

RECONHECIMENTO DE PADRÕES DE DEFEITOS DE SOLDAGEM EM  
RADIOGRAFIAS INDUSTRIAIS

Romeu Ricardo da Silva

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. José Manoel de Seixas, D.Sc.

---

Prof. Ricardo Tadeu Lopes, D.Sc.

---

Prof. Luís Volnei Sudati Sagrilo, D.Sc.

---

Prof. Domingo Arturo Mery Quiroz, Dr.Ing.

RIO DE JANEIRO RJ, BRASIL

DEZEMBRO DE 2003

DA SILVA, ROMEU RICARDO

Reconhecimento de Defeitos de Soldagem  
em Radiografias Industriais [Rio de Janeiro]  
2003

XIV, 150p. 29,7cm (COPPE/UFRJ, D.Sc.,  
Engenharia Metalúrgica e de Materiais, 2003)

Tese – Universidade Federal do Rio de  
Janeiro, COPPE

1. Ensaaios Não-Destrutivos
2. Inspeção Radiográfica
3. Defeitos de Soldagem
4. Reconhecimento de Padrões

I. COPPE/UFRJ    II. Título (série)

*Sede como os pássaros que, ao pousarem um instante sobre ramos muito  
leves, sentem-nos ceder, mas cantam! Eles sabem que possuem asas.*  
(Victor Hugo)

## DEDICATÓRIA

---

*Dedico aos meus avôs Nestor e Romeu, e as minhas avós Amábíla e Maria de Lourdes, por tudo aquilo que significaram em suas existências, pela bela origem da minha educação. Aonde quer que estejam, sei que cuidaram de mim... IN MEMMORIAN*

---

*Dedico aos meus amados pais Nestor e Ayrce, e ao meu amado irmão Rogério. Vocês foram sempre tudo além do que eu merecia, me deram sempre mais do que podiam, sem nunca terem cobrado de mim uma atitude que fosse. Certamente, tudo o que fiz e que procuro ser justifica-se na existência de vocês na minha história de vida. Deus não poderia ter sido mais generoso comigo, tendo vocês como família...*

---

## AGRADECIMENTOS

---

Ao meu orientador, professor João Marcos Alcoforado Rebello, agradeço muito por sua orientação em todos os momentos da tese. Sempre atencioso com as minhas necessidades, me forneceu todo o suporte que foi preciso para realização deste trabalho, nunca deixando de ser compreensivo com os meus possíveis erros.

Ao meu segundo orientador, professor Luiz Pereira Calôba, fico também extremamente agradecido pela sua orientação. Agradeço pelas inúmeras vezes que lhe procurei para discutir resultados, e ouvir sugestões de passos subsequentes a serem tomados, nunca também deixando de ter compreensão com a minha incipiência em determinados assuntos acadêmicos.

Agradeço ao Programa de Engenharia Metalúrgica e de Materiais, à COPPE, à UFRJ e a todos os professores, funcionários e alunos que tiveram papel importante na minha formação. Muito obrigado ao professor João Payão pela ajuda na tradução dos padrões do BAM, e ao professor Luís Volnei S. Sagrilo que colaborou em uma parte importante da tese.

Agradeço ao meu amigo, engenheiro e doutor Marcio Humberto S. Siqueira, pela sua imensa colaboração em várias fases da tese. Seu comportamento altruísta nos momentos que mais precisei - muitas vezes interrompendo seu trabalho para me emprestar suas experiências com os algoritmos de MATLAB, contribuiu de forma marcante na obtenção dos resultados. Marcio, muitíssimo obrigado!

À minha amiga Fátima Galvão, faço meus sinceros agradecimentos por todos os favores que me fez, pela sua atenção, pela sua paciência com as minhas chatices e brincadeiras, e também por todos os *cafezinhos*, *bolinhos*, *biscoitinhos* e etc., que foram de fundamental importância para o convívio social durante esses anos. Fátima, obrigado pela sua amizade sincera!

Agradeço à ABENDE (Associação Brasileira de Ensaaios Não-Destrutivos) e seus dirigentes por me permitir acesso ilimitado à sua sede no Rio de Janeiro.

Aos meus amigos *LABOENDIANOS*: Antonio, Elineudo e Catunda, alunos de doutorado e mestrado, fico grato pela amizade de vocês durante esses anos, agradeço o carinho com que me trataram, as brincadeiras e também a ajuda que sempre me deram quando precisei.

Faço agradecimentos ao nosso recém estagiário e estudante de engenharia, Marcos Paulo, que pôde, ao final deste trabalho, dar uma contribuição importante para a obtenção dos últimos resultados. Agradeço também aos outros estagiários e colegas: Jordana, Víctor, Rodrigo, Carlos Aberto, C.A Neves, André e Anderson. Não podendo esquecer de agradecer aos trabalhadores *polivalentes* e contratados do LABOEND, Demerson e Pedro, pela ajuda e amizade.

Gostaria de agradecer ao meu amigo chileno, professor Domingo Mery, cuja amizade surgiu há dois anos em uma mensagem eletrônica, mas que vem crescendo a cada dia, permitindo um trabalho de colaboração extremamente valioso para mim. Domingo, *muchas gracias!*

Agradeço à PETROBRAS por ter fornecido os primeiros padrões radiográficos IIW (*International Institute of Welding*) utilizados.

Meus agradecimentos ao próprio IIW por permitir a utilização acadêmica dos padrões, inclusive pela concessão de permissão às publicações científicas destes padrões.

Ao BAM (*Bundesanstalt für Materialforschung und-prüfung*) pelo fornecimento de seus padrões radiográficos, assim como à *Universidad Politécnica de Cartagena* (*Departamento de Estructuras y Construcción*) que também emprestou padrões radiográficos do IIW.

Agradeço ao CNPq e à FAPERJ pelas bolsas concedidas para a realização do doutorado.

Agradeço a todos os integrantes da banca examinadora por aceitarem o convite de participação.

Um agradecimento todo especial faço à minha namorada Catarina (*minha Julieta*), sempre tão tolerante com a minha ausência em momentos de intenso trabalho. Seu amor, seu carinho e sua atenção se transformaram num sentimento de força extra para que conseguisse chegar até o fim. *Mon amour, merci beaucoup!*

Agradeço à minha tia e madrinha, Daisy dos Santos Silva, pelo seu amor e dedicação à minha educação quando criança, e ao meu tio, Isaias de Alvarenga Pereira, que sempre foi mais do que simplesmente um tio, substituindo os avôs que a vida não me deixou conhecer.

Finalmente, agradeço ao meu pai, à minha mãe e ao meu irmão, pelo amor que me fornecem a cada dia, me impulsionando para a solução de problemas, e não me deixando esmorecer diante de dificuldades.

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

## RECONHECIMENTO DE PADRÕES DE DEFEITOS DE SOLDAGEM EM RADIOGRAFIAS INDUSTRIAIS

Romeu Ricardo da Silva

Dezembro/2003

Orientadores: João Marcos Alcoforado Rebello

Luiz Pereira Calôba

Programa: Engenharia Metalúrgica e de Materiais

A análise de filmes radiográficos de juntas soldadas é bastante subjetiva, e sujeita a erros de interpretação por parte do inspetor laudista. Consequentemente, há uma grande concentração de pesquisas voltadas para o desenvolvimento de um sistema automático ou semi-automático de interpretação de radiografias digitalizadas. Neste trabalho, objetiva-se avaliar metodologias de reconhecimento de padrões de defeitos de soldagem em radiografias usando redes neurais artificiais. Como dados de entradas dos classificadores, são usadas características geométricas dos defeitos extraídas de radiografias contendo padrões de defeitos, sendo estas avaliadas em grau de relevância na discriminação de cada classe de defeito, visando a redução do número de características a serem usadas pelo sistema. Além disso, recorre-se a algumas técnicas de inferência estatística para estimar a confiabilidade dos resultados obtidos. Os resultados obtidos mostraram que o importante é a “qualidade” das características usadas e não a quantidade, sendo possível a redução do número de características sem detrimento do desempenho dos classificadores. Realizou-se também um estudo da acurácia dos classificadores não-lineares usando sorteios aleatórios de pares de conjuntos para treinamento e teste. Os resultados da acurácia estimada foram da ordem de 80%, resultados satisfatórios quando comparados aos obtidos por outros autores.

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

## PATTERN RECOGNITION OF WELDING DEFECTS IN INDUSTRIAL RADIOGRAPHYS

Romeu Ricardo da Silva

December/2003

Advisors: João Marcos Alcoforado Rebello

Luiz Pereira Calôba

Department: Metallurgical and Materials Engineering

The analysis of conventional welded bead radiographs used in testing is quite subjective and is therefore prone to errors of interpretation even by the expert inspector. Consequently, there is much research going on, around the world, with the goal to develop an automatic or semiautomatic system for digital radiography interpretation. The main objective of this work is to evaluate pattern recognition methodologies of welding defects by using artificial neural networks. The inputs for the classifiers were geometric features of defects, which were extracted from radiographs with known defect patterns. These defect patterns had been evaluated in a relevancy level for the discrimination of each defect class in order to reduce the input data dimension (the number of features to be used by the system). Also, some statistic inference techniques were carried out to calculate the reliability of the results obtained. The results obtained proved that it is possible to use a reduced input data, by elimination of irrelevant features, without decreasing significantly the accuracy of the classifiers. Concluding that feature “quality” is more important than quantity. One evaluation of the non-linear classifier accuracy was carried out by using random sample for training and test sets. The results of estimated accuracy were at about 80%, which can be considered satisfactory when these were compared to the results obtained by other authors.

# ÍNDICES

---

## ÍNDICE DE TEXTO

|                                                                                                                                           |           |
|-------------------------------------------------------------------------------------------------------------------------------------------|-----------|
| <b>CAPÍTULO 1 – INTRODUÇÃO.....</b>                                                                                                       | <b>1</b>  |
| <b>CAPÍTULO 2 – REVISÃO BIBLIOGRÁFICA.....</b>                                                                                            | <b>5</b>  |
| 2.1. <i>Digitalização de Filmes Radiográficos.....</i>                                                                                    | 5         |
| 2.1.1. <i>Câmaras CCD.....</i>                                                                                                            | 6         |
| 2.1.2. <i>Escâneres para Digitalização de Filmes Radiográficos.....</i>                                                                   | 7         |
| 2.2. <i>Processamento Digital de Radiografias.....</i>                                                                                    | 7         |
| 2.2.1. <i>Suavização de Ruído com Filtros Passa-baixa.....</i>                                                                            | 8         |
| 2.2.2. <i>Otimização do Contraste das Imagens Radiográficas.....</i>                                                                      | 9         |
| 2.2.3. <i>Segmentação (Detecção de Defeitos).....</i>                                                                                     | 10        |
| 2.3. <i>Detecção dos Defeitos de Soldagem nas Imagens Radiográficas via Perfil de Nível de Cinza.....</i>                                 | 12        |
| 2.4. <i>Classificação dos Defeitos de Soldagem.....</i>                                                                                   | 18        |
| 2.5. <i>Considerações Finais.....</i>                                                                                                     | 24        |
| <b>CAPÍTULO 3 – REVISÃO TEÓRICA SOBRE RECONHECIMENTO DE PADRÕES<br/>USANDO REDES NEURAIS.....</b>                                         | <b>28</b> |
| 3.1. <i>O Que é um Padrão de uma Classe.....</i>                                                                                          | 28        |
| 3.2. <i>Sistema de Reconhecimento de Padrões.....</i>                                                                                     | 29        |
| 3.3. <i>O que são Redes Neurais Artificiais?.....</i>                                                                                     | 31        |
| 3.4. <i>Modelo de um Neurônio.....</i>                                                                                                    | 32        |
| 3.5. <i>Perceptrons de uma Camada.....</i>                                                                                                | 34        |
| 3.6. <i>Perceptrons de Múltiplas Camadas.....</i>                                                                                         | 37        |
| 3.6.1. <i>Algoritmo de Retropropagação do Erro.....</i>                                                                                   | 38        |
| <b>CAPÍTULO 4 – METODOLOGIA DE TRABALHO.....</b>                                                                                          | <b>43</b> |
| 4.1. <i>Filmes Radiográficos.....</i>                                                                                                     | 43        |
| 4.2. <i>Digitalização dos Filmes Radiográficos.....</i>                                                                                   | 43        |
| 4.3. <i>Pré-processamento das Imagens.....</i>                                                                                            | 44        |
| 4.4. <i>Imagens após Pré-processamento.....</i>                                                                                           | 44        |
| 4.5. <i>Extração de Características.....</i>                                                                                              | 48        |
| 4.6. <i>Pré-processamento dos Dados.....</i>                                                                                              | 51        |
| 4.7. <i>Desenvolvimento dos Discriminadores Lineares Não-Hierárquicos e Hierárquicos que Compõem<br/>os Classificadores Lineares.....</i> | 52        |
| 4.8. <i>Classificadores Não-Hierárquicos e Hierárquicos.....</i>                                                                          | 54        |
| 4.8.1. <i>Classificador Não-Hierárquico.....</i>                                                                                          | 55        |
| 4.8.2. <i>Classificador Hierárquico.....</i>                                                                                              | 55        |
| 4.9. <i>Classificadores Não-Lineares.....</i>                                                                                             | 58        |
| 4.10. <i>Avaliação da Relevância das Características por Matriz dos Coeficientes de Correlação Linear...</i>                              | 59        |
| 4.11. <i>Critério de Relevância.....</i>                                                                                                  | 61        |

|                                                                                                                                                                                                    |     |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| 4.12. <i>Generalização dos Classificadores Lineares Não-Hierárquicos e Hierárquicos e Não-Lineares</i> .....                                                                                       | 62  |
| 4.12.1. <i>Distribuição Normal ou Gaussiana</i> .....                                                                                                                                              | 62  |
| 4.12.2. <i>Teste de Distribuição de Komolgorov-Smirnov (K-S)</i> .....                                                                                                                             | 62  |
| 4.12.3. <i>Probabilidade de Classificação Correta Usando os Classificadores Lineares</i> .....                                                                                                     | 65  |
| 4.13. <i>Componentes Principais de Discriminação Não-Linear</i> .....                                                                                                                              | 67  |
| 4.14. <i>Metodologia Complementar</i> .....                                                                                                                                                        | 72  |
| 4.14.1. <i>Coleção de Radiografias</i> .....                                                                                                                                                       | 72  |
| 4.14.2. <i>Extração de Características</i> .....                                                                                                                                                   | 73  |
| 4.14.3. <i>Acurácia dos Classificadores</i> .....                                                                                                                                                  | 75  |
| <b>CAPÍTULO 5 – APRESENTAÇÃO E DISCUSSÕES DOS RESULTADOS</b> .....                                                                                                                                 | 79  |
| 5.1. <i>Classificadores Lineares</i> .....                                                                                                                                                         | 79  |
| 5.1.1. <i>Classificadores Não-Hierárquicos</i> .....                                                                                                                                               | 79  |
| 5.1.2. <i>Classificadores Hierárquicos</i> .....                                                                                                                                                   | 81  |
| 5.2. <i>Avaliação da Relevância dos Características: Matriz dos Coeficientes de Correlação Linear e Critério de Relevância usando um classificador linear implementado por redes neurais</i> ..... | 84  |
| 5.2.1. <i>Matriz dos Coeficientes de Correlação Linear</i> .....                                                                                                                                   | 84  |
| 5.2.2. <i>Critério de Relevância com um Classificador Linear</i> .....                                                                                                                             | 88  |
| 5.3. <i>Generalização dos Classificadores Lineares</i> .....                                                                                                                                       | 89  |
| 5.4. <i>Classificadores Não-Lineares</i> .....                                                                                                                                                     | 94  |
| 5.5. <i>Critério de Relevância com um Classificador Não- Linear</i> .....                                                                                                                          | 99  |
| 5.6. <i>Componentes Principais de Discriminação Não-Linear</i> .....                                                                                                                               | 101 |
| 5.7. <i>Resultados Complementares</i> .....                                                                                                                                                        | 105 |
| 5.7.1. <i>Classificador Linear-Hierárquico</i> .....                                                                                                                                               | 109 |
| 5.7.2. <i>Classificador Não-Linear e Não-Hierárquico</i> .....                                                                                                                                     | 113 |
| 5.7.2.1. <i>Estimadores de Acurácia do Classificador Não-Linear e Não-Hierárquico</i> .....                                                                                                        | 114 |
| 5.7.3. <i>Classificador Não-Linear Hierárquico</i> .....                                                                                                                                           | 129 |
| 5.7.4. <i>Seleção de Características e Redução de Dimensionalidade</i> .....                                                                                                                       | 129 |
| 5.7.4.1. <i>Matriz dos Coeficientes de Correlação Linear</i> .....                                                                                                                                 | 130 |
| 5.7.4.2. <i>Critério de Relevância</i> .....                                                                                                                                                       | 135 |
| 5.7.4.3. <i>Redução da Dimensionalidade</i> .....                                                                                                                                                  | 135 |
| 5.8. <i>Discussões Gerais e Artigos Publicados</i> .....                                                                                                                                           | 137 |
| <b>CAPÍTULO 6 – CONCLUSÕES E TRABALHOS FUTUROS</b> .....                                                                                                                                           | 139 |
| <b>CAPÍTULO 7 – REFERÊNCIAS BIBLIOGRÁFICAS</b> .....                                                                                                                                               | 142 |
| <b>APÊNDICE</b> .....                                                                                                                                                                              | 150 |

## ÍNDICE DE FIGURAS

### CAPÍTULO 2 – REVISÃO BIBLIOGRÁFICA

|                                                                                                                                                                                                                   |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>FIGURA 2.1:</b> 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 [27].....                                | 12 |
| <b>FIGURA 2.2:</b> Ilustração do princípio de detecção de defeito em perfis de Liao [22].....                                                                                                                     | 15 |
| <b>FIGURA 2.3:</b> Arquitetura típica de uma sistema para classificação de defeitos de soldagem [20].....                                                                                                         | 20 |
| <b>FIGURA 2.4:</b> Fluxograma das técnicas pesquisadas divididas basicamente em três partes do sistema de inspeção radiográfica computadorizado: aquisição, detecção e classificação de defeitos de soldagem..... | 26 |

### CAPÍTULO 3 – REVISÃO TEÓRICA

|                                                                                                                                                                                    |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>FIGURA 3.1:</b> Ilustração das etapas normalmente envolvidas em um sistema de reconhecimento de padrão [48].....                                                                | 30 |
| <b>FIGURA 3.2:</b> Modelo de um neurônio artificial [30].....                                                                                                                      | 33 |
| <b>FIGURA 3.3:</b> Ilustração do hiperplano (aqui, uma reta) como fronteira de decisão para um problema de classificação linear de padrões bidimensional de duas classes [30]..... | 36 |
| <b>FIGURA 3.4:</b> (a) Padrões linearmente separáveis; (b) padrões não linearmente separáveis [30].....                                                                            | 37 |
| <b>FIGURA 3.5:</b> Arquitetura de uma rede múltipla camada com uma camada intermediária e uma camada de saída [30].....                                                            | 38 |
| <b>FIGURA 3.6:</b> Rede em retropropagação do erro com três camadas [47].....                                                                                                      | 42 |

### CAPÍTULO 4 – METODOLOGIA DE TRABALHO

|                                                                                                                                                                                                                                                                                                             |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>FIGURA 4.1:</b> Exemplos de padrões IIW após pré-processamento.....                                                                                                                                                                                                                                      | 48 |
| <b>FIGURA 4.2:</b> Organograma representando a separação das classes de defeitos através das características escolhidas.....                                                                                                                                                                                | 50 |
| <b>FIGURA 4.3:</b> Exemplo de padrão IIW utilizado indicando a presença de inclusão de escória; (b) ilustração para a definição das características utilizadas.....                                                                                                                                         | 51 |
| <b>FIGURA 4.4:</b> As cinco classes $C_j$ , $j = MO, FP, PO, IEL, IENL$ , e seus respectivos separadores não hierárquicos $S_j$ com as polaridades indicadas. As classes mais externas MO e FP são perfeitamente separadas e as mais internas IEL e IENL, muito imperfeitamente separadas.....              | 53 |
| <b>FIGURA 4.5:</b> (a) e (b): Após a exclusão das entradas classificadas como FP e MO, os demais discriminadores podem assumir posições muito mais eficazes na separação das classes restantes, principalmente $S_{PO}$ , (c) e (d); o mesmo ocorre após a exclusão das entradas classificadas como PO..... | 54 |
| <b>FIGURA 4.6:</b> Algoritmo do classificador não-hierárquico.....                                                                                                                                                                                                                                          | 56 |
| <b>FIGURA 4.7:</b> Algoritmo do classificador hierárquico.....                                                                                                                                                                                                                                              | 57 |
| <b>FIGURA 4.8:</b> Arquitetura da rede neural utilizada para implementação do classificador não-linear.....                                                                                                                                                                                                 | 59 |
| <b>FIGURA 4.9:</b> Distribuição de frequência acumulativa e função de distribuição teórica[56].....                                                                                                                                                                                                         | 63 |
| <b>FIGURA 4.10:</b> Distribuição normal dos $U$ 's de duas classes hipotéticas 1 e 2 mostrando as probabilidade de classificação correta, e de haver confusão de classificação entre estas duas classes, soma das áreas hachuradas na figura dividida pela área total que é 2.....                          | 65 |
| <b>FIGURA 4.11:</b> (a) cálculo da diferença entre o $U_A$ e $U_B$ para quando há mais de um $U$ positivo. (b) cálculo da diferença entre o $U_A$ e $U_B$ para quando todos os $U$ 's são negativos.....                                                                                                    | 66 |
| <b>Figura 4.12:</b> Distribuição normal que permite calcular a probabilidade de ocorrer classificação correta usando o critério de reclassificação.....                                                                                                                                                     | 67 |
| <b>FIGURA 4.13:</b> Projeção $p_1 w_1$ de $\underline{x}$ na direção principal de discriminação.....                                                                                                                                                                                                        | 69 |
| <b>FIGURA 4.14:</b> Rede para implementação da primeira componente principal de discriminação não-linear.....                                                                                                                                                                                               | 70 |
| <b>FIGURA 4.15:</b> Ilustração das três características novas extraídas.....                                                                                                                                                                                                                                | 74 |
| <b>FIGURA 4.16:</b> Distribuição das classes de defeitos no conjunto total de amostras.....                                                                                                                                                                                                                 | 74 |

### CAPÍTULO 5 – APRESENTAÇÃO DE RESULTADOS

|                                                                                                                                                                                                                                                                                                                                                                                                                                                                                     |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>FIGURA 5.1:</b> Curvas de distribuição normal obtidas com o resultado da subtração entre o valor de $U$ de uma classe e o maior valor de $U$ das demais classes, representando assim o cálculo de probabilidade de acerto do <i>classificador não-hierárquico com critério de reclassificação</i> . De (a) a (f), as classes: mordedura, falta de penetração, porosidade, inclusão de escória linear, inclusão de escória não-linear e inclusão de escória, respectivamente..... | 91 |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|

|                                                                                                                                                                                                                                                                                                                                                                                                                                                                          |     |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>FIGURA 5.2:</b> Curvas de distribuição normal obtidas com o resultado da subtração entre o valor de U de uma classe e o maior valor de U das demais classes, representando assim o cálculo probabilidade de acerto do <i>classificador hierárquico com critério de reclassificação</i> . De (a) a (f), as classes: mordedura, falta de penetração, porosidade, inclusão de escória linear, inclusão de escória não-linear e inclusão de escória, respectivamente..... | 93  |
| <b>FIGURA 5.3:</b> (a) e (b) Gráficos de otimização do número de neurônios na camada oculta da rede neural para obter o melhor desempenho com o classificador não-linear tendo como entrada as características: a, e/A, R e P, para inclusão dividida e não dividida, respectivamente.....                                                                                                                                                                               | 95  |
| <b>FIGURA 5.4:</b> Distribuições resultantes para a diferença entre a saída obtida no classificador para uma dada classe e a maior saída entre as outras classes.....                                                                                                                                                                                                                                                                                                    | 98  |
| <b>FIGURA 5.5:</b> Gráfico com os desempenhos obtidos com os classificadores não-lineares alimentados com as combinações de características indicadas, para as duas situações: 4 e 5 classes. Note que a origem do eixo vertical está deslocada.....                                                                                                                                                                                                                     | 101 |
| <b>FIGURA 5.6:</b> (a) e (b) : gráficos formados pelas duas componentes principais de discriminação não-linear de atuação independente para as quatro classes (a classe de inclusão sendo considerada como apenas uma classe) e cinco classes (inclusão subdividida em inclusão linear e não-linear).....                                                                                                                                                                | 103 |
| <b>FIGURA 5.7:</b> Gráfico mostrando os desempenhos obtidos quando utiliza-se como entrada do classificador as componentes principais de discriminação não-linear com atuação independente e de forma cooperativa. Note que a origem do eixo vertical está deslocada.....                                                                                                                                                                                                | 105 |
| <b>FIGURA 5.8:</b> (a) Espaço de representação bidimensional representado pelas duas CPDNL independentes, considerando todas as classes; (b)-(e), mesma representação, mas apenas considerando uma classe contra as demais.....                                                                                                                                                                                                                                          | 107 |
| <b>FIGURA 5.9 :</b> (a) Espaço de representação bidimensional representado pelas duas CPDNL independentes, descartando, neste caso, as classes TR e FF; (b)-(e), mesma representação, mas apenas considerando uma classe contra as demais.....                                                                                                                                                                                                                           | 108 |
| <b>FIGURA 5.10:</b> Otimização do número de neurônios na camada intermediária para permitir o melhor resultado de teste.....                                                                                                                                                                                                                                                                                                                                             | 114 |

## ÍNDICE DE TABELAS

### CAPÍTULO 2 – REVISÃO BIBLIOGRÁFICA

|                                                                      |    |
|----------------------------------------------------------------------|----|
| <b>TABELA 2.1:</b> Defeitos e suas características visuais [31]..... | 22 |
|----------------------------------------------------------------------|----|

### CAPÍTULO 5 – APRESENTAÇÃO DE RESULTADOS

|                                                                                                                                                                                                                   |     |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>TABELA 5.1:</b> Tabela de Confusão (%). <i>Classificador Não-Hierárquico (Sem reclassificação)</i> .....                                                                                                       | 80  |
| <b>TABELA 5.2:</b> Tabela de Confusão (%). <i>Classificador Não-Hierárquico (Com reclassificação)</i> .....                                                                                                       | 80  |
| <b>TABELA 5.3:</b> Tabela de Acertos e Erros. <i>Classificador Não-Hierárquico (Sem reclassificação)</i> .....                                                                                                    | 81  |
| <b>TABELA 5.4:</b> Tabela de Acertos e Erros. <i>Classificador Não-Hierárquico (Com reclassificação)</i> .....                                                                                                    | 81  |
| <b>TABELA 5.5:</b> Tabela de Confusão (%). <i>Classificador Hierárquico (Sem reclassificação)</i> .....                                                                                                           | 83  |
| <b>TABELA 5.6:</b> Tabela de Confusão (%). <i>Classificador Hierárquico (Com reclassificação)</i> .....                                                                                                           | 83  |
| <b>TABELA 5.7:</b> Tabela de Acertos e Erros. <i>Classificador Hierárquico (Sem reclassificação)</i> .....                                                                                                        | 83  |
| <b>TABELA 5.8:</b> Tabela de Acertos e Erros. <i>Classificador Hierárquico (Com reclassificação)</i> .....                                                                                                        | 84  |
| <b>TABELA 5.9:</b> Matriz de correlação linear com as características correlacionadas.....                                                                                                                        | 87  |
| <b>Tabela 5.10:</b> Matriz de correlação com as características descorrelacionadas.....                                                                                                                           | 87  |
| <b>TABELA 5.11:</b> Critério de Relevância usando um Classificador Linear.....                                                                                                                                    | 88  |
| <b>Tabela 5.12:</b> Probabilidades Estimadas de Acerto (%). <i>Classificador Linear Não-Hierárquico (Com critério de Reclassificação)</i> .....                                                                   | 90  |
| <b>TABELA 5.13:</b> Probabilidades Estimadas de Acerto (%). <i>Classificador Linear Hierárquico (Com critério de Reclassificação)</i> .....                                                                       | 94  |
| <b>TABELA 5.14:</b> Tabela de Confusão obtida para as características a-e/A-R-P. <i>Sem critério de reclassificação</i> .....                                                                                     | 96  |
| <b>TABELA 5.15:</b> Tabela de Confusão obtida para as características a-e/A-R-P. <i>Com critério de reclassificação</i> .....                                                                                     | 96  |
| <b>Tabela 5.16:</b> Critério de Relevância usando um Classificador Não-Linear.....                                                                                                                                | 99  |
| <b>TABELA 5.17 :</b> Tabela de Confusão. <i>Classificador Linear-Hierárquico na 1ª Ordem de Classificação</i> .....                                                                                               | 111 |
| <b>TABELA 5.18 :</b> Tabela de Confusão. <i>Classificador Linear-Hierárquico na 2ª Ordem de Classificação</i> .....                                                                                               | 112 |
| <b>TABELA 5.19 :</b> Tabela de Confusão. <i>Classificador Linear-Hierárquico na 2ª Ordem de Classificação</i> .....                                                                                               | 113 |
| <b>TABELA 5.20:</b> Estimadores de Acurácia dos Classificadores Não-Lineares e Não-Hierárquicos para Cada Condição de Classificação. <i>Resultados Percentuais Obtidos Somente com os Conjuntos de Teste</i> . .. | 117 |

|                                                                                                                                                                                                 |     |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>TABELA 5.21</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Sem reclassificação). Sem Duplicamento – Dados de Treinamento.....                                      | 118 |
| <b>TABELA 5.22</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Com reclassificação). Sem Duplicamento – Dados de Treinamento.....                                      | 118 |
| <b>TABELA 5.23</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Sem reclassificação). Sem Duplicamento – Dados de Teste.....                                            | 119 |
| <b>TABELA 5.24</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Com reclassificação). Sem Duplicamento – Dados de Teste.....                                            | 119 |
| <b>TABELA 5.25</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Sem reclassificação). Com Duplicamento – Dados de Treinamento.....                                      | 120 |
| <b>TABELA 5.26</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Com reclassificação). Com Duplicamento – Dados de Treinamento.....                                      | 120 |
| <b>TABELA 5.27</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Sem reclassificação). Com Duplicamento – Dados de Teste.....                                            | 121 |
| <b>TABELA 5.28</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Com reclassificação). Com Duplicamento – Dados de Teste.....                                            | 121 |
| <b>TABELA 5.29</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Sem reclassificação). Sem Duplicamento – Dados de Treinamento.....                                      | 123 |
| <b>TABELA 5.30</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Com reclassificação). Sem Duplicamento – Dados de Treinamento.....                                      | 123 |
| <b>TABELA 5.31</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Sem reclassificação). Sem Duplicamento – Dados de Teste.....                                            | 124 |
| <b>TABELA 5.32</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Com reclassificação). Sem Duplicamento – Dados de Teste.....                                            | 124 |
| <b>TABELA 5.33</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Sem reclassificação). Com Duplicamento – Dados de Treinamento.....                                      | 125 |
| <b>TABELA 5.34</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Com reclassificação). Com Duplicamento – Dados de Treinamento.....                                      | 125 |
| <b>TABELA 5.35</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Sem reclassificação). Com Duplicamento – Dados de Teste.....                                            | 126 |
| <b>TABELA 5.36</b> : Tabela de Confusão (%).Classificador Não-Linear e Não-Hierárquico (Com reclassificação). Com Duplicamento – Dados de Teste.....                                            | 126 |
| <b>TABELA 5.37</b> : Estimadores de Acurácia por <i>Bootstrap</i> para o Classificador Não-Linear e Não-Hierárquico com as 6 classes, cada classe com a sua população original de amostras..... | 128 |
| <b>TABELA 5.38</b> : Estimadores de Acurácia por <i>Bootstrap</i> para o Classificador Não-Linear e Não-Hierárquico com as 5 classes, cada classe com a sua população original de amostras..... | 129 |
| <b>TABELA 5.39</b> : Matriz com os coeficientes de correlação. As células hachuradas correspondem aos valores que estão contidos dentro do intervalo de confiança de 95%.....                   | 132 |
| <b>TABELA 5.40</b> : Tabela com a matriz dos coeficientes de correlação. As células hachuradas contêm os valores próximos ao limite de $2/\sqrt{N}$ .....                                       | 132 |
| <b>TABELA 5.41</b> : Correlações entre características/classes para 200 amostras de <i>bootstrap</i> .....                                                                                      | 133 |
| <b>TABELA 5.42</b> : Valores de correlações entre as características encontrados para as 200 amostras de <i>bootstrap</i> .....                                                                 | 134 |
| <b>TABELA 5.43</b> : Critério de relevância usando um classificador não-linear.....                                                                                                             | 135 |
| <b>TABELA 5.44</b> : Tabela de Acurácia do Classificador NL e NH Usando 6 Características (Sem Ângulo). Valores Numéricos e Percentuais.....                                                    | 136 |
| <b>TABELA 5.45</b> : Tabela de Acurácia Aparente do Classificador NL e NH Usando como Entradas as CPDNL Independentes.....                                                                      | 137 |

## ACRÔNIMOS

**ASME** – *American Society for Materials Engineering.*

**ASNT** - *American Society for Nondestructive Testing.*

**BAM** – *Bundesanstalt für Materialforschung und-prüfung (Federal Institute for Materials Research and Testing - Berlin).*

**CCD** – *Charge Couple Device.*

**CPD** – Componente Principal de Discriminação.

**CPDNL** – Componente Principal de Discriminação Não-Linear.

**DPI** – *Dot per Inch.*

**FF** – Falta de Fusão.

**FN** – Falso Negativo.

**FP** – Falta de Penetração.

**PF** – Falso Positivo (sigla invertida para não confundir com FP).

**IE** – Inclusão de Escória.

**IEL** – Inclusão de Escória Linear.

**IENL** – Inclusão de Escória Não-Linear.

**IIW** – *International Institute of Welding.*

**IQI** – Indicador de Qualidade de Imagem.

**K-NN** – *K- Nearest Neighbours.*

**LMS** - *Least Mean Square.*

**MO** – Mordedura.

**MDA** – *Multiple Discriminant Analysis.*

**NH** – Não-Hierárquico.

**NL** – Não-Linear.

**O.D.** – *Optical Density.*

**PCA** – *Principal Component Analysis.*

**PO** – Porosidade.

**ROC** – *Receiver Operating Characteristic*

**SR** – Sem Reclassificação ou **R** – Reclassificado.

**TR** – Trinca.

**VP** – Verdadeiro Positivo.

# CAPÍTULO 1 - INTRODUÇÃO

---

Em um mundo moderno e globalizado, cada vez mais diversas indústrias como a naval, nuclear, química, automobilística, aeroespacial, metalúrgica, petroquímica e petrolífera, entre outras, estão voltadas para a melhoria da qualidade dos seus materiais e equipamentos, requisito básico para manter-se competitivo nos mercados nacionais e internacionais. Por este motivo, os ensaios não-destrutivos têm importância fundamental na avaliação da qualidade dos materiais e equipamentos, seja no processo de fabricação, ou durante o período de funcionamento.

Dentre os ensaios não-destrutivos, o ensaio radiográfico é um dos métodos mais antigos e vem sendo utilizado ao longo de aproximadamente cinco décadas. Entre as vantagens obtidas com este método, em relação aos demais métodos, como o ensaio por ultra-som por exemplo, está o fato da imagem projetada no filme representar uma *fotografia* interna da peça, o que nenhum outro método possibilita. O ensaio radiográfico usando fonte de raios X ou gama de juntas soldadas e de peças fundidas está entre as aplicações mais importantes deste método de inspeção. Neste trabalho, trataremos em especial de radiografias de juntas soldadas que são utilizadas para verificar a existência de defeitos de soldagem originados por várias causas.

O método convencional de inspeção exige que a qualidade da imagem radiográfica seja a melhor possível e, por este motivo, esta é controlada por normas rígidas internacionais. Além disso, sabe-se que a inspeção visual da radiografia pelo inspetor é conduzida de forma que, em certos casos, deixa margem à interpretação subjetiva, necessitando de extrema experiência, acuidade visual e conhecimento da técnica empregada, além de ser um processo lento e influenciado por diversos fatores como: dimensão da fonte, distância foco-filme, tempo de exposição, revelação do filme e etc. [1]. Porém, mesmo quando a análise da radiografia é feita de maneira adequada, há ocorrência de erros de interpretação dos defeitos existentes no cordão-de-solda, seja na não detecção de um defeito presente, ou na classificação incorreta do defeito detectado, erro provocado pela similaridade de características entre algumas classes de defeito. Atualmente, existem algumas pesquisas visando medir o grau de confiabilidade da técnica radiográfica em função de algumas variáveis do processo de laudo, como por exemplo, o nível de experiência do inspetor [2,3]. Adicionalmente, sabe-se que a

medida a ser tomada com respeito a aprovação ou não da peça, após inspeção, dependerá da localização, do tamanho e do tipo de defeito encontrado. Neste caso, é de suma importância a precisão da análise radiográfica.

Os avanços no campo da informática e das ciências ligadas aos processos baseados em *inteligência artificial*<sup>1</sup> permitiram o surgimento de várias pesquisas voltadas para se estudar e avaliar metodologias que possam ser usadas para desenvolver um sistema automático, ou semi-automático, de análise de radiografias industriais. As primeiras publicações datam da década de 70. Entretanto, a grande concentração de publicações relacionadas a estes assuntos vem ocorrendo ao longo dos últimos 15/20 anos. Isto deve-se à inegável relevância e importância que tem esta área de desenvolvimento tecnológico.

O sistema de análise automática de radiografias de juntas soldadas, ocorrendo da mesma forma para radiografias de peças fundidas, envolve basicamente as etapas de digitalização dos filmes, ou aquisição digital diretamente dispensando o filme, pré-processamento das imagens, segmentação (identificação dos defeitos no cordão-de-solda) e classificação dos defeitos encontrados; podendo algumas vezes realizar-se uma etapa de pós-processamento dos resultados. A etapa de classificações dos padrões tem sido umas das mais difundidas em termos de pesquisa atualmente. É importante ressaltar que, embora haja muitos esforços direcionados para o desenvolvimento deste sistema de análise automática de defeitos em radiografias, ainda não existe registro de um sistema pronto e que funcione efetivamente até o presente momento. O que comprova a complexidade envolvida em seu projeto de desenvolvimento.

O trabalho de tese tem como objetivos principais:

- Extrair características geométricas das principais classes de defeitos de soldagem a partir de padrões radiográficos internacionalmente reconhecidos e respeitados.
- Desenvolver e avaliar classificadores lineares e não-lineares de padrões de defeitos de soldagem, sendo estes implementados por redes neurais artificiais.
- Avaliar as características geométricas dos defeitos utilizadas como vetores de entrada dos classificadores em termos de relevância na discriminação das classes de defeitos: mordedura, falta de penetração, porosidade, inclusão de escória linear e não-linear, trinca e falta de fusão. Neste caso, recorre-se à análise da matriz dos

---

<sup>1</sup> Existem várias definições para o que seja *Inteligência Artificial*, mas em nosso caso, considera-se como sendo um processo emulado em *hardware* ou *software* visando realizar tarefas usualmente feitas por seres humanos [4].

coeficientes de correlação linear e ao critério de relevância de características usando também redes neurais. A meta desta etapa do estudo é avaliar a possibilidade de redução da dimensão dos dados de entrada, descartando características irrelevantes e correlacionadas.

- Usar técnicas de amostragem para estimar a acurácia “verdadeira” dos classificadores de padrões.
- Numa forma de aprofundar o estudo do problema de classificação de padrão proposto, recorre-se à técnica de análise das componentes principais de discriminação não-linear das classes de defeitos, tanto para visualização da separação entre as classes em duas dimensões, quanto para utilização das componentes principais como vetores de entradas dos classificadores não-lineares.

De forma resumida, pode-se dizer que o principal objetivo do trabalho de tese é *desenvolver e avaliar metodologias que possam servir de base para o desenvolvimento de um sistema automático (ou semi-automático) de classificação de defeitos de soldagem detectados por ensaio radiográfico.*

A apresentação do texto de tese seguirá com os seguintes assuntos distribuídos por capítulos:

- Capítulo 2 – Revisão Bibliográfica: neste capítulo, as principais publicações científicas existentes sobre este tema serão descritas e comentadas resumidamente.
- Capítulo 3 – Revisão Teórica sobre Reconhecimento de Padrões usando Redes Neurais Artificiais: neste capítulo, fazendo-se uma síntese breve sobre o que existe na literatura, aborda-se a utilização das redes neurais para implementação de tarefas de reconhecimento de padrões.
- Capítulo 4 – Metodologia de Trabalho: no capítulo 4, trata-se dos materiais e metodologias empregados para o desenvolvimento do trabalho proposto, visando facilitar a compreensão dos resultados obtidos.
- Capítulo 5 – Apresentação e Discussões dos Resultados: todos os resultados obtidos são apresentados e discutidos detalhadamente, freqüentemente comparando-os com os trabalhos de outros pesquisadores desta área, ressaltando os aspectos mais importantes.
- Capítulo 6 – Conclusões e Trabalhos Futuros: apresentação das conclusões principais resultantes do trabalho de tese; e sugestões de continuidade do trabalho.

- Capítulo 7 – Referências Bibliográficas: relação de todas as referências usadas como base para estudo.
- Apêndice 1 – Publicações Científicas dos Resultados Obtidos na Tese: texto final de todas as publicações originadas com os resultados.

## CAPÍTULO 2 – REVISÃO BIBLIOGRÁFICA

---

As pesquisas voltadas para o desenvolvimento de um sistema automático de análise de radiografias de juntas soldadas vêm crescendo consideravelmente nos últimos anos. Atualmente, vários centros de pesquisa no mundo possuem projetos direcionados para a otimização do ensaio radiográfico, seja na aquisição das imagens ou no processo de análise das radiografias. Provavelmente, uma das primeiras referências seja a de Pearson [Apud 5], e data de 1975. Contudo, o grande número de publicações neste área de pesquisa concentraram-se nos últimos 15 anos.

Apenas para destacar, a importância deste assunto se tornou de tamanha grandeza que instituições como o BAM (*Bundesanstalt für Materialforschung und-prüfung*<sup>2</sup>-Berlim – DGZfP – *Germany Society for Nondestructive Testing*) e ASNT (*American Society for Nondestructive Testing*) organizam congressos exclusivos para divulgações científicas desta área.

Neste capítulo, descreve-se o resultado de uma revisão bibliográfica sobre este tema de pesquisa, que serviram de base para estudo e comparação com os resultados obtidos neste trabalho.

### 2.1. *Digitalização de Filmes Radiográficos*

As técnicas convencionais de inspeção radiográfica envolvem somente análise visual direta dos filmes radiográficos em negatoscópios<sup>3</sup>. Deste modo, existem diversos fatores que influem na aceitabilidade dos resultados obtidos no ensaio: qualidade da imagem (influenciada por vários parâmetros da técnica de inspeção), bom funcionamento do aparelho negatoscópio, acuidade visual do inspetor, assim como sua experiência na interpretação de radiografias [2,3]. Além destes fatores, existe uma série de outras variáveis nos processos de inspeção não-destrutiva de materiais, como pode ser visto no trabalho de Moré [6], que aumentam a probabilidade de ocorrência de erro de interpretação.

---

<sup>2</sup> Federal Institute for Materials Research and Testing (BAM).

<sup>3</sup> Aparelho que torna as sombras das imagens de raios X visíveis.

Durante muitos anos, o método convencional de inspeção foi o único a ser utilizado. Porém, atualmente, várias técnicas modernas, que empregam interpretação feita em computadores das imagens radiográficas, têm surgido gradativamente. Para que as imagens sejam analisadas em um computador, estas precisam passar por um processo de digitalização.

Um processo de digitalização é normalmente dividido em duas etapas sequenciais: etapa de amostragem, na qual define-se sua resolução espacial, e etapa de quantização, na qual define-se sua resolução em profundidade de cinza. Estas duas etapas são muito importantes, pois determinam o nível de informação que a imagem conterá após ser digitalizada. Os livros de Russ [7], Castleman [8] e Gonzalez [9] contêm descrições detalhadas dos processos de digitalização.

Para digitalização de filmes radiográficos, duas técnicas são normalmente empregadas: utilização de câmaras CCD (da sigla em inglês: *Charge Couple Device* - dispositivo de carga acoplada) e emprego de escâneres especiais para digitalização de filmes [10]. Estas técnicas serão descritas e discutidas nas seções seguintes a partir de suas aplicações pelos pesquisadores. Além destas técnicas, existem atualmente sistemas de inspeção, que normalmente possuem telas fluorescentes, intensificadores de imagens, câmaras CCD e placas digitalizadoras, nos quais a imagem radiográfica é obtida diretamente na forma digital, dispensando o uso de filmes. Estes sistemas não serão descritos por não terem sido utilizados neste trabalho. É importante ressaltar que a digitalização de filmes radiográficos é regida por norma ASME V [11].

#### 2.1.1. *Câmaras CCD*

Os dispositivos de carga acoplada são os equipamentos mais utilizados em digitalização de imagens. Inicialmente, os filmes radiográficos eram digitalizados sendo colocados sobre um negatoscópio, e fotografados por uma câmara CCD [12-13] ou vidicon [14]. Neste processo, a energia dos fótons de luz capturados pela câmara é transformada em voltagem para cada pixel da imagem, sendo o número de pixels determinados pela resolução espacial. Em seguida, cada voltagem dos pixels corresponde a um nível de cinza/cor (determinado pela resolução em profundidade de cor). Posteriormente, as imagens radiográficas digitalizadas são transferidas para o computador para serem processadas com filtros digitais visando a remoção de ruídos, melhoria de contraste e segmentação [12-13].

Suga [13] detalha o processo de obtenção de imagens com contraste elevado durante a digitalização usando câmara CCD. Estes processos de digitalização de radiografias já se tornaram ultrapassados e praticamente não são mais utilizados, pois as resoluções espaciais e em profundidade de cinza são normalmente insatisfatórias, como por exemplo, a resolução espacial do trabalho de Aoki [12] que foi de 512×512 pixels.

### **2.1.2. *Escâneres para Digitalização de Filmes Radiográficos***

Existem atualmente vários tipos de escâneres próprios para digitalização de radiografias que trabalham em modo de transmissão de luz. Neste caso, os filmes são colocados na área de digitalização, que pode ser do tipo *Flatbed* (similar aos escâneres convencionais) ou bandeja, e a luz proveniente do adaptador de transparência atravessa a imagem e é capturada, normalmente, por um dispositivo CCD na parte inferior do escâner. As características destes equipamentos como limite de resolução e densidade[1] (hoje existem escâneres capazes de digitalizar filmes de até 4,0 de densidade, como o RADView FS50/AGFA [15] ou o LS85 SDR/Limisys [16]), assim como do programa de captura, definem a qualidade da imagem radiográfica ao final da digitalização.

Cherfa [17] e Liao [18] utilizaram escâneres em seus trabalhos para digitalização de radiografias. Liao [18, 19] utilizou o escâner NDT SCAN II que lhe permitiu uma resolução espacial final de 70µm de tamanho de pixel, tendo cada pixel 12 bits (4096 níveis de cinza). A melhoria da qualidade da imagem em comparação ao uso do conjunto negatoscópio-câmara é evidente devido às melhores resoluções atingidas.

## **2.2. *Processamento Digital de Radiografias***

A qualidade das imagens radiográficas é um fator importante na detecção dos defeitos de soldagem, sendo normalmente avaliada através do emprego de indicadores de qualidade de imagem (IQIs) [1]. Os fatores como tipo de filme, densidade do filme, distância foco-filme, nível de energia da fonte, tempo de exposição e temperatura do revelador são devidamente controlados para que, ao final do ensaio, tenha-se uma imagem com qualidade satisfatória à correta detecção e classificação de defeitos [1].

Mesmo quando há um controle rígido dos parâmetros do ensaio radiográfico, as imagens radiográficas apresentam problemas, tais como: existência de ruído,

distribuição não uniforme de cinza e contraste deficiente. Desta maneira, quando existe um defeito muito pequeno no cordão-de-solda, este pode ser confundido com ruídos presentes na imagem, sejam estes provenientes da etapa de digitalização ou mesmo do processo de inspeção [10].

Após a digitalização das imagens, tem-se a possibilidade de processá-las com aplicação de filtros digitais de imagem, eliminando ou suavizando a existência de tais problemas. Destaca-se que a aplicação dos filtros deverá ser realizada cuidadosamente para que as informações relevantes não sejam perdidas [10], o que pode gerar, por exemplo, o subdimensionamento de um defeito ou até mesmo a sua exclusão da imagem.

Como será mostrada, a etapa de processamento digital de radiografias industriais é bastante complexa e a diversificação das técnicas empregadas é constatada em diversos trabalhos [4, 12-14, 17, 20-21].

#### **2.2.1. Suavização de Ruído com Filtros Passa-baixa**

A primeira etapa no processamento das imagens é a suavização de ruídos, que podem ser oriundos tanto da técnica de ensaio, como do processo de digitalização, neste caso conhecidos como ruídos eletrônicos. Nesta etapa, aplicam-se normalmente os filtros do tipo passa-baixa [10], já que os ruídos são caracterizados por frequências altas[8, 9]. O filtro mais utilizado para tal fim é do tipo *mediana*. Neste filtro, o valor mediano entre os valores (elementos) da matriz de operação será o valor de saída do pixel. O filtro *mediana* tem efeito mais brando na eliminação dos ruídos, não provocando eliminação de defeitos relevantes e também não denegrindo a nitidez da imagem de forma tão acentuada como acontece com os filtros de média e Gauss [10], Aoki [12, 21] e Maklashevsky [22].

Cherfa [17] relata a possibilidade de utilização de filtros passa-baixa do tipo Gaussiano, exponencial e mediana no processamento de imagens radiográficas, mas realça que o filtro mediana é o mais adequado pelas vantagens citadas.

Kehoe [5] descreve a suavização de ruído usando uma média aritmética entre as imagens capturadas, porém, este método só é utilizado em sistemas de inspeção radiográfica em tempo real (radioscopia).

Liao [23] realça a dificuldade existente para suavização de ruídos em radiografias, devido a variação de níveis de cinza existente nas imagens, sendo inclusive

muito difícil a escolha de uma filtro ou uma técnica de suavização que possa ser utilizada em todas as imagens radiográficas. Entretanto, como a maioria dos outros autores, relata em uma de suas últimas publicações [19], que o filtro mediana com janelas de operação de  $3 \times 3$  e  $5 \times 5$  é o mais adequado para ser aplicado nas radiografias de juntas soldadas.

### 2.2.2. *Otimização do Contraste das Imagens Radiográficas*

Os filmes radiográficos normalmente apresentam contraste deficiente após ensaio, devido a diversos problemas como iluminação não-uniforme oriunda da técnica de inspeção, variação de espessura da peça ensaiada, exposição não adequada do filme, controle inadequado do processamento do filme e etc. [1].

O processo de digitalização das radiografias também pode ser responsável pelo baixo contraste da imagem digital. Nesta etapa, deve-se controlar a abertura da câmara para não gerar reflexão interna no sistema ótico, isto no caso de digitalização com câmara. Problemas como desfocagem, reflexão e distorção devem ser efetivamente controlados. O circuito eletrônico da placa digitalizadora deverá impedir a diminuição da distribuição dos níveis de cinza na digitalização das imagens. Outro fator importante para correta digitalização sem prejuízo do contraste da imagem é a utilização de equipamentos que atinjam a densidade do filme a ser digitalizado [5, 10].

O objetivo do estágio de melhoramento de contraste em radiografias é realçar as regiões nas quais existam defeitos, sem denegrir as outras regiões da imagem, garantindo assim que técnicas subsequentes de segmentação sejam bem sucedidas [5].

Para otimizar o contraste radiográfico, é usual o emprego de uma etapa conhecida normalmente como extensão de contraste (otimização da distribuição dos níveis de cinza da imagem através dos *pixels*). Cherfa e Kabir [17], para expandir o contraste da imagem radiográfica, utilizaram uma função de transformação aplicada ao histograma de tons de cinza. O mesmo foi realizado por Merenyi e Heller [24] para otimizar a distribuição de níveis de cinza nas radiografias em que trabalharam. O resultado deste procedimento foi normalmente satisfatório, melhorando sensivelmente a qualidade das imagens radiográficas em termos de contraste [24].

A etapa de melhoramento do contraste das radiografias é posterior a eliminação de ruídos, para que estes não sejam realçados conjuntamente com o contraste. Todas

estas referências citadas contêm descrições mais detalhadas dos métodos usados para ajustar o nível de contraste nas radiografias a níveis satisfatórios de inspeção.

### 2.2.3. *Segmentação (Detecção de Defeitos)*

O procedimento de segmentação (transformação da imagem para os níveis preto e branco) das radiografias é normalmente a última etapa no processamento digital de radiografias. O objetivo principal é a eliminação de informações irrelevantes, restando apenas os objetos de interesse na imagem, como por exemplo, os defeitos de soldagem existentes no cordão-de-solda, o que, neste caso, denomina-se de detecção de defeitos. As técnicas mais usuais de segmentação de radiografia empregam usualmente uma série de filtros para encontrar variações significativas nos pixels das imagens, que possam corresponder aos defeitos. Algumas técnicas de segmentação são abordadas freqüentemente na literatura como os métodos de *Canny* e *Deriche* [8, 9] e o emprego de filtros derivativos como *Laplacian* e *Prewitt* [8, 9], assim como técnicas conhecidas como *Crescimento de Região* [9].

Murakami [14] descreve a utilização de técnicas de segmentação para detecção de defeitos de soldagem em radiografias usando vários tipos de filtros, como: filtro de suavização, filtro de ponte, operador de Kirsch, Prewitt, Sobel e filtros de contraste. Ele mostra em seu artigo um exemplo de radiografia segmentada aplicando-se uma seqüência destes filtros. O resultado foi excelente com a detecção eficiente do defeito porosidade. Entretanto, Murakami [14] ressalta que a seqüência de filtros empregados foi diferente para cada tipo de imagem radiográfica, fato que se configura em nítida desvantagem, já que o número de radiografias é enorme, devendo-se ter portanto, um número excessivo de algoritmos.

Dentro do campo de segmentação de radiografias para detecção de defeitos usando seqüência de filtros, destaca-se o trabalho de Mery [25] para encontrar defeitos de fundição em rodas de alumínio de automóveis. O princípio de segmentação de Mery [25] visava detectar regiões que pudessem corresponder a defeitos reais, se baseando no fato de que duas características gerais dos defeitos podem ser usadas para identificá-los: i) um defeito é uma sub-região conectada de uma imagem radiográfica; ii) há uma diferença significativa de nível de cinza entre o defeito e a sua região de vizinhança. A identificação dos defeitos, neste caso, foi atingida usando duas etapas básicas:

- Detecção de contornos: aplicação de um filtro do tipo *Laplacian-of-Gaussian* (LoG) disponível na caixa de ferramentas do programa MATLAB [26], e utilização do algoritmo de *Zero-Crossing*. O operador LoG envolve o filtro passa-baixa de Gauss para suavização de ruído. A imagem binária resultante deve produzir defeitos reais fechados e contornos conectados que demarcam regiões. Entretanto, Mery [25] ressalta que um defeito pode estar perfeitamente fechado se estiver localizado próximo a um contorno de uma estrutura regular. Para resolver o problema nesta condição, um engrossamento dos contornos da estrutura regular é realizado nas etapas: i) cálculo do gradiente da imagem original; ii) limiarização da imagem gradiente em níveis elevados, obtendo uma imagem binária; iii) a imagem resultante é adicionada a imagem final da aplicação do algoritmo de *Zero-Crossing*.
- Segmentação e classificação de defeitos potenciais: em seguida, cada região fechada é então segmentada e classificada como provável defeito se: i) o nível médio de cinza é maior do que 2,5% em relação a região vizinha (garantindo a detecção de defeitos de baixo contraste); ii) se a sua área for maior do que 15 pixels (permitindo a detecção de defeitos muito pequenos).

Mery [25] constata que as vantagens deste método baseiam-se no fato de ser um processo simples de detecção (sendo o mesmo aplicado para todas as imagens), e independente da localização do defeito e da estrutura da peça.


Outro trabalho de Mery [27], atualmente um dos pesquisadores mais envolvidos na otimização das etapas de segmentação e reconhecimento de defeitos em peças fundidas, aborda a identificação automática de defeitos de soldagem em radiografias usando características de texturas. Neste trabalho, Mery [27] aplica também o mesmo procedimento anterior para segmentação e detecção de defeitos em uma radiografia do BAM. Os resultados mostraram 1419 defeitos hipotéticos; entretanto, em uma inspeção visual nas regiões segmentadas, apenas 198 foram confirmados como defeitos reais. Com um, classificador polinomial, Mery obteve cerca de 91% de acertos e apenas cerca de 8% de falsas indicações.

A segmentação das imagens radiográficas é uma tarefa complexa e nem sempre conduz a resultados satisfatórios. A maioria das técnicas empregadas, se não forem devidamente controladas, pode causar a eliminação de informações importantes na imagem, provocando, por exemplo, o subdimensionamento de defeitos solda, e

prejudicando desta maneira etapas posteriores de classificação estruturadas em medição de características geométricas.

### 2.3. *Deteção dos Defeitos de Soldagem nas Imagens Radiográficas via Perfil de Nível de Cinza*

Uma outra linha de pesquisa para o desenvolvimento do sistema automatizado de análise de radiografias de juntas soldadas é a que visa a detecção dos defeitos via perfil de nível de cinza transversal ao cordão-de-solda. Neste caso, recorre-se normalmente à extração do cordão antes da detecção. A figura 2.1 a seguir mostra dois exemplos típico de perfis transversais ao cordão-de-solda do trabalho de Padua [28], um com a presença de defeito, figura 2.1(a), e outro sem defeito, figura 2.1(b).



**FIGURA 2.1:** 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 [28].

Li [29] recorreu, primeiramente, a uma técnica de extração do cordão-de-solda da imagem radiográfica para posterior identificação dos defeitos. Ele analisou três características dos cordões-de-solda: largura de objeto, erro médio quadrático entre o perfil do defeito e uma curva Gaussiana, e intensidade do pico do objeto. Segundo Li

[29], um perfil de intensidade do cordão-de-solda se comporta mais como uma curva Gaussiana do que outros objetos presentes na imagem.

Para verificar a capacidade de discriminação destas das classes solda e não-solda, Li [29] recorreu aos critério de “distância” entre os valores médios das características de cada classe, assim como a “justaposição” (*overlapping*) entre as classes. Para o critério de “distância”, ele concluiu que a característica largura do objeto era a melhor, e para o critério de “justaposição”, a característica erro médio quadrático teve o melhor desempenho. Utilizando estas duas características, Li [29] utilizou um total de 44 dados em um algoritmo de lógica fuzzy K-NN para classificação das classes solda e não-solda, tendo atingido um desempenho de 93,2% para a situação em que os dados estavam normalizados.

Liao e Tang [30] avaliaram a possibilidade de extração dos cordões-de-solda utilizando redes neurais. Neste trabalho, Liao [30] relata que a extração de soldas da imagens radiográficas é um problema de segmentação, constatando que é impossível a aplicação de um corte simples no nível de cinza no histograma da radiografia para segmentá-la. Portanto, ele recorre ao emprego de cortes múltiplos da seguinte forma:

$$\text{Se o nível for } <25 \text{ ou } >50 \Rightarrow 0 \text{ (preto)} \quad (2.1)$$

$$\text{Entre 25 e 50} \Rightarrow 255 \text{ (branco)} \quad (2.2)$$

Contudo, Liao [30] não atingiu bons resultados usando somente está técnica. Por isso, Liao [30] passou a trabalhar com redes neurais para extração do cordão na imagem radiográfica. Para tal, primeiramente definiu as características capazes de discriminar uma solda do restante da imagem. As características foram extraídas do perfil de cinza transversal à imagem do cordão. Foram elas: posição do pico, largura do pico, erro médio quadrático entre o perfil da solda e uma curva Gaussiana, e intensidade do pico. Primeiro, o sistema funcionava com um algoritmo para detecção dos picos e objetos na imagem, baseado na detecção de mudanças na tangente à linha do perfil em cada ponto. Para cada objeto detectado, a intensidade do pico e sua posição eram determinados. Em seguida, aplicou um algoritmo para detectar os vales associados aos picos/objetos encontrados. Depois de encontrados os vales, mediu a largura de cada objeto e calculou o erro médio quadrático.

Após as etapas descritas acima, uma rede neural do tipo *retropropagação* do erro com duas camadas, utilizando momento [4] e treinamento em batelada, foi utilizada para classificar as entradas em duas classes: solda e não-solda. Liao [30] recorreu também à técnica Fletcher-Reeves para treinamento da rede, comparando-a em desempenho com o método de *retropropagação*. Feita a classificação pela rede neural, o resultado então era uma imagem binária com a solda em branco e o restante em preto. Para eliminar erros de classificação, um sistema de pós-processamento foi aplicado, otimizando os resultados.

Um conjunto de dados de validação foi usado para determinar os parâmetros ótimos da rede. Na comparação entre os dois treinamentos, os resultados mostraram que a técnica de Fletcher-Reeves apresentou melhor resultado. Liao [30] também executou uma série de testes com as redes visando obter a melhor configuração de rede possível, chegando a conclusão que a rede com 7 neurônios na camada intermediária apresentava o melhor desempenho, permitindo 100% de acerto na classificação das soldas.

Em outra publicação (parte I), Liao e Ni [18] extraíram o cordão-de-solda da imagem radiográfica digital utilizando também o software *Khoros*, porém, neste caso, eles não utilizaram redes neurais para classificação dos cordões. Liao [18] detalha os 15 passos que compõem o algoritmo de extração do cordão em seu trabalho. Seus resultados comprovaram a total eficiência de sua metodologia (100% de acerto) para extração de cordões-de-solda que possuam arestas/borda lineares, contudo, ele ressaltou a necessidade de desenvolvimento deste método para o caso de cordões com bordas curvas.


Em sua segunda publicação (parte II), Liao [23] descreve a segunda parte de seu trabalho para elaboração de um sistema automático de inspeção radiográfica na qual trata da detecção do defeito no cordão. A metodologia empregada por Liao [23] foi desenvolvida com base na observação de que um perfil de intensidade dos níveis de cinza transversal ao cordão-de-solda descreve a forma de um “sino” perfeito. Um defeito de soldagem, se estiver presente na solda, resultará em uma anomalia no formato do perfil. Liao [23] classificou esta anomalia em três categorias: pico, vale e declividade côncava.

O método de detecção de Liao [23] compreendeu 4 etapas principais: módulo de pré-processamento, módulo de ajuste de curva, módulo de detecção de perfil anômalo e módulo de pós-processamento. O módulo de pré-processamento foi usado para remover o fundo da imagem (*background*) e normalizar todas as imagens no mesmo nível de

cinza. O módulo de ajuste de curva foi utilizado para suavizar os perfis pela aplicação de filtro nas variações locais. A detecção de perfil anômalo detecta a existência de anomalias nos perfis. Os resultados obtidos dos perfis processados foram então reunidos para gerar um mapa bidimensional do defeito. O módulo de pós-processamento removeu anomalias isoladas que foram identificadas em um passo anterior e atualizou os mapas dos defeitos.

No módulo para detecção dos defeitos, que Liao [23] denomina de detecção de pico anômalo, ele definiu alguns conceitos que foram usados no sistema para encontrar os picos nos perfis que podiam ser interpretados como defeitos de soldagem, tais como (figura 2.2):

- “perna” interna e externa do pico: a “perna” interna é definida como a mais próxima da linha de centro, enquanto que a externa, a mais distante.
- ângulo do pico  $\theta$ : ângulo entre as duas “pernas”: externa e interna.
- pico pontudo: se o ângulo do pico é menor do que um dado valor limiar (*threshold*), este é considerado pontudo. Um pico é duplamente pontudo se o seu ângulo é menor do que a metade do valor limiar.
- pontos internos e externos do pico: o ponto aonde a “perna” externa/interna do pico começa a descrever uma curva “sino” é denominado de ponto externo/interno.



**FIGURA 2.2:** Ilustração do princípio de detecção de defeito em perfis de Liao (figura adaptada) [23].

Usando as definições acima, um pico anômalo (provável indicação de um defeito) normalmente tem as seguintes características:

- Se o pico é duplamente pontudo, ele é considerado como anômalo.
- Um pico pontudo pode ou não ser anômalo. Outra informação é necessária para confirmação.
- A maior “perna” de um pico anômalo é geralmente menor do que duas vezes o tamanho da menor.
- A tangente à “perna” externa de um pico é elevada.
- Se um pico é pontudo e seu nível de cinza correspondente é o maior da linha perfil, este é normalmente um pico anômalo.

Baseado nas características acima, foi desenvolvido um algoritmo para detecção dos picos anômalos, como descrito em seu trabalho. Após testes com 24 imagens contendo ao todo 75 defeitos, Liao [23] obteve um índice de 93,3% de acerto em seu sistema, o que ele considerou um ótimo desempenho.

Utilizando também perfis de intensidade de nível de cinza transversalmente ao cordão, o trabalho de Jacobsen [20] também é bastante interessante. Ele recorreu ao uso de filtros no domínio da frequência, em uma dimensão, para detecção de trinca e mordedura nas radiografias que trabalhou. Para realçar a visibilidade e as indicações das trincas longitudinais, Jacobsen [20] utilizou um filtro passa-alta (operador de Bessel) desenvolvido no BAM para filtrar frequências iguais ou superiores à frequência relativa à presença do defeito trinca. Partindo-se do princípio de que o defeito mordedura tem meia-largura superior ao defeito trinca, foi possível separar as duas classes de defeitos.

Para detecção dos defeitos na solda, Lashkia [31] empregou um sistema de varredura na solda baseado em lógica *fuzzy* nas direções horizontal e vertical. O algoritmo do sistema de Lashkia [31] consistiu dos seguintes passos:

- Primeiramente, uma região de interesse na radiografia é digitalizada e armazenada no computador.

- A parte principal do algoritmo é o procedimento para detecção de defeito. Aplicando lógica *fuzzy* nas direções vertical e horizontal, as posições dos defeitