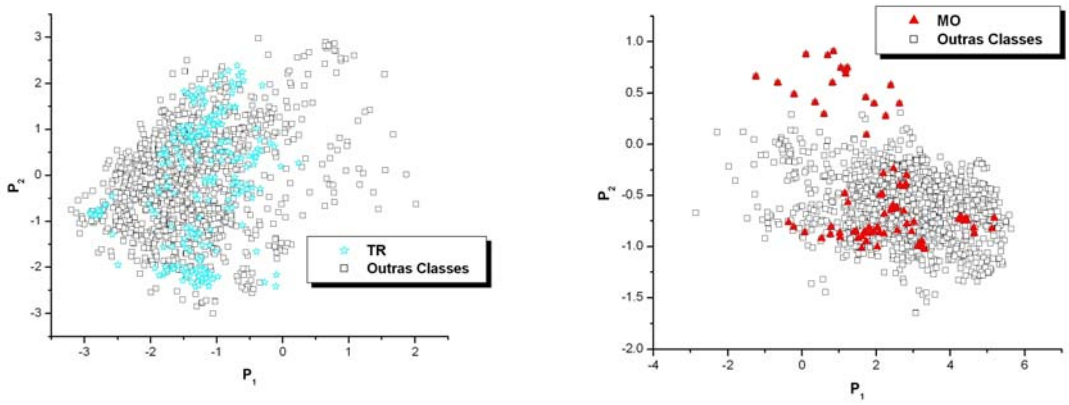

(a) (b)

Figura 4.24: Gráfico das componentes principais de discriminação não linear para as classes: (a) TR e (b) MO contra as demais.

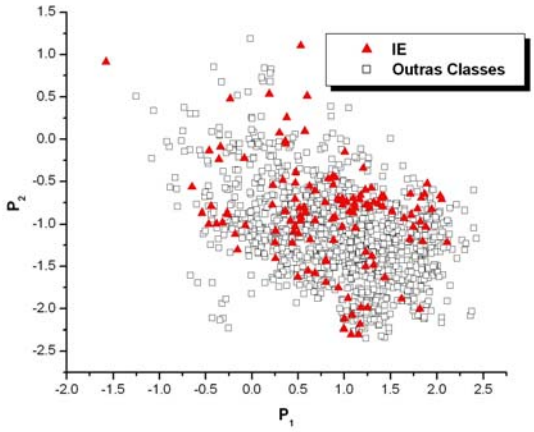

(g)

Figura 4.25: Gráfico das componentes principais de discriminação não linear para a classe IE contra as demais.

O gráfico bidimensional das componentes principais de discriminação não-linear para todas as classes, figura 4.21, mostra que o espaço de representação dos dados das sete classes estudadas não consegue separar os pontos referentes aos diferentes defeitos, mesmo na forma mais otimizada de visualização, o que comprova a complexidade de separação das classes de padrões de defeitos presentes nos perfis de cinza. Entretanto, quando se trabalhou com casos de duas classes de padrões: uma classe de defeito separada das classes restantes (figuras 4.22 a 4.25), se percebe que classes como SD e PO (figura 4.22) apresentam regiões de confusão menores quando comparadas às outras classes (IE, TR, MO, FP e FF – figura 4.23 a 4.25).

É importante destacar que, na prática, em termos de classificação, normalmente utiliza-se um número maior de componentes para separação das classes. Após a obtenção destes gráficos, o passo seguinte foi o cálculo da acurácia de classificação com o classificador não-linear, visto que pelos gráficos das CPDNL o classificador linear certamente não permitiria resultados satisfatórios de classificação.

4.4.2.3 Acurácia do Classificador Não-Linear

Após estabelecer o número ótimo de 20 neurônios na camada intermediária, devemos calcular a acurácia de classificação com os novos dados processados e invertidos. Para tanto, 10 novos pares de conjuntos de treinamento e teste com replicação de dados foram sorteados aleatoriamente para serem usados no treinamento e teste do classificador não-linear. Neste caso, 15% dos dados originais foram usados para teste e os 85% restantes destinados ao treinamento, sendo 15% usados para formar os conjuntos de validação que controlaram o "supertreinamento" dos parâmetros da rede (sinapses e *bias*). A tabela 4.7 contém todos os resultados de desempenhos obtidos com estes conjuntos.

Tabela 4.7: Cálculo da acurácia de classificação do classificador não-linear (Perfis Suavizados e Invertidos – Replicação após Sorteio).

Conjuntos	**Treinamento**		**Teste**		**Parada**
	R	**SR**	**R**	**SR**	**Número de Épocas**
1	100,0	100,0	100,0	98,9	920
2	100,0	99,9	98,5	93,4	1044
3	99,9	99,9	97,9	94,6	948
4	99,9	99,9	97,5	91,9	923
5	99,9	99,9	97,9	94,6	940
6	**99,9**	**99,9**	**97,3**	**95,2**	**940**
7	100,0	99,9	99,0	96,7	939
8	99,9	99,9	97,7	92,1	1044
9	99,9	99,9	99,4	97,1	949
10	99,9	99,9	98,1	95,4	1135
Media	99,9	99,9	98,3	95,0	
Desvio Padrão	0,02	0,02	0,90	2,21	

A média de acerto resultante, nosso estimador de acurácia de classificação, foi de 95,0% para dados de teste na situação de Sem Reclassificação (SR), índice bastante satisfatório quando comparado aos resultados obtidos com os outros conjuntos anteriormente utilizados, apresentados nas seções 4.2 e 4.3, e com outros procedimentos de sorteio de pares de conjunto de treinamento/teste. Com Reclassificação (R), atingiu-se cerca de 98,0% de acerto, índice muito próximo ao obtido com a média dos conjuntos de treinamento (cerca de 100%). Outro resultado importante a ser destacado é o baixo desvio-padrão resultante, 2,2% para os dados de teste sem reclassificação, o que comprova a boa confiabilidade na estimação da acurácia de classificação da detecção e classificação das principais classes de defeitos de soldagem presentes em perfis transversais de níveis de cinza que foram submetidos ao pré-processamento desenvolvido.

A figura 4.23 mostra as curvas de treinamento e validação do sexto conjunto da tabela 4.7 que foi o conjunto que mais se aproximou da média, ou seja, aquele que pode ser considerado como o mais representativo em termos de índice de acerto de classificação esperado.

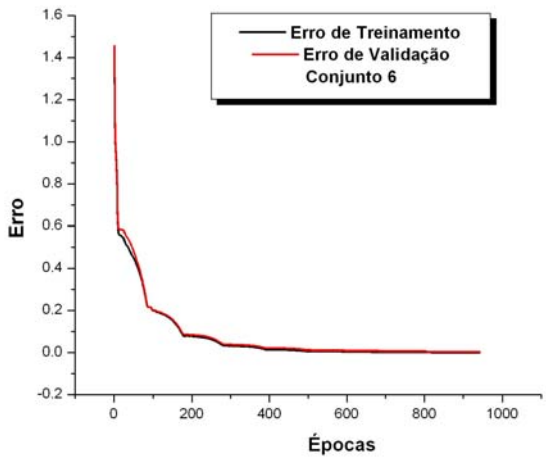

Figura 4.23: Curvas de erro no treinamento e validação, utilizando 20 neurônios na camada intermediária do conjunto 6 que foi o que mais se aproximou da média.

É importante destacar que todos estes treinamentos foram realizados com os mesmos ajustes de parâmetros da rede que foram empregados nos conjuntos preliminares, a saber: treinamento em batelada até 3000 épocas, parada com o conjunto de validação, utilização de momento β=0,9 e taxa de aprendizagem α variável inicializando em 0,1. O critério de validação foi fixado em 100 épocas, isto é, se o erro de validação fosse mantido inalterado ou crescesse pelo período de 100 épocas, interrompia-se o treinamento e ajustava-se os valores das sinapses e *bias* aos valores que resultaram no menor erro de validação.

Como na tabela 4.7 citada anteriormente, tem-se apenas a média geral de acerto de todas as classes, assim como os índices de cada conjunto sem termos noção dos acertos e erros de cada classe, construiu-se a tabela de confusão, tabela 4.8 a seguir, referente ao sexto conjunto da tabela 4.7, que apresenta os índices de acerto e de erro (confusão) de cada classe com respeito às demais classes. Para simplificar o entendimento, tem-se a classe falta de fusão (FF) na primeira linha e na primeira coluna da tabela 4.8 que atingiu o resultado de 53 dados corretamente classificados entre os 69 usados no conjunto de teste, com 16 perfis tendo sido classificados como "Nenhuma classe", ou seja, neste caso todas as saídas dos neurônios foram negativas, lembrando que na condição da tabela 4.8 uma classe só é indicada quando houver apenas uma saída positiva entre os 7 neurônios das 7 classes estudadas. Para a classe FP, 66 dados foram corretamente classificados e 3 dados confundidos com a classe PO e segue assim a mesma interpretação para as demais classes. Nota-se, na mesma tabela, que classes como MO e IE tiveram todos os perfis de teste classificados corretamente. A tabela 4.9 mostra os mesmos índices de acerto e confusão em valores percentuais. Deve-se ressaltar, novamente, que estas tabelas de confusão, 4.8 e 4.9, são para a situação mais conservadora de classificação (sem reclassificação) com os dados de teste,

evidentemente que para o caso de Reclassificação os índices de erro são ainda menores, como mostrado nas tabelas 4.10 e 4.11, a seguir.

Tabela 4.8: Tabela de confusão em quantidade de perfis para o conjunto 6 de teste, o que mais se aproximou da média de acerto da tabela 4.7. Sem Reclassificação (SR). Perfis Suavizados e Invertidos – Replicação após Sorteio

		CONFUSÃO								
		FF	FP	MO	TR	IE	PO	SD	Nenhuma	Mais de uma
CLASSE EM ESTUDO	**FF**	53	0	0	0	0	0	0	16	0
	FP	0	66	0	0	0	3	0	0	0
	MO	0	0	69	0	0	0	0	0	0
	TR	0	0	2	67	0	0	0	0	0
	IE	0	0	0	0	69	0	0	0	0
	PO	0	0	0	0	0	68	0	1	0
	SD	0	0	0	0	0	0	68	1	0

Tabela 4.9: Tabela de confusão em percentual de acerto/erro para o conjunto 6 de teste, o que mais se aproximou da média de acerto da tabela 4.7. Sem Reclassificação (SR). Perfis Suavizados e Invertidos – Replicação após Sorteio

		CONFUSÃO (%)								
		FF	FP	MO	TR	IE	PO	SD	Nenhuma	Mais de uma
CLASSE EM ESTUDO	**FF**	77%	0	0	0	0	0	0	23%	0
	FP	0	96%	0	0	0	4%	0	0	0
	MO	0	0	100%	0	0	0	0	0	0
	TR	0	0	3%	97%	0	0	0	0	0
	IE	0	0	0	0	100%	0	0	0	0
	PO	0	0	0	0	0	98%	0	1%	0
	SD	0	0	0	0	0	0	98%	1%	0

Tabela 4.10: Tabela de confusão em quantidade de perfis para o conjunto 6 de teste, o que mais se aproximou da média de acerto da tabela 4.7. Com Reclassificação (R). Perfis Suavizados e Invertidos – Replicação após Sorteio

		CONFUSÃO						
		FF	FP	MO	TR	IE	PO	SD
CLASSE EM ESTUDO	**FF**	**61**	0	0	8	0	0	0
	FP	0	**66**	0	0	0	3	0
	MO	0	0	**69**	0	0	0	0
	TR	0	0	2	**67**	0	0	0
	IE	0	0	0	0	**69**	0	0
	PO	0	0	0	0	0	**69**	0
	SD	0	0	0	0	0	0	**69**

Tabela 4.11: Tabela de confusão em percentual de acerto/erro para o conjunto 6 de teste, o que mais se aproximou da média de acerto da tabela 4.7. Com Reclassificação (R). Perfis Suavizados e Invertidos – Replicação após Sorteio

		CONFUSÃO (%)						
		FF	FP	MO	TR	IE	PO	SD
CLASSE EM ESTUDO	**FF**	88%	0	0	12%	0	0	0
	FP	0	96%	0	0	0	4%	0
	MO	0	0	100%	0	0	0	0
	TR	0	0	3%	97%	0	0	0
	IE	0	0	0	0	100%	0	0
	PO	0	0	0	0	0	100%	0
	SD	0	0	0	0	0	0	100%

As tabelas 4.10 e 4.11 mostram os resultados, em quantidade de perfis e valores percentuais, da reclassificação aplicada aos vetores de entrada do conjunto de teste 6, que não foram classificados inicialmente, como mostram as tabelas 4.8 e 4.9. O

procedimento de reclassificação consiste, basicamente, em verificar dentre as saídas da rede qual dos vetores mais se aproximou de suas respectivas classes.

Pode-se verificar que para quatro classes (MO, IE, PO e SD) o desempenho da rede atingiu sua plenitude, com índice de acerto em 100% dos casos, corrigindo pequenos desvios verificados nas classes PO e SD identificados antes da reclassificação. No caso das classes de defeito FP e TR, o desempenho do classificador foi excelente com índice de acerto acima de 95%, apesar do procedimento de reclassificação não ter promovido melhoria no desempenho da rede o que já era esperado, pois a reclassificação é aplicada somente àquelas amostras que não foram alocadas em nenhuma classe, provavelmente devido a amostras espúrias, esperadas em qualquer população. No caso da FF, a reclassificação promove uma considerável melhoria no índice de acerto do classificador, porém o mesmo ainda fica abaixo da média das outras classes. Contudo, devemos considerar que na prática a confusão do defeito falta de fusão com trinca não é crítico, pois a presença de qualquer um deles implica na rejeição da solda.

4.4.3 Redes Neurais Tipo ART Modificada

4.4.3.1 Obtenção dos Padrões de Classes

O primeiro passo no processo de agrupamento de cada classe é determinar o raio de similaridade e, conseqüentemente, o número de padrões a serem usados. Como visto nas seções 3.9.2 e 3.9.5 temos dois critérios, o primeiro visando primordialmente a definição do domínio da classe e o segundo buscando a geração de padrões “naturais”

para as classes. Como nosso objetivo ao usar agrupamentos foi, principalmente, gerar padrões para as classes, iniciamos com o segundo método.

Como o número de padrões "naturais" para cada classe deve ser bastante limitado, iniciamos com um raio de similaridade grande de modo a gerar um único padrão e fomos reduzindo-o gradativamente para gerar um número maior de padrões, N. Assim, os padrões de classe foram obtidos individualmente para cada classe de defeito e para a classe sem defeito através de uma rotina de processamento, na qual os conjuntos são inseridos e o parâmetro de vigilância é aumentado por incrementos fixos de forma a aumentar o número de padrões criados. Estudou-se, então, a relação entre o fator de demérito, D, dos agrupamentos de cada classe *versus* o número de padrões formados, buscando-se o ponto de inflexão da curva que caracteriza o agrupamento "natural". Para visualizar esta relação foram traçados os gráficos de D (fator de demérito) *versus* N (número de padrões). As figuras 4.24 a 4.27 mostram estes gráficos para cada classe envolvida.

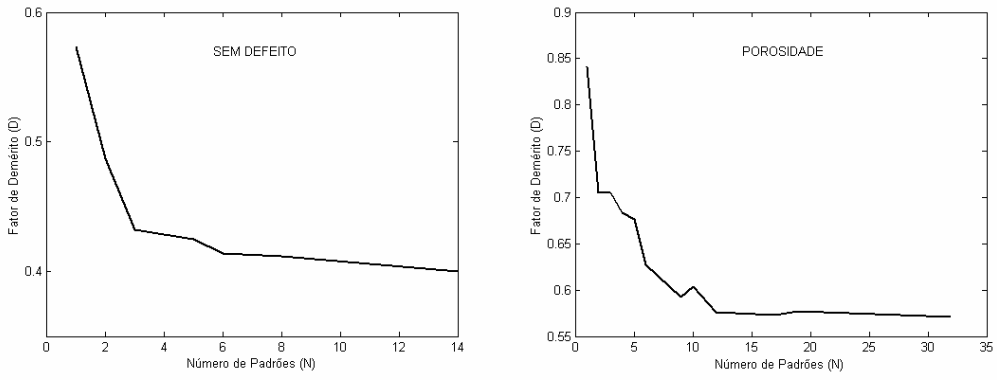

(a) (b)

Figura 4.24: Gráfico N x D para as classes (a) SD e (b) PO.

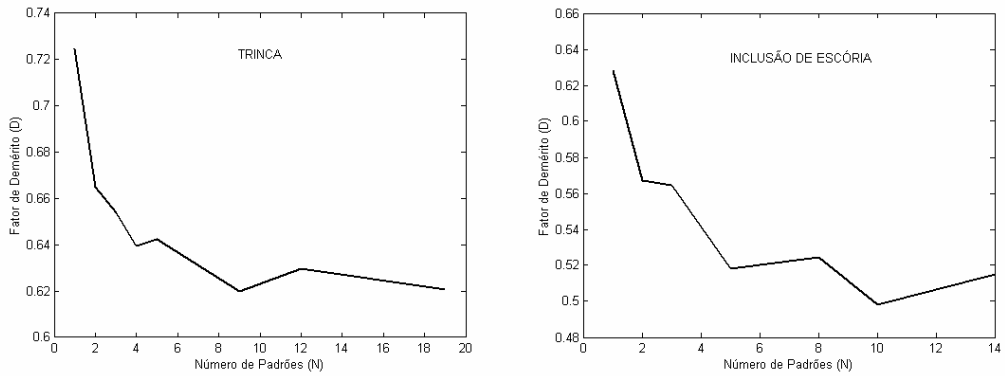

(a) (b)

Figura 4.25: Gráfico N x D para as classes (a) TR e (b) IE.

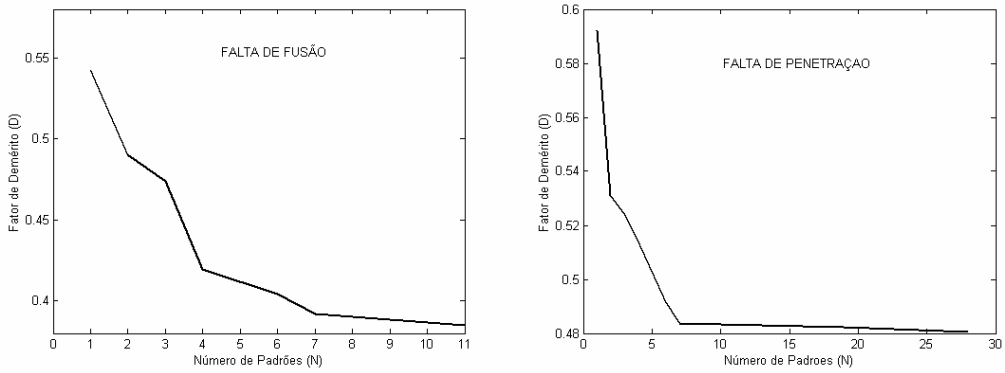

(a) (b)

Figura 4.26: Gráfico N x D para as classes (a) FF e (b) FP.

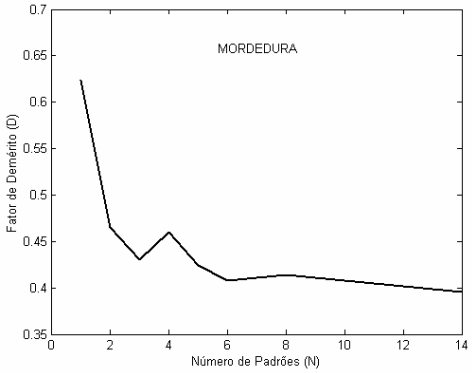

Figura 4.27: Gráfico N x D para a classe MO.

A análise dos gráficos N x D nos leva aos possíveis pontos de inflexão apresentados na tabela 4.12. Estes pontos não são absolutos na decisão do número de padrões representativos de cada classe, mas delimitam a região de estudo.

Tabela 4.12: Possíveis pontos de inflexão (N) para cada classe analisada.

Classe	N
SD	3
PO	2 e 9
TR	4
IE	2 e 5
FF	2 e 4
FP	2 e 7
MO	2 e 3

Os padrões gerados para cada um destes casos estão apresentados a seguir, nas figuras 4.28 a 4.39. Para que a semelhança e individualidade dos padrões possam ser apreciadas, apresenta-se, inicialmente, uma figura contendo todos os padrões e em seguida cada um dos padrões isoladamente.

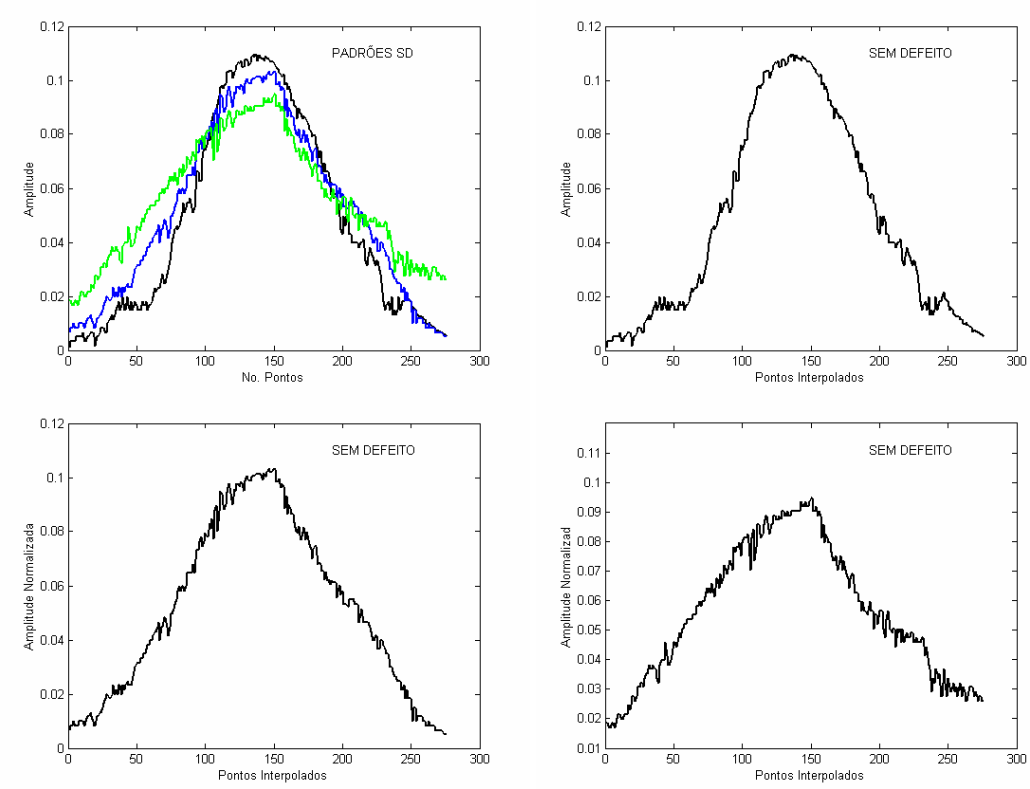

Figura 4.28: Padrões gerados para a classe SD; ρ = 0,56 e N = 3.

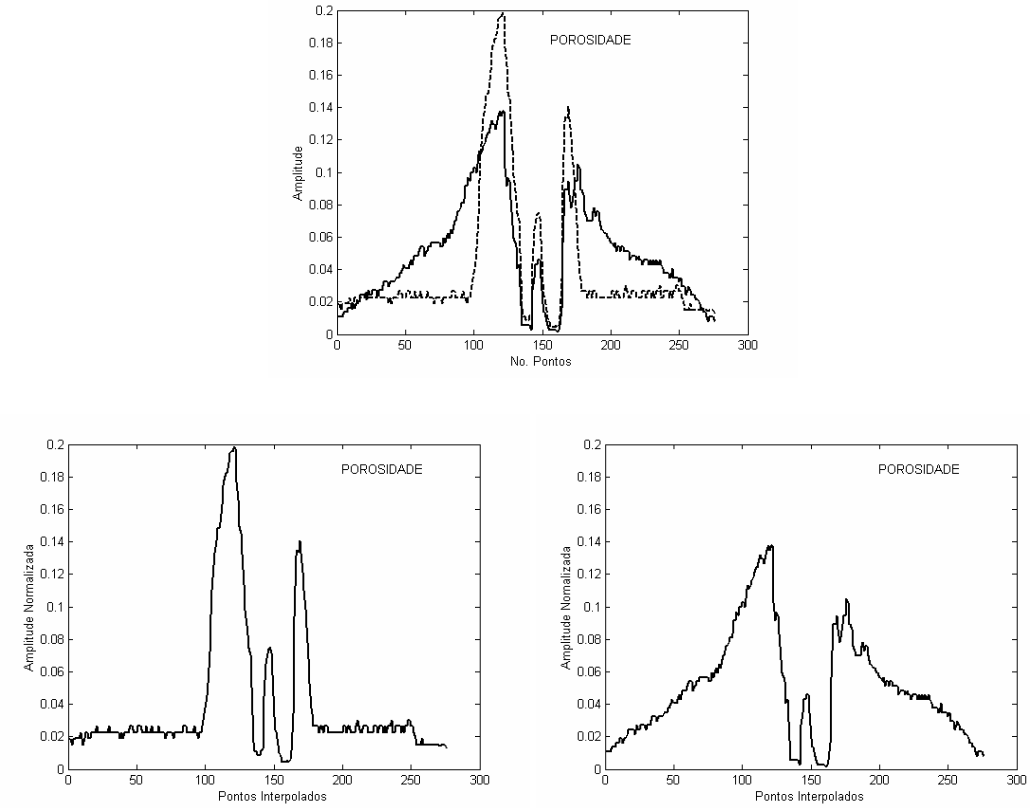

Figura 4.29: Padrões gerados para a classe PO; ρ = 0,22 e N = 2.

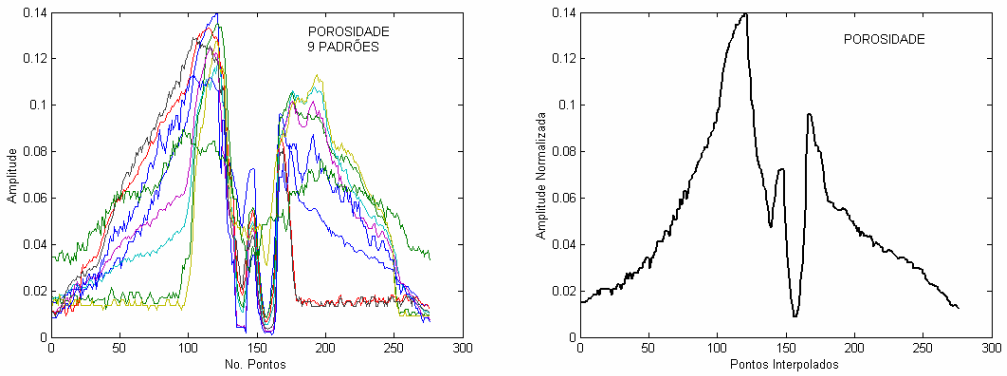

Figura 4.30: Padrões gerados para a classe PO; ρ = 0,43 e N = 9.

(Continua na página seguinte)

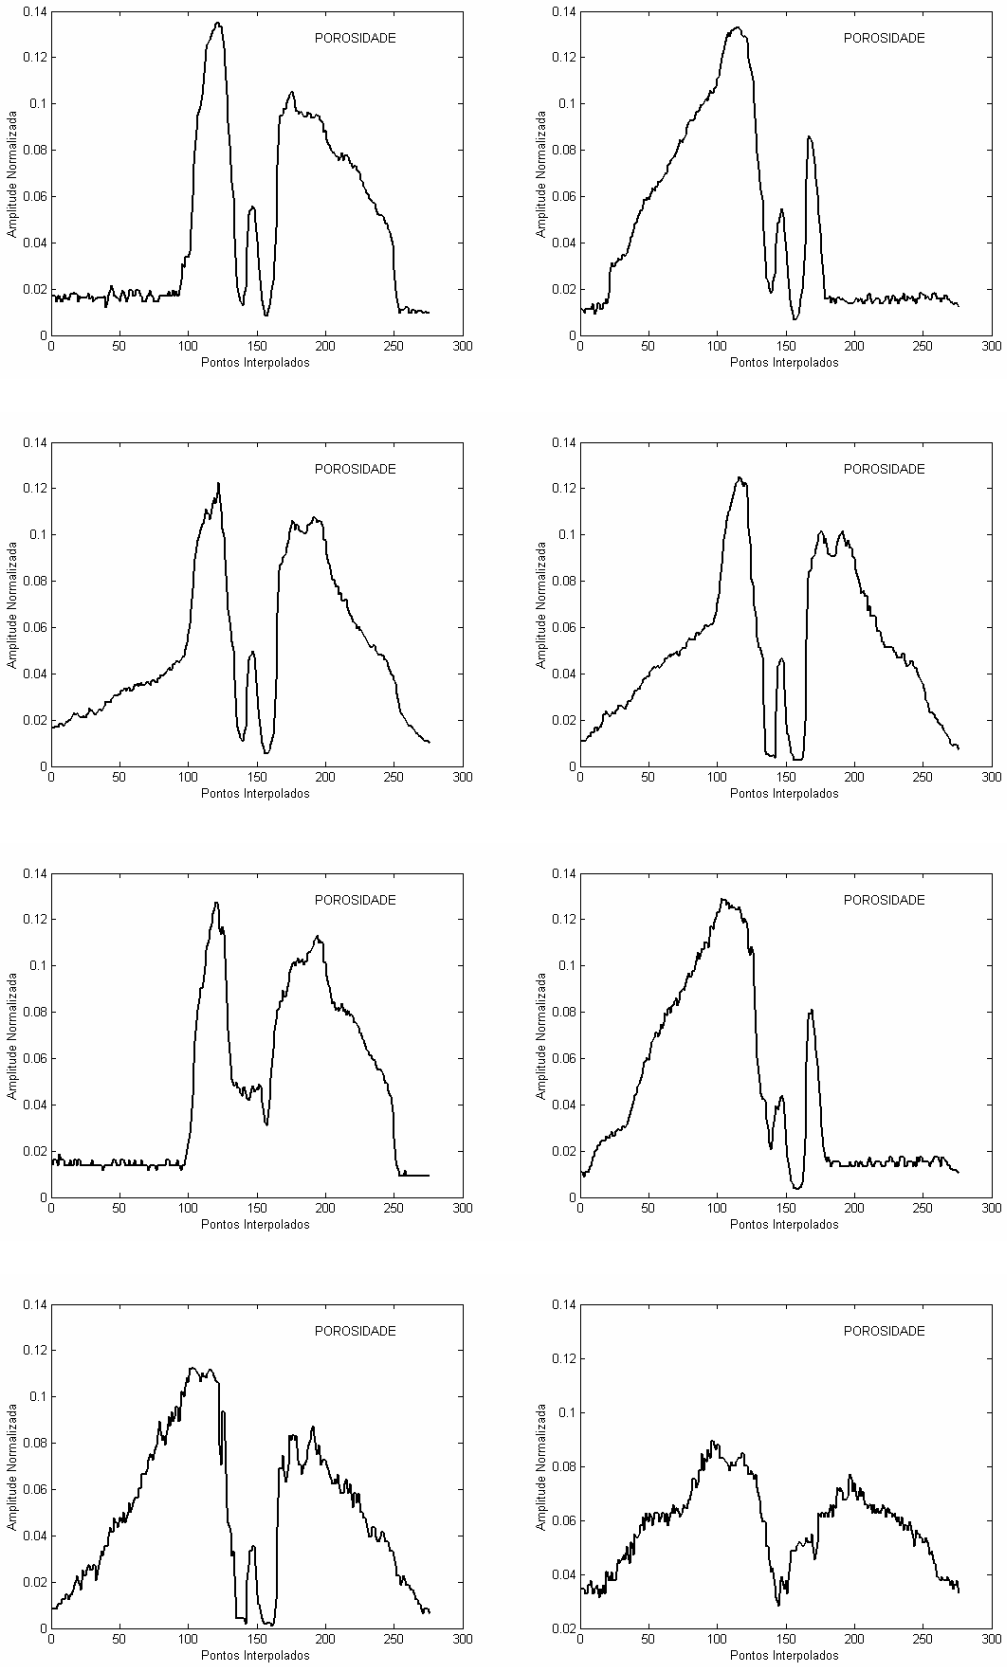

Figura 4.30: Padrões gerados para a classe PO; ρ = 0,43 e N = 9.

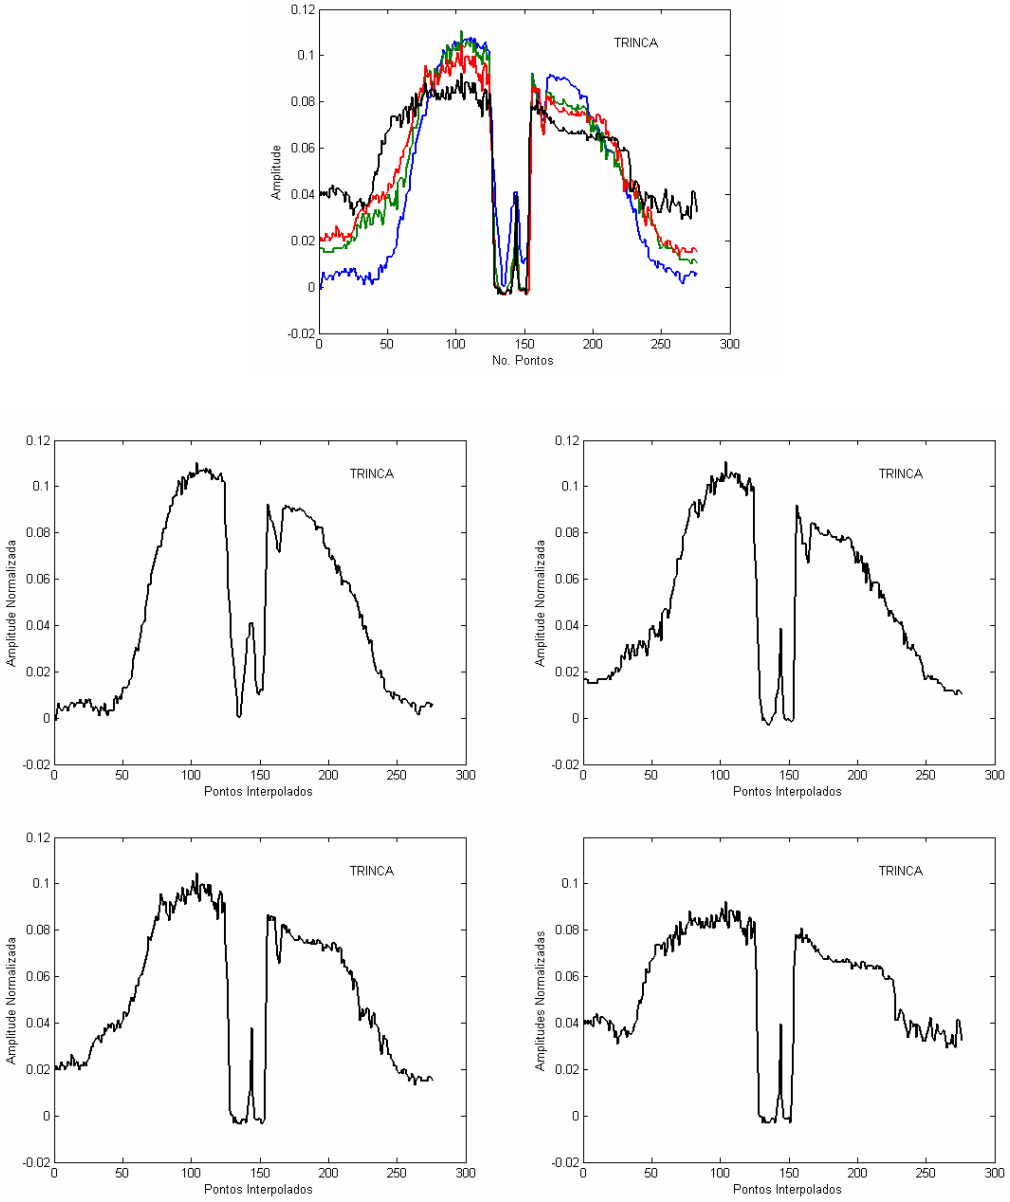

Figura 4.31: Padrões gerados para a classe TR; ρ = 0,55 e N = 4.

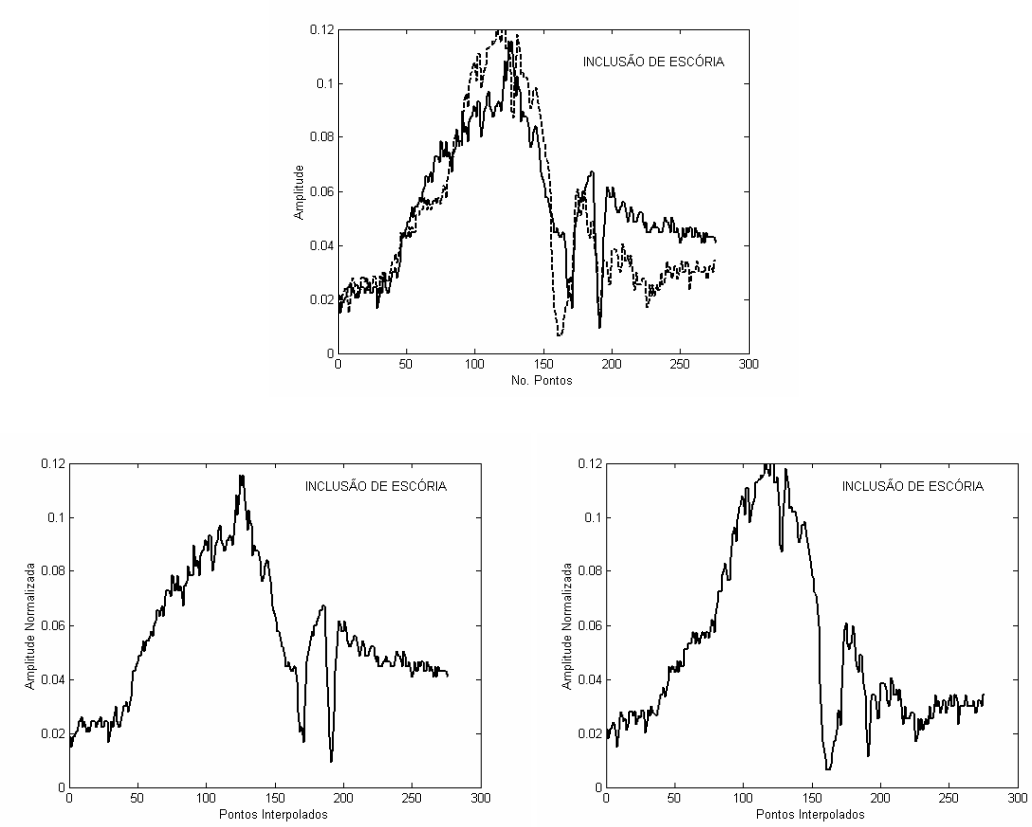

Figura 4.32: Padrões gerados para a classe IE; $\rho = 0{,}45$ e $N = 2$.

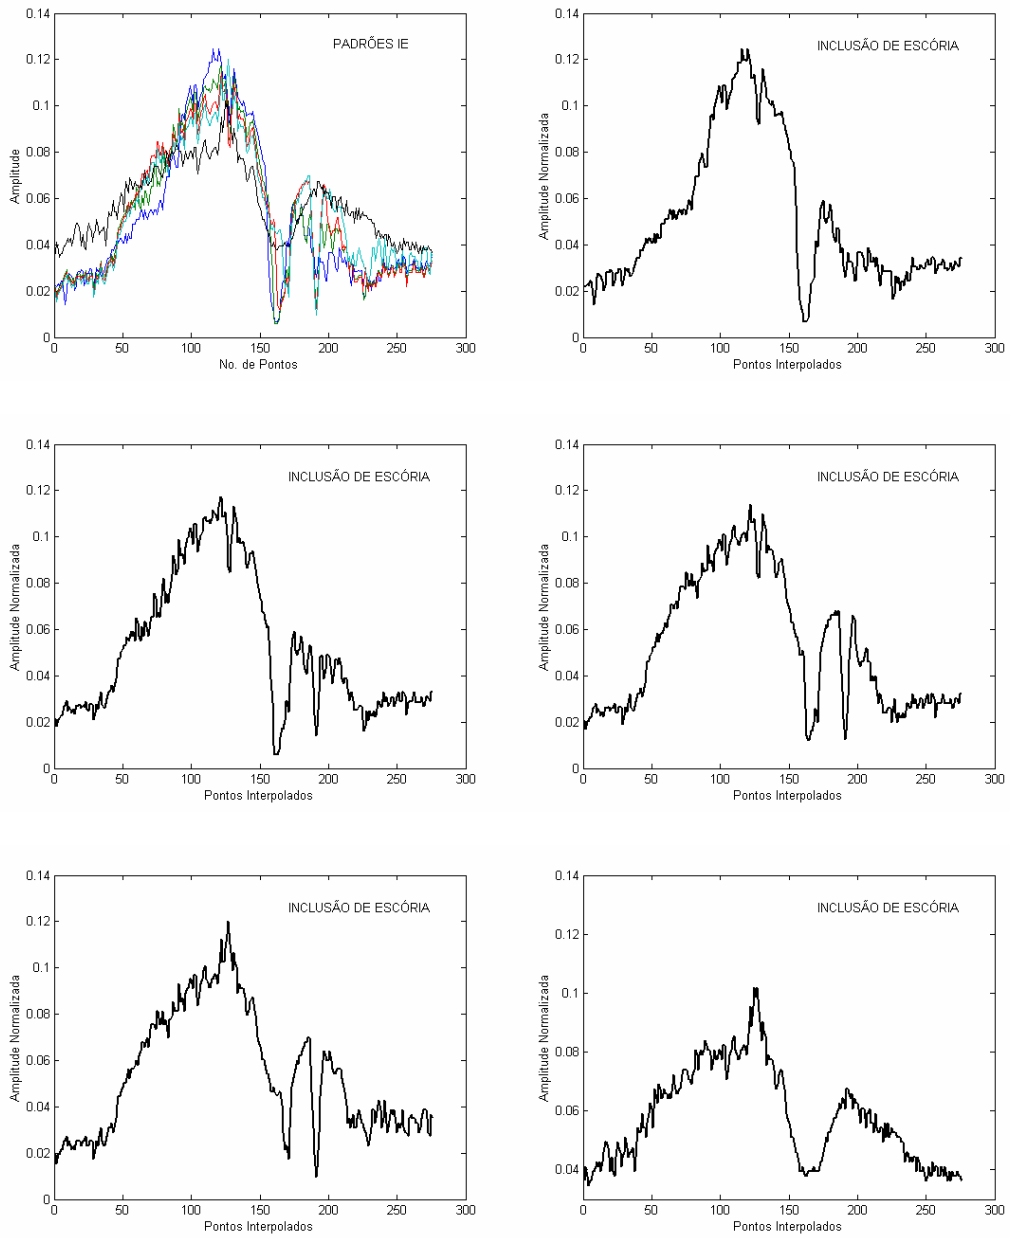

Figura 4.33: Padrões gerados para a classe IE; ρ = 0,50 e N = 5.

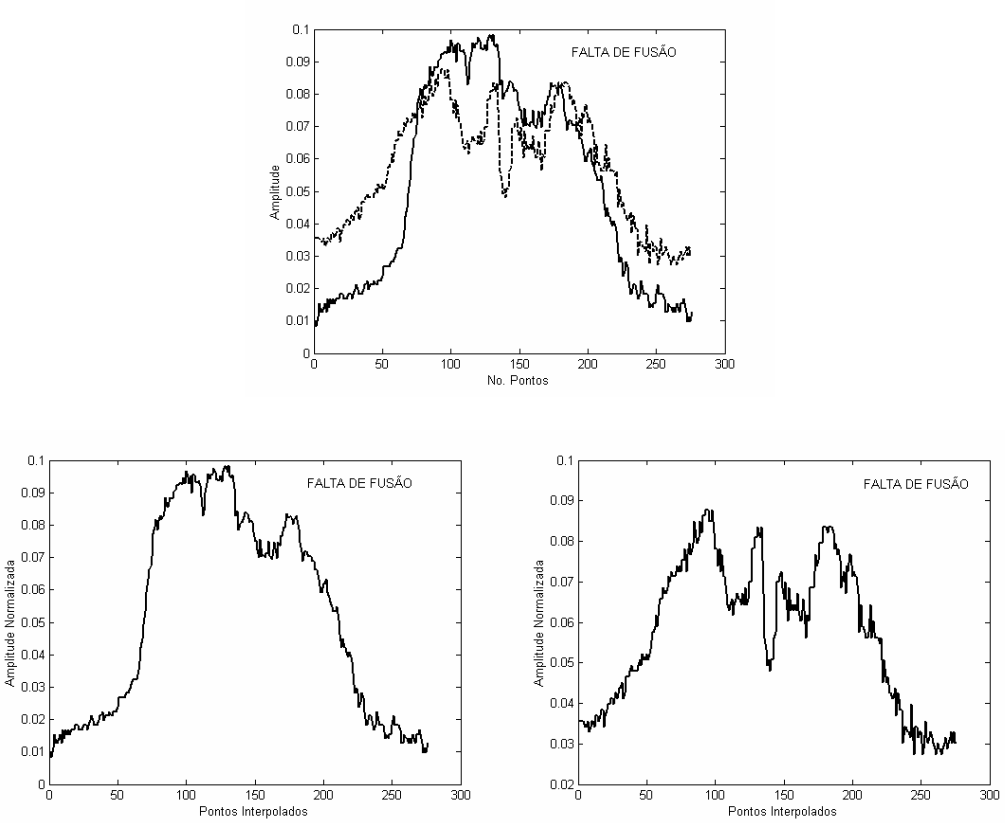

Figura 4.34: Padrões gerados para a classe FF; $\rho = 0{,}66$ e $N = 2$.

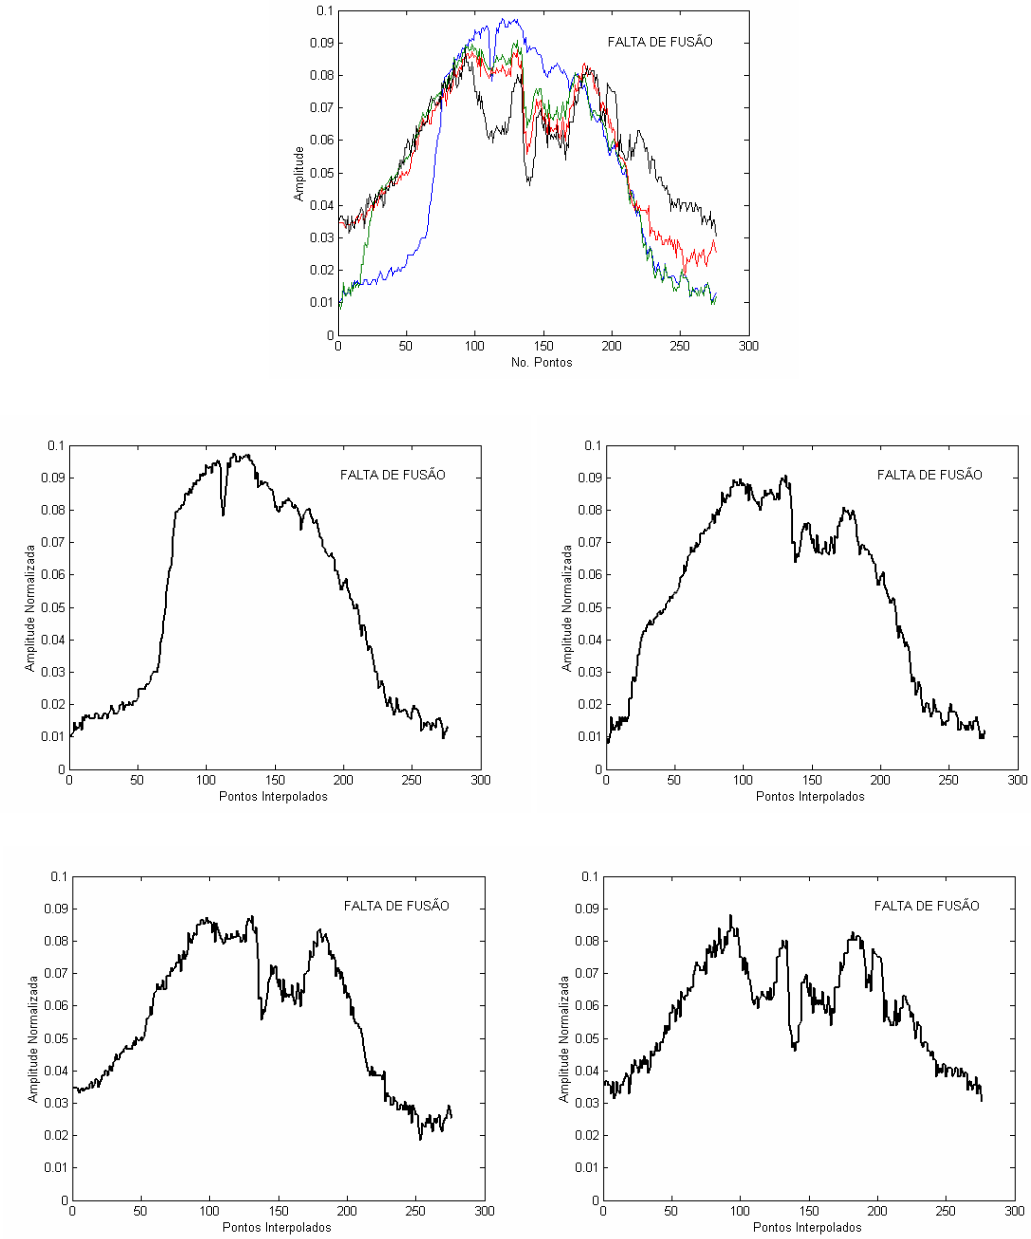

Figura 4.35: Padrões gerados para a classe FF; ρ = 0,74 e N = 4.

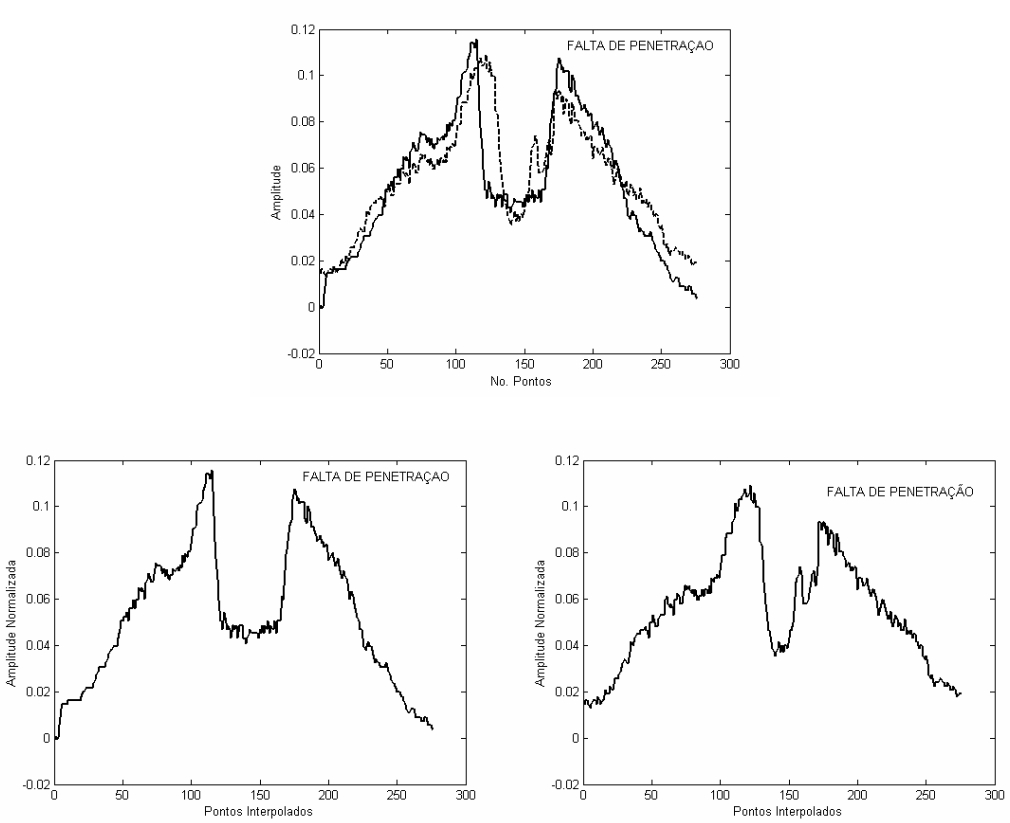

Figura 4.36: Padrões gerados para a classe FP; $\rho = 0{,}53$ e $N = 2$.

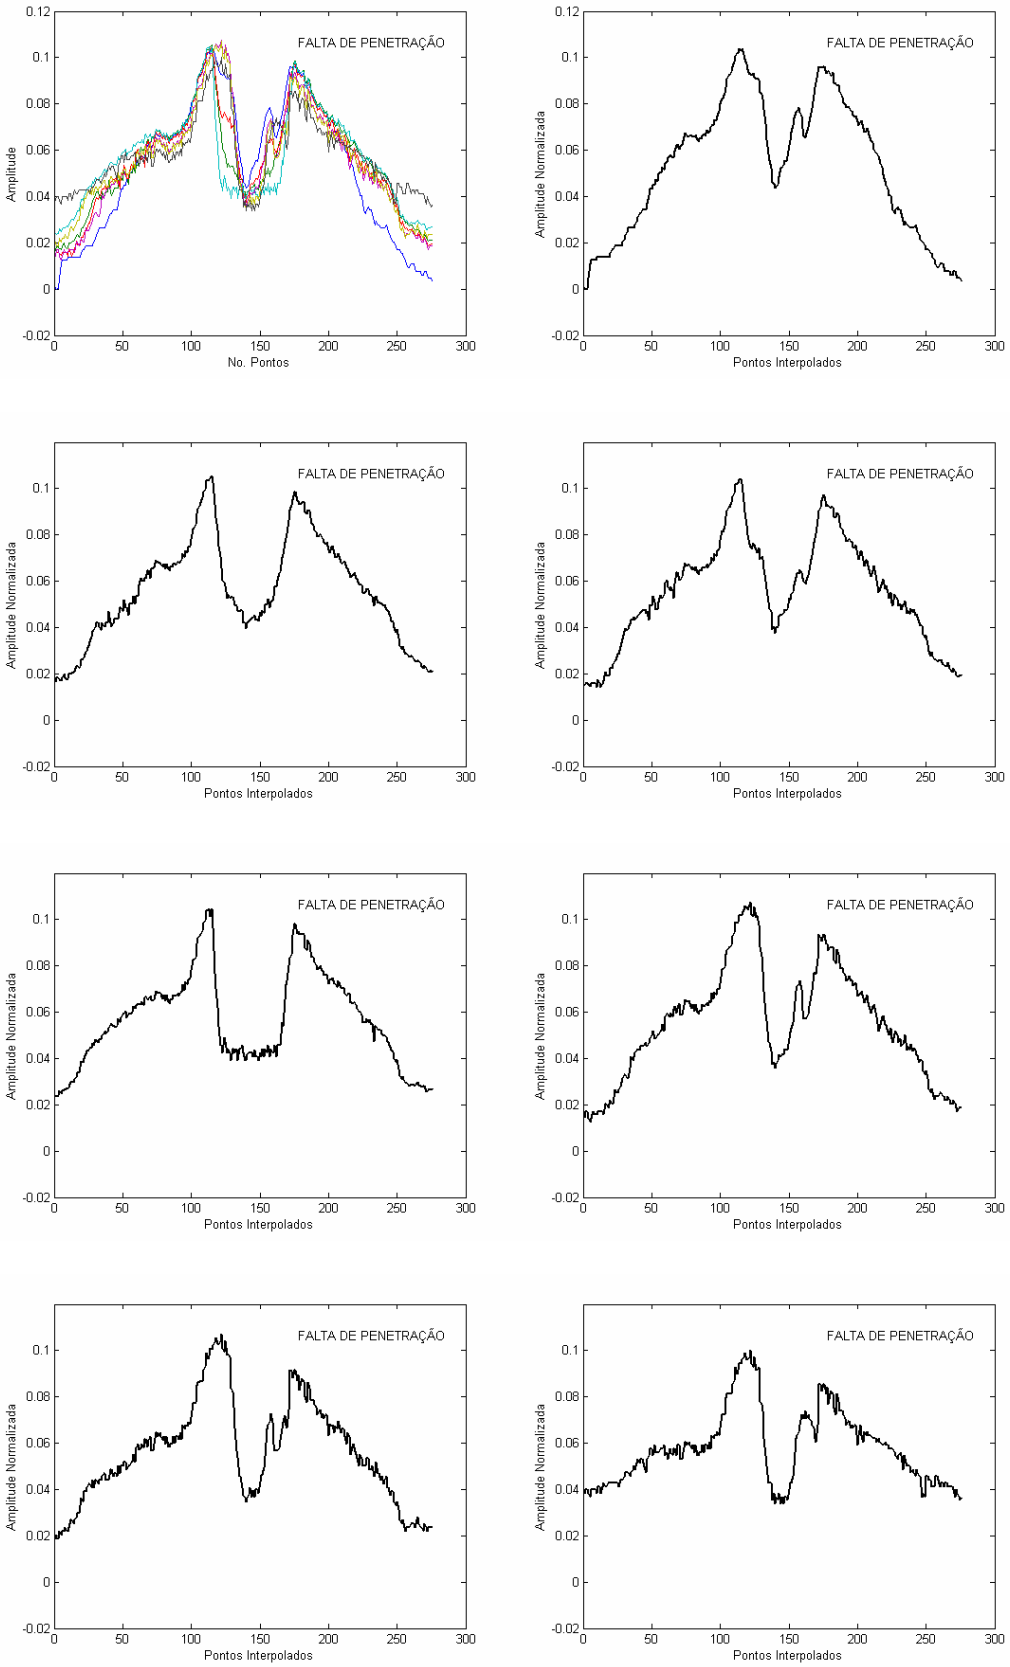

Figura 4.37: Padrões gerados para a classe FP; ρ = 0,63 e N = 7.

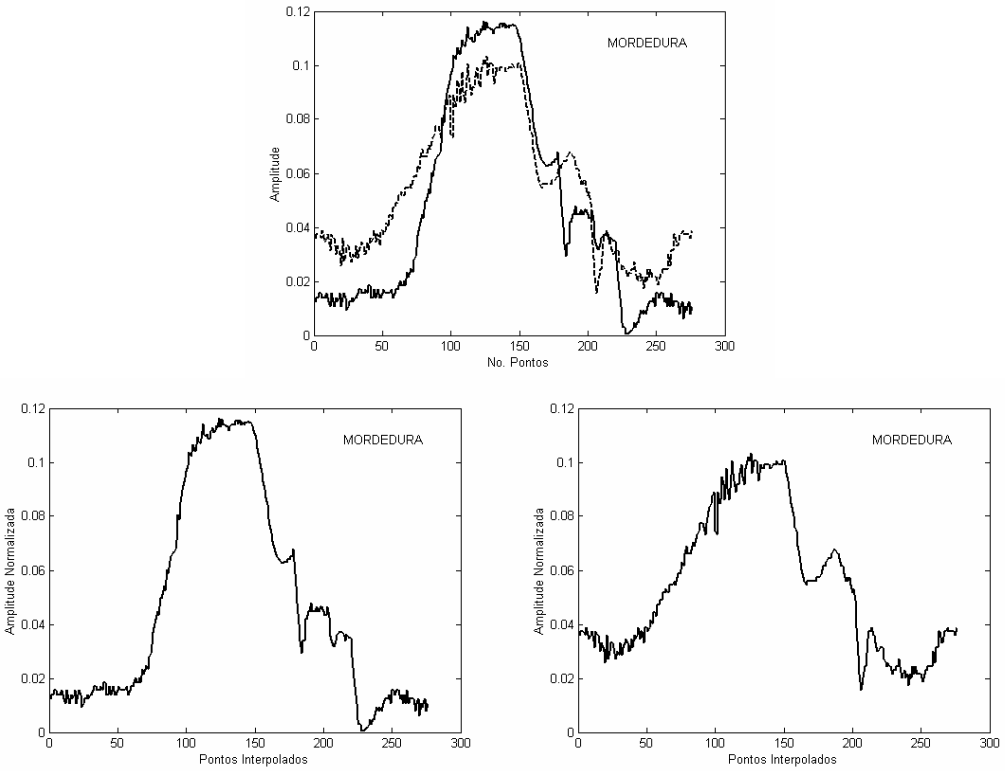

Figura 4.38: Padrões gerados para a classe MO; ρ = 0,60 e N = 2.

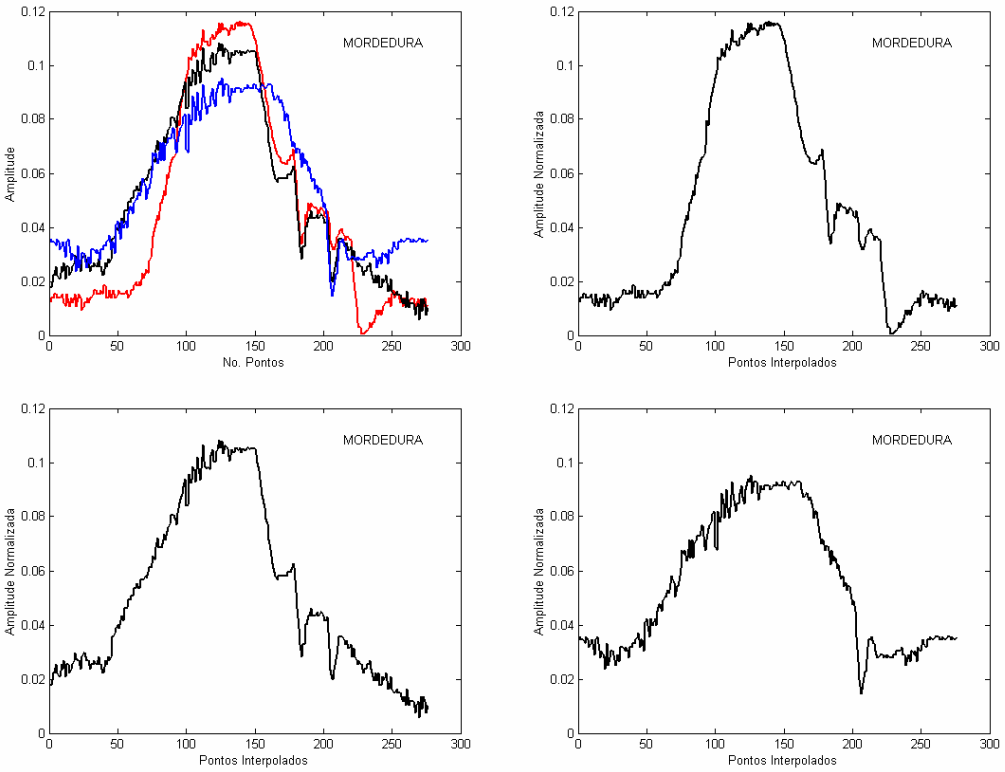

Figura 4.39: Padrões gerados para a classe MO; ρ = 0,63 e N = 3.

4.4.3.2 Análise Fenomenológica dos Padrões Gerados

A análise fenomenológica dos padrões foi feita individualmente para cada classe, a partir das situações tidas como melhor relação entre D e N pela análise dos gráficos apresentados nas figuras 4.24 a 4.27 em consonância com a literatura [38, 42], seguida da análise visual dos padrões obtidos. Esta análise é descrita a seguir:

a) Classe SD: a partir do gráfico D x N o ponto ótimo seria dado por 3 padrões, que é o ponto onde esta curva sofre inflexão. Contudo, a partir da análise visual destes 3 padrões pode-se observar que existe uma significativa similaridade entre dois deles, podendo estes dois serem representados por somente um; os dois padrões, gerados a partir de um parâmetro de vigilância maior são apresentados na figura 4.40, a seguir.

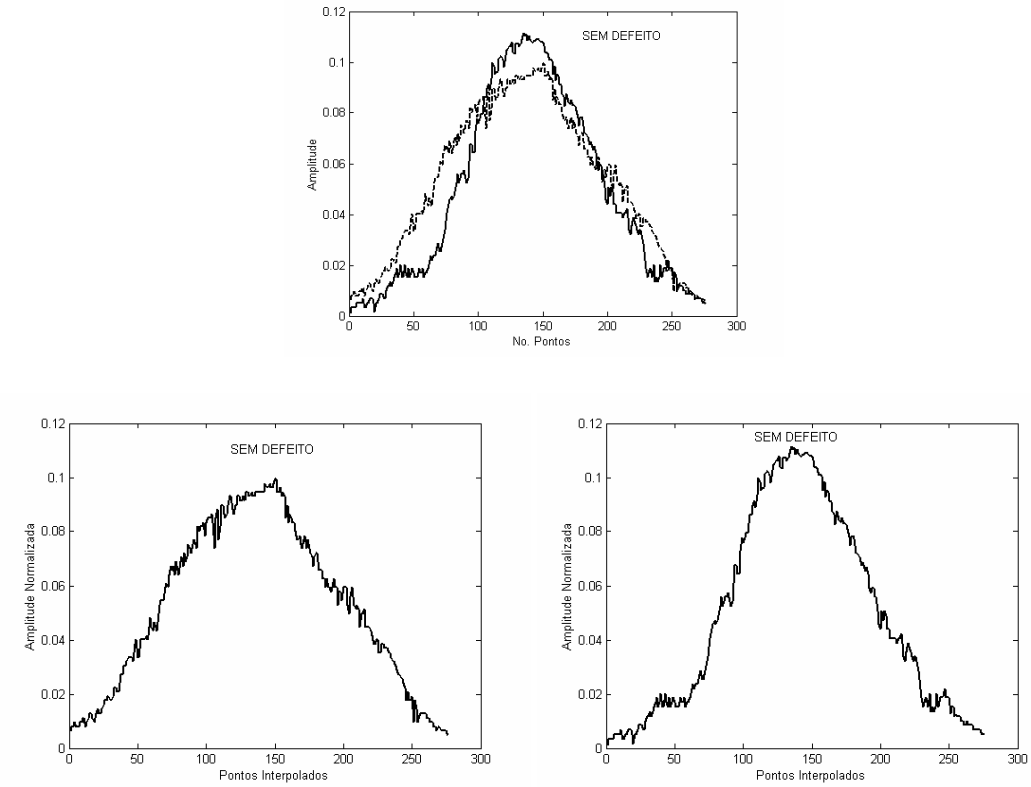

Figura 4.40: Os 2 padrões que representam a classe SD; (a) todos os padrões, (b) os padrões separadamente.

b) Classe PO: a partir do gráfico N x D observa-se dois pontos onde é interessante fazer uma análise, são eles: 2 e no entorno de 10 padrões; os dois padrões gerados são considerados não similares, porém nota-se razoável similaridade entre alguns dos 9 padrões; assim, adotamos 2 padrões para representar esta classe. Estes padrões foram anteriormente mostrados na figura 4.29 e são reapresentados abaixo, na figura 4.41.

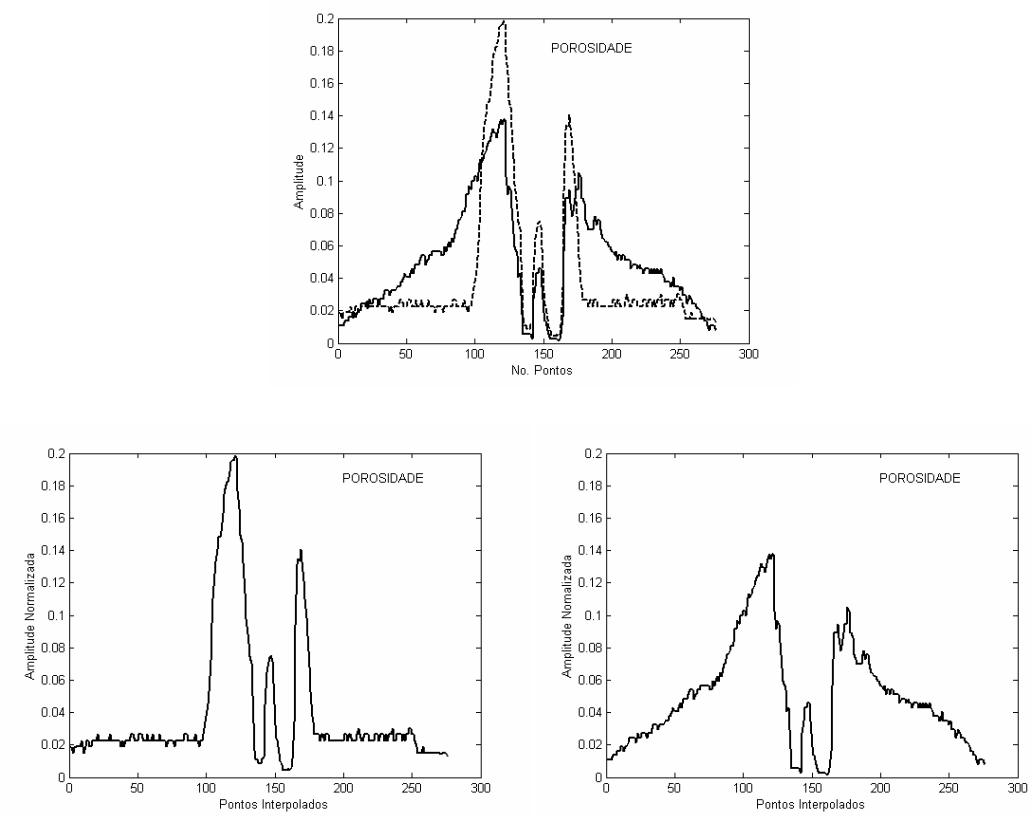

Figura 4.41: Os 2 padrões que representam a classe PO, com todos os padrões e os padrões separadamente.

c) Classe TR: no gráfico N x D o ponto de mudança na inclinação é observado em 4 padrões, contudo ao analisar visualmente estes padrões nota-se considerável similaridade entre eles, para reduzir este número foram analisadas as situações com 1, 2 e 3 padrões, quando ainda foi identificada grande similaridade; finalmente foi adotada a situação com 2 padrões, conforme mostra a figura 4.42.

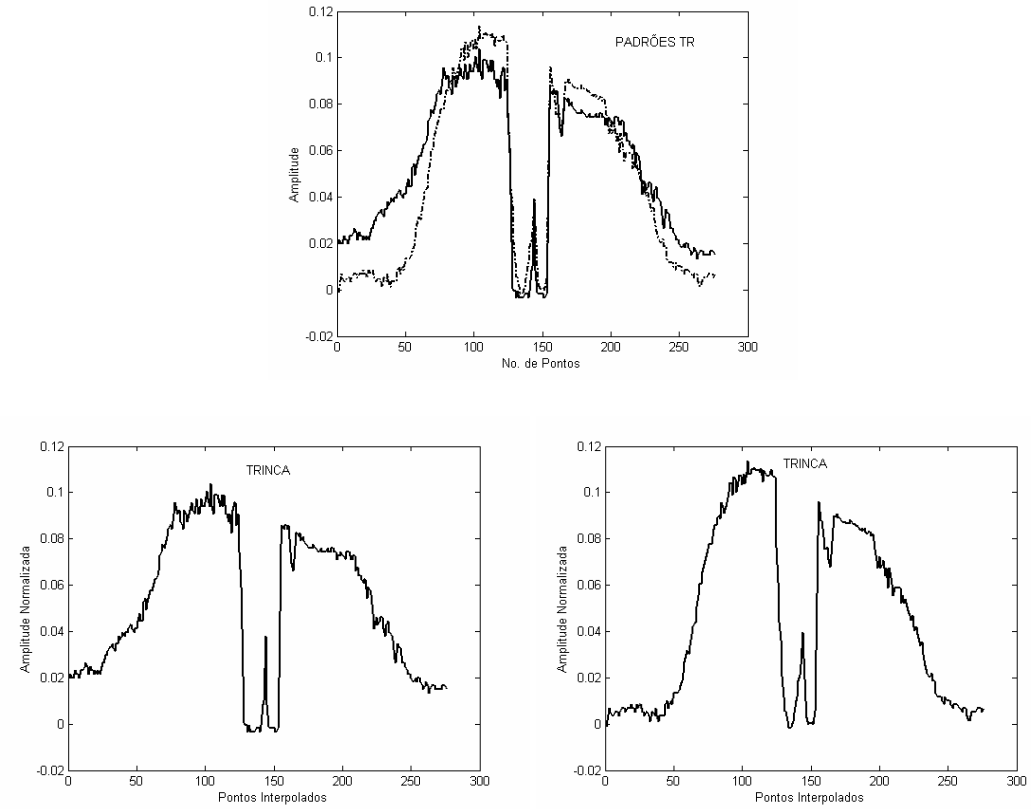

Figura 4.42: Os 2 padrões que representam a classe TR.

d) Classe IE: o gráfico N x D fornece dois pontos de interesse, localizados em 2 e 5 padrões; a análise visual destes padrões indica que com dois padrões obtém-se boa representatividade, os 2 padrões adotados foram apresentados anteriormente na figura 4.32 e são reproduzidos na figura 4.43 abaixo.

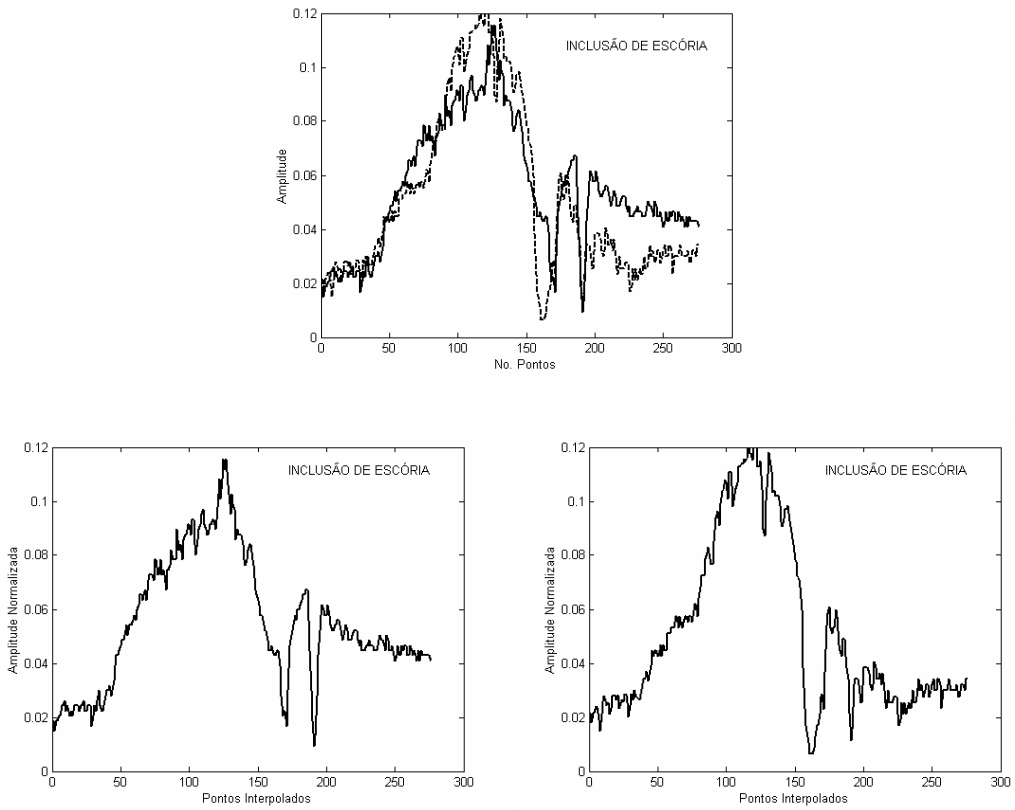

Figura 4.43: Os 2 padrões que representam a classe IE.

e) Classe FF: ao analisar o gráfico N x D desta classe nota-se 2 possíveis pontos de inflexão, em 2 e 4 padrões. Ao visualizar estes padrões pode-se verificar que alguns deles são semelhantes e podem ser comprimidos com algumas ressalvas; Adotamos como "naturais" 2 padrões que podem ser vistos na figura 4.34 e foram reproduzidos abaixo, na figura 4.44.

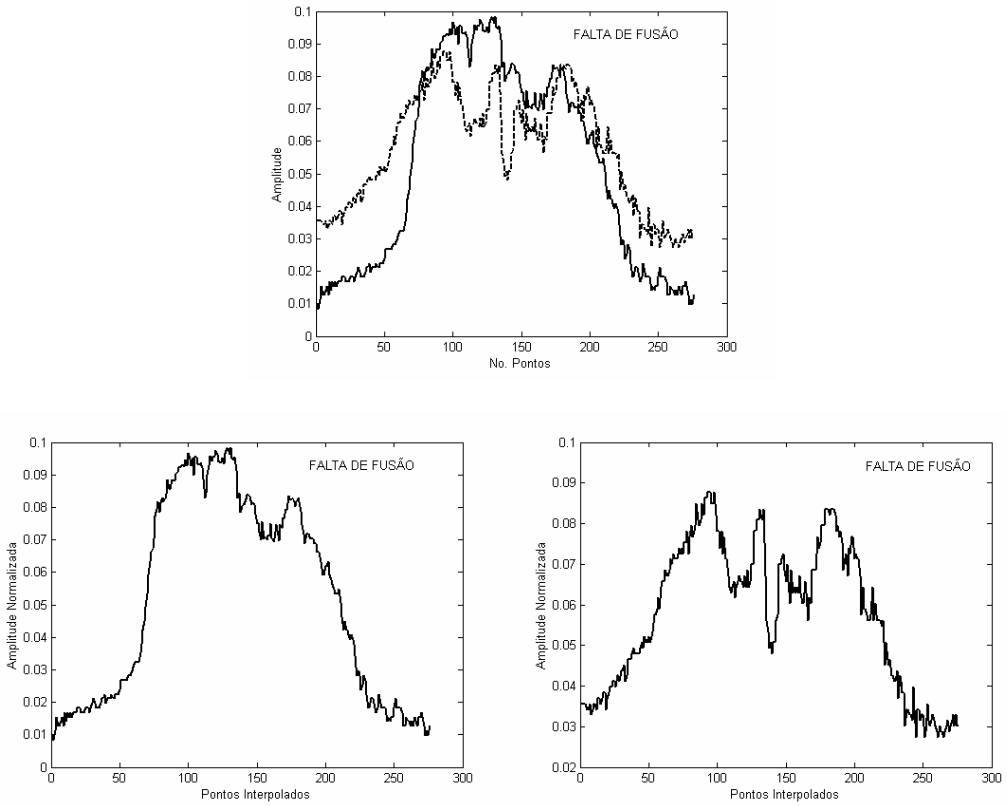

Figura 4.44: Os 2 padrões que representam a classe FF.

f) Classe FP: o gráfico N x D desta classe é bastante didático, mostrando dois pontos, 2 e 7 padrões, onde uma análise é necessária; quando se tem 2 padrões, estes são bastante característicos e importantes sob o ponto de vista da representatividade da classe FP; na visualização de 7 padrões nota-se grande similaridade entre alguns deles; adotamos 2 padrões que foram apresentados anteriormente na figura 4.36 e são reproduzidos na figura 4.45, a seguir.

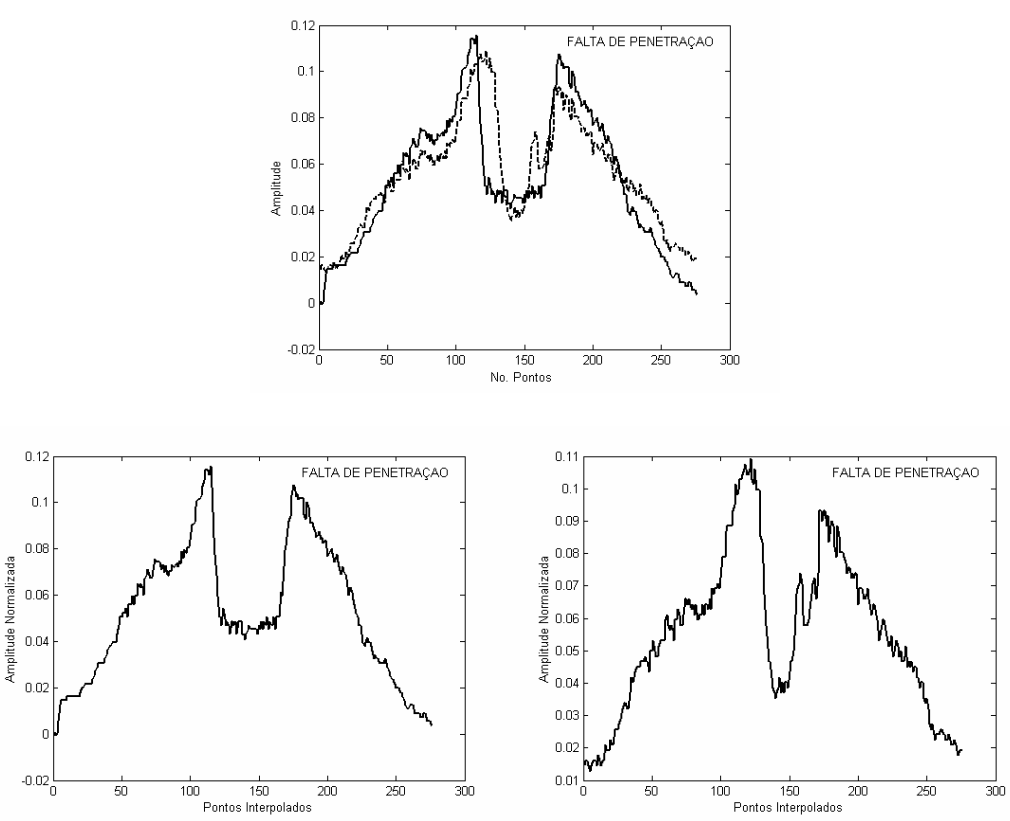

Figura 4.45: Os 2 padrões que representam a classe FP.

g) Classe MO: nota-se claramente no gráfico N x D que o ponto de mudança na inclinação mais acentuada encontra-se em 3 padrões, contudo, através da análise visual destes padrões nota-se uma considerável similaridade entre 2 destes padrões, o que nos leva a apenas 2 padrões, anteriormente mostrados na figura 4.38 e reproduzidos na figura 4.46, a seguir.

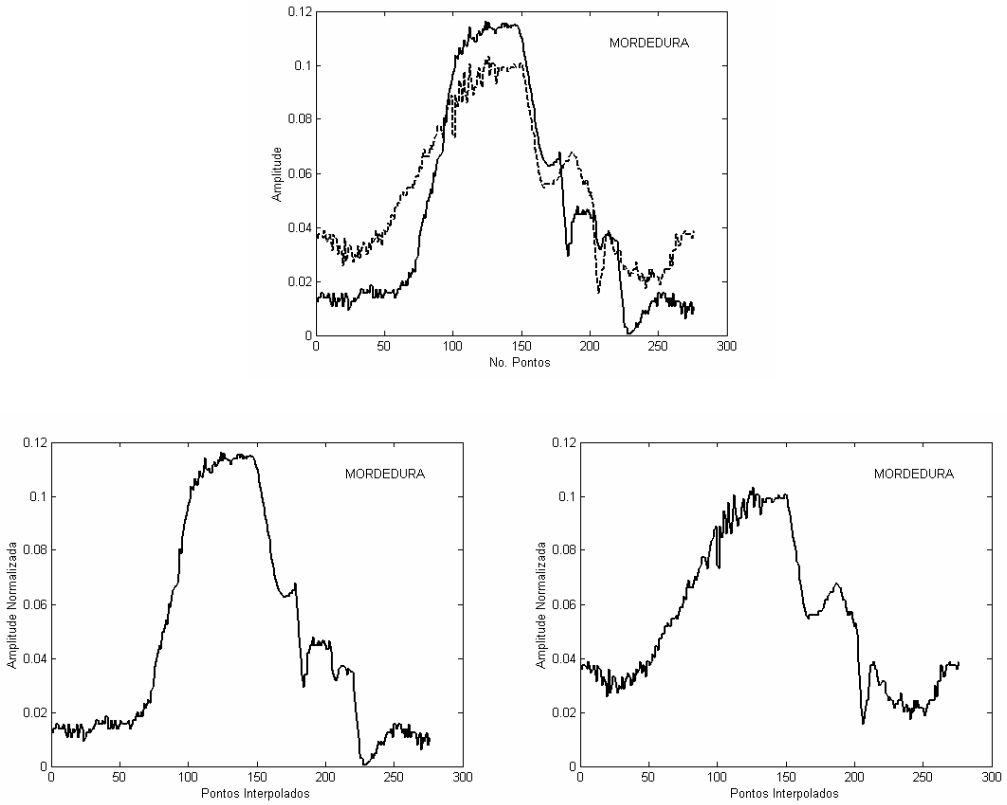

Figura 4.46: Os 2 padrões que representam a classe MO.

4.4.3.3 A Rede ART Modificada como Classificador

Além do objetivo de obter os padrões, a rede foi testada como classificador, mas o resultado obtido foi muito inferior ao da rede *feedforward*. Isto ocorre porque, para obtermos um baixo número de padrões "naturais", o parâmetro de vigilância deve ser pequeno, levando a um raio de similaridade muito grande, no nosso caso entorno de 1, e conseqüentemente uma grande invasão de classes.

Para utilizar a rede como classificador devemos utilizar um raio otimizado para a definição dos domínios, como descrito na seção 3.9.2.

Examinando as distâncias intra-classe, ou seja, entre entradas das mesmas classes de defeito encontramos os histogramas mostrados nas figuras 4.47 a 4.50.

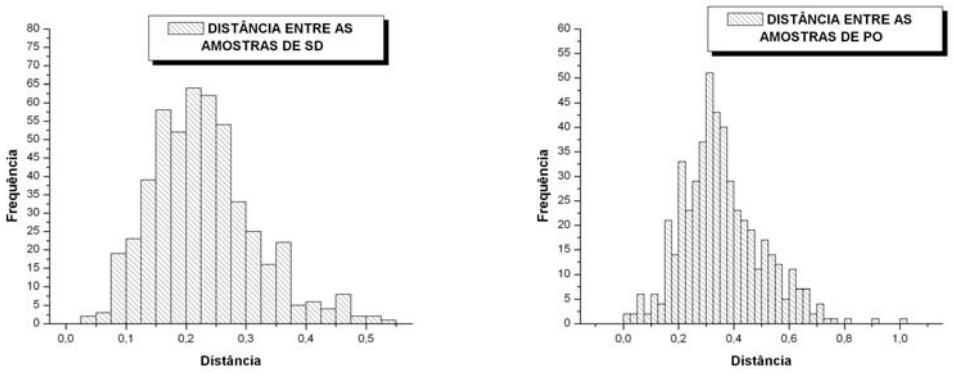

Figura 4.47: Histograma de distribuição das distâncias entre as amostras para as classes;

(a) SD, m = 0,2 e (b) PO, m = 0,30.

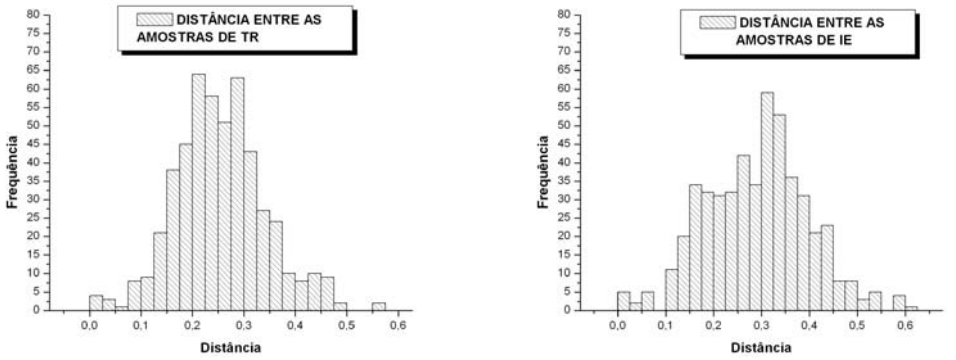

Figura 4.48: Histograma de distribuição das distâncias entre as amostras para as classes

(a) TR, m = 0,20 e (b) IE, m = 0,15.

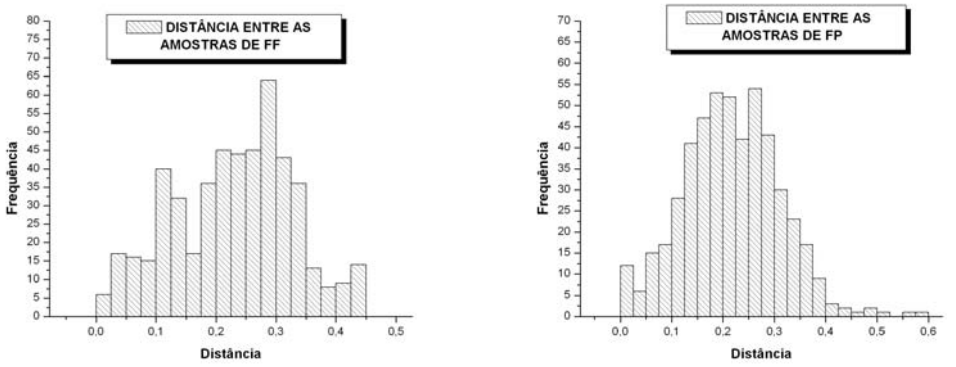

Figura 4.49: Histograma de distribuição das distâncias entre as amostras para as classes

(a) FF, m = 0,10 e (b) FP, m = 0,20.

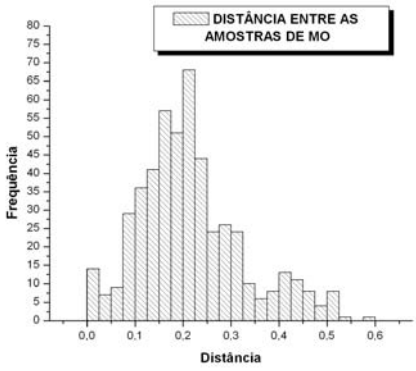

Figura 4.50: Histograma de distribuição das distâncias entre as amostras para a classe MO, m = 0,20.

Nota-se que a distribuição das distâncias entre as amostras de cada classe possui distribuição aproximadamente normal, concentrando-se praticamente dentro da mesma faixa para todas as classes, o que é vantajoso para este estudo. Este levantamento permite avaliar o comportamento das populações de cada classe e estimar o valor do raio de similaridade destas quando da definição dos padrões de classes e sub-classes.

A partir dos histogramas adotamos um valor conservador, pequeno, para a menor moda, *m*, de cada distribuição, e a partir deste e do critério definido na seção 3.9.2 o parâmetro de vigilância, ρ, de cada classe, onde

$$\rho = 1 - \frac{(1{,}5m)^2}{2} \tag{4.1}$$

O uso de raios de similaridade menores deverá levar a um número bem maior de padrões e uma melhor discriminação do domínio das classes, permitindo o uso da rede também como classificador. Foram estabelecidos os parâmetros de vigilância a partir da menor moda de cada classe. Sendo ρ = 0,989 o maior deles para a classe FF. Para as classes SD, TR, FP e MO foi estabelecido ρ = 0,955, ρ = 0,975 para a classe IE e ρ = 0,899 para a classe PO.

Considerando que os raios de similaridade não são muito discrepantes entre si, resolvemos utilizar o mesmo raio para todas as classes, devido à grande facilidade de implementação que isto acarreta. Como o raio encontrado para cada classe é o máximo valor sugerido, utilizamos o menor de todos eles, r = 0,15, que corresponde a m = 0,10, encontrado para a classe FF, e que fornece um parâmetro de vigilância ρ = 0,989. Aplicando o procedimento temos os seguintes números de padrões para cada classe apresentados na tabela 4.13.

Tabela 4.13: Número de Padrões por Classe (ρ = 0,989).

Classes	SD	PO	TR	IE	FF	FP	MO
Número de Padrões	26	55	22	31	7	16	12

O número maior de padrões nas classes que admitiriam raios maiores é uma indicação de que o uso de raios maiores nestas classes, a princípio, é possível.

Aplicamos então os dados e obtivemos as tabelas 4.14 e 4.15 de confusão percentual abaixo para os conjuntos de treinamento e de teste.

Tabela 4.14: Tabela de Confusão para o Conjunto de Treinamento.

		CONFUSÃO (%)							
		SD	PO	TR	IE	FF	FP	MO	Nenhuma Classe
CLASSE EM ESTUDO TREINAMENTO	**SD**	**71**	8	4	5	1	9	2	0
	PO	3	**94**	1	0	0	2	0	0
	TR	2	4	**91**	1	1	1	0	0
	IE	4	1	3	**89**	2	1	0	0
	FF	8	4	0	0	**88**	0	0	0
	FP	12	1	1	1	0	**85**	0	0
	MO	1	0	0	0	0	0	**99**	0

Tabela 4.15: Tabela de Confusão para o Conjunto de Teste.

		CONFUSÃO (%)							
		SD	PO	TR	IE	FF	FP	MO	Nenhuma Classe
CLASSE EM ESTUDO TESTE	**SD**	**66**	9	6	2	0	13	3	1
	PO	4	**87**	0	1	0	5	0	4
	TR	2	2	**92**	2	0	2	0	
	IE	10	7	0	**80**	0	0	0	3
	FF	0	25	0	0	**58**	17	0	
	FP	19	3	6	0	0	**72**	0	
	MO	11	0	0	0	0	5	**84**	

A resposta "nenhuma classe" indica que nenhum neurônio foi acionado para uma dada entrada. Os erros indicados nas tabelas de confusão são "invasões", que podem ser corrigidos com a redução do raio de similaridade do neurônio que sofreu a "invasão" e foi erroneamente ativado, mas este procedimento em princípio requer um re-treinamento da rede especializada na classe, para preencher com outros neurônios possíveis lacunas deixadas pela redução do raio. Para testar esta hipótese usamos um raio de similaridade ainda menor, $r = 0{,}10$, que é menos susceptível de ser invadido; este novo raio levou a uma taxa de acerto consideravelmente maior do que a presente, mas as custas de um aumento considerável no número de padrões. As taxas de acerto atuais, embora menores que as obtidas com a rede *feedforward* treinada com *backpropagation*, já evidenciam que a rede pode ser usada como classificador.

4.6 Discussão Geral

Os diversos processamentos e a definição criteriosa da metodologia desta pesquisa proporcionaram ótimos resultados quando comparados às publicações internacionais nesta linha de pesquisa. A correta classificação dos defeitos de soldagem em 98% dos casos e a detecção de defeitos em 100%, visto que não houve nenhuma confusão entre a classe SD e as outras estudadas é superior, por exemplo, ao sistema de Liao [7] que utilizou uma metodologia de ajuste da curva para detectar defeitos e obteve sucesso em 93,3% e 90% dos casos respectivamente, que sendo o pesquisador que mais publica nesta área, também utilizou agrupamentos *fuzzy* para detecção de defeitos [10] pela extração de parâmetros do perfil transversal à solda, onde obteve 83,15% de detecções corretas e 18,68% de alarmes falsos. Da Silva [9] ao utilizar discriminadores lineares hierárquicos e não hierárquicos para classificar defeitos previamente detectados dentre 4 classes (MO, FP, PO e IE) a partir de parâmetros geométricos dos defeitos obteve desempenho máximo de 96%. Em trabalho subseqüente, Da Silva[24] obteve uma taxa de acerto de 99,2% na classificação daquelas 4 classes de defeitos ao utilizar um classificador não linear, porém aplicável somente a defeitos previamente detectados. Nafaa[8] utilizou redes neurais com treinamento por retropropagação do erro para classificar defeitos em volumétricos ou planares a partir de parâmetros geométricos, obtendo um percentual de acerto de 95%.

Existem ainda pesquisas que se limitam a detectar somente um ou dois tipos de defeitos, como Alekseychuk [29] que obteve eficiência comparável ao inspetor qualificado, sem mencionar números, na detecção de trincas (TR) a partir de parâmetros geométricos e de contraste. Jacobsen [20] obteve percentual de acerto de 94% na detecção de mordedura e trinca utilizando parâmetros de contraste para detectar e

classificar estes defeitos. Zhang[33] utilizou classificadores *fuzzy* supervisionados em parâmetros da imagem para detectar porosidade e inclusão de escória somente. Murakami[28] inserindo parâmetros geométricos, obtidos após tratamento de imagens para detecção de defeitos, em árvores de decisão verificou que a detecção de porosidade e inclusão de escória é fácil, porém relata dificuldade em detectar trincas.

Outras publicações ainda relatam o desenvolvimento de sistemas de detecção e classificação de defeitos de soldagem [30, 31, 32, 45], porém limitam-se a descrever a metodologia, não informando o desempenho destes sistemas.

Após a análise das publicações disponíveis até esta data pode-se verificar que a metodologia empregada nesta pesquisa não foi relatada em nenhuma delas, bem como o desempenho do sistema de reconhecimento de padrões envolvendo detecção e classificação dos defeitos de soldagem mais importantes, podendo ser considerado este, um dos melhores resultados obtidos no sentido de desenvolver um sistema de detecção e classificação de defeitos de soldagem e orientando o caminho para este desenvolvimento.

5 – CONCLUSÕES

O objetivo geral desta tese é contribuir para a concepção e construção de um sistema automático de interpretação de radiografias de juntas soldadas.

Neste trabalho foram estudados métodos específicos de pré-processamento para sinais provenientes de perfis transversais à solda em níveis de cinza retirados de radiografias digitalizadas e destinados à implementação de um sistema de reconhecimento de padrões.

Em seguida, sistemas de reconhecimento de padrões baseados em redes neurais e especificamente adequados ao problema também foram objeto de estudo.

A partir dos resultados obtidos concluímos que:

- Conforme informado por Liao [7, 14, 16, 18, 19], foi constatado que o perfil transversal à solda normalmente possui comportamento gaussiano, entretanto, deve-se ressaltar que esta característica não se aplica a todos os tipos de solda, mas somente àquelas com reforço.
- Um pré-processamento adequado, não limitado à suavização dos sinais de entrada, é essencial para se obter um melhor desempenho nos sistemas de reconhecimento de padrões. A normalização da posição do defeito, representado pela irregularidade no sinal, promove uma considerável melhora no desempenho dos classificadores não lineares com treinamento por retropropagação do erro.
- A obtenção das Componentes Principais de Discriminação Não Linear permite avaliar o grau de dificuldade na discriminação de classes existente em determinado conjunto de sinais.

- A detecção de defeitos, isto é, a separação entre perfis sem a presença de defeito e com a ocorrência de defeitos é comprovadamente possível usando um classificador não linear, após um adequado pré-processamento do perfil
- A classificação dos defeitos de soldagem a partir do perfil transversal ao cordão de solda dentre os seis principais tipos de defeitos (falta de fusão, falta de penetração, trinca, inclusão de escória, porosidade e mordedura), bem como a indicação da inexistência de defeitos, é perfeitamente possível quando se estabelece a metodologia correta de utilização de um classificador não linear com treinamento por retropropagação do erro.
- A utilização das redes neurais semi-supervisionadas do tipo ART Modificada possibilita o estabelecimento de padrões representativos para cada uma das sete classes (sem defeito e seis tipos de defeito) de sinais utilizadas independentemente.
- O estabelecimento de uma correta metodologia e estudo de parâmetros para implementação das redes ART Modificadas mostrou-se viável para a identificação de defeitos de soldagem a partir do perfil transversal em níveis de cinza, bem como para identificar uma solda sem defeitos.
- O desenvolvimento de um sistema de detecção e classificação de defeitos de soldagem em radiografias é objeto de pesquisa nos maiores centros de pesquisa em Ensaios Não Destrutivos, não existindo até o momento nenhum sistema deste tipo disponível comercialmente. Este trabalho chegou a resultados promissores, comparados às publicações disponíveis, utilizando como entrada para as redes neurais artificiais um tipo de dado não relatado em nenhuma publicação anterior, e redes especialmente projetadas para a tarefa.

Para complementar este trabalho, ou ainda dar seguimento ao desenvolvimento de um sistema automático ou semi-automático de interpretação radiográfica, apresentamos as seguintes sugestões:

- Utilizar as componentes principais de discriminação como entrada nos classificadores, definindo previamente, através de um estudo de relevância, a dimensão a ser utilizada, isto é, o número de componentes que representarão cada vetor original.
- A implementação de uma metodologia de processamento de imagens para automatizar a extração da parte da imagem referente à solda, o que exigirá um estudo aprofundado.
- Desenvolver uma metodologia para automatizar a extração do perfil transversal ao cordão de solda somente a região referente à solda, baseada no fato deste perfil possuir forma gaussiana quando a solda de origem possui material de reforço.
- Implementar um sistema de varredura da imagem radiográfica integrado aos classificadores não lineares, de forma que o pré-processamento dos perfis seja executado nesta interligação.
- Desenvolver a automatização da fase posterior à detecção e classificação do defeito, isto é, efetuar o seu dimensionamento e julgamento conforme Norma ou Código aplicável.
- De uma forma geral, o sistema automático de interpretação de radiografias de juntas soldadas deve conter diversos sub-sistemas entre eles o apresentado neste trabalho. Estes sub-sistemas devem varrer a imagem, detectar o defeito, classificá-lo, dimensioná-lo e julgá-lo, porém podem ainda recompor a imagem

e localizar o defeito com clareza, permitindo ao inspetor avaliar o desempenho do sistema.

6 – REFERÊNCIAS BIBLIOGRÁFICAS

[1] ASME – The American Society of Mechanical Engineers – CODES, STANDARDS AND SPECIFICATIONS (www.asme.org).

[2] FUCSOK, F. et al "Reliability of Routine Radiographic Film Evaluation – an Extended ROC Study of the Human Factor", In: *8th European Conference on Nondestructive Test (ECNDT)*, Barcelona, 2002.

[3] MORE, J.D. "Aplicação Da Lógica Fuzzy Para Avaliação Da Confiabilidade Humana Nos Ensaios Não Destrutivos Tipo Ultra-Som", Tese de D.Sc., COPPE/UFRJ, Março, 2004.

[4] HAYKIN, S., "Redes Neurais - Princípios e Prática", 2ª edição, Porto Alegre, Bookman, 2001.

[5] PINTO, H.L.C.P. "Estudo de um Método para Geração Automática de codebook para voz", Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 1999.

[6] PINTO, R.C.C.P. "Identificação de Locutores não-cooperativos", Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 1999.

[7] LIAO, T. W. e LI, Y. "An Automated Radiographic NDT System for Weld Inspection: Part II – Flaw Detection", *NDT&E International*, v. 31, n. 3, pp. 183-192, 1998.

[8] NAFAÂ, N., REDOUANE, D. e AMAR, B. "Weld Defect Extraction and Classification in Radiographic Testing Based Artificial Neural Networks", In: *15th World Conference on Nondestructive Testing (WCNDT)*, Roma, 2000.

[9] SILVA, R. R., SIQUEIRA, M. H. S., CALÔBA, L. P. e REBELLO, J. M. A. "Radiographics Pattern Recognition Of Welding Defects Using Linear Classifiers", *Insight*, v. 43, n. 10, pp. 669-674, October, 2001.

[10] LIAO, T.W. LI, D.M. e LI, Y.M. "Detection Of Welding Flaws From Radiographic Images With Fuzzy Clustering Methods", *Fuzzy Sets and Systems*, v. 108, pp. 145-158, 1999.

[11] KEHOE, A. e PARKER, G. A. "Image Processing For Industrial Radiographic Inspection: Image Enhancement", *British Journal of NDT*, v. 32, n. 4, pp. 183-190, April, 1990.

[12] MERY, D. "Flaw Simulation in Casting Inspection by Radioscopy", *Insight*, v. 43, n. 10, pp. 664-667, October, 2001.

[13] DIERCKX, P. "Curve And Surface Fitting With Splines", Oxford, Clarendon Press, 1993.

[14] LIAO, T. W. e NI, J. "An Automated Radiographic NDT System for Weld Inspection: Part I – Weld Extraction", *NDT&E International*, v. 29, n. 3, pp. 157-162, 1996.

[15] KONSTANTINIDES, K. e RASURE, J. R. “The Khoros Software Development Environment For Image And Signal Processing”, In: *IEEE Trans Image Proc 3*, pp. 243-252, 1994.

[16] LIAO, T. W. e TANG, K. “Automated Extraction Of Welds From Digitized Radiographic Images Based on MLP Neural Networks”, *Applied Artificial Intelligence*, v. 11, n. 13, pp. 197-218, April-May, 1997.

[17] CHENG, R., TOSAWA, T. e GEN, M. “AE Behaviors Evaluation with BP Neural Network”, Computers ind. Eng., v. 31, n. ¾, pp. 867-871, 1996.

[18] LI, D. e LIAO, T. W. “Applications of Fuzzy K-NN in Weld Recognition and Tool Failure Monitoring”, In: *Proceedings of the Annaul Southeastern Symposium on System Theory*, IEEE, pp. 222-226, 1996.

[19] LIAO, T.W., LI, D. e LI, Y. “Extraction Of Welds From Radiographic Images Using Fuzzy Classifiers”, *Information Sciences*, v. 126, pp. 21-40, 2000.

[20] JACOBSEN, C. ZSCHERPEL, U. e PERNER, P. “A Comparison between Neural Networks and Decision Trees”, In: *Institute of Computer Vision and Applied Computer Sciences*, pp. 27-37, Leipzig, Germany.

[21] PADUA, G.X. SILVA, R.R. REBELLO, J.M.A. e CALÔBA, L.P. "Extração do Cordão de Solda e Detecção de Defeitos Usando Redes Neurais", In: *7ª Conferência Nacional em Tecnologia de Equipamentos (COTEQ)*, Florianópolis, 2000.

[22] SOPHOCLES, J.O. "Introduction to Signal Processing", Prentice-Hall, 1995.

[23] CALÔBA, L.P. "CPE 721 – Redes Neurais Feedforward", Notas de Aula, COPPE/UFRJ, 2003.

[24] SILVA, R. R., SIQUEIRA, M. H. S., CALÔBA, L. P. e REBELLO, J. M. A. "Pattern Recognition of Weld Defects by Radiographic Test", *NDT&E International*, v. 37, n. 6, pp. 461-470, September, 2004.

[25] AOKI, K. e SUGA, Y. "Application Of Artificial Neural Network To Discrimination Of Defect Type Automatic Radiographic Testing Of Welds", In: *Proceeding of the Seventh International Offshore and Polar Engineering Conference*, Honolulu, USA, pp. 527-531, May, 1999.

[26] KATO, Y. OKOMURA, T. MATSUI, S. ITOGA, K. HARADA, T. SUGIMOTO, K. MICHIBA, K, IUCHI, S. e KAWANO, S. "Development Of An Automatic Weld Defect Identification System For Radiographic Testing", In: *Welding in the Word*, v. 30, n. 7/8, pp. 182-188, 1992.

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

[28] MURAKAMI, K. “Image Processing For Non-Destructive Testing”, In: *Welding International*, v. 4, n. 2, pp. 144-149, 1998.

[29] ALEKSEYCHUCK, O. e ZSCHERPEL, U. “Probabilistic Crack Detection in Digitized Radiographs of Welding Inspection”, In: *DGZfP Proceedings BB84-CD*, 2003.

[30] SHAFEEK, H.I. GADELMAWALA, E.S. ABBEL-SHAFY, A.A. e ELEWA, I.W. “Automatic Inspection of Gas Pipeline Welding Defects Using an Expert Vision System”, *NDT&E International*, v. 37, n. 4, pp. 301-307, June, 2004.

[31] SHAFEEK, H.I. GADELMAWALA, E.S. ABBEL-SHAFY, A.A. e ELEWA, I.W. “Automatic Inspection of Gas Pipeline Welding Defects Using Computer Vision System”, *NDT&E International*, v. 37, n. 4, pp. 291-299, June, 2004.

[32] LASHKIA, V. “Defect Detection In X-ray Images Using Fuzzy Reasoning”, *Image and Vision Computing*, n. 19, pp. 261-269, 2001.

[33] ZHANG, Z. e BASART, J. P. “Feature Extraction And Classification In Automated Inspection Of NDE Images”, *Review of Progress in Quantitative Nondestructive Evaluation*, v. 14, pp. 741-746, 1995.

[34] “Signal Processing Toolbox for Use with MATLAB”, User's Guide, Version 4, The Mathworks Inc., 1999.

[35] PÁDUA, G.X. et al., “Extração do Cordão de Solda e Detecção de Defeitos em Radiografias Usando Redes Neurais”, In: *3rd Panamerican Conference for Nondestructive Testing (PANNDT*), pp. 1-8, Rio de Janeiro, 2-5 June, 2003.

[36] BISHOP, C.M. “Neural Networks for Pattern Recognition”, New York, Oxford University Press, 1995.

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

[38] DUDA, R.O. HART, P.E. e STORK, D.G. “Pattern Classification”, ed. 2, U.S.A., John Wiley & Sons, 2001.

[39] PADUA, G.X. et al., “Classification of Welding Defects in Radiographs Using Traversal Profiles to the Weld Seam”, In: *16th World Conference on Nondestructive Testing (WCNDT)*, Montreal, 30 Aug-3 Sep, 2004.

[40] SIQUEIRA, M.H.S. et al., “Estimated Accuracy of Classification of Defects Detected in Welded Joints by Radiographic Tests”, In: *16th World Conference on Nondestructive Testing (WCNDT)*, Montreal, 30 Aug-3 Sep, 2004.

[41] SILVA, R.R., CALÔBA, L.P., SIQUEIRA, M.H.S. et al., "Patterns Nonlinear Classifiers of Weld Defects in Industrial Radiographies", In: *3rd Panamerican Conference for Nondestructive Testing (PANNDT)*, pp. 1-11, Rio de Janeiro, 2-5 June, 2003.

[42] CALÔBA, L.P. "CPE 722 – Redes Neurais e Agrupamentos", Notas de Aula, COPPE/UFRJ, 2003.

[43] PINTO, H.L.C.P., PINTO, R.G.C.P., CALÔBA, L.P. "A Speaker Verification Method Using LPC Singularity Location", In: *Proc. IEEE Intern. Telecommunic. Symp.*, pp 39-43, Acapulco, 1996.

[44] CHAVES, R.O. "Classificador Automático de Alvos de Sonar Passivo Utilizando Redes Neurais", Projeto de Fim de Curso de Graduação em Engenharia, Departamento de Engenharia Eletrônica, UFRJ, Outubro, 1995.

[45] RAJ, B. et al "A Novel Tool for Automated Evaluation of Radiographic Weld Images", In: *16th World Conference on Nondestructive Testing (WCNDT)*, Montreal, 30 Aug-3 Sep, 2004.

APÊNDICE A

EXEMPLOS DE RADIOGRAFIAS COM E SEM DEFEITOS DE SOLDAGEM

A.1 – SOLDA SEM DEFEITO

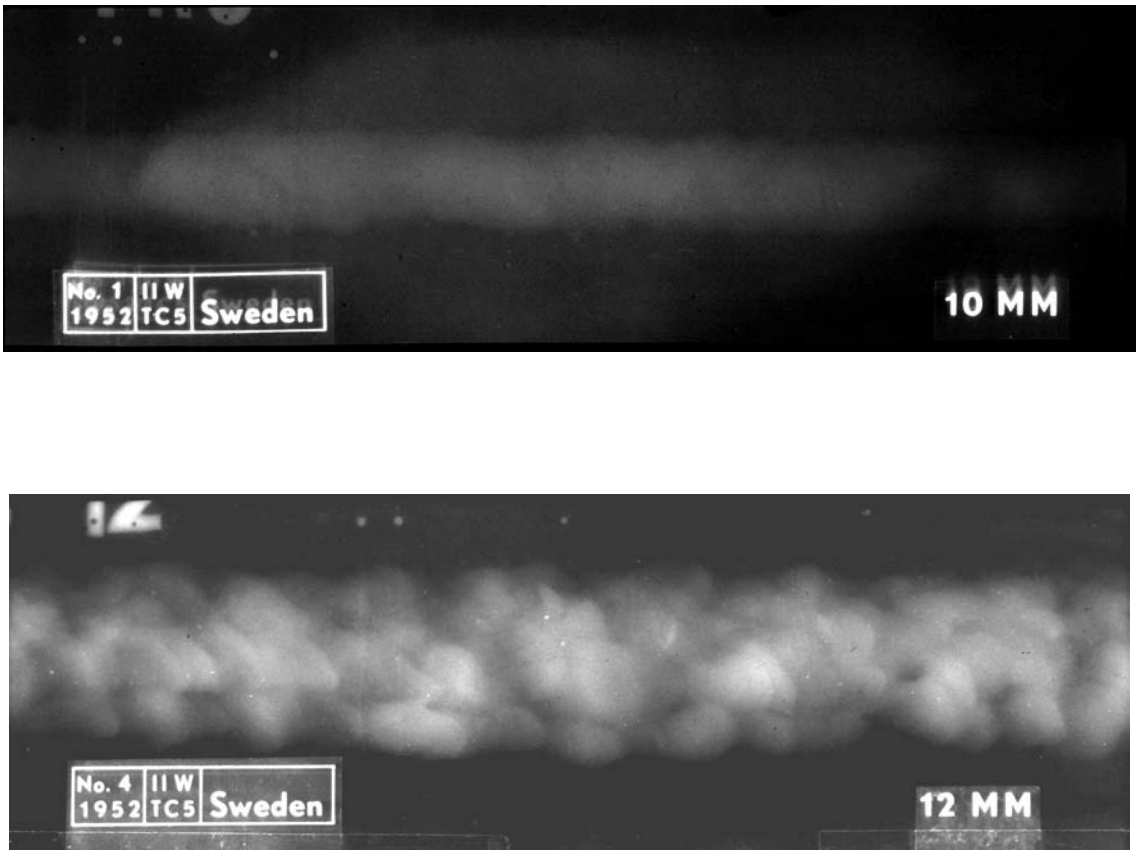

Figura A.1: Padrões radiográficos do IIW de soldas sem defeito.

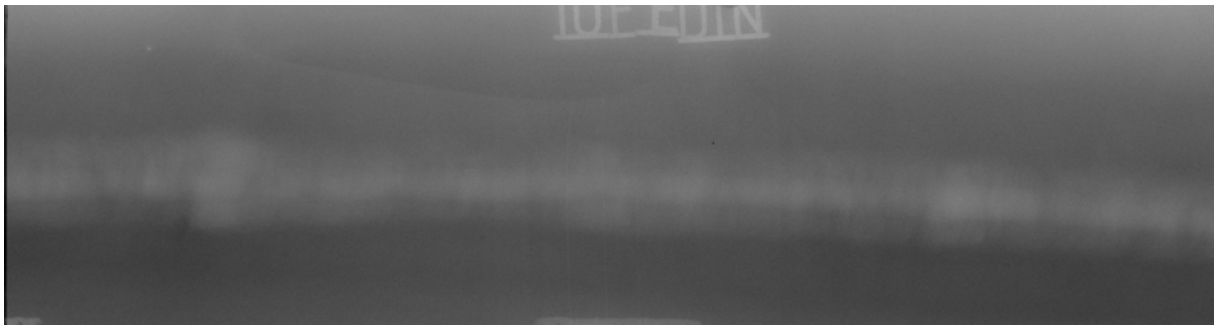

Figura A.2: Padrão radiográfico do BAM de uma solda sem defeito.

A.2 – DEFEITO FALTA DE PENETRAÇÃO

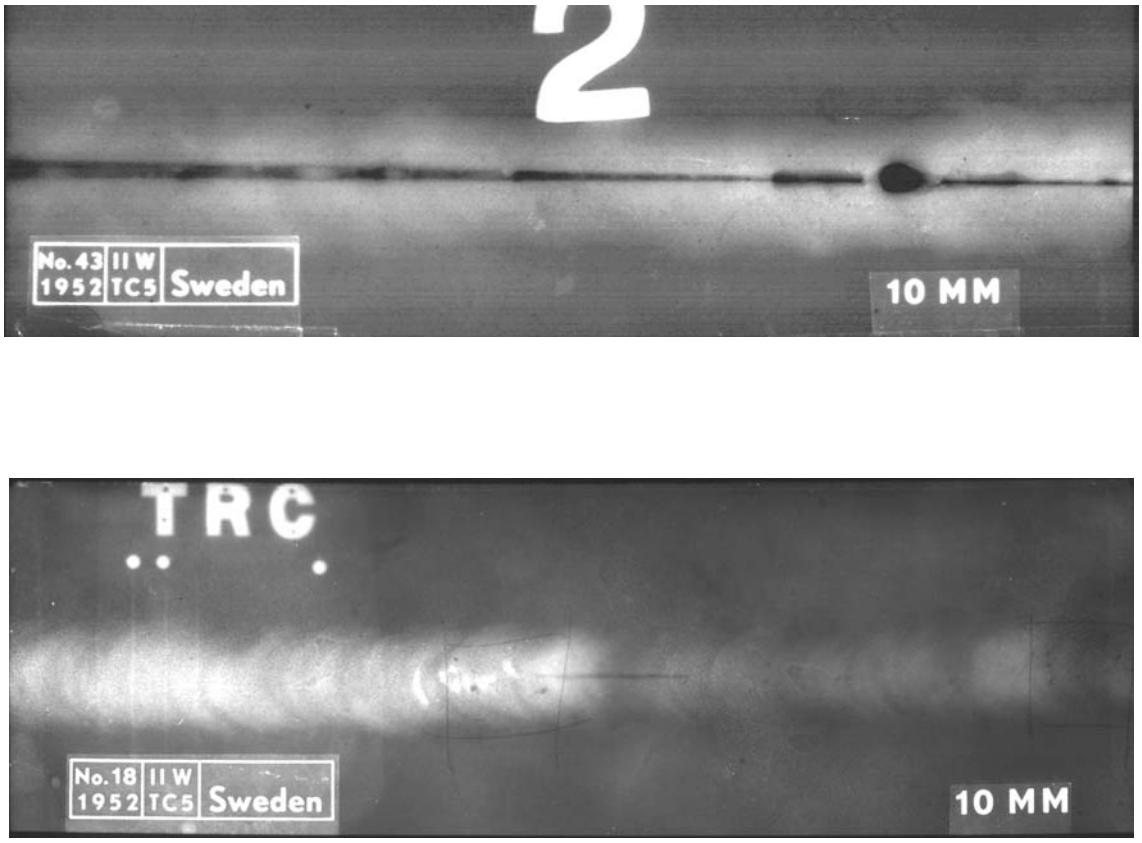

Figura A.3: Padrões radiográficos do IIW com defeitos do tipo falta de penetração.

Figura A.4: Padrão radiográfico do BAM de um defeito tipo falta de penetração.

A.3 – DEFEITO FALTA DE FUSÃO

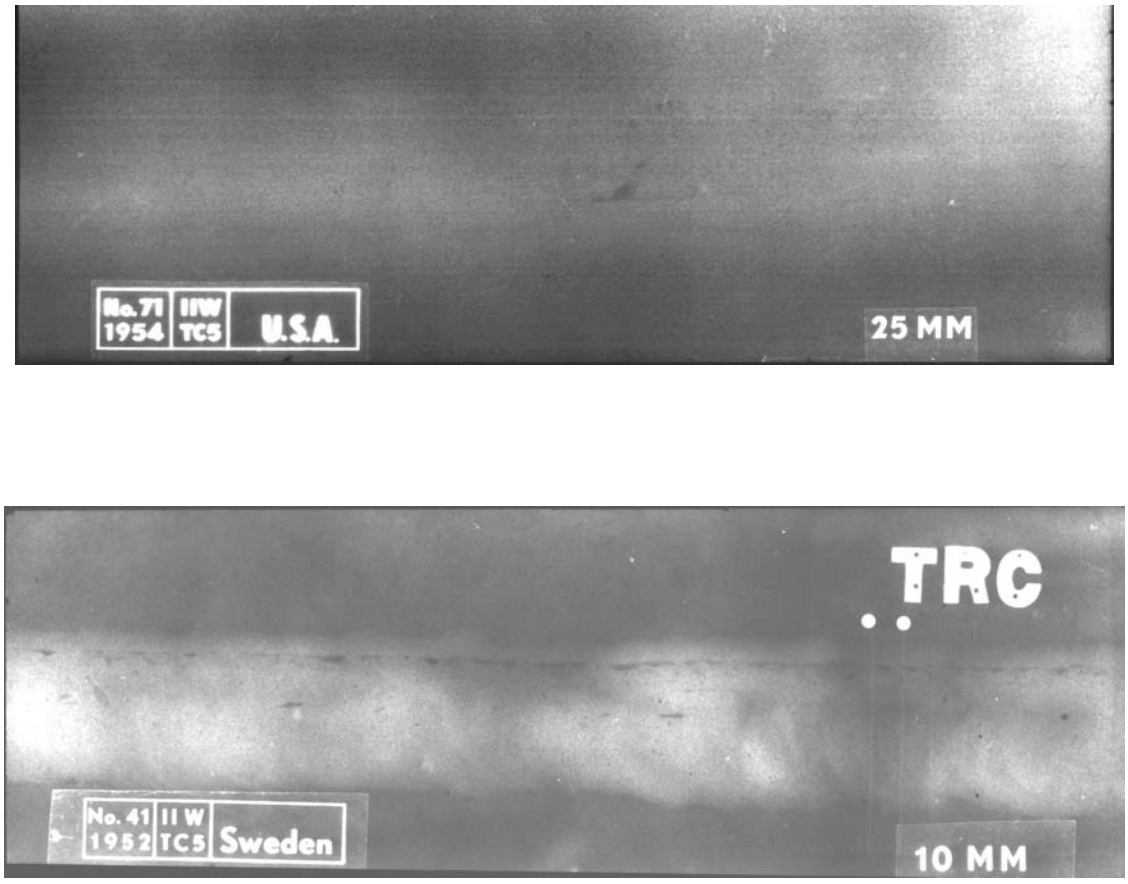

Figura A.5: Padrões radiográficos IIW de defeitos do tipo falta de fusão.

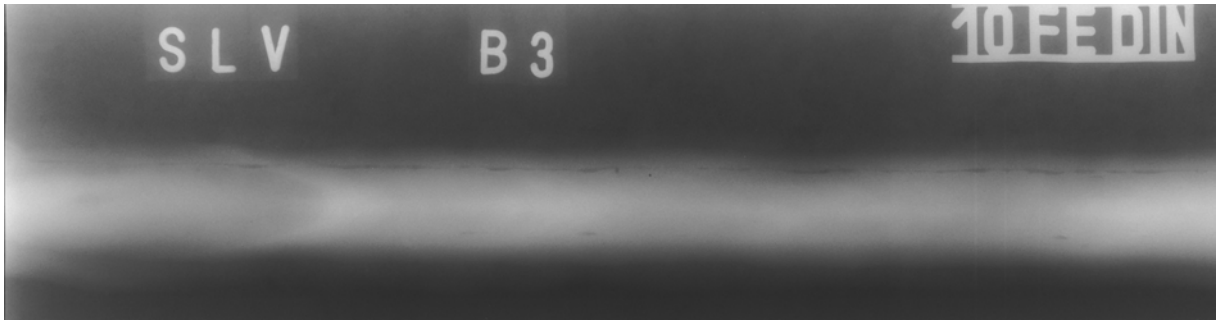

Figura A.6: Padrão radiográfico do BAM de um defeito tipo falta de fusão.

A.4 – POROSIDADE

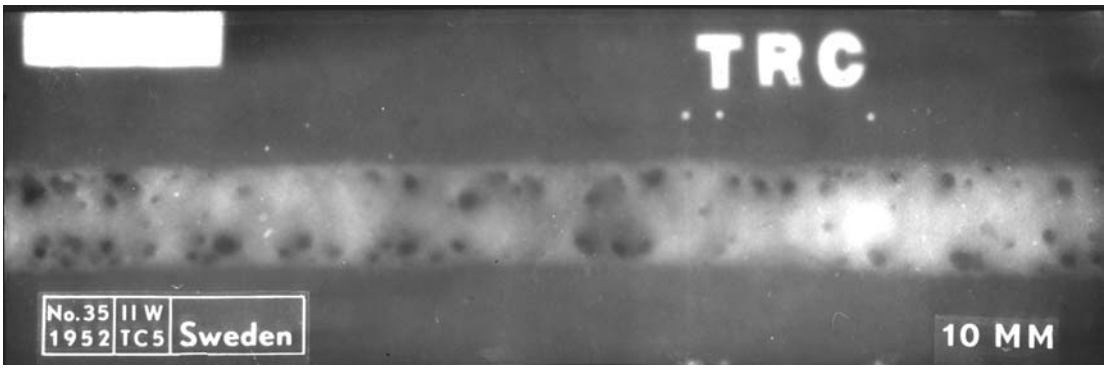

Figura A.7: Padrão radiográfico do IIW de defeitos do tipo porosidade.

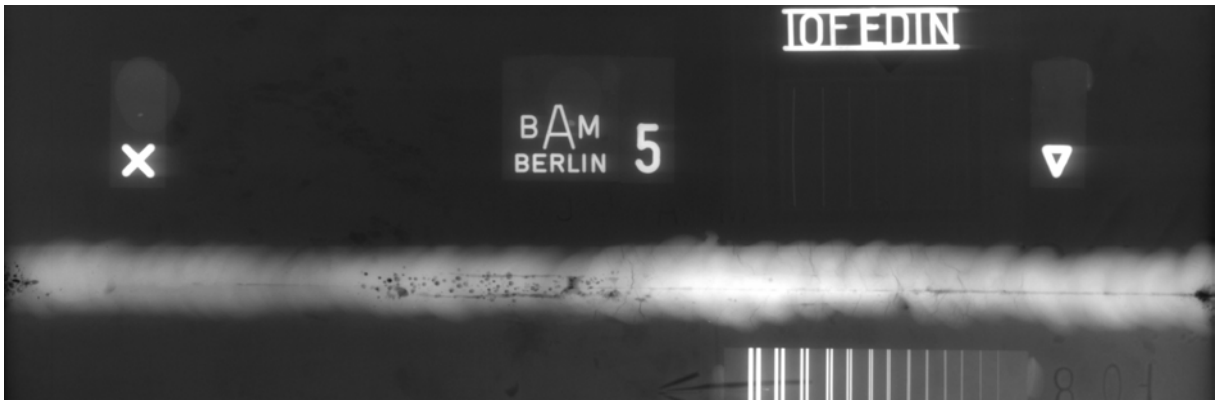

Figura A.8: Padrões radiográficos do BAM de defeitos do tipo porosidade.

A.5 – INCLUSÃO DE ESCÓRIA

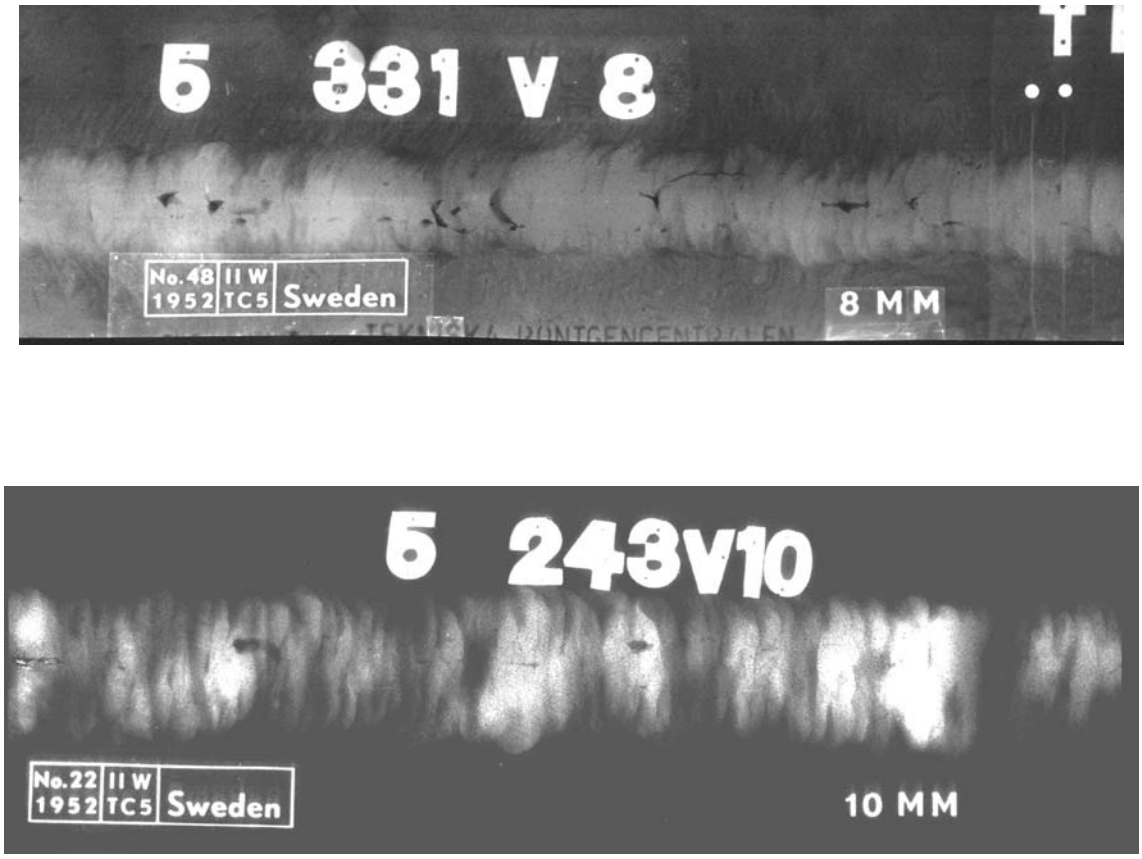

Figura A.9: Padrões radiográficos IIW de defeitos do tipo inclusão de escória.

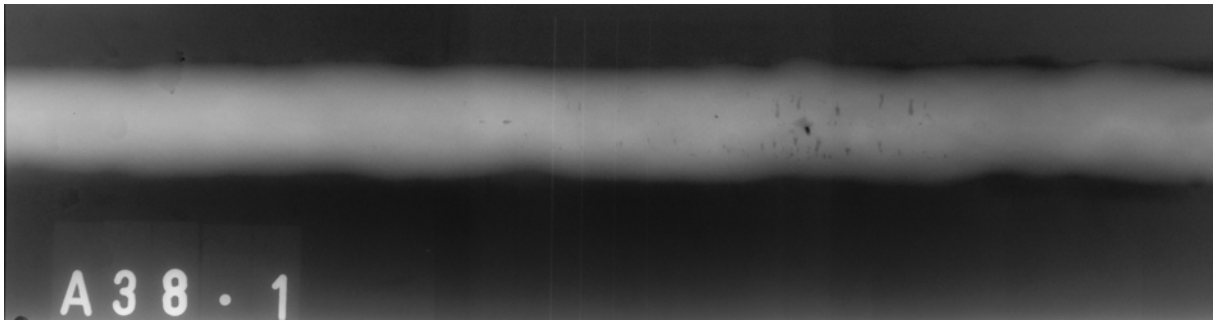

Figura A.10: Padrão radiográfico do BAM de defeitos do tipo inclusão de escória.

A.6 – TRINCA

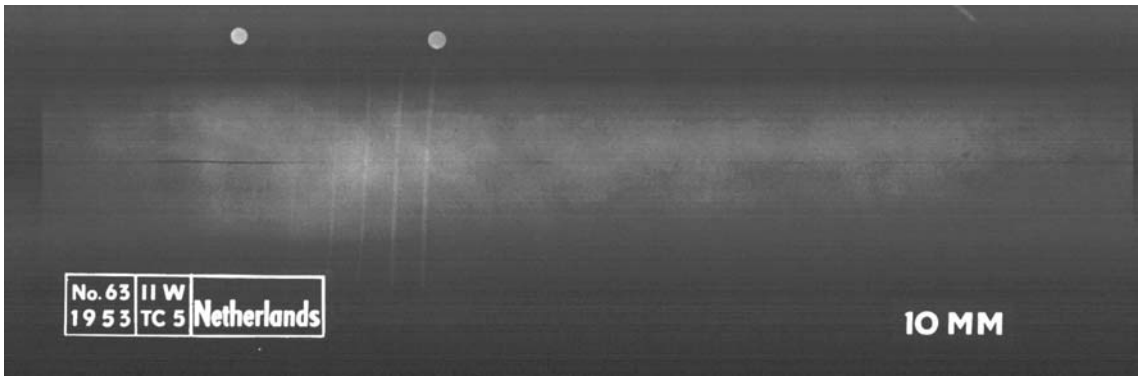

Figura A.11: Padrão radiográfico IIW de um defeito tipo trinca.

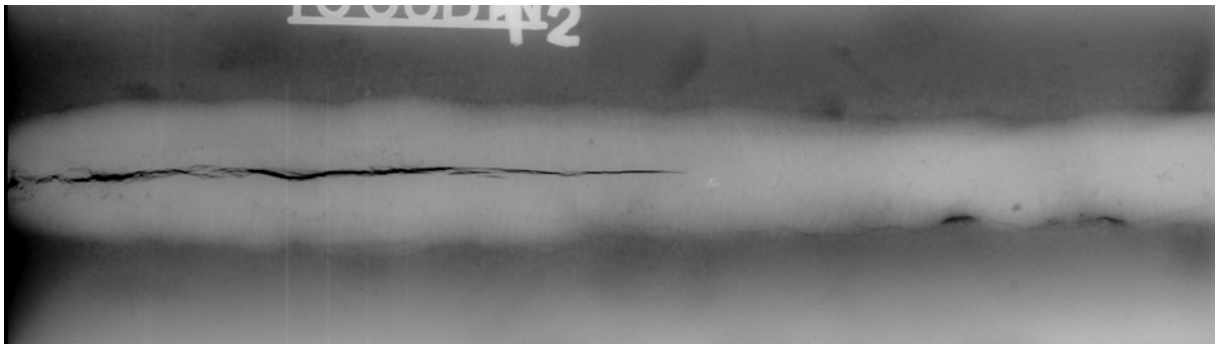

(a)

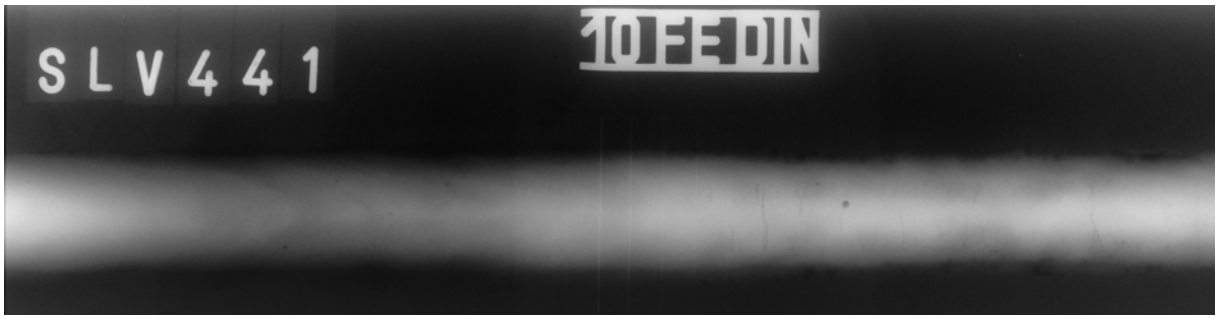

(b)

Figura A.12: Padrão radiográfico do BAM de defeitos do tipo trinca; (a) longitudinal e (b) transversal.

A.7 – MORDEDURA

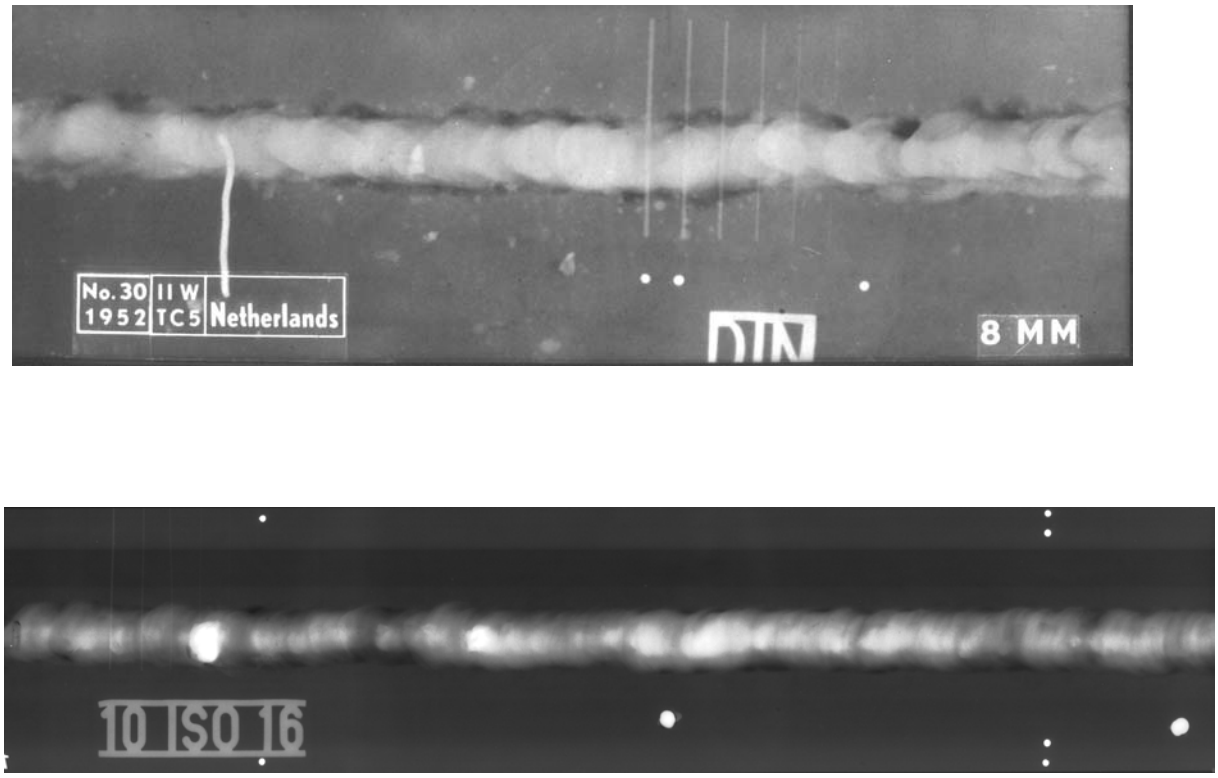

Figura A.13: Padrões radiográficos do IIW de defeitos do tipo mordedura.

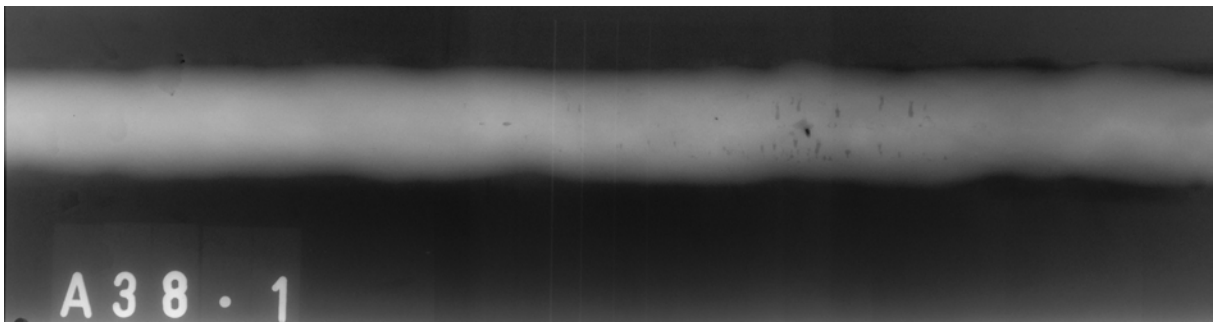

Figura A.14: Padrão radiográfico do BAM de defeitos do tipo mordedura.

APÊNDICE B

ARTIGOS PUBLICADOS E SUBMETIDOS

APÊNDICE B.1

NDT & E INTERNATIONAL

Tuesday , December 14, 2004

A NEW TECHNIQUE FOR DETECTION AND CLASSIFICATION OF WELD DEFECTS IN RADIOGRAPHIC IMAGES

Germano X. de Pádua[1], Romeu R. da Silva[2], Marcio H. S. Siqueira[3], João M.A. Rebello[3] e Luiz P. Calôba[4]

1* Correspondent Author. Petróleo Brasileiro S.A. – PETROBRAS, 65 Rep. Chile Av. 601, Rio de Janeiro RJ Brazil, germanox@petrobras.com.br
2* Correspondent Author. 299 José dos Reis St. House, 4 Engenho de Dentro, Rio de Janeiro e-mail: romric@globo.com
3 Department of Metallurgical and Materials Engineering, Federal University of Rio de Janeiro (UFRJ), P.O Box 68505 CEP 21945-970 Rio de Janeiro RJ Brazil
4 Department of Electrical Engineering, Federal University of Rio de Janeiro (UFRJ), P.O Box 68504 CEP 21945-970 Rio de Janeiro RJ Brazil

ABSTRACT

Radiographic tests of weld joints are of great importance among nondestructive tests for checking weld quality. The present work presents a new technique for the development of an automatic or semiautomatic system for weld radiographic analysis. This technique used gray level profiles transversal to weld beads in radiographic patterns. These profiles were processed to aid the setting up of nonlinear pattern classifiers developed by neural networks with algorithms by backpropagation of error. The accuracy of classification was estimated via the average correctness of 10, randomly chosen, test sets. The results presented a general accuracy of classification correctness of around 95% for the class patterns in the profiles used. These results were very satisfactory and were an incentive to publish this work.

KEYWORDS: Transversal Gray level Profiles, Nonlinear Classifier, Weld Defects, Radiography, Nondestructive Testing.

Review Copy

Elsevier

Tuesday , December 14, 2004

1. INTRODUCTION

Nondestructive tests are being used more and more as a tool to evaluate equipment and material quality these days. Among the various types of tests, radiographic tests have a favored position among others, due to their ability to register, in an image form, the internal structure of the item being inspected [1]. However, since technical reports are based on visual analysis of radiographs, it becomes subjective and depends on the experience of the examiner and the test adjustment parameters to have a precise technical report [2, 3], even from a radiographic image with satisfactory quality.

With the technological advances of digitalized radiographic image equipment, as well as the science of artificial intelligence, with artificial neural networks, *Fuzzy* logic, Neuro-Fuzzy systems, genetic algorithms etc., much research for the development of automatic and semiautomatic systems to analyze the radiographic images has emerged.

In terms of welded joints, radiographic tests are widely used and have motivated a great amount of research for their development not mentioning the acquisition of images and development of software for the interpretation of the images of weld bead radiographs.

This work presents the results of classification of weld defects presented in radiographic patterns from institutions of international renown such as IIW (*International Institute of Welding*) and BAM (*Federal Institute for Materials Research and Testing - Berlin*). The main objective of the work is to evaluate the performance of nonlinear pattern classifiers, set up by artificial neural networks, in detection and classification of the main classes of weld defects, such as: undercut, lack of penetration, lack of fusion, porosity, slag inclusion and crack. A new methodology was used, which will be described in detail in the present work. This methodology is based on the extraction of transversal gray level profiles of the weld beads to be used as input data in the classifiers, a resource that various other

Review Copy

Elsevier

Tuesday , December 14, 2004

authors have been using [4-6], however with different classification techniques. These profiles were preprocessed using a distinct procedure from other works in order to optimize the classification of the defects. The accuracy of the classification was estimated through the employment of randomly chosen training and test sets and the generalization of the classifiers assured by using validation sets. The results are presented in performance tables of the classifiers and compared with the results of other works. It should be appointed out that this work is a continuation of works already published [7, 8]

2. MATERIALS AND METHODOLOGIES

2.1 Radiographic Films and Scanners

To give the greatest possible reliability to the results of the classification, radiographic patterns from the highly respected institutes of IIW (*International Institute of Welding*) and BAM (*Federal Institute of Materials Research and Testing – Berlin*) were used. The largest possible number of radiographs was used to obtain the best possible statistical significance of the results. An older collection of radiographic patterns from IIW was digitalized with a UMAX Mirage II scanner, and in this case, used a spacial resolution of 500 pixels per inch (dpi) and 256 levels of gray. The second collection of radiographs from IIW was recently digitalized using a Microtek ScannerMaker 9800 XL scanner with the maximum available resolution of 2000 dpi. The collection of radiographs from BAM was digitalized using a LS 85 SDR Lumisys/Kodak scanner with 600 dpi and 12 bits of gray level, which later were converted to eight (8) bits (256 levels). Although these patterns contained various other types of weld defects, only the more common classes of defects found in welding such as: Undercut (UC), Lack of Penetration (LP), Lack of Fusion (LF),

Review Copy

Tuesday , December 14, 2004

Porosity (PO), Slag Inclusion (SI) and longitudinal crack (CR) were studied. Besides these above-mentioned defect classes, the class No Defect (ND) was also studied.

2.2 Data Preprocessing

The digitalized radiographs were pre-processed with a filter measuring 3X3 to reduce noise [9] and contrast enhancement mainly of the weld bead and for subsequent procedures.

The majority of works in this area of research normally involve processing of complex images for segmentation of the weld joint image, extraction of the characteristics of the "objects" detected in the segment and for defect classification [9-14] but have not yet found a final solution applicable to the various types of radiographs. However, in this work, the procedure to use transversal gray level profiles of the beads was employed as descriptors [15], not only to indicate the presence of discontinuities in the joint, but the type of discontinuity class as well. This line of research has been investigated by some renowned authors such as Liao [4-6]. However, the technique used in this work is innovative and promisingly more practical from the point of view of a project for semiautomatic or automatic systems for the detection and classification of weld defects in radiographs.

Figure 1 illustrates '*didactically*' the shape of the transversal gray level profile of a weld bead in a radiograph. The vertical axis corresponds to a scale of gray that is normally 256 levels, while the horizontal axis corresponds to the vertical dimension of the weld. Since the aim of the work is only to find and classify defects present in the weld, the horizontal parameter of the graph that represents the region of Base Metal can be discarded to reduce computational calculations and optimize the development of the classifiers.

Review Copy

Elsevier

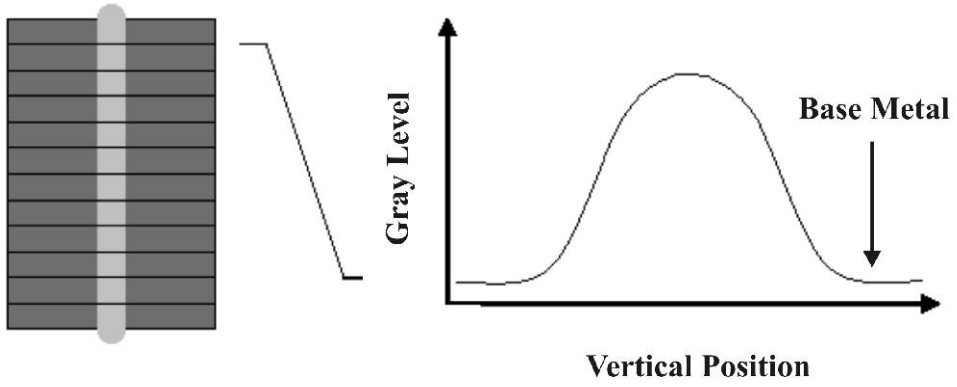

Figure 1: *Example of a traversal profile to the weld in a radiograph, this example, without the presence of discontinuities.*

Firstly, the part of the image referring to the weld bead was visually extracted from the whole image so that the profiles traced had the least amount of irrelevant information possible for the development of the classifier. It is enough to point out that the follow-up of this work of research will involve the development of an image processing technique for the automatic extraction of the bead, which will later be connected to algorithms of the classifiers developed in this work.

Figure 2, below, illustrates the extraction of the bead image from the rest of the radiograph

Review Copy

Tuesday , December 14, 2004

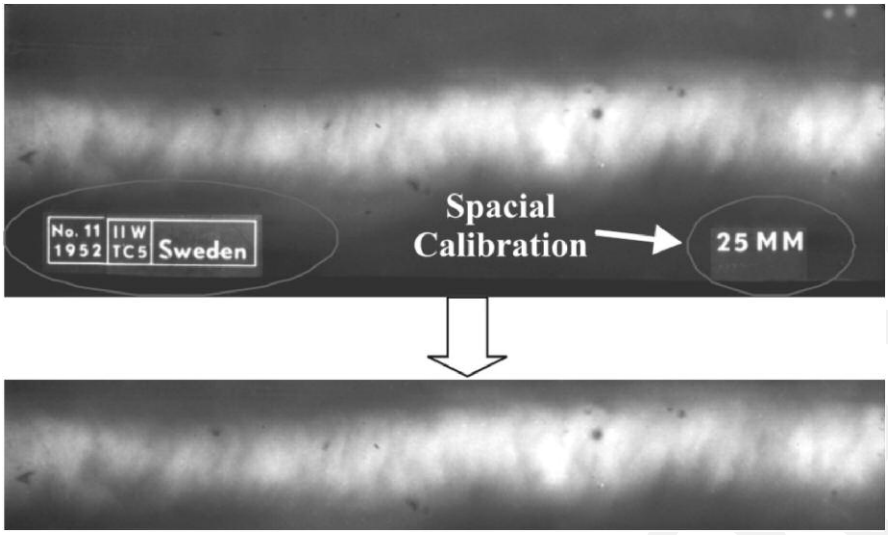

Figure 2*: An example of a radiographic pattern used, identification label and calibration measurement and the respective bead image extracted from the original pattern.*

Before the extraction of the weld bead, the images were calibrated spacially as shown in figure 2 so that the transversal profiles had a precise vertical measurement of the bead.

The profiles were extracted from each weld image using the program MATLAB [16]. The quantities of profiles available for each defect class were distributed as such: LF (64), UC (95), LP (151), SI (154), CR (265), PO (412) and ND (467). After acquisition of the profiles, which can also be called signals, three types of processing were carried out:

1) Firstly the profiles were standardized in relation to their respective amplitudes; a procedure carried out by dividing each point of the profile by its maximum value of gray level so that all the profiles had amplitudes situated on the scale from zero to one.
2) The profiles were treated for noise reduction by use using the low pass filter Savitzky-Golay that has the advantage of not altering the amplitudes of the signals

Elsevier

Tuesday , December 14, 2004

as much as the average mobile filter [17]. Empirically, the best performance of this filter was obtained for an operational window with eight points and polynomial function of the second order. Taking into account that the original radiographic images had different resolutions, due to their distinct origins and the equipment available at the time of digitalization of the films, the profiles contained a quantity of distinct points making the correct implementation of the classifiers impossible. In this case the profiles were interpolated using the Fast Fourier Transformation (FFT) technique [17] so that they would contain the same quantity of profile points with the smallest size (276).

3) The defects are situated randomly in the vertical dimension of the bead, except LP which is normally found in the center of the profile. This variation of position certainly increases the interclass variation making the training of the classifiers more difficult and therefore affecting their performance. Consequently it was deemed that all the defects should be "adjusted" to a position to the right of the average (center) of an estimated Gauss curve [4-6] based on each profile. The profiles that originally contained defects situated to the right of the peak or in the center of the Gaussian curve did not need to have their position inverted.

Figure 3a shows an example of an original profile with standardization of amplitude and quantity of points, but without noise reduction. Figure 3b shows the same profile as (a) after application of low pass filter, and figure 3c shows the profile (b) after inversion of the position of the defect in relation to the center of the adjusted Gaussian curve.

Review Copy

Elsevier

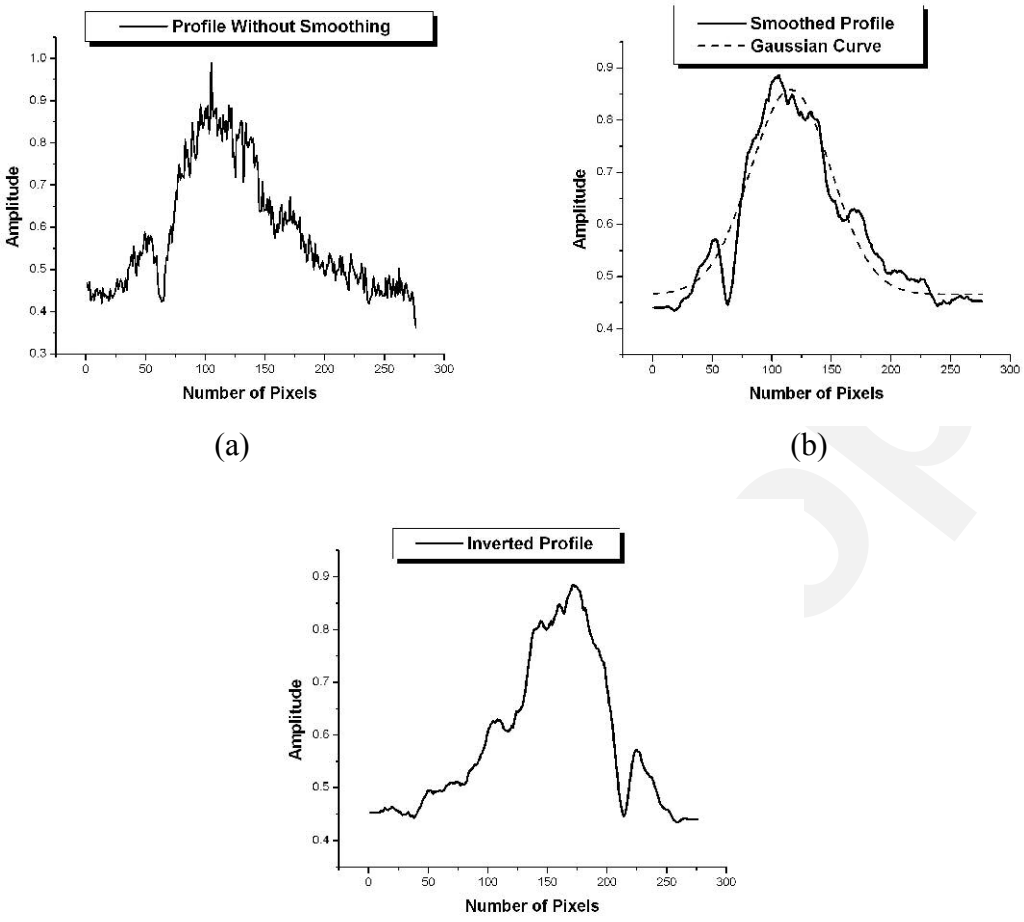

Figure 3: *(a) original profile with standardization of amplitude and quantity of points; (b) profile after application of Savitzky-Golay filter and the Gaussian curve; (c) profile after inversion of position of the defect in relation to the center of the Gaussian curve.*

2.3 Nonlinear Pattern Classifiers

Architecture and Classifier Training

The nonlinear classifiers were implemented with neural networks of two trained layers with algorithms of back propagation of error [18]. The output layers of the networks contained seven neurons of the hyperbolic tangent type due to the seven classes of patterns present in the data. A question that occurs in the development of a nonlinear classifier is to

Tuesday , December 14, 2004

know the ideal number of neurons that should be used to permit the best performance of the classifier. And so in this work, the number of neurons (also with activation function hyperbolic tangent type) used in the intermediate layers were varied and the performance obtained for a pair of randomly chosen sets for training and test were observed. The trainings were carried out up to 3000 epochs or error of training equal to 0.001, using a learning ratio α variable and moment β=0.9 [18], adjustments that allowed for faster convergence of training after empirical tests.

Accuracy of the Classifiers

On recognizing the patterns, one of the greatest concerns is the estimated accuracy of the classifiers that can be calculated using weighted averages of correctness between the training and test data [19-22].

With a pronounced difference in the quantity of data between pattern classes studied, which in terms of algorithm of training for backpropagation of error, could produce favoritism of classification correctness of the classes containing larger quantities of data. A large amount of data tends to influence quite significantly the calculation of training error. In this case, an acceptable solution, that in the majority of cases produces good results, is data replication of the class with the least number of data until it reaches the number of data of the most favored class. So, in order to estimate the classification accuracy of the nonlinear classifier used in this work, 10 random selections of pairs for sets of training and tests were carried out in the following manner: from class ND (No Defect), which had the largest quantity of data (467), 15% was extracted from this total to make up the test sets, that is to say, 69 data were chosen for test and the others were left over to make up the training set (398 data). The same was done with the other classes, however, their data had

Review Copy

Elsevier

Tuesday , December 14, 2004

to be replicated until it reached the number of data for test and training as class ND, that is to say, all classes then had 69 data for test and 398 data for training. This procedure guaranteed that the chosen data for tests were not used for training and all classes had the same quantity of data for training and test.

The results of the performance of the classifiers, as well as the estimated accuracy, which in this work was considered as the arithmetic mean of the performances obtained with the test sets, are presented in tables. Also the confusion tables of classification between classes for the set with performance nearest to the estimated accuracy are presented.

3. RESULTS AND DISCUSSIONS

Optimization of the Number of Neurons in the Intermediate Layer

After carrying out the random selections as in the procedure described, a study was carried out to optimize the number of neurons to be used in the intermediate layer of the non linear classifier with these new sets, using only a pair of training/test sets among the 10 selected. In order to control super-training and guarantee generalization of the classifier, 15% of the training data was extracted (85% of the original data) to make a validation set. Table 1 that follows shows the results obtained, where it is evident that only 20 neurons in the intermediate layer obtained 100% of correctness with the training data and 97.7 2% for the test data under the most conservative conditions, *Without Reclassification* (WR), and 99.38% of correctness with *Reclassification* (R), the best indices of correctness with the test set. The criterion for Reclassification (R) considers the greatest output neuron (in this case, seven outputs due two to seven pattern classes) of the classifier as the indicator of the tested pattern class input. The criterion Without Reclassification (WR) is the most conservative

Review Copy

Elsevier

Tuesday , December 14, 2004

because it uses as the output class indicator the only positive output. These criteria of classification are explained in detail in [9].

Figure 4 shows the training and test curves resulting from the training with 20 neurons in the intermediary layer, showing that the training was interrupted with less than 1000 epochs due to the validation control.

Table 1: *Optimization of the number of neurons in the intermediate layer of the nonlinear classifier.*

Number of Neurons in the Intermediate Layer	**Training Data (%)**		**Test Data (%)**	
	R	**WR**	**R**	**WR**
10	100	99.93	97.72	96.89
20*	100	100	99.38	97.72
30	100	100	98.96	97.10
40	100	100	98.14	95.45

*Best result with the test data.

Review Copy

Elsevier

Tuesday , December 14, 2004

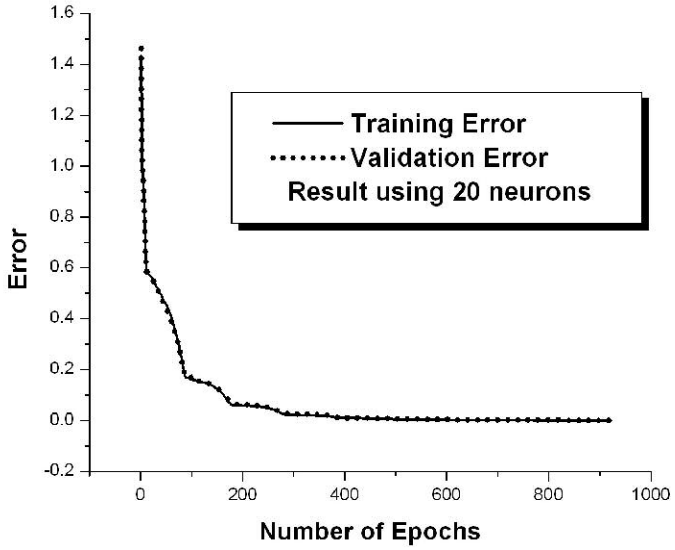

Figure 4: *Curves of training and validation error using 20 neurons in the intermediate layer.*

Estimated Accuracy of Classification

Table 2 contains all the results of the performance obtained with the test sets chosen for criteria *Without Reclassification* (WC) and *Reclassification* (R), as well as the number of epochs of interruption of training by the validation control. The criteria of validation was fixed in 100 epochs, that is, if the error of validation was maintained unaltered or grew over 100 epochs, training was interrupted and the values of the synapses and bias [18] were adjusted to the values that resulted in the smallest error of validation.

The resultant average correctness, for our estimate of accuracy of classification, was 95.0 % for the test data with *Without Reclassification* (WR), a very satisfactory index. With *Reclassification* (R), it reached 98.4 % of correctness, an index very close to that obtained on average with the training sets (about 100%). Another import result worth

Elsevier

Tuesday , December 14, 2004

mentioning is the small standard deviation 2.1 % for the classification *Without Reclassification* for the test data. This proves the reliability of the classification accuracy estimation and classification of the main classes of welding defects present in traversal gray level profiles that were submitted to the preprocessing mentioned. The generalization of the classifier was proven in the small differences of performance between the training and test sets. Figure 5 shows the training and validation curves of the 6th set of table 2, the set that was closest to the average, that is to say, the one that could be considered the most representative in terms of correctness of classification expected.

Table 2: *Calculation of the classification accuracy for the nonlinear classifier.*

Data Sets	Training Data (%)		Test Data (%)		Number of Epochs
	R	WR	R	WR	
1	100	100	100	99.0	920
2	100	100	98.6	93.4	1044
3	100	100	98.0	94.6	948
4	100	100	97.6	92.0	923
5	100	100	98.0	94.6	940
6*	100	100	97.3	95.3	940
7	100	100	99.0	96.7	939
8	100	100	97.8	92.1	1044
9	100	100	99.4	97.1	949
10	100	100	98.2	95.5	1135
Mean	100	100	98.4	95.0	
Standard Deviation	0	0	0.9	2.1	

*Set that was closest to the average

Elsevier

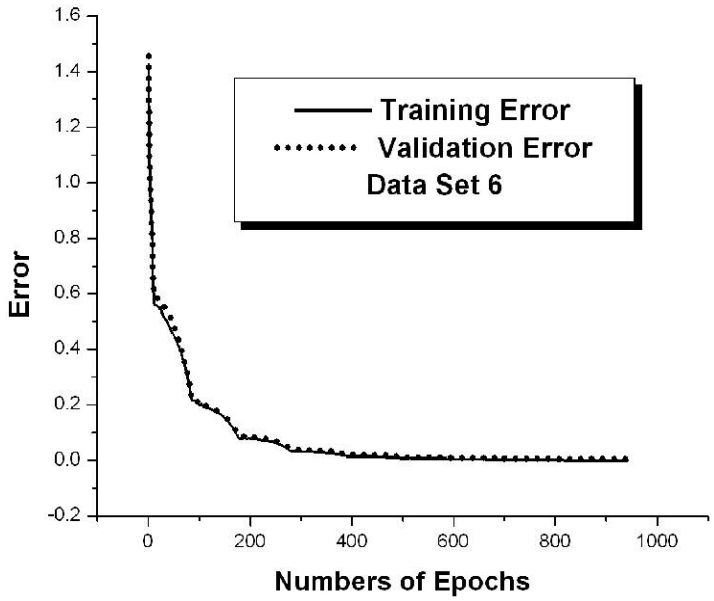

Figure 5: *Curves of training and validation error, using 20 neurons in the intermediate layer of set 6 that was the closest to the average.*

In table 2 there is only the general average correctness of all classes, as well as the indices of each set, without an idea of the correctness and errors of each class. Thus, a confusion table 3 was set up, as seen below, referring to the 6th set of table 2 that represents the indices of correctness and error (confusion) of each class with respect to the other classes. To exemplify the understanding of this type of table, we have class Lack of Fusion (LF) in the first line and in the first column of table 3 that reached the result of 53 correctly classified data among the 69 used in the test set. 16 profiles were classified with *No* class, that is to say, in this case all the outputs of the neurons were negative, remembering that in the condition of table 3 one class only is indicated when it has only one positive output among the 7 neurons of the 7 classes studied. For the class LP, 66 data were correctly classified and 3 data confused with the class PO and so on for the other classes. Note that in

Tuesday , December 14, 2004

the same table 3, for the classes such as UC and SI, all the profiles of test were classified correctly. Table 4 gives the same information but with indices of correctness and confusion in percentages. It is worth noting once again that these confusion tables 3 and 4 are for the most conservative situation of classification with test data. Evidently for the case of Reclassification, indices of error are even less, as can be seen in table 5 in terms of quantity of data, and table 6 in percentage terms.

Table 3: *Confusion table for test set 6, which was the closest to the average of correctness of table 2. Results Without Reclassification (WR).Results of confusion in quantity of profiles.*

	LF	**LP**	**UC**	**CR**	**SI**	**PO**	**ND**	**None**	**More than One**
LF	53	0	0	0	0	0	0	16	0
LP	0	66	0	0	0	3	0	0	0
UC	0	0	69	0	0	0	0	0	0
CR	0	0	2	67	0	0	0	0	0
SI	0	0	0	0	69	0	0	0	0
PO	0	0	0	0	0	68	0	1	0
ND	0	0	0	0	0	0	68	1	0

Review Copy

Elsevier

Tuesday , December 14, 2004

Table 4: *Confusion table for test set 6, which was the closest to the average of correctness of table 2 Result Without Reclassification (WR).Results of confusion in percentage of correctness/error.*

	LF	LP	UC	CR	SI	PO	ND	None	More than One
LF	76.81%	0	0	0	0	0	0	23.19%	0
LP	0	95.65%	0	0	0	4.35%	0	0	0
UC	0	0	100%	0	0	0	0	0	0
CR	0	0	2.9%	97.1%	0	0	0	0	0
SI	0	0	0	0	100%	0	0	0	0
PO	0	0	0	0	0	98.55%	0	1.45%	0
ND	0	0	0	0	0	0	98.55%	1.45%	0

Table 5: *Confusion table for test set 6, which was the closest to the average of correctness of table 2. Result with Reclassification (R). Results of confusion in quantity of profiles.*

	LF	LP	UC	CR	SI	PO	ND
LF	61	0	0	8	0	0	0
LP	0	66	0	0	0	3	0
UC	0	0	69	0	0	0	0
CR	0	0	2	67	0	0	0
SI	0	0	0	0	69	0	0
PO	0	0	0	0	0	69	0
ND	0	0	0	0	0	0	69

Elsevier

Tuesday , December 14, 2004

Table 6: *Confusion table for test set 6, which was the closest to the average of correctness of table 2. Result with Reclassification (R).Results of confusion in percentage of correctness/error.*

	LF	**LP**	**UC**	**CR**	**SI**	**PO**	**ND**
LF	88.41%	0	0	11.59%	0	0	0
LP	0	95.65%	0	0	0	4.35%	0
UC	0	0	100%	0	0	0	0
CR	0	0	2.9%	97.1%	0	0	0
SI	0	0	0	0	100%	0	0
PO	0	0	0	0	0	100%	0
ND	0	0	0	0	0	0	100%

The indexes of table 6 show that the classes ND, PO and SI present indices of 100% of correctness for the set 6, and only for the classes LP and CR have small indices of confusion with the classes PO and UC respectively. The largest index of confusion was class LF with the class CR (11.59%), which is not critical, since both defects imply a rejection and repair of the welding according to norms and international codes.

In general terms of classification, the results are extremely satisfactory since the estimated accuracy even for the most conservative situation was 95.0 %, a value above the results obtained in other works [4-14]. It is evident that these results were possible due to see processes carried out on the profiles before being used in the development of the classifiers, something that had not been done in the previous works [7, 8]. It should be pointed out also that the results obtained in this work have greater reliability from the

Review Copy

Tuesday , December 14, 2004

statistical point of view due to the amount of data used, as well as the number of sets used to estimate the classification accuracy. The use of gray level profiles is more promising for the development of automatic systems of inspection for radiographic weld joints, since it does not require the use of complicated techniques of segmentation of the images and extraction of the defect characteristics to create the input data for the classifiers. These complicated techniques make it more difficult to develop a system that can be applied efficiently on various types of radiographic joint images existing in the industrial field. The proposal of this work can already be considered an algorithm of detection of operational defects, since the class ND was not confused with any other type of defect.

The work presented here will be continued with research directed towards the development of the first part of the system, extraction of weld bead from the radiographs and automatic acquisition of transversal profiles, this latter part will afterwards be connected to the algorithms developed for this work presented here.

4. CONCLUSIONS

Going by the classification results presented here, it is proven that the transversal profiles after noise reduction with a filter Savitzky-Golay and the standardization processes of amplitude and quantity of points, as well as the adjustment of the position of the defects reducing interclass variance, can be used as input data in the nonlinear classifiers for identification and classification of the main classes of defects, giving good classification results.

The optimization of the number of neurons used in the intermediate layer, as well as the utilization of validation sets to control the best moment to interrupt training permitted the generalization of the classifier for the test sets.

Review Copy

Elsevier

Tuesday , December 14, 2004

The methodology applied is capable of distinguishing signals with and without defects without creating classification errors.

The techniques presented in this work are totally innovative when compared to other important works in this area of research [4-6], and an incentive to continue the work for the development of a complete automatic or semiautomatic system interpretation of digitalized radiographs of soldered equipment.

5. ACKNOWLEDGEMENT

Authors wish to acknowledge CNPq (The National Council for Scientific and Technological Development, CAPES (Higher Level Training Agency), FAPERJ (Research Foundation from Rio de Janeiro) and ANP (Brazilian Agency for Petroleum) for financial support and scholarships and also to the International Institute of Welding and BAM (*Bundesanstalt für Materialforschung und-prüfung* -Berlin) for permission to publish the radiographic patterns used in the present work.

6. REFERENCES

1. Halmshaw, R. Industrial Radiography. Agfa-Gevaert N.V., Mortsel, Belgium.

2. Fucsok, F. Scharmak, M. Human factors: The NDE Reliability of Routine Radiographic Film Evaluation. In: 15th World Conference on Non-destructive Testing. Rome, October 15–21 2000.

3. Fucsok, F. Muller, C. Scharmak, M. Reliability of Routine Radiographic Film Evaluation - An Extended ROC Study of the Human Factor. In: Eighth European Conference on Non destructive testing. Barcelona, June 17–21 2002.

Review Copy

Tuesday , December 14, 2004

4. Liao, T.W. Ni, J. An Automated Radiographic NDT System for Weld Inspection: Part I - Weld Extraction. NDT&E International 1996; 29(3):157-162.

5. Liao, T W. Li, Y. An Automated Radiographic NDT System for Weld Inspection: Part II - Flaw Detection. NDT&E International 1998. 31(3):183-192.

6. Liao, T.W. Li, D. Li, Y. Detection of Welding Flaws from Radiographic Images with Fuzzy Clustering Methods. Fuzzy sets and Systems 1999; 108:145-158.

7. De Padua, G. X. Da Silva, R.R.. Rebello, J.M.A. Calôba, L.P. Extração do Cordão-de-Solda e Detecção de Defeitos em Radiografias Usando Redes Neurais. 3rd Pan-American Conference for Nondestructive Testing (PANNDT) June 2003. p. 1-8 (In Portuguese).

8. De Padua, G.X. Da Silva, R.R. Calôba, L.P.. Siqueira, M.H.S. Rebello, J.M.A. Classification of Welding Defects in Radiographs Using Transversal Profiles to the Weld Seam. 16th World Conference on Non-destructive Testing, Montreal, august 30, 2004.

9. Da Silva, R. R. Siqueira, M H. S. Calôba, L P. Rebello, J.M.A. Radiographics Pattern Recognition of Welding Defects using Linear Classifiers. Insight 2001; 43(10): 669-674.

10. Wang, G. Liao, T. W. Automatic Identification of Different Types of Welding Defects in Radiographic Images. NDT&E International 2002; 35: 519-528.

11. Shafeek, H.I. Gadelmawla, E. Abdel-Shafy, A.A. Elewa, I.M. Automatic Inspection of Gas Pipeline Welding Defects Using an Expert System. NDT&E International 2004; 37(4): 301-307.

12. Shafeek, H.I. Gadelmawla. E., Abdel-Shafy, A.A. Elewa, I.M. Assessment of Welding Defects for Gas Pipeline Radiographs Using Computer Vision. NDT&E International 2004; 37(4):291-299.

Review Copy

Elsevier

Tuesday , December 14, 2004

13. Da Silva, R R. Siqueira, M H. S. Calôba, L P. Rebello, J.M.A. Evaluation of the Relevant Feature Parameters of Welding Defects and Probability of Correct Classification using Linear Classifiers. Insight 2002; 44(10): 616-622.

14. Da Silva, R R. Calôba, L P. Siqueira, M H.S. Rebello, J.M.A. Pattern Recognition of Weld Defects Detected by Radiographic Test. NDT&E International 2004; 37(6): 461-470.

15. Gonzalez, R.C. Woods, R. E. Digital Image Processing. 1st edition, U.S.A, Addison-Wesley Publishing Company, 1992.

16. Image Processing ToolBox for Use With Matlab. User's Guide, Version 4.0. The Mathworks.

17. Curve Fitting ToolBox for Use With Matlab. User's Guide, Version 1.0. The Mathworks.

18. Haykin S. Neural Networks – A Comprehensive Foundation. Macmillian College Publishing. Inc. 1994.

19. Da Silva, R R. Siqueira, M H.S. De Souza, M.P.V. Rebello, J.M.A. Calôba, L P. Estimated Accuracy of Classification of Defects Detected in Welded Joints by Radiographic Tests. Articles accepted to be published in NDT&E International.

20. Diamantidis, N.A., Karlis, D., Giakoumakis, E.A. Unsupervised Stratification of Cross-Validation for Accuracy Estimation. Artificial Intelligence 2000. 116: 1-16.

21. Efron, B., Tibshirani, R. J. An Introduction to the Bootstrap. New York, Chapman & Hall/CRC, 1993.

22. Efron, B., Tibshirani. Cross-Validation and the Bootstrap: Estimating the Error Rate of the Prediction Rule. Technical Report 477, Stanford University 1995. **http://utstat.toronto.edu/tibs/research.html**.

Review Copy

Elsevier

Tuesday , December 14, 2004

TABLES LEGENDS

Table 1: *Optimization of the number of neurons in the intermediate layer of the nonlinear classifier.*

Table 2: *Calculation of the classification accuracy for the nonlinear classifier.*

Table 3: *Confusion table for test set 6, which was the closest to the average of correctness of table 2. Results Without Reclassification (WR).Results of confusion in quantity of profiles.*

Table 4: *Confusion table for test set 6, which was the closest to the average of correctness of table 2 Result Without Reclassification (WR).Results of confusion in percentage of correctness/error.*

Table 5: *Confusion table for test set 6, which was the closest to the average of correctness of table 2. Result with Reclassification (R). Results of confusion in quantity of profiles.*

Table 6: *Confusion table for test set 6, which was the closest to the average of correctness of table 2. Result with Reclassification (R).Results of confusion in percentage of correctness/error.*

FIGURES LEGENDS

Figure 1: *Example of a traversal profile to the weld in a radiograph, this example, without the presence of discontinuities.*

Figure 2*: An example of a radiographic pattern used, identification label and calibration measurement and the respective bead image extracted from the original pattern.*

Figure 3: *(a) original profile with standardization of amplitude and quantity of points; (b) profile after application of Savitzky-Golay filter and the Gaussian curve; (c) profile after inversion of position of the defect in relation to the center of the Gaussian curve.*

Review Copy

Elsevier

Tuesday , December 14, 2004

Figure 4: *Curves of training and validation error using 20 neurons in the intermediate layer.*

Figure 5: *Curves of training and validation error, using 20 neurons in the intermediate layer of set 6 that was the closest to the average.*

Review Copy

Elsevier

APÊNDICE B.2

16th WCNDT 2004 – Conferência Mundial de Ensaios Não Destrutivos

CLASSIFICATION OF WELDING DEFECTS IN RADIOGRAPHS USING TRAVERSAL PROFILES TO THE WELD SEAM

G. X. Padua[1], R. R. Silva[2], M. H. S. Siqueira[2], J. M. A. Rebello[2], L. P. Caloba[2]
[1]Petrobras, Rio de Janeiro, Brazil, [2]Department of Metallurgical and Materials Engineering, Federal University of Rio de Janeiro (UFRJ), Rio de Janeiro RJ Brazil

Abstract: In patterns recognition applied to welding defects in digitized radiographic images, there are two research fields basically: techniques that involve segmentation, extraction of features and classification of the detected defects, or methods that involve transverse profiles to the weld seams. In this work, we present the results of a study to detect welding defects in radiographs using traverse profiles to the weld seam. The profiles were traced transversely to the weld seam of several radiographic patterns from IIW (International Institute of welding). Later on, the resulting profiles were normalized and pre-processed for noise smoothing. With training and test input sets, selected using techniques of random sampling, the performances of the classifiers, which were implemented using feedforward networks with learning algorithm for error backpropagation, were evaluated. The true accuracy of these classifiers was estimated with base in the results of each set input. Techniques of *principal components of nonlinear discrimination* were also used for two-dimension visualizations of the separation between two classes (Defect and Nondefect). The accuracy results obtained are presented in tables and they were about 80% with test sets.

Introduction: Considering the relevancy of radiographic inspection to many types of industries, there has been having many researches aiming to automate the analysis and interpretation of welding discontinuities in radiographic films for a long time. Generally, these researches are divided into four main steps: digitizing and acquisition of radiographic image, welding seam extraction, detection of discontinuities and, finally, classification and judgment of the discontinuities detected. The first step consists usually on a digitizing of the radiographic film by an image scanner constructed specifically to do it. This device shall provide appropriated resolution. Recently, we already have the digital radiography available to have these images. The welding seam extraction require an algorithm of image processing to extract only the interest area, and them reduce the amount of information and time necessary for subsequent steps. On the third step, algorithms of pattern recognition are applied in order to detect anomalies on the transversal profile of the radiographic image. These algorithms are applied with intelligent systems that look for discontinuities along the welding. Finally, the classification of defects is carried out by an intelligent system too. The discontinuity detected previously must be recognized among many known types regarding their geometry, location and other features inherent to the image [1-10]. Beyond classification, the discontinuities shall be judged as acceptable or not, according to the Standard or Code applicable.

In this paper, we present the results obtained by a methodology for automatic detection of welding defects. Radiographic patterns of IIW were digitized by using professional scanner. The digitized images were pre-processed to reduce the noise and improve the contrast with median filter and contrast equalization. Then, profiles were transversely traced images out. These profiles were employed as training and test input sets in nonlinear pattern classifiers, which were implemented by artificial neural networks. Techniques of principal components of nonlinear discrimination [7] were also used for two-dimension visualizations of the separation between classes. The present problem of pattern classification involved discrimination between two classes: *profiles without defect* (ND) and *profiles with defect*s (D), including: undercut (UC), incomplete penetration (IP), lack of fusion (LF), pore (PO), slag inclusion (SI) and crack (CR). The accuracies of these classifiers were estimated by random sampling of the input set and the results obtained are presented in tables. The estimated accuracies were up to 80% for test sets, which can be considered has a successful performance regarding the number of samples used and the classification complexity involved in this system.

- ***Radiographic Patterns and Film Digitalization***

Although there are scanners such as the Agfa RADView FS 50, ideal for high-density films, due to the high quality of the films, a low-cost scanner, a UMAX, Mirage II model (3.0 maximum optical density; with 2000 dpi of maximum resolution for films) was used for the digitalization of the radiographs, following the ASME Code Sec. V. The resolution employed was 500 dpi (dots per inch), giving an average size (due to a small variation in the film sizes) image of 2,900 pixels (horizontal length) × 950 pixels (vertical length), which resulted in an average pixel size of 50μm. This resolution was adopted as it permitted the detection and measurement of defects of sizes in the order of hundredths of an mm, which in practical terms of radiographic inspection is well above normal. The resolution in tones of gray chosen was eight bits (256 levels).

- ***Pre-processing of Gray level Profiles***

Gray level profiles transversal to weld seam was extracted from radiographic images. Each profile is considered as a signal. The system involved 2 classes of signals, nondefects (ND) and defects (D). The input set had 1400 signals (200 signals without defects and 1200 with defects). Firstly, a smoothing was carried out with the filter Savitzky-Golay [11]. The best condition of smoothing was found using 8 points in the window size and a second order function. Originally, profiles were different in number of points due to variation in resolution of images and width of weld seams. Then, smoothed profiles were interpolated using FFT (Fast Fourier Transform) method [12] in order to have all profiles with the same dimension (number of points). Figure 1 shows two examples of profiles extracted from radiographic patterns, with and without defect. After smoothing, it was noted that location of defect is important for classifier performance. As normalization of the data concerning to defect positions, some profiles were inverted in order to obtain all defects at the right side of the center of the Gaussian curve fitted from the smoothed profiles, as far as Liao [2-4] showed that this transversal signal present a shape similar to Gaussian curve. The right side of Gaussian curve was chosen only to normalize all signals, i.e., there is no specific reason.

- ***Nonlinear Classifiers***

Nonlinear classifiers were implemented with two layers neural network, backpropagation of error was used as training algorithm [13-14]. The number of neurons in hidden layer was worked out to provide the best results for tests, aiming to improve generalization capability of classifier. Some neural network parameters was tested and adjusted to make training faster and improve its performance. Training of classifiers was done with moment (β=0.9) and α variable what provided a faster convergence during training. Normally, training stopped at 3000 epochs, when learning errors are stabilized.

- ***Principal Components of Nonlinear Discrimination***

The calculation of principal components is very useful, because they provide a data distribution in a bi-dimensional plot. In addition, it's a technique to reduce data dimension. In this work, two independent principal components of nonlinear discrimination were obtained from a three layer neural network; in which the first layer contains only one linear neuron, as described on [6-7]. Two-dimensional plots, composed by two principal components of nonlinear discrimination, were obtained to the classification of the two classes: Defect (D) and Nondefect (ND). Figure 1 show this plot for two classes.

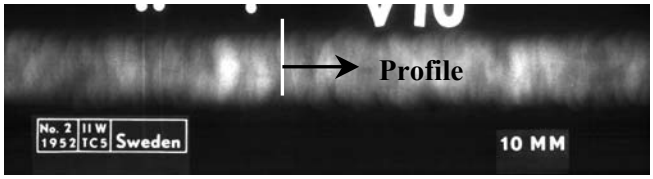

Radiography without defect.

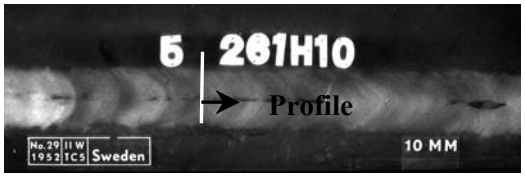

Radiography with incomplete penetration.

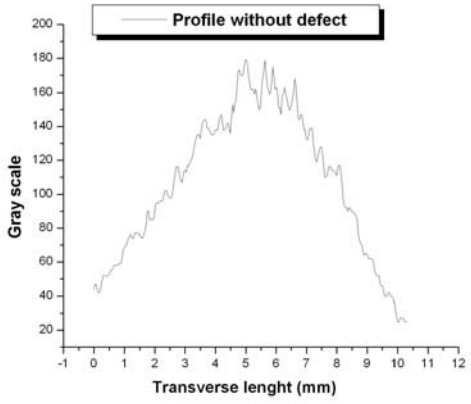

(a)

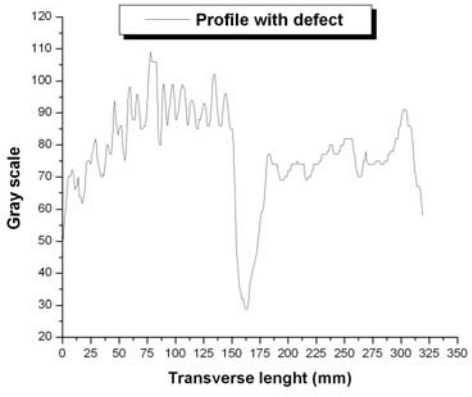

(b)

FIGURE 1: Examples of a grayscale profile without defect (a) and with incomplete penetration (b).

- ***Estimated Accuracy of Classifiers***

There are various techniques to estimate the accuracy of a classifier, but basically there are three that are the most used: simple random selection of samples, cross validation that presents diverse implementations [15], and the *bootstrap* technique [16-17]. Actually, it is not possible to confirm whether one method is better than the other for any specific pattern classification system. The choice of one of these techniques will depend on the quantity of samples available and the specific classification to be made. To calculate the accuracy of the detection (classification between the two classes: profiles with defect (D) and profiles without defects (ND)), random sampling was applied to the each original input set in order to produce the training and test sets. The original set was divided into 80% for training sets and 20% for test sets. The training group was divided into two groups, 90% for training and 10% for validation in order to assure the classifier reliability. It was carried out ten times and the estimated accuracies were calculated by average of the performance sets.

Results:

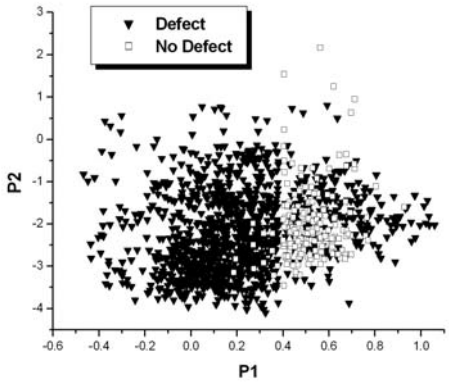

FIGURE 2: P1 x P2 nonlinear for the two classes: Defect and Nondefect.

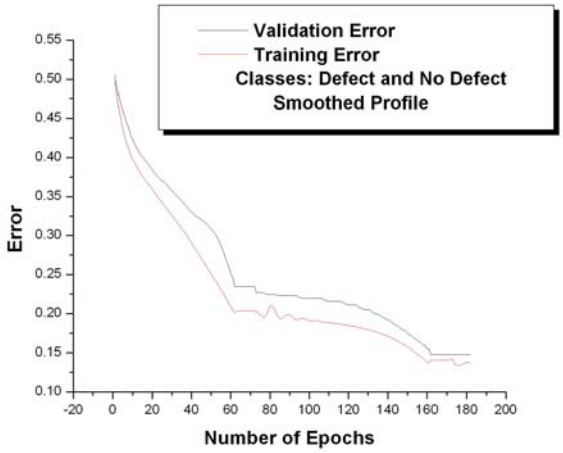

FIGURE 3: Error curve, demonstration of stop criteria.

TABLE 1: Variation of the number of neurons in the intermediate layer and the performances obtained for the training and test sets in the defect detection (smoothed profiles; two classes: with and without defect).

Number of Neurons	Training	Test
5	99.55	91.07
7	99.91	93.57
9	99.20	91.43
11	99.55	95.00
13	99.64	93.21
15	**99.82**	**96.07**
17	100.00	93.21
19	99.46	94.29
Maximum	100.00	96.07
Minimum	99.20	91.07

TABLE 2: Performance of classifier for 10 random groups (15 neurons; smoothed profiles; two classes: with and without defect).

Group	Training	Test
1	94.20	73.81
2	81.76	65.71
3	90.76	71.90
4	92.18	70.95
5	91.51	71.43
6	92.44	70.95
7	93.11	78.10
8	92.77	77.14
9	91.93	77.62
10	91.85	75.24
Media	**91.25**	**73.29**
Standard Deviation	**3.46**	**3.86**
Maximum	94.20	78.10
Minimum	81.76	65.71

TABLE 3: Variation of the number of neurons in the intermediate layer and the performances obtained for the training and test sets in the defect detection (smoothed and inverted profiles; two classes: with and without defect).

Number of Neurons	Training	Test	Difference
5	99.73	95.00	4.73
7	99.91	95.71	4.20
9	99.91	94.64	5.27
11	99.82	93.57	6.25
13	**99.46**	**96.43**	**3.04**
15	100.00	95.00	5.00
17	99.73	96.43	3.30
19	99.46	95.71	3.75
21	99.73	94.29	5.45
Maximum	100.00	96.43	
Minimum	99.46	93.57	

TABLE 4: Performance of classifier for 10 random groups, smoothed and inverted profiles, 13 neurons (two profile classes: with and without defect).

Group	Training	Test
1	99.73	94.64
2	99.46	87.86
3	99.46	93.21
4	99.73	89.64
5	99.02	78.93
6	85.89	85.71
7	100.00	86.07
8	98.21	86.43
9	99.82	88.93
10	99.91	88.57
Media	**98.13**	**88.00**
Standard-Deviation	**4.33**	**4.33**
Maximum	100.00	94.64
Minimum	85.89	78.93

Discussion: Figure 2 shows a plot of two principal components of linear discrimination obtained by a nonlinear classifier, implemented by three layer network. The first layer contains only one linear type neuron, others hiperbolic tangent type [7]. The plot of principal components allowed a two dimensions view of separation level between Nondefect and Defect classes. They presented a considerable separation level in this bi-dimensional space, even when classification errors are considered for both classes. However, in practice, more than two discrimination components can be used to identify both classes. In this work, these components were not used as input of classifiers, aiming to reduce dimension of files. It will be accomplished in future works.

This type of hierarchic classification was used by Silva [5] and will be studied for future implementation. The next step was to study the best number of neurons in intermediate layer of classifier to detect detects.

Figure 3 shows the error curve, where we can observe that stop criteria intend to minimize difference between training and validation error in order to control the over fitting of the classifier.

Tables 1 show the performance of training/test sets for smoothed signal, previous normalization regarding to defect position. Table 2 the performance of nonlinear classifier with 15 neurons. The performance of classifier was improved a lot after inversion of some profiles, as discussed below.

Table 3 show the performance of a training/test sets, where number of neurons in intermediate layer was varied. The choice of training/test group was accomplished to guarantee the same percentage of defects (1200) and nondefects (200) profiles, i.e., 960 profiles of defects for training and 240 for test, 160 profiles of nondefects for training and 40 for test. According to table 3, the success percentage increases from 5 to 21 neurons, the best performance of test was observed with 13 neurons in intermediate layer. Since the quantity of samples was small, principally for nondefects profiles, validation groups were not created during training as usual to overtraining control. However, the number of neurons control in intermediate layer allows reducing probability of network parameters overtraining. Generally, the number of neurons is adjusted to perform the smallest difference between results of training and test, what occurred with 13 neurons in intermediate layer in this case. This reduction on number of neurons at intermediate layer was possible after performing the inversion of smoothed signal. Since processing the same group of smoothed signal without any inversion of profile was done previously, as described above. A great improvement of network performance was reached with normalization of defect position.

Table 4 shows the performance of nonlinear classifier with 13 neurons. Standard-deviation found was low enough to guarantee a successful system of welding defects detection, since among 10 groups only one was found to be below 98% for training and 85% for test. It's a good result if we consider that most experience group of inspectors distinguishes correctly 90% defects from nondefects [18-19].

Conclusions: From results presented above, we can conclude as follows:

- Pre-processing of profiles prior submitting to classifier is very important for successful detection system, not only to smooth noises from the profiles, but to normalize the defect position.
- Normalization of defect position regarding to one side of center of Gauss fitted curve provides a great improvement on classifier performance.
- Nonlinear classifier implemented by neural network provides a good accuracy on detection of welding defects from transversal profiles to weld seams.
- This work must continue in order to turn this system able to discriminate the main type of welding defects detected.

Acknowledgements: Authors wish to acknowledge CNPq (The National Council for Scientific and Technological Development, FAPERJ (Research Foundation from Rio de Janeiro) and ANP (Brazilian Agency for Petroleum) for financial support and scholarships and also to International Institute of Welding for permission given to publicate the present work.

References:

1. A. Kehoe, G.A. Parker "Image Processing for Industrial Radiographic Inspection: Image Enhancement". British Journal of NDT 1990; Vol.32 N.4. pp. 183-190.
2. T.W. Liao, K. Tang "Automated Extraction of Welds from Digitized Radiographic Images Based on MLP Neural Networks". Applied Artificial Intelligence 1997. vol.11.pp 197-218.
3. T.W. Liao, Y. Li "An Automated Radiographic NDT System for Weld Inspection: Part II – Flaw Detection". NDT&E International 1998. Vol.31. N.3.pp. 183-192.
4. Wang, G, Liao, T. W. Automatic Identification of Different Types of Welding Defects in Radiographic Images. NDT&E International 2002; 35: 519-528.
5. R. R. Silva, M.H.S. Siqueira, L.P. Calôba, et al. "Radiographics Pattern Recognition of Welding Defects using Linear Classifiers". Insight 2001. Vol. 43. N.10: 669-674.
6. R.R Silva et al. "Patterns Nonlinear Classifiers of Weld Defects in Industrial Radiographs". 3rd PANNDT. June 2003. Rio de Janeiro. Brazil.
7. R. R. Silva, Calôba L P, Siqueira M.H.S, Rebello, J.M.A. Pattern Recognition of Weld Defects Detected by Radiographic Test. NDT&E International, 2004.
8. G.X. Padua et al "Detection of Welding Defects on Radiographic Patterns Using Artificial Neural Networks". 3rd PANNDT. June 2003. Rio de Janeiro. Brazil.
9.Shafeek, H.I, Gadelmawla, E., Abdel-Shafy, A.A, Elewa, I.M. Automatic Inspection of Gas Pipeline Welding Defects Using an Expert System. NDT&E International, 2004.
10. Shafeek, H.I, Gadelmawla, E., Abdel-Shafy, A.A, Elewa, I.M. Assessment of Welding Defects for Gas Pipeline Radiographs Using Computer Vision. NDT&E International, 2004.
11. J.O. Sophocles. "Introduction to Signal Processing". Prentice-Hall.1995.
12. Curve Fitting Toolbox –For use with MATLAB. User's Guide, Version 1. The Mathworks.
13. S. Haykin ."Neural Networks – A Comprehensive Foundation". Macmillian College Publishing. Inc. 1994.
14. C.M. Bishop. "Neural Networks for Pattern Recognition". New York. Oxford University Press. 1995.
15. Diamantidis, N.A., Karlis, D., Giakoumakis, E.A. Unsupervised Stratification of Cross-Validation for Accuracy Estimation. Artificial Intelligence 2000. 116: 1-16.
16. Efron, B., Tibshirani, R. J. An Introduction to the Bootstrap. New York, Chapman & Hall/CRC, 1993.
17. Efron, B., Tibshirani. Cross-Validation and the Bootstrap: Estimating the Error Rate of the Prediction Rule. Technical Report 477, Stanford University 1995. http://utstat.toronto.edu/tibs/research.html.
18. F. Fucsok, M. Scharmak. Human Factors: The NDE Realibility of Routine Radiographic Film Evaluation. In: 15th World Conference on Non-Destructive Testing. Rome, October 15-21 2000.
19. F. Fucsok, C. Muller, M. Scharmak. Reliability of Routine Radiographic Film Evaluation – An Extended ROC Study of the Human Factor. In: 8th European Conference on Non Destructive Testing. Barcelona, June 17-21 2002.

APÊNDICE B.3

II Inspeq 2004 – Encontro Técnico de Inspeção de Equipamentos Estáticos da Petrobras

EXTRAÇÃO DO CORDÃO DE SOLDA E DETECÇÃO DE DEFEITOS EM RADIOGRAFIAS USANDO REDES NEURAIS

Germano X. de Padua [1], Romeu R. da Silva [2], Prof. João M. A. Rebello [3], Prof. Luiz P. Caloba [4]

Abstract

Nowadays, there are several researches directed to the development of an automatic system of analysis and interpretation of weld joint, which is also occurring in the radiographic inspection of casting pieces and tomographic processes. The process of building of this automatic system is usually divided into three steps: radiographic film digitizing, the preprocessing of digitized images and data, and finally a step of pattern recognition, being the last one frequently implemented by neural networks. This work aims to show one researched methodology of welding defect detection in radiography digitized. To assure the precision of the results, the radiographic patterns of the International Institute of Welding (IIW) were used. The authors firstly present one method to discriminate the weld joint region from the metal base region in the radiographic image. For this, Gaussian curves were obtained from the transversal grayscale profiles of the weld joint. Furthermore, these profiles are preprocessing and are employed to set the training and test input of the linear and non-linear classifiers implemented by neural networks. The results are presented and discussed in regard to these classifier performances and, whenever it is possible, they are compared to other results obtained by the principal authors of this research field. The results achieved until this moment encourage this work publication.

Resumo

Atualmente, existem diversas pesquisas voltadas para o desenvolvimento de um sistema automático de análise e interpretação de radiografias de juntas soldadas, o que similarmente também ocorre na inspeção radiográfica de peças fundidas e processos tomográficos. Para o projeto deste sistema, normalmente são necessárias as etapas de digitalização dos filmes radiográficos, pré-processamentos das imagens digitalizadas e dos dados, e uma etapa de reconhecimento de padrões, sendo esta última freqüentemente implementada por redes neurais artificiais. Este trabalho tem como objetivo principal apresentar uma metodologia para extração automática de cordão de solda e detecção de defeitos em radiografias, esta última etapa usando redes neurais. Para garantir a precisão dos resultados, utilizou-se padrões radiográficos do IIW (Internacional Institute of Welding). Apresenta-se, primeiramente, um método para separação do cordão de solda da região de metal de base na imagem radiográfica. Para tal, utilizou-se as curvas Gaussianas obtidas dos perfis de níveis de cinza transversais ao cordão. Posteriormente, estes perfis são pré-processados e são utilizados para formação do conjunto de treinamento e teste dos classificadores lineares desenvolvidos por redes neurais supervisionadas. Os resultados conseguidos até o presente momento incentivam a publicação deste trabalho.

Palavras-chave: Radiografia, Extração de Cordão, Defeitos de Soldagem, Reconhecimento de padrão e Redes Neurais

Introdução

Existem algumas pesquisas, muitas delas ainda em fase inicial, que visam a automatização do processo de análise e interpretação de defeitos em radiografias, normalmente dividido em quatro etapas principais: digitalização da radiografia/aquisição da imagem, extração do cordão de solda, detecção e classificação de defeitos. A primeira etapa consiste da digitalização do filme radiográfico por meio de um scanner desenvolvido para este fim, proporcionando resolução adequada, ou

[1] Doutorando, Engenheiro de Equipamentos Pleno – PETROBRAS – COPPE/UFRJ

[2] Doutorando, Engenheiro Metalúrgico – COPPE/UFRJ

[3] Prof. Doutor, Engenheiro Metalúrgico – COPPE/UFRJ

[4] Prof. Doutor, Engenheiro Eletricista – COPPE/UFRJ

mais recentemente, a aquisição já digitalizada da radiografia. A extração do cordão de solda consiste de um algoritmo de tratamento de imagem para extrair somente a área de interesse e reduzir o tempo gasto nas etapas subseqüentes. Na detecção dos defeitos, são aplicados algoritmos para o reconhecimento de anomalias no perfil da imagem, estes algoritmos são aplicados com sistemas inteligentes (redes neurais artificiais mais freqüentemente) e devem prever a existência de descontinuidades ao longo da imagem da solda. Por fim, a classificação dos defeitos também é executada automaticamente, de forma que o defeito encontrado anteriormente seja reconhecido dentre os diversos tipos, considerando a sua geometria, localização dentro do cordão e outras particularidades relativas à imagem.

No presente trabalho, apresenta-se os resultados obtidos com uma metodologia para extração automática do cordão de solda de padrões radiográficos do IIW (Internacional Institute of Welding). O algoritmo empregado envolve as etapas de suavização de ruído com o filtro Savitzky-Golay, regressão não linear dos perfis com base na curva de Gauss e extração das partes referentes ao cordão de solda, dispensando a informação irrelevante do metal de base. Posteriormente, os perfis resultantes são usados em classificadores lineares de padrões desenvolvidos com redes neurais artificiais para separação entre perfis contendo defeitos no cordão de solda e perfis sem defeito.

Início do Trabalho

REVISÃO BIBLIOGRÁFICA

Warren Liao e Jiawei Ni[1] desenvolveram uma metodologia baseada na observação de que o gráfico de intensidade de nível de cinza em um cordão de solda aproxima-se mais de uma Gaussiana do que os outros objetos da mesma imagem. Para Liao[1], a similaridade entre o gráfico de intensidade de cada objeto e sua Gaussiana é definido em termos do erro médio quadrado (MSE). Assumindo que o objeto é centrado em x = X e seus vales a esquerda e direita estão localizado em x = X-d e x = X+d, MSE é calculado pela equação 1:

$$MSE = \frac{\sum_{x=X-d}^{X+d} f(x) - g(x)}{2d} \qquad (1)$$

onde d é a distância entre o pico e o seu vale mais próximo.

O objeto com menor MSE é considerado mais similar a Gaussiana. Visto que geralmente o gráfico de intensidade de uma solda parece mais Gaussiano que outros objetos, o objeto com menor MSE pode ser identificado como a solda. Liao recorreu a este princípio para desenvolver uma metodologia para extração do cordão de solda em radiografias, conforme detalhado em [1].

Extração de Características através de Perfis de Níveis de Cinza

Para distinguir objetos da solda de outros objetos estranhos ao cordão, fatores com capacidade de discriminação devem ser identificados, isto é, deve ser feita uma seleção de parâmetros característicos. Liao e Tang[2] utilizaram a técnica "eyeball" para determinar estes fatores, baseados na observação dos gráficos de intensidade das imagens. Eles definiram, então, quatro fatores para cada objeto na imagem: a posição do pico (X_1), a largura (X_2), o erro médio quadrado (MSE) entre o objeto e a Gaussiana do seu gráfico de intensidade (X_3) e a intensidade do pico (X_4). O programa para extração consistia de três maiores etapas: primeiro, um algoritmo de detecção de pico é usado para detectar objetos em uma imagem linear. Para cada objeto detectado, a intensidade do pico e sua posição são obtidas. Segundo, um algoritmo de detecção de vale é aplicado para encontrar os vales associados a cada objeto detectado anteriormente. Após encontrar os vales, a largura dos objetos é calculada. Terceiro, o MSE entre o gráfico de intensidade de cada objeto e sua Gaussiana é computado.

Liao e Tang[2] utilizaram redes neurais MLP (Multi-Layered Perceptron) para reconhecimento de padrões, i.e., distinguir soldas de qualquer objeto que não seja um cordão soldado, baseado nos parâmetros definidos anteriormente, detecção de picos (vales) e sua similaridade com a Gaussiana. Foram usadas 100 soldas em 25 imagens. Verificou-se que a detecção foi perfeita para soldas lineares e quase perfeita para soldas curvas. O percentual de alarme falso variou entre 2 e 12%. Este procedimento foi desenvolvido para extrair os cordões de solda antes de aplicar um algoritmo ou rotina para detecção de defeitos na solda[2].

DESENVOLVIMENTO EXPERIMENTAL

As imagens radiográficas utilizadas foram padrões do IIW (Internacional Institute of Welding) para aumentar a confiabilidade dos resultados obtidos. As radiografias foram digitalizadas com um scanner tipo Flatbed UMAX Mirage II, com resolução de 500 dpi (dots per inch – resultando em um tamanho médio de pixel de 50µm) e 256 níveis de cinza, sendo armazenadas no formato TIFF (sem compressão). Estes padrões contêm imagens com todos os tipos de defeitos detectáveis pelo exame radiográfico, como falta de fusão, falta de penetração, porosidade, inclusão de escória, mordedura, trinca, etc.
Conforme verificado em várias publicações[3-5], normalmente é necessário que seja feito um préprocessamento na imagem radiográfica antes que se proceda a extração da solda, com o objetivo de melhorar a qualidade da imagem, e proporcionar a redução na taxa de erros deste procedimento. O pré-processamento consiste, principalmente, da aplicação de dois procedimentos de melhoramento da imagem, conforme proposto por [3-5], inicialmente deve-se reduzir, e se possível eliminar, o ruído decorrente da digitalização da imagem, e posteriormente fazer um realçamento do contraste da imagem. As imagens foram trabalhadas no programa de tratamento de imagens Image Pro Plus 4.0 (Media Cybenetcs), de onde, posteriormente ao pré-processamento, foram ext raídos os perfis transversais de níveis de cinza nos cordões de solda, segundo figura 1. Um total de 100 perfis de cordão de solda sem presença de defeitos foi extraído, assim como 100 perfis de cordões aonde havia a existência de defeitos de soldagem.

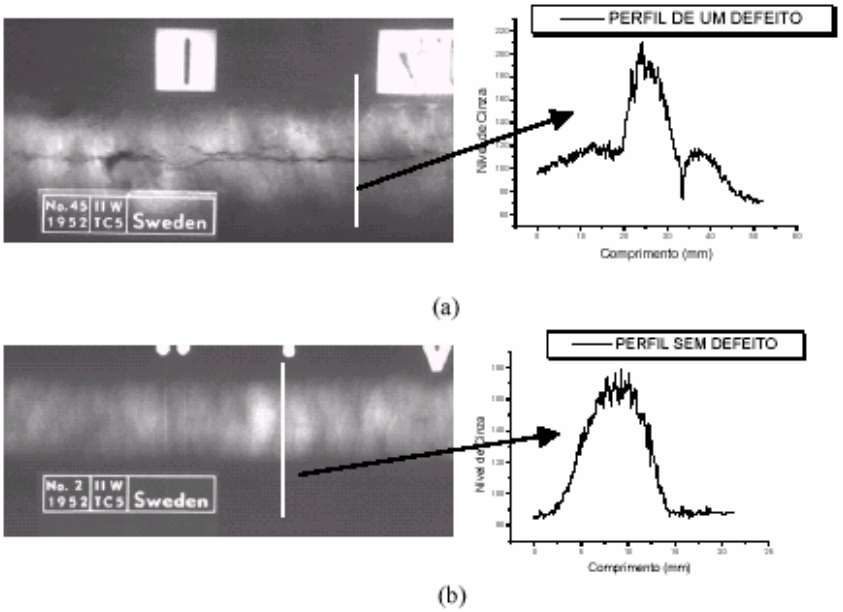

Figura 1: (a) Perfil transversal ao cordão de solda para a situação de presença de defeito no cordão; (b) perfil transversal para a situação de ausência de defeito.

Aos perfis obtidos, foi aplicado o filtro Savitzky-Golay[6] com o objetivo de suavizar o ruído ainda existente após pré-processamento com filtro mediana[3]. Este filtro é tipicamente utilizado para suavizar um sinal de banda larga com ruído. Escolheu-se este filtro porque ele é superior à média móvel padrão, no sentido de que o novo ponto, o ponto existente após aplicação do filtro, é obtido de uma regressão polinomial local que minimiza o erro quadrático dos dados ruidosos do intervalo, e não pela média dos pontos adjacentes como ocorre com o Filtro de Média Móvel padrão, que tende a eliminar uma porção importante do conteúdo de alta freqüência do sinal junto com o ruído. Este método preserva certas características dos dados, tais como os picos e largura de intervalo[6]. A partir do sinal/perfil suavizado, fez-se uma regressão não linear do perfil segundo a curva de Gauss, sabendo-se que os perfis transversais a juntas soldadas com reforço têm um comportamento Gaussiano[1,2]. Posteriormente, os parâmetros média e desvio padrão dos perfis Gaussianos obtidos foram utilizados para definir o limite de corte para a extração do cordão de solda, sem perda de informações da solda, e retirando do sinal informações irrelevantes do metal de base. A figura 2 mostra a seqüência das etapas realizadas pelo algoritmo de extração de cordão.

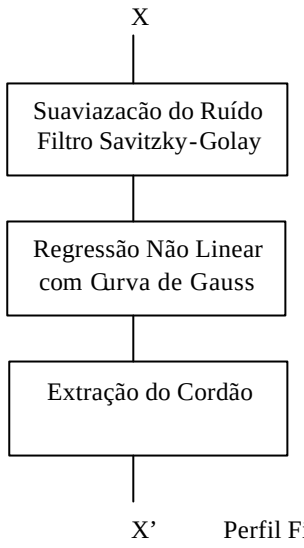

Figura 2: Etapas utilizadas para Extração do perfil contendo apenas o cordão de solda.

Antes de formar os conjuntos de dados de treinamento e teste para os classificadores, procedeu-se uma normalização dos perfis processados e reduzidos para terem média zero e desvio padrão igual a 1 (μ=0, ó=1). Com isso, permite-se que todos os perfis tenham escalas similares de amplitude, o que facilita o treinamento e desempenho dos classificadores.

O conjunto de treinamento das redes neurais foi composto de 70 perfis contendo defeitos e 70 perfis sem presença de defeito. Dois conjuntos de treinamento foram construídos: um conjunto com os perfis originais sem aplicação do filtro Savitzky-Golay, neste caso a extração do cordão foi realizada diretamente nos perfis sem processamento; e um segundo conjunto com os perfis após suavização e extração, ambos com a mesma quantidade de perfis. Para avaliar a capacidade de generalização do classificador, ou seja, acertar corretamente entradas que não tenham sido usadas durante a etapa de aprendizagem da rede neural, formou-se dois conjuntos de teste da mesma forma que os perfis de treinamento (com e sem processamento), mas contendo cada conjunto 30 perfis com presença de defeito e 30 sem defeito existente. Cada perfil utilizado possui 500 pontos, resultantes após extração do cordão de solda.

Normalmente, quando se trabalha com reconhecimento de padrão, avalia-se primeiro a possibilidade de separação entre as classes estudadas por um processo de classificação linear, visto ser este o processo mais simples e fácil de implementação. Conforme descreve Haykin em seu livro[7], e também Bishop[8], uma rede neural de uma única camada pode ser usada para implementação de um classificador linear de padrão. Neste caso, desenvolveu-se para este trabalho classificadores lineares implementados com uma rede neural supervisionada de apenas uma camada, composta por um neurônio do tipo tangente hiperbólica. Como treinamento, o algoritmo de retropropagação do erro foi adotado, usando momento e taxa de aprendizado variável. Uma descrição detalhada destes parâmetros de treinamento é encontrada em uma vasta literatura, como bons exemplos temos Haykin[7] e Bishop[8]. Em Silva[9], encontra-se uma descrição aprofundada do estudo de classificadores lineares de padrões usados para separar defeitos de soldagem típicos como: mordedura, falta de penetração, porosidade e inclusão de escória, mas neste caso, os dados eram compostos por características geométricas extraídas dos defeitos.

Para avaliar a capacidade de separação entre as classes de perfis: com defeito (CD) e sem defeito (SD), recorreu-se a técnica de componentes principais de discriminação linear, também implementada por redes neurais. Um gráfico bidimensional composto pelas duas componentes principais de discriminação linear foi obtido, permitindo a visualização otimizada do problema proposto. Em Silva[10], detalha-se a implementação desta metodologia.

RESULTADOS E DISCUSSÕES

A figura 3 (a) mostra um exemplo de perfil obtido no trabalho para a um cordão de solda sem a presença de defeitos (SD), neste caso, sem processamento com o filtro de Savitzky-Golay. Fica claro, como podemos observar, a existência de ruído no sinal. A justificativa para presença de ruído em radiografias de materiais é muito discutida e diversos fatores são relacionados[3-5]. Sabe-se, entretanto, que o ruído eletrônico aleatório provocado pelo processo de digitalização é quase sempre presente[3]. Para suavização desse ruído, escolheu-se empiricamente um filtro de Savitzky-Golay com um polinômio de segundo grau em uma janela de processamento de 10×10[6], pois na prática foi o ajuste que permitiu resultado melhor, sem prejuízo

significante das altas freqüências de interesse que pudessem haver no perfil, como por exemplo a presença de defeitos. A figura 3(b) representa o perfil resultante obtido para aplicação do filtro no perfil da figura 3(a), mostrando a suavização considerável do ruído, mantendo a forma original do perfil. Na mesma figura 3(b), temos uma linha contínua representando a curva de Gauss obtida para o perfil processado. Observa-se que, distante da média três desvios padrões simetricamente para os dois lados, entramos na região de representação do metal de base, portanto, fora do interesse do trabalho proposto. O mesmo foi verificado para todos os outros perfis (num total de 100) referentes a condição sem defeito (SD), assim como para os 100 perfis com existência de defeito (CD). O que permitiu chegar a conclusão que, com uma boa margem de segurança, pode-se definir o limite de três desvios (3ó) para extração do cordão. É importante destacar que os 100 perfis contendo defeitos tinham as classes porosidade, trinca, falta de penetração, falta de fusão e inclusão de escória conforme indicação do IIW. A classe mordedura, também muito freqüente em cordões de solda, não foi ainda analisada por se tratar de uma classe que normalmente ocorre na borda do cordão, o que cria um fator complicador para a extração do cordão sem eliminação da parte do perfil referente ao defeito. Entretanto, os resultados das extrações automáticas dos cordões para os perfis estudados pelo algoritmo desenvolvido mostraram que esta metodologia é eficiente e menos complexa do que as proposta por Liao[1], por exemplo. A inclusão dos perfis contendo o defeito mordedura nesta metodologia será feita na seqüência do trabalho que está sendo desenvolvido.

A figura 3(c) mostra um perfil original contendo o defeito trinca no cordão de solda, visualizado no "vale" acentuado próximo ao centro do cordão. A figura 3(d) representa o resultado da aplicação do filtro no perfil original, mostrando que o ruído foi claramente alisado, mas a amplitude do "vale" referente ao defeito sofreu uma redução notável, mesmo com as características de preservação de altas freqüências que o filtro possui. O ajuste com curva de Gauss, na figura 3(d), também ilustra a constatação de que, com três desvios padrões distantes da média (centro da Gaussiana), simetricamente, elimina-se a parte do perfil referente ao metal de base. Apenas esta figura é mostrada porque todas as demais obtidas são similares em resultados e observações a respeito do filtro aplicado e da técnica de extração do cordão. Vale destacar que esta técnica destina-se somente as condições em que há ocorrência de reforço de cordão de solda, aonde o comportamento Gaussiano é evidente. Para outras condições, possivelmente outros tipos de ajustes terão que ser feitos.

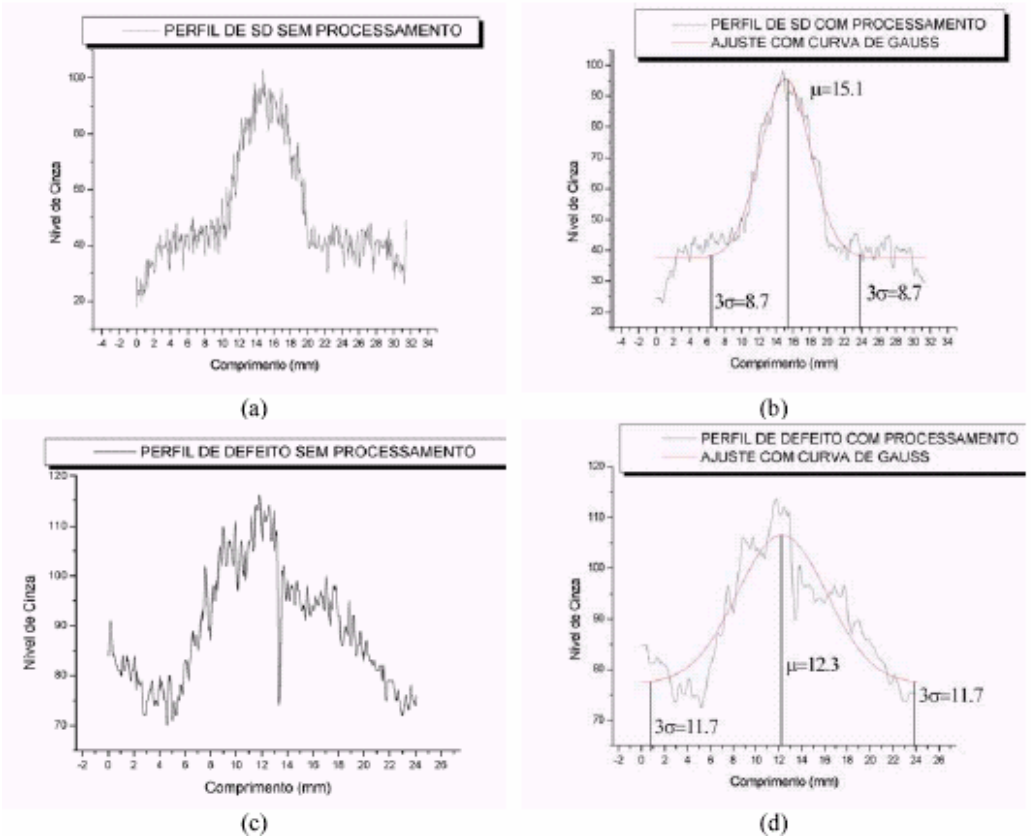

Figura 3: (a) perfil obtido diretamente da imagem radiográfica de uma solda sem defeito na condição sem processamento, aonde a presença de ruído é visível; (b) mesmo perfil com processamento com filtro Savitzy-Golay, e o resultado de um ajuste Gaussiano; (c) perfil de uma radiografia na região de ocorrência de um defeito, sem processamento; (d) perfil anterior com processamento e ajuste Gaussiano.

O gráfico bidimensional obtido para as duas componentes principais de discriminação linear é mostrado na figura 4. A utilização das componentes principais de discriminação usando redes neurais é detalhada em Silva[10], tanto para visualização otimizada da separação entre as classes, quanto para redução da dimensão dos dados de entrada de um classificador. Na figura 4, verifica-se que as duas classes de perfis estudadas CD e SD têm regiões distintas no gráfico e são linearmente separáveis, não sendo necessário portanto a utilização de um classificador não linear.

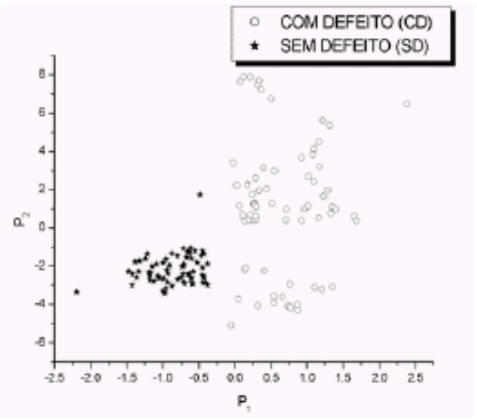

Figura 4: Gráfico das duas componentes principais de discriminação linear.

Os classificadores lineares desenvolvidos pela rede do tipo retropropagação do erro, com treinamento em batelada e usando apenas um neurônio, proporcionaram 100% de acerto geral para os dados de treinamento (70 perfis de cada classe) nas condições de perfis: com e sem processamento com filtro, comprovando o que havia sido constatado no gráfico de separação. Com os dados de teste (30 perfis de cada classe), os sinais sem processamento resultaram em 100% de acerto para os perfis da classe SD e 53.3% de acerto para a classe CD, o que resulta em um índice geral de acerto de 76,7% (46 em um total de 60 perfis). Este índice é consideravelmente bom tendo em vista a simplicidade do classificador e as características complexas de informações que estão presentes em perfis de cinza de cordões de solda, que normalmente contêm ruídos de origem variada, variações intensas de distribuição de cinza e contraste, espessuras não uniformes na seção transversal à imagem e etc.

Com os sinais processados, obteve-se também 100% de acerto para os dados de treinamento. Porém, para este caso, o índice de acerto para a classe CD aumentou para 63,3%, mostrando uma pequena melhora em relação aos perfis sem processamento para esta classe, mantendo os 100% de acerto para a classe SD. O índice geral de acerto para esta condição foi de 81,7% (49 acertos em um total de 60). A tabela 1 contém todos os índices de acerto obtidos em quantidade numérica e percentual.

Estes resultados são excelentes para os dados estudados, mostrando que a utilização de perfis para detecção de defeitos em cordões de solda é plenamente viável utilizando redes neurais. Entretanto, mais investigações são necessárias para aprofundamento desta linha de pesquisa, principalmente nas fases de pré-processamento dos sinais com filtros visando a suavização de ruídos e realce das descontinuidades que possam existir, assim como normalização dos perfis. Na seqüência do trabalho, os mesmos classificadores e possivelmente também os classificadores não lineares serão estudados para a classificação de cada classe de defeito de soldagem. Assim como a utilização de redes neurais não supervisionadas.

Tabela 1: Índices de acerto numérico e percentual para os conjuntos de dados usados para treinamento e teste dos classificadores lineares.

	SEM PROCESSAMENTO		**COM PROCESSAMENTO**	
	Treinamento	Teste	Treinamento	Teste
Com Defeito (CD)	70 (100%)	16 (53,3%)	70 (100%)	19 (63,3%)
Sem Defeito (SD)	70 (100%)	30 (100%)	70 (100%)	30 (100%)
Índice Geral de Acerto	140 (100%)	46 (76,7%)	140 (100%)	49 (81,7%)

CONCLUSÕES

Conforme constatado por Liao, os perfis transversais de níveis de cinza em cordões de solda reforçados têm realmente um comportamento normalmente Gaussiano.

Para os perfis estudados, a metodologia empregada para extração do cordão de solda se mostrou eficiente, com os perfis sendo extraídos no limite de três desvios padrões a partir da média (centro do cordão) simetricamente. A inclusão da classe mordedura nesta metodologia será realizada subseqüentemente no trabalho.

A separação entre perfis sem a presença de defeito e com a ocorrência de defeitos é comprovadamente possível usando apenas um classificador linear. Isto deve ser ainda mais evidente com o aprofundamento das etapas de pré-processamento dos perfis.

O presente trabalho motiva a continuação dos estudos no sentido de avaliar técnicas de detecção e classificação de defeitos de soldagem através dos perfis transversais aos cordões em radiografias,usando redes neurais para implementação dos classificadores de padrões. Com isto, visa-se darcontribuições relevantes ao desenvolvimento de um sistema automático de análise e interpretação deradiografias industriais.

AGRADECIMENTOS

Os autores do trabalho agradecem o apoio financeiro e as bolsas de estudo dados pelos órgãos FAPERJ, CNPq e CAPES, assim como a PETROBRAS pelo incentivo dado ao seu funcionário e aluno de doutorado Germano para a consolidação da sua tese.

REFERÊNCIAS BIBLIOGRÁFICAS

1. Liao T W, Li Y. “An Automated Radiographic NDT System for Weld Inspection: Part II – Flaw Detection”. NDT&E International 1998. Vol.31. N.3.pp. 183-192.
2. Liao T W, Tang K. “Automated Extraction of Welds from Digitized Radiographic Images Based on MLP Neural Networks”. Applied Artificial Intelligence 1997. vol.11.pp 197-218.
3. Silva R R. “Radiographic Image Processing and Analysis of Defects in Weld Bead”. Master’s Degree. PEMM/COPPE/UFRJ. RJ, Brazil,1999. (In Portuguese).
4. Kehoe A, Parker G A. “Image Processing for Industrial Radiographic Inspection: Image Enhancement”. British Journal of NDT 1990; Vol.32 N.4. pp. 183-190.
5. Murakami, K. “Image Processing For Non-Detructive Testing. Welding International. 1990;144-149.
6. Sophocles, J.O. Introduction to Signal Processing. Prentice-Hall.1995.
7. Haykin S. Neural Networks– A Comprehensive Foundation. Macmillian College Publishing. Inc. 1994.
8. Bishop C. M. Neural Networks for Pattern Recognition. New York. Oxford University Press. 1995. 9. Silva R R, Siqueira M H. S, Calôba L P, et al. Radiographics Pattern Recognition of Welding Defects using Linear Classifiers. Insight 2001. Vol. 43. N.10: 669-674.
10. Silva, R.R. et al. Patterns Nonlinear Classifiers of Weld Defects in Industrial Radiographies. 3rd PANNDT. June 2003. Rio de Janeiro. Brazil.

APÊNDICE B.4

7ª Coteq 2003 – Conferência Sobre Tecnologia de Equipamentos

7ª COTEQ
Conferência sobre Tecnologia de Equipamentos
09-12/setembro 2003
Florianópolis • Santa Catarina

COTEQ285_03

EXTRAÇÃO DO CORDÃO DE SOLDA E DETECÇÃO DE DEFEITOS EM RADIOGRAFIAS USANDO REDES NEURAIS

Germano X. de Padua[1], Romeu R. da Silva[2], Prof. João M. A. Rebello[3] , Prof. Luiz P. Caloba[4]

Copyright 2003, Instituto Brasileiro de Petróleo e Gás - IBP

Este Trabalho Técnico foi preparado para apresentação na *7ª Conferência sobre Tecnologia de Equipamentos*, realizada no período de 09 a 12 de Setembro de 2003, em Florianópolis - SC. Este Trabalho Técnico foi selecionado para apresentação pela Comissão Técnica do Evento, seguindo as informações contidas na sinopse submetida pelo(s) autor(es). O conteúdo do Trabalho Técnico, como apresentado, não foi revisado pelo IBP. *Os organizadores não irão traduzir ou corrigir os textos recebidos*. O material, conforme apresentado, não necessariamente reflete as opiniões do Instituto Brasileiro de Petróleo e Gás, Sócios e Representantes. É de conhecimento e aprovação do(s) autor(es) que este Trabalho Técnico seja publicado nos Anais da *7ª Conferência sobre Tecnologia de Equipamentos.*

Abstract

Nowadays, there are several researches directed to the development of an automatic system of analysis and interpretation of weld joint, which is also occurring in the radiographic inspection of casting pieces and tomographic processes. The process of building of this automatic system is usually divided into three steps: radiographic film digitizing, the preprocessing of digitized images and data, and finally a step of pattern recognition, being the last one frequently implemented by neural networks. This work aims to show one researched methodology of welding defect detection in radiography digitized. To assure the precision of the results, the radiographic patterns of the International Institute of Welding (IIW) were used. The authors firstly present one method to discriminate the weld joint region from the metal base region in the radiographic image. For this, Gaussian curves were obtained from the transversal grayscale profiles of the weld joint. Furthermore, these profiles are preprocessing and are employed to set the training and test input of the linear and non-linear classifiers implemented by neural networks. The results are presented and discussed in regard to these classifier performances and, whenever it is possible, they are compared to other results obtained by the principal authors of this research field. The results achieved until this moment encourage this work publication.

Resumo

Atualmente, existem diversas pesquisas voltadas para o desenvolvimento de um sistema automático de análise e interpretação de radiografias de juntas soldadas, o que similarmente também ocorre na inspeção radiográfica de peças fundidas e processos tomográficos. Para o projeto deste sistema, normalmente são necessárias as etapas de digitalização dos filmes radiográficos, pré-processamentos das imagens digitalizadas e dos dados, e uma etapa de reconhecimento de padrões, sendo esta última freqüentemente implementada por redes neurais artificiais. Este trabalho tem como objetivo principal apresentar uma metodologia para extração

[1] Doutorando, Engenheiro de Equipamentos Pleno – PETROBRAS – COPPE/UFRJ
[2] Doutorando, Engenheiro Metalúrgico – COPPE/UFRJ
[3] Prof. Doutor, Engenheiro Metalúrgico – COPPE/UFRJ
[4] Prof. Doutor, Engenheiro Eletricista – COPPE/UFRJ

automática de cordão de solda e detecção de defeitos em radiografias, esta última etapa usando redes neurais. Para garantir a precisão dos resultados, utilizou-se padrões radiográficos do IIW (Internacional Institute of Welding). Apresenta-se, primeiramente, um método para separação do cordão de solda da região de metal de base na imagem radiográfica. Para tal, utilizou-se as curvas Gaussianas obtidas dos perfis de níveis de cinza transversais ao cordão. Posteriormente, estes perfis são pré-processados e são utilizados para formação do conjunto de treinamento e teste dos classificadores lineares desenvolvidos por redes neurais supervisionadas. Os resultados conseguidos até o presente momento incentivam a publicação deste trabalho.

Palavras-chave: Radiografia, Extração de Cordão, Defeitos de Soldagem, Reconhecimento de padrão e Redes Neurais

Introdução

Existem algumas pesquisas, muitas delas ainda em fase inicial, que visam a automatização do processo de análise e interpretação de defeitos em radiografias, normalmente dividido em quatro etapas principais: digitalização da radiografia/aquisição da imagem, extração do cordão de solda, detecção e classificação de defeitos. A primeira etapa consiste da digitalização do filme radiográfico por meio de um scanner desenvolvido para este fim, proporcionando resolução adequada, ou mais recentemente, a aquisição já digitalizada da radiografia. A extração do cordão de solda consiste de um algoritmo de tratamento de imagem para extrair somente a área de interesse e reduzir o tempo gasto nas etapas subseqüentes. Na detecção dos defeitos, são aplicados algoritmos para o reconhecimento de anomalias no perfil da imagem, estes algoritmos são aplicados com sistemas inteligentes (redes neurais artificiais mais freqüentemente) e devem prever a existência de descontinuidades ao longo da imagem da solda. Por fim, a classificação dos defeitos também é executada automaticamente, de forma que o defeito encontrado anteriormente seja reconhecido dentre os diversos tipos, considerando a sua geometria, localização dentro do cordão e outras particularidades relativas à imagem, além de classificá-lo quanto a aceitação de acordo com a norma ou código aplicável (ASME, ASNT, ASTM, etc.).

No presente trabalho, apresenta-se os resultados obtidos com uma metodologia para extração automática do cordão de solda de padrões radiográficos do IIW (Internacional Institute of Welding). O algoritmo empregado envolve as etapas de suavização de ruído com o filtro Savitzky-Golay, regressão não linear dos perfis com base na curva de Gauss e extração das partes referentes ao cordão de solda, dispensando a informação irrelevante do metal de base. Posteriormente, os perfis resultantes são usados em classificadores lineares de padrões desenvolvidos com redes neurais artificiais para separação entre perfis contendo defeitos no cordão de solda e perfis sem defeito.

REVISÃO BIBLIOGRÁFICA

Warren Liao e Jiawei Ni[1] desenvolveram uma metodologia baseada na observação de que o gráfico de intensidade de nível de cinza em um cordão de solda aproxima-se mais de uma Gaussiana do que os outros objetos da mesma imagem. Para Liao[1], a similaridade entre o gráfico de intensidade de cada objeto e sua Gaussiana é definido em termos do erro médio quadrado (MSE). Assumindo que o objeto é centrado em x = X e seus vales a esquerda e direita estão localizado em x = X–d e x = X+d, MSE é calculado pela equação 1:

$$MSE = \frac{\sum_{x=X-d}^{X+d} f(x) - g(x)}{2d} \tag{1}$$

onde d é a distância entre o pico e o seu vale mais próximo.

O objeto com menor MSE é considerado mais similar a Gaussiana. Visto que geralmente o gráfico de intensidade de uma solda parece mais Gaussiano que outros objetos, o objeto com menor MSE pode ser identificado como a solda. Liao recorreu a este princípio para desenvolver uma metodologia para extração do cordão de solda em radiografias, conforme detalhado em [1].

Extração de Características através de Perfis de Níveis de Cinza

Para distinguir objetos da solda de outros objetos estranhos ao cordão, fatores com capacidade de discriminação devem ser identificados, isto é, deve ser feita uma seleção de parâmetros característicos. Liao e Tang[2] utilizaram a técnica "eyeball" para determinar estes fatores, baseados na observação dos gráficos de intensidade das imagens. Eles definiram, então, quatro fatores para cada objeto na imagem: a posição do pico (X_1), a largura (X_2), o erro médio quadrado (MSE) entre o objeto e a Gaussiana do seu gráfico de intensidade (X_3) e a intensidade do pico (X_4). O programa para extração consistia de três maiores etapas: primeiro, um algoritmo de detecção de pico é usado para detectar objetos em uma imagem linear. Para cada objeto detectado, a intensidade do pico e sua posição são obtidas. Segundo, um algoritmo de detecção de vale é aplicado para encontrar os vales associados a cada objeto detectado anteriormente. Após encontrar os vales, a largura dos objetos é calculada. Terceiro, o MSE entre o gráfico de intensidade de cada objeto e sua Gaussiana é computado.

Liao e Tang[2] utilizaram redes neurais MLP (Multi-Layered Perceptron) para reconhecimento de padrões, i.e., distinguir soldas de qualquer objeto que não seja um cordão soldado, baseado nos parâmetros definidos anteriormente, detecção de picos (vales) e sua similaridade com a Gaussiana. Foram usadas 100 soldas em 25 imagens. Verificou-se que a detecção foi perfeita para soldas lineares e quase perfeita para soldas curvas. O percentual de alarme falso variou entre 2 e 12%. Este procedimento foi desenvolvido para extrair os cordões de solda antes de aplicar um algoritmo ou rotina para detecção de defeitos na solda[2].

DESENVOLVIMENTO EXPERIMENTAL

As imagens radiográficas utilizadas foram padrões do IIW (Internacional Institute of Welding) para aumentar a confiabilidade dos resultados obtidos. As radiografias foram digitalizadas com um scanner tipo Flatbed UMAX Mirage II, com resolução de 500 dpi (dots per inch – resultando em um tamanho médio de pixel de 50μm) e 256 níveis de cinza, sendo armazenadas no formato TIFF (sem compressão). Estes padrões contêm imagens com todos os tipos de defeitos detectáveis pelo exame radiográfico, como falta de fusão, falta de penetração, porosidade, inclusão de escória, mordedura, trinca, etc.

Conforme verificado em várias publicações[3-5], normalmente é necessário que seja feito um préprocessamento na imagem radiográfica antes que se proceda a extração da solda, com o objetivo de melhorar a qualidade da imagem, e proporcionar a redução na taxa de erros deste procedimento. O pré-processamento consiste, principalmente, da aplicação de dois procedimentos de melhoramento da imagem, conforme proposto por [3-5], inicialmente deve-se reduzir, e se possível eliminar, o ruído decorrente da digitalização da imagem, e posteriormente fazer um realçamento do contraste da imagem. As imagens foram trabalhadas no programa de tratamento de imagens Image Pro Plus 4.0 (Media Cybenetcs), de onde, posteriormente ao pré-processamento, foram extraídos os perfis transversais de níveis de cinza nos cordões de solda, segundo figura 1. Um total de 100 perfis de cordão de solda sem presença de defeitos foi extraído, assim como 100 perfis de cordões aonde havia a existência de defeitos de soldagem.

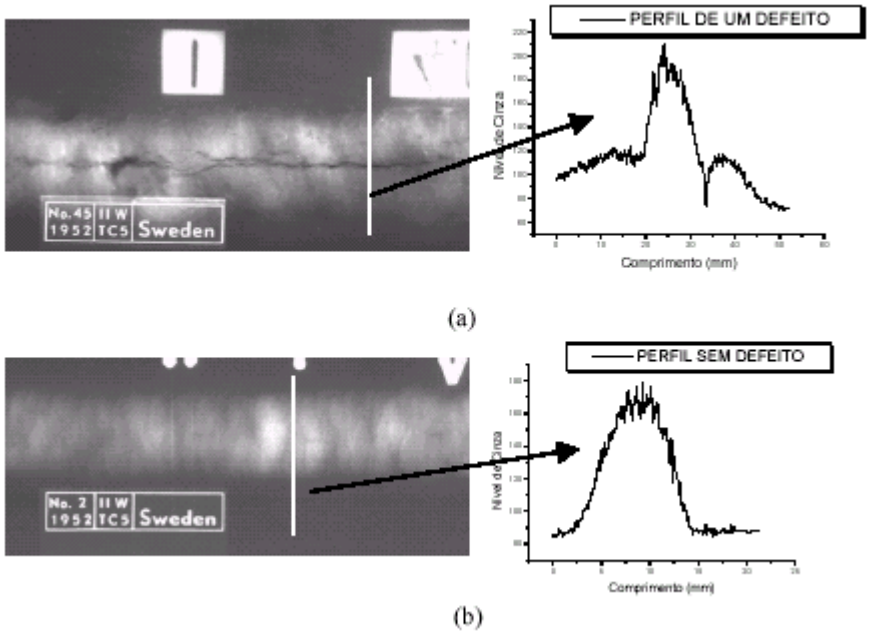

Figura 1: (a) Perfil transversal ao cordão de solda para a situação de presença de defeito no cordão; (b) perfil transversal para a situação de ausência de defeito.

Aos perfis obtidos, foi aplicado o filtro Savitzky-Golay[6] com o objetivo de suavizar o ruído ainda existente após pré-processamento com filtro mediana[3]. Este filtro é tipicamente utilizado para suavizar um sinal de banda larga com ruído. Escolheu-se este filtro porque ele é superior à média móvel padrão, no sentido de que o novo ponto, o ponto existente após aplicação do filtro, é obtido de uma regressão polinomial local que minimiza o erro quadrático dos dados ruidosos do intervalo, e não pela média dos pontos adjacentes como ocorre com o Filtro de Média Móvel padrão, que tende a eliminar uma porção importante do conteúdo de alta freqüência do sinal junto com o ruído. Este método preserva certas características dos dados, tais como os picos e largura de intervalo[6]. A partir do sinal/perfil suavizado, fez-se uma regressão não linear do perfil segundo a curva de Gauss, sabendo-se que os perfis transversais a juntas soldadas com reforço têm um comportamento Gaussiano[1,2]. Posteriormente, os parâmetros média e desvio padrão dos perfis Gaussianos obtidos foram utilizados para definir o limite de corte para a extração do cordão de solda, sem perda de informações da solda, e retirando do sinal informações irrelevantes do metal de base. A figura 2 mostra a seqüência das etapas realizadas pelo algoritmo de extração de cordão.

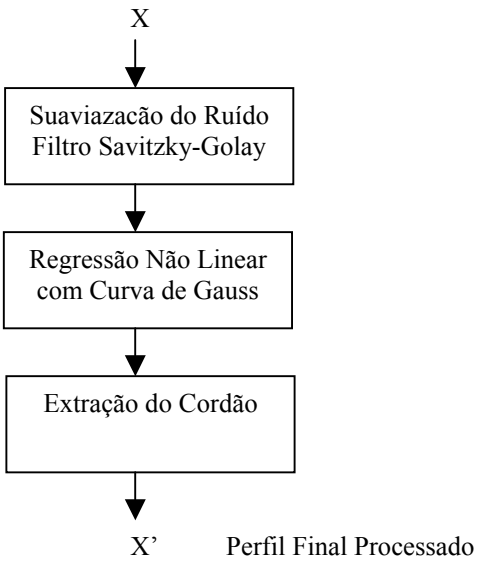

Figura 2: Etapas utilizadas para Extração do perfil contendo apenas o cordão de solda.

Antes de formar os conjuntos de dados de treinamento e teste para os classificadores, procedeu-se uma normalização dos perfis processados e reduzidos para terem média zero e desvio padrão igual a 1 (μ=0, ó=1). Com isso, permite-se que todos os perfis tenham escalas similares de amplitude, o que facilita o treinamento e desempenho dos classificadores.

O conjunto de treinamento das redes neurais foi composto de 70 perfis contendo defeitos e 70 perfis sem presença de defeito. Dois conjuntos de treinamento foram construídos: um conjunto com os perfis originais sem aplicação do filtro Savitzky-Golay, neste caso a extração do cordão foi realizada diretamente nos perfis sem processamento; e um segundo conjunto com os perfis após suavização e extração, ambos com a mesma quantidade de perfis. Para avaliar a capacidade de generalização do classificador, ou seja, acertar corretamente entradas que não tenham sido usadas durante a etapa de aprendizagem da rede neural, formou-se dois conjuntos de teste da mesma forma que os perfis de treinamento (com e sem processamento), mas contendo cada conjunto 30 perfis com presença de defeito e 30 sem defeito existente. Cada perfil utilizado possui 500 pontos, resultantes após extração do cordão de solda.

Normalmente, quando se trabalha com reconhecimento de padrão, avalia-se primeiro a possibilidade de separação entre as classes estudadas por um processo de classificação linear, visto ser este o processo mais simples e fácil de implementação. Conforme descreve Haykin em seu livro[7], e também Bishop[8], uma rede neural de uma única camada pode ser usada para implementação de um classificador linear de padrão. Neste caso, desenvolveu-se para este trabalho classificadores lineares implementados com uma rede neural supervisionada de apenas uma camada, composta por um neurônio do tipo tangente hiperbólica. Como treinamento, o algoritmo de retropropagação do erro foi adotado, usando momento e taxa de aprendizado variável. Uma descrição detalhada destes parâmetros de treinamento é encontrada em uma vasta literatura, como bons exemplos temos Haykin[7] e Bishop[8]. Em Silva[9], encontra-se uma descrição aprofundada do estudo de classificadores lineares de padrões usados para separar defeitos de soldagem típicos como: mordedura, falta de penetração, porosidade e inclusão de escória, mas neste caso, os dados eram compostos por características geométricas extraídas dos defeitos.

Para avaliar a capacidade de separação entre as classes de perfis: com defeito (CD) e sem defeito (SD), recorreu-se a técnica de componentes principais de discriminação linear, também implementada por redes neurais. Um gráfico bidimensional composto pelas duas componentes

principais de discriminação linear foi obtido, permitindo a visualização otimizada do problema proposto. Em Silva[10], detalha-se a implementação desta metodologia.

RESULTADOS E DISCUSSÕES

A figura 3 (a) mostra um exemplo de perfil obtido no trabalho para a um cordão de solda sem a presença de defeitos (SD), neste caso, sem processamento com o filtro de Savitzky-Golay. Fica claro, como podemos observar, a existência de ruído no sinal. A justificativa para presença de ruído em radiografias de materiais é muito discutida e diversos fatores são relacionados[3-5]. Sabe-se, entretanto, que o ruído eletrônico aleatório provocado pelo processo de digitalização é quase sempre presente[3]. Para suavização desse ruído, escolheu-se empiricamente um filtro de Savitzky-Golay com um polinômio de segundo grau em uma janela de processamento de 10×10[6], pois na prática foi o ajuste que permitiu resultado melhor, sem prejuízo significante das altas freqüências de interesse que pudessem haver no perfil, como por exemplo a presença de defeitos. A figura 3(b) representa o perfil resultante obtido para aplicação do filtro no perfil da figura 3(a), mostrando a suavização considerável do ruído, mantendo a forma original do perfil. Na mesma figura 3(b), temos uma linha contínua representando a curva de Gauss obtida para o perfil processado. Observa-se que, distante da média três desvios padrões simetricamente para os dois lados, entramos na região de representação do metal de base, portanto, fora do interesse do trabalho proposto. O mesmo foi verificado para todos os outros perfis (num total de 100) referentes a condição sem defeito (SD), assim como para os 100 perfis com existência de defeito (CD). O que permitiu chegar a conclusão que, com uma boa margem de segurança, pode-se definir o limite de três desvios (3ó) para extração do cordão. É importante destacar que os 100 perfis contendo defeitos tinham as classes porosidade, trinca, falta de penetração, falta de fusão e inclusão de escória conforme indicação do IIW. A classe mordedura, também muito freqüente em cordões de solda, não foi ainda analisada por se tratar de uma classe que normalmente ocorre na borda do cordão, o que cria um fator complicador para a extração do cordão sem eliminação da parte do perfil referente ao defeito. Entretanto, os resultados das extrações automáticas dos cordões para os perfis estudados pelo algoritmo desenvolvido mostraram que esta metodologia é eficiente e menos complexa do que as proposta por Liao[1], por exemplo. A inclusão dos perfis contendo o defeito mordedura nesta metodologia será feita na seqüência do trabalho que está sendo desenvolvido.

A figura 3(c) mostra um perfil original contendo o defeito trinca no cordão de solda, visualizado no "vale" acentuado próximo ao centro do cordão. A figura 3(d) representa o resultado da aplicação do filtro no perfil original, mostrando que o ruído foi claramente alisado, mas a amplitude do "vale" referente ao defeito sofreu uma redução notável, mesmo com as características de preservação de altas freqüências que o filtro possui. O ajuste com curva de Gauss, na figura 3(d), também ilustra a constatação de que, com três desvios padrões distantes da média (centro da Gaussiana), simetricamente, elimina-se a parte do perfil referente ao metal de base. Apenas esta figura é mostrada porque todas as demais obtidas são similares em resultados e observações a respeito do filtro aplicado e da técnica de extração do cordão. Vale destacar que esta técnica destina-se somente as condições em que há ocorrência de reforço de cordão de solda, aonde o comportamento Gaussiano é evidente. Para outras condições, possivelmente outros tipos de ajustes terão que ser feitos.

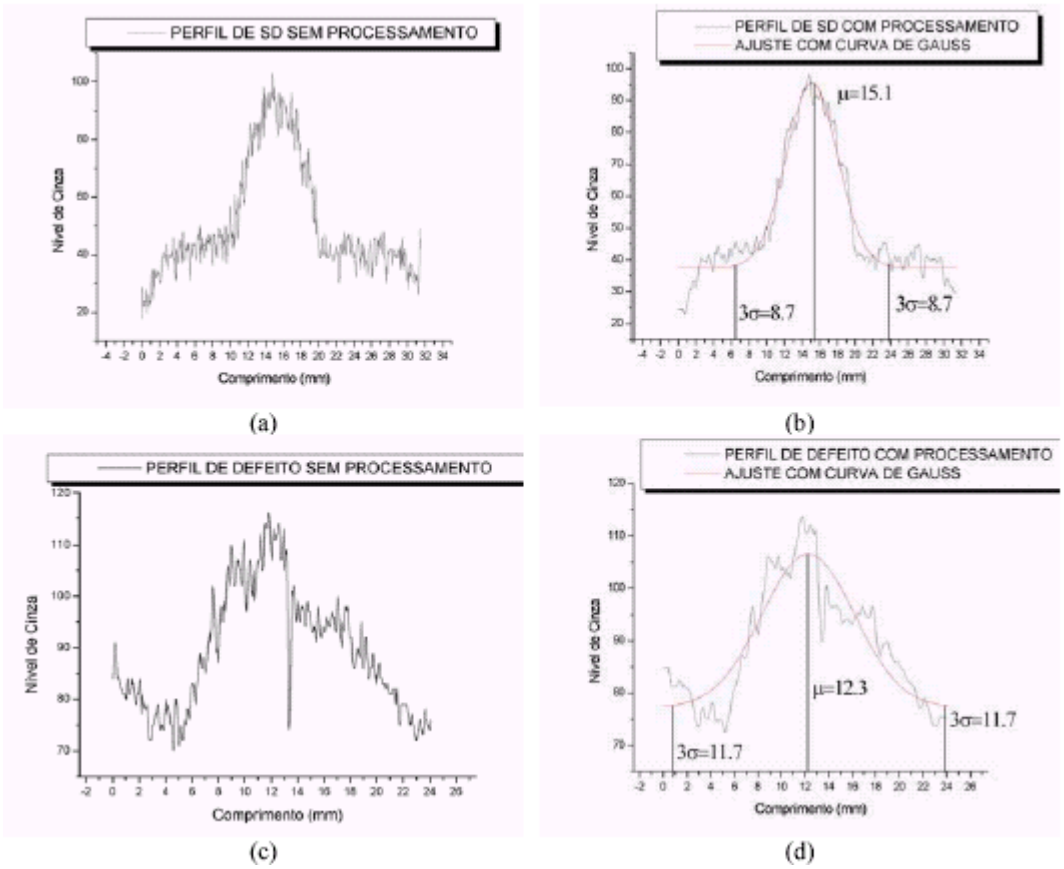

Figura 3: (a) perfil obtido diretamente da imagem radiográfica de uma solda sem defeito na condição sem processamento, aonde a presença de ruído é visível; (b) mesmo perfil com processamento com filtro Savitzy-Golay, e o resultado de um ajuste Gaussiano; (c) perfil de uma radiografia na região de ocorrência de um defeito, sem processamento; (d) perfil anterior com processamento e ajuste Gaussiano.

O gráfico bidimensional obtido para as duas componentes principais de discriminação linear é mostrado na figura 4. A utilização das componentes principais de discriminação usando redes neurais é detalhada em Silva[10], tanto para visualização otimizada da separação entre as classes, quanto para redução da dimensão dos dados de entrada de um classificador. Na figura 4, verifica-se que as duas classes de perfis estudadas CD e SD têm regiões distintas no gráfico e são linearmente separáveis, não sendo necessário portanto a utilização de um classificador não linear.

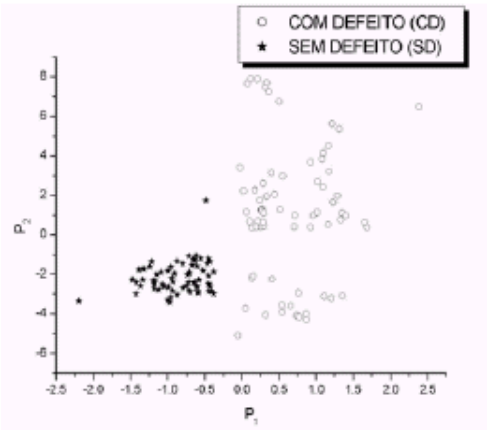

Figura 4: Gráfico das duas componentes principais de discriminação linear.

Os classificadores lineares desenvolvidos pela rede do tipo retropropagação do erro, com treinamento em batelada e usando apenas um neurônio, proporcionaram 100% de acerto geral para os dados de treinamento (70 perfis de cada classe) nas condições de perfis: com e sem processamento com filtro, comprovando o que havia sido constatado no gráfico de separação. Com os dados de teste (30 perfis de cada classe), os sinais sem processamento resultaram em 100% de acerto para os perfis da classe SD e 53.3% de acerto para a classe CD, o que resulta em um índice geral de acerto de 76,7% (46 em um total de 60 perfis). Este índice é consideravelmente bom tendo em vista a simplicidade do classificador e as características complexas de informações que estão presentes em perfis de cinza de cordões de solda, que normalmente contêm ruídos de origem variada, variações intensas de distribuição de cinza e contraste, espessuras não uniformes na seção transversal à imagem e etc.

Com os sinais processados, obteve-se também 100% de acerto para os dados de treinamento. Porém, para este caso, o índice de acerto para a classe CD aumentou para 63,3%, mostrando uma pequena melhora em relação aos perfis sem processamento para esta classe, mantendo os 100% de acerto para a classe SD. O índice geral de acerto para esta condição foi de 81,7% (49 acertos em um total de 60). A tabela 1 contém todos os índices de acerto obtidos em quantidade numérica e percentual.

Estes resultados são excelentes para os dados estudados, mostrando que a utilização de perfis para detecção de defeitos em cordões de solda é plenamente viável utilizando redes neurais. Entretanto, mais investigações são necessárias para aprofundamento desta linha de pesquisa, principalmente nas fases de pré-processamento dos sinais com filtros visando a suavização de ruídos e realce das descontinuidades que possam existir, assim como normalização dos perfis. Na seqüência do trabalho, os mesmos classificadores e possivelmente também os classificadores não lineares serão estudados para a classificação de cada classe de defeito de soldagem. Assim como a utilização de redes neurais não supervisionadas.

Tabela 1: Índices de acerto numérico e percentual para os conjuntos de dados usados para treinamento e teste dos classificadores lineares.

	SEM PROCESSAMENTO		***COM PROCESSAMENTO***	
	Treinamento	Teste	Treinamento	Teste
Com Defeito (CD)	70 (100%)	16 (53,3%)	70 (100%)	19 (63,3%)
Sem Defeito (SD)	70 (100%)	30 (100%)	70 (100%)	30 (100%)
Índice Geral de Acerto	140 (100%)	46 (76,7%)	140 (100%)	49 (81,7%)

CONCLUSÕES

Conforme constatado por Liao, os perfis transversais de níveis de cinza em cordões de solda reforçados têm realmente um comportamento normalmente Gaussiano.

Para os perfis estudados, a metodologia empregada para extração do cordão de solda se mostrou eficiente, com os perfis sendo extraídos no limite de três desvios padrões a partir da média (centro do cordão) simetricamente. A inclusão da classe mordedura nesta metodologia será realizada subseqüentemente no trabalho.

A separação entre perfis sem a presença de defeito e com a ocorrência de defeitos é comprovadamente possível usando apenas um classificador linear. Isto deve ser ainda mais evidente com o aprofundamento das etapas de pré-processamento dos perfis.

O presente trabalho motiva a continuação dos estudos no sentido de avaliar técnicas de detecção e classificação de defeitos de soldagem através dos perfis transversais aos cordões em radiografias,usando redes neurais para implementação dos classificadores de padrões. Com isto, visa-se darcontribuições relevantes ao desenvolvimento de um sistema automático de análise e interpretação deradiografias industriais.

AGRADECIMENTOS

Os autores do trabalho agradecem o apoio financeiro e as bolsas de estudo dados pelos órgãos FAPERJ, CNPq e CAPES, assim como a PETROBRAS pelo incentivo dado ao seu funcionário e aluno de doutorado Germano para a consolidação da sua tese.

REFERÊNCIAS BIBLIOGRÁFICAS

1. Liao T W, Li Y. “An Automated Radiographic NDT System for Weld Inspection: Part II – Flaw Detection”. NDT&E International 1998. Vol.31. N.3.pp. 183-192.
2. Liao T W, Tang K. “Automated Extraction of Welds from Digitized Radiographic Images Based on MLP Neural Networks”. Applied Artificial Intelligence 1997. vol.11.pp 197-218.
3. Silva R R. “Radiographic Image Processing and Analysis of Defects in Weld Bead”. Master’s Degree. PEMM/COPPE/UFRJ. RJ, Brazil,1999. (In Portuguese).
4. Kehoe A, Parker G A. “Image Processing for Industrial Radiographic Inspection: Image Enhancement”. British Journal of NDT 1990; Vol.32 N.4. pp. 183-190.
5. Murakami, K. “Image Processing For Non-Detructive Testing. Welding International. 1990;144-149.
6. Sophocles, J.O. Introduction to Signal Processing. Prentice-Hall.1995.
7. Haykin S. Neural Networks – A Comprehensive Foundation. Macmillian College Publishing. Inc. 1994.
8. Bishop C. M. Neural Networks for Pattern Recognition. New York. Oxford University Press. 1995. 9. Silva R R, Siqueira M H. S, Calôba L P, et al. Radiographics Pattern Recognition of Welding Defects using Linear Classifiers. Insight 2001. Vol. 43. N.10: 669-674.
10. Silva, R.R. et al. Patterns Nonlinear Classifiers of Weld Defects in Industrial Radiographies. 3rd PANNDT. June 2003. Rio de Janeiro. Brazil.

APÊNDICE B.5

3º Pan-NDT 2003 – Congresso Pan-americano em Ensaios Não Destrutivos

EXTRAÇÃO DO CORDÃO DE SOLDA E DETECÇÃO DE DEFEITOS EM RADIOGRAFIAS USANDO REDES NEURAIS

Germano X. de Padua
Engenheiro de Equipamentos Pleno
PETROBRAS/MATERIAIS/CQDM/IDFA
Av Rep. Chile, 65, sl 601 - CEP 20035-900 Rio de Janeiro Brasil
E-mail: germanox@petrobras.com.br

Romeu R. da Silva
Programa de Engenharia Metalúrgica e de Materiais/COPPE/UFRJ
Laboratório de Ensaios Não Destrutivos, Cidade universitária, CT
Bloco I Sala I-243 CEP 21945-970 Rio de Janeiro Brasil
E-mail:romeu@metalmat.ufrj.br
http://www.metalmat.ufrj.br

Raquel R. Lavouras
Departamento de Engenharia Metalúrgica e de Materiais, Escola de Engenharia/UFRJ
Laboratório de Ensaios Não Destrutivos, Cidade universitária, CT
Bloco I Sala I-243 CEP 21945-970 Rio de Janeiro Brasil
E-mail:raquel@metalmat.ufrj.br
http://www.metalmat.ufrj.br

Professor João M. A. Rebello
Programa de Engenharia Metalúrgica e de Materiais/COPPE/UFRJ
Laboratório de Ensaios Não Destrutivos, Cidade universitária, CT
Bloco I Sala I-243 CEP 21945-970 Rio de Janeiro Brasil
E-mail:jmarcos@metalmat.ufrj.br
http://www.metalmat.ufrj.br

Professor Luiz P. Calôba
Programa de Engenharia Elétrica/COPPE/UFRJ
Laboratório de Processamento de Sinais, Cidade Universitária, CT
Bloco H Sala H-220 CEP 21945-970 Rio de Janeiro
E-mail:caloba@lps.ufrj.br
http://www.lps.ufrj.br

Resumo. *O ensaio radiográfico é um dos ensaios não-destrutivos mais antigos, sendo utilizado amplamente no controle da qualidade de equipamentos e materiais em vários tipos de indústrias. Uma das maiores aplicações da inspeção por raios-X ou raios gama é na inspeção de juntas soldadas. Por ser um ensaio que depende essencialmente da experiência, qualificação e acuidade visual do inspetor, torna-se subjetivo, o que muitas vezes provoca erros de interpretação, causando a não detecção de um defeito, ou a confusão entre classes de defeitos de soldagem. Outro fator importante neste tipo de ensaio é a qualidade da imagem radiográfica, a qual depende de inúmeros fatores. Em geral, quanto melhor a qualidade da imagem, mais fácil e eficiente será a interpretação da radiografia. Atualmente, após avanços nos campos da informática e das técnicas de inteligência artificial, há diversas pesquisas voltadas para o desenvolvimento de um sistema automático de análise e interpretação de radiografias de juntas soldadas, o que similarmente também ocorre na inspeção radiográfica de peças fundidas e processos tomográficos.*

Para o projeto deste sistema, normalmente são necessárias as etapas de digitalização dos filmes radiográficos, pré-processamentos das imagens digitalizadas e dos dados, e uma etapa de reconhecimento de padrões, sendo esta última freqüentemente implementada por redes neurais artificiais.

Este trabalho tem como objetivo principal apresentar uma metodologia para extração automática de cordão de solda e detecção de defeitos em radiografias, esta última etapa usando redes neurais. Para garantir a precisão dos resultados, utilizou-se padrões radiográficos do IIW (Internacional Institute of Welding). Apresenta-se, primeiramente, um método para separação do cordão de solda da região de metal de base na imagem radiográfica. Para tal, utilizou-se as curvas Gaussianas obtidas dos perfis de níveis de cinza transversais ao cordão. Posteriormente, estes perfis são pré-processados e são utilizados para formação do conjunto de treinamento e teste dos classificadores lineares desenvolvidos por redes neurais supervisionadas. Os resultados conseguidos até o presente momento incentivam a publicação deste trabalho.

Palavras-chaves: *Radiografia, Extração de Cordão, Defeitos de Soldagem, Reconhecimento de padrão e Redes Neurais*

1. INTRODUÇÃO

Existem alguns pesquisas, muitas delas ainda em fase inicial, que visam a automatização do processo de análise e interpretação de defeitos em radiográfias, normalmente dividido em quatro etapas principais: digitalização da radiografia/aquisição da imagem, extração do cordão de solda, detecção e classificação de defeitos. A primeira etapa consiste da digitalização do filme radiográfico por meio de um *scanner* desenvolvido para este fim, proporcionando resolução adequada, ou mais recentemente, a aquisição já digitalizada da radiografia. A extração do cordão de solda consiste de um algoritmo de tratamento de imagem para extrair somente a área de interesse e reduzir o tempo gasto nas etapas subseqüentes. Na detecção dos defeitos, são aplicados algoritmos para o reconhecimento de anomalias no perfil da imagem, estes algoritmos são aplicados com sistemas inteligentes (redes neurais artificiais mais freqüentemente) e devem prever a existência de descontinuidades ao longo da imagem da solda. Por fim, a classificação dos defeitos também é executada automaticamente, de forma que o defeito encontrado anteriormente seja reconhecido dentre os diversos tipos, considerando a sua geometria, localização dentro do cordão e outras particularidades relativas à imagem, além de classificá-lo quanto a aceitação de acordo com a norma ou código aplicável (ASME, ASNT, ASTM, etc.)

No presente trabalho, apresenta-se os resultados obtidos com uma metodologia para extração automática do cordão de solda de padrões radiográficos do IIW (*Internacional Institute of Welding*). O algoritmo empregado envolve as etapas de suavização de ruído com o filtro Savitzky-Golay, regressão não linear dos perfis com base na curva de Gauss e extração das partes referentes ao cordão de solda, dispensando a informação irrelevante do metal de base. Posteriormente, os perfis resultantes são usados em classificadores lineares de padrões desenvolvidos com redes neurais artificiais para separação entre perfis contendo defeitos no cordão de solda e perfis sem defeito.

2. REVISÃO BIBLIOGRÁFICA

Warren Liao e Jiawei Ni[1] desenvolveram uma metodologia baseada na observação de que o gráfico de intensidade de nível de cinza em um cordão de solda aproxima-se mais de uma Gaussiana do que os outros objetos da mesma imagem. Para Liao [1], a similaridade entre o gráfico de intensidade de cada objeto e sua Gaussiana é definido em termos do erro médio quadrado (MSE). Assumindo que o objeto é centrado em x = X e seus vales a esquerda e direita estão localizado em x = X–d e x = X+d, MSE é calculado pela equação 1:

$$MSE = \frac{\sum_{x=X-d}^{X+d} f(x) - g(x)}{2d} \tag{1}$$

onde d é a distância entre o pico e o seu vale mais próximo.

O objeto com menor MSE é considerado mais similar a Gaussiana. Visto que geralmente o gráfico de intensidade de uma solda parece mais Gaussiano que outros objetos, o objeto com menor MSE pode ser identificado como a solda. Liao recorreu a este princípio para desenvolver uma metodologia para extração do cordão de solda em radiografias, conforme detalhado em [1].

Extração de Características através de Perfis de Níveis de Cinza

Para distinguir objetos da solda de outros objetos estranhos ao cordão, fatores com capacidade de discriminação devem ser identificados, isto é, deve ser feita uma seleção de parâmetros característicos. Liao e Tang[2] utilizaram a técnica "eyeball" para determinar estes fatores, baseados na observação dos gráficos de intensidade das imagens. Eles definiram, então, quatro fatores para cada objeto na imagem: a posição do pico (x_1), a largura (x_2), o erro médio quadrado (MSE) entre o objeto e a Gaussiana do seu gráfico de intensidade (x_3) e a intensidade do pico (x_4). O programa para extração consistia de três maiores etapas: primeiro, um algoritmo de detecção de pico é usado para detectar objetos em uma imagem linear. Para cada objeto detectado, a intensidade do pico e sua posição são obtidos. Segundo, um algoritmo de detecção de vale é aplicado para encontrar os vales associados a cada objeto detectado anteriormente. Após encontrar os vales, a largura dos objetos é calculada. Terceiro, o MSE entre o gráfico de intensidade de cada objeto e sua Gaussiana é computado.

Liao e Tang[2] utilizaram redes neurais MLP (*Multi-Layered Perceptron*) para reconhecimento de padrões, i.e., distinguir soldas de qualquer objeto que não seja um cordão soldado, baseado nos parâmetros definidos anteriormente, detecção de picos (vales) e sua similaridade com a Gaussiana. Foram usadas 100 soldas em 25 imagens. Verificou-se que a detecção foi perfeita para soldas lineares e quase perfeita para soldas curvas. O percentual de alarme falso variou entre 2 e 12%. Este procedimento foi

desenvolvido para extrair os cordões de solda antes de aplicar um algoritmo ou rotina para detecção de defeitos na solda[2].

3. DESENVOLVIMENTO EXPERIMENTAL

As imagens radiográficas utilizadas foram padrões do IIW (*Internacional Institute of Welding*) para aumentar a confiabilidade dos resultados obtidos. As radiografias foram digitalizadas com um *scanner* tipo Flatbed UMAX Mirage II, com resolução de 500 dpi (dots per inch – resultando em um tamanho médio de pixel de 50μm) e 256 níveis de cinza, sendo armazenadas no formato TIFF (sem compressão). Estes padrões contêm imagens com todos os tipos de defeitos detectáveis pelo exame radiográfico, como falta de fusão, falta de penetração, porosidade, inclusão de escória, mordedura, trinca, etc.

Conforme verificado em várias publicações[3,-5], normalmente é necessário que seja feito um pré-processamento na imagem radiográfica antes que se proceda a extração da solda, com o objetivo de melhorar a qualidade da imagem, e proporcionar a redução na taxa de erros deste procedimento.

O pré-processamento consiste, principalmente, da aplicação de dois procedimentos de melhoramento da imagem, conforme proposto por [3-5], inicialmente deve-se reduzir, e se possível eliminar, o ruído decorrente da digitalização da imagem, e posteriormente fazer um realçamento do contraste da imagem. As imagens foram trabalhadas no programa de tratamento de imagens Image Pro Plus 4.0 (Media Cybenetcs), de onde, posteriormente ao pré-processamento, foram extraídos os perfis transversais de níveis de cinza nos cordões de solda, segundo figura 1. Um total de 100 perfis de cordão de solda sem presença de defeitos foram extraídos, assim como 100 perfis de cordões aonde havia a existência de defeitos de soldagem.

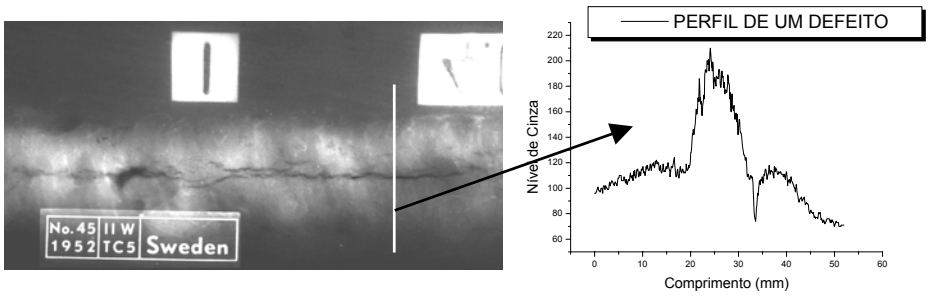

(a)

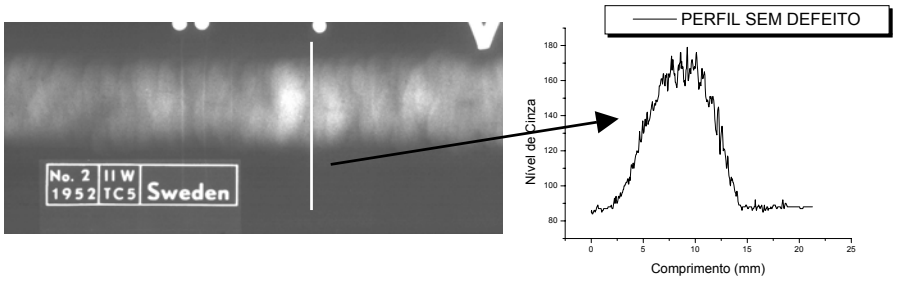

(b)

Figura 1: (a) Perfil transversal ao cordão de solda para a situação de presença de defeito no cordão; (b) perfil transversal para a situação de ausência de defeito.

Aos perfis obtidos, foi aplicado o filtro Savitzky-Golay[6] com o objetivo de suavizar o ruído ainda existente após pré-processamento com filtro mediana[3]. Este filtro é tipicamente utilizado para suavizar um sinal de banda larga com ruído. Escolheu-se este filtro porque ele é superior à média móvel padrão, no sentido de que o novo ponto, o ponto existente após aplicação do filtro, é obtido de uma regressão polinomial local que minimiza o erro quadrático dos dados ruidosos do intervalo, e não pela média dos pontos adjacentes como ocorre com o Filtro de Média Móvel padrão, que tende a eliminar uma porção importante do conteúdo de alta freqüência do sinal junto com o ruído. Este método preserva certas características dos dados, tais como os picos e largura de intervalo[6].

A partir do sinal/perfil suavizado, fez-se uma regressão não linear do perfil segundo a curva de Gauss, sabendo-se que os perfis transversais a juntas soldadas com reforço têm um comportamento

Gaussiano[1,2]. Posteriormente, os parâmetros média e desvio padrão dos perfis Gaussianos obtidos foram utilizados para definir o limite de corte para a extração do cordão de solda, sem perda de informações da solda, e retirando do sinal informações irrelevantes do metal de base. A figura 2 mostra a seqüência das etapas realizadas pelo algoritmo de extração de cordão.

Figura 2: Etapas utilizadas para Extração do perfil contendo apenas o cordão de solda.

Antes de formar os conjuntos de dados de treinamento e teste para os classificadores, procedeu-se uma normalização dos perfis processados e reduzidos para terem média zero e desvio padrão igual a 1 (μ=0, σ=1). Com isso, permite-se que todos os perfis tenham escalas similares de amplitude, o que facilita o treinamento e desempenho dos classificadores.

O conjunto de treinamento das redes neurais foi composto de 70 perfis contendo defeitos e 70 perfis sem presença de defeito. Dois conjuntos de treinamento foram construídos: um conjunto com os perfis originais sem aplicação do filtro Savitzky-Golay, neste caso a extração do cordão foi realizada diretamente nos perfis sem processamento; e um segundo conjunto com os perfis após suavização e extração, ambos com a mesma quantidade de perfis. Para avaliar a capacidade de generalização do classificador, ou seja, acertar corretamente entradas que não tenham sido usadas durante a etapa de aprendizagem da rede neural, formou-se dois conjuntos de teste da mesma forma que os perfis de treinamento (com e sem processamento), mas contendo cada conjunto 30 perfis com presença de defeito e 30 sem defeito existente. Cada perfil utilizado possui 500 pontos, resultantes após extração do cordão de solda.

Normalmente, quando se trabalha com reconhecimento de padrão, avalia-se primeiro a possibilidade de separação entre as classes estudadas por um processo de classificação linear, visto ser este o processo mais simples e fácil de implementação. Conforme descreve Haykin em seu livro[7], e também Bishop[8], uma rede neural de uma única camada pode ser usada para implementação de um classificador linear de padrão. Neste caso, desenvolveu-se para este trabalho classificadores lineares implementados com uma rede neural supervisionada de apenas uma camada, composta por um neurônio do tipo tangente hiperbólica. Como treinamento, o algoritmo de retropropagação do erro foi adotado, usando momento e taxa de aprendizado variável. Uma descrição detalhada destes parâmetros de treinamento é encontrada em uma vasta literatura, como bons exemplos temos Haykin[7] e Bishop[8]. Em Silva[9], encontra-se uma descrição aprofundada do estudo de classificadores lineares de padrões usados para separar defeitos de soldagem típicos como: mordedura, falta de penetração, porosidade e inclusão de escória, mas neste caso, os dados eram compostos por características geométricas extraídas dos defeitos.

Para avaliar a capacidade de separação entre as classes de perfis: com defeito (CD) e sem defeito (SD), recorreu-se a técnica de componentes principais de discriminação linear, também implementada por redes neurais. Um gráfico bidimensional composto pelas duas componentes principais de discriminação linear foi obtido, permitindo a visualização otimizada do problema proposto. Em Silva[10], detalha-se a implementação desta metodologia.

4. RESULTADOS E DISCUSSÕES

A figura 3 (a) mostra um exemplo de perfil obtido no trabalho para a um cordão de solda sem a presença de defeitos (SD), neste caso, sem processamento com o filtro de Savitzky-Golay. Fica claro, como podemos observar, a existência de ruído no sinal. A justificativa para presença de ruído em radiografias de materiais é muito discutida e diversos fatores são relacionados[3-5]. Sabe-se, entretanto, que o ruído eletrônico aleatório provocado pelo processo de digitalização é quase sempre presente[3]. Para suavização desse ruído, escolheu-se empiricamente um filtro de Savitzky-Golay com um polinômio de segundo grau em uma janela de processamento de 10×10[6], pois na prática foi o ajuste que permitiu resultado melhor, sem prejuízo significante das altas freqüências de interesse que pudessem haver no perfil, como por exemplo a presença de defeitos. A figura 3(b) representa o perfil resultante obtido para aplicação do filtro no perfil da figura 3(a), mostrando a suavização considerável do ruído, mantendo a forma original do perfil. Na mesma figura 3(b), temos uma linha contínua representando a curva de Gauss obtida para o perfil processado. Observa-se que, distante da média três desvios padrões simetricamente para os dois lados, entramos na região de representação do metal de base, portanto, fora do interesse do trabalho proposto. O mesmo foi verificado para todos os outros perfis (num total de 100) referentes a condição sem defeito (SD), assim como para os 100 perfis com existência de defeito (CD). O que permitiu chegar a conclusão que, com uma boa margem de segurança, pode-se definir o limite de três desvios (3σ) para extração do cordão. É importante destacar que os 100 perfis contendo defeitos tinham as classes porosidade, trinca, falta de penetração, falta de fusão e inclusão de escória conforme indicação do IIW. A classe mordedura, também muito freqüente em cordões de solda, não foi ainda analisada por se tratar de uma classe que normalmente ocorre na borda do cordão, o que cria um fator complicador para a extração do cordão sem eliminação da parte do perfil referente ao defeito. Entretanto, os resultados das extrações automáticas dos cordões para os perfis estudados pelo algoritmo desenvolvido mostraram que esta metodologia é eficiente e menos complexa do que as proposta por Liao[1], por exemplo. A inclusão dos perfis contendo o defeito mordedura nesta metodologia será feita na seqüência do trabalho que está sendo desenvolvido.

A figura 3(c) mostra um perfil original contendo o defeito trinca no cordão de solda, visualizado no "vale" acentuado próximo ao centro do cordão. A figura 3(d) representa o resultado da aplicação do filtro no perfil original, mostrando que o ruído foi claramente alisado, mas a amplitude do "vale" referente ao defeito sofreu uma redução notável, mesmo com as características de preservação de altas freqüências que o filtro possui. O ajuste com curva de Gauss, na figura 3(d), também ilustra a constatação de que, com três desvios padrões distantes da média (centro da Gaussiana), simetricamente, elimina-se a parte do perfil referente ao metal de base. Apenas esta figura é mostrada porque todas as demais obtidas são similares em resultados e observações a respeito do filtro aplicado e da técnica de extração do cordão. Vale destacar que esta técnica destina-se somente as condições em que há ocorrência de reforço de cordão de solda, aonde o comportamento Gaussiano é evidente. Para outras condições, possivelmente outros tipos de ajustes terão que ser feitos.

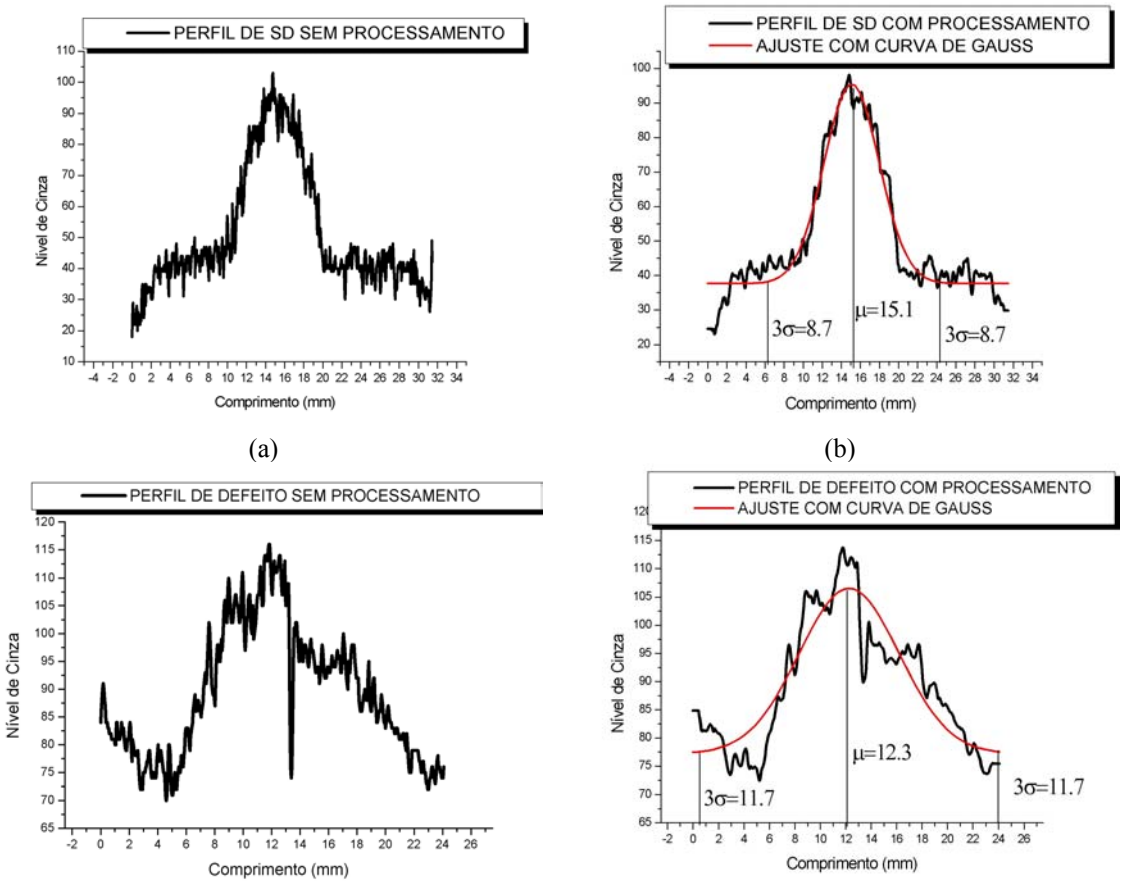

Figura 3: (a) perfil obtido diretamente da imagem radiográfica de uma solda sem defeito na condição sem processamento, aonde a presença de ruído é visível; (b) mesmo perfil com processamento com filtro Savitzy-Golay, e o resultado de um ajuste Gaussiano; (c) perfil de uma radiografia na região de ocorrência de um defeito, sem processamento; (d) perfil anterior com processamento e ajuste Gaussiano.

O gráfico bidimensional obtido para as duas componentes principais de discriminação linear é mostrado na figura 4. A utilização das componentes principais de discriminação usando redes neurais é detalhada em Silva[10], tanto para visualização otimizada da separação entre as classes, quanto para redução da dimensão dos dados de entrada de um classificador. Na figura 4, verifica-se que as duas classes de perfis estudadas **CD** e **SD** têm regiões distintas no gráfico e são linearmente separáveis, não sendo necessário portanto a utilização de um classificador não linear.

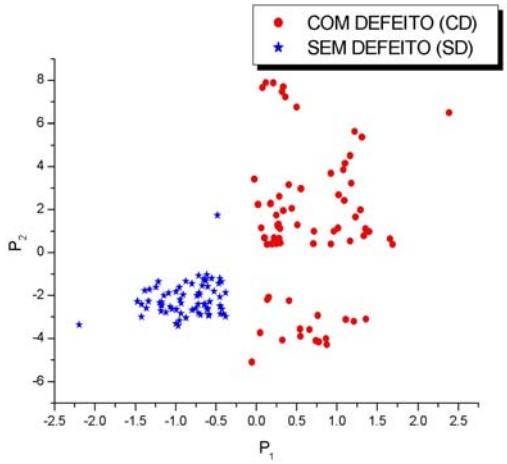

Figura 4: Gráfico das duas componentes principais de discriminação linear.

Os classificadores lineares desenvolvidos pela rede do tipo retropropagação do erro, com treinamento em batelada e usando apenas um neurônio, proporcionaram 100% de acerto geral para os dados de treinamento (70 perfis de cada classe) nas condições de perfis: com e sem processamento com filtro, comprovando o que havia sido constatado no gráfico de separação. Com os dados de teste (30 perfis de cada classe), os sinais sem processamento resultaram em 100% de acerto para os perfis da classe **SD** e 53.3% de acerto para a classe **CD**, o que resulta em um índice geral de acerto de 76,7% (46 em um total de 60 perfis). Este índice é consideravelmente bom tendo em vista a simplicidade do classificador e as características complexas de informações que estão presentes em perfis de cinza de cordões de solda, que normalmente contêm ruídos de origem variada, variações intensas de distribuição de cinza e contraste, espessuras não uniformes na seção transversal à imagem e etc.

Com os sinais processados, obteve-se também 100% de acerto para os dados de treinamento. Porém, para este caso, o índice de acerto para a classe **CD** aumentou para 63,3%, mostrando uma pequena melhora em relação aos perfis sem processamento para esta classe, mantendo os 100% de acerto para a classe **SD**. O índice geral de acerto para esta condição foi de 81,7% (49 acertos em um total de 60). A tabela 1 contém todos os índices de acerto obtidos em quantidade numérica e percentual.

Estes resultados são excelentes para os dados estudados, mostrando que a utilização de perfis para detecção de defeitos em cordões de solda é plenamente viável utilizando redes neurais. Entretanto, mais investigações são necessárias para aprofundamento desta linha de pesquisa, principalmente nas fases de pré-processamento dos sinais com filtros visando a suavização de ruídos e realce das descontinuidades que possam existir, assim como normalização dos perfis. Na seqüência do trabalho, os mesmos classificadores e possivelmente também os classificadores não lineares serão estudados para a classificação de cada classe de defeito de soldagem. Assim como a utilização de redes neurais não supervisionadas.

Tabela 1: Índices de acerto numérico e percentual para os conjuntos de dados usados para treinamento e teste dos classificadores lineares.

	SEM PROCESSAMENTO		**COM PROCESSAMENTO**	
	Treinamento	Teste	Treinamento	Teste
Com defeito (CD)	70 (100%)	16 (53,3%)	70 (100%)	19 (63,3%)
Sem defeito (SD)	70 (100%)	30 (100%)	70 (100%)	30 (100%)
Índice Geral de acerto	140 (100%)	46 (76,7%)	140 (100%)	49 (81,7%)

5. CONCLUSÕES

Conforme constatado por Liao, os perfis transversais de níveis de cinza em cordões de solda reforçados têm realmente um comportamento normalmente Gaussiano.

Para os perfis estudados, a metodologia empregada para extração do cordão de solda se mostrou eficiente, com os perfis sendo extraídos no limite de três desvios padrões a partir da média (centro do cordão) simetricamente. A inclusão da classe mordedura nesta metodologia será realizada subseqüentemente no trabalho.

A separação entre perfis sem a presença de defeito e com a ocorrência de defeitos é comprovadamente possível usando apenas um classificador linear. Isto deve ser ainda mais evidente com o aprofundamento das etapas de pré-processamento dos perfis.

O presente trabalho motiva a continuação dos estudos no sentido de avaliar técnicas de detecção e classificação de defeitos de soldagem através dos perfis transversais aos cordões em radiografias, usando redes neurais para implementação dos classificadores de padrões. Com isto, visa-se dar contribuições relevantes ao desenvolvimento de um sistema automático de análise e interpretação de radiografias industriais.

6. AGRADECIMENTOS

Os autores do trabalho agradecem o apoio financeiro e as bolsas de estudo dados pelos órgãos FAPERJ, CNPq e CAPES, assim como a PETROBRAS pelo incentivo dado ao seu funcionário e aluno de doutorado Germano para a consolidação da sua tese.

7. REFERÊNCIAS BIBLIOGRÁFICAS

1. Liao T W, Li Y. "An Automated Radiographic NDT System for Weld Inspection: Part II – Flaw Detection". NDT&E International 1998. Vol.31. N.3.pp. 183-192.
2. Liao T W, Tang K. "Automated Extraction of Welds from Digitized Radiographic Images Based on MLP Neural Networks". Applied Artificial Intelligence 1997. vol.11.pp 197-218.
3. Silva R R. "Radiographic Image Processing and Analysis of Defects in Weld Bead". Master's Degree. PEMM/COPPE/UFRJ. RJ, Brazil,1999. (In Portuguese).
4. Kehoe A, Parker G A. "Image Processing for Industrial Radiographic Inspection: Image Enhancement". British Journal of NDT 1990; Vol.32 N.4. pp. 183-190.
5. Murakami, K**.** "Image Processing For Non-Detructive Testing. Welding International. 1990;144-149.
6. Sophocles, J.O. Introduction to Signal Processing. Prentice-Hall.1995.
7. Haykin S. Neural Networks – A Comprehensive Foundation. Macmillian College Publishing. Inc. 1994.
8. Bishop C. M. Neural Networks for Pattern Recognition. New York. Oxford University Press. 1995.
9. Silva R R, Siqueira M H. S, Calôba L P, et al. Radiographics Pattern Recognition of Welding Defects using Linear Classifiers. Insight 2001. Vol. 43. N.10: 669-674.
10. Silva, R.R. et al. Patterns Nonlinear Classifiers of Weld Defects in Industrial Radiographies. 3rd PAN-NDT. June 2003. Rio de Janeiro. Brazil.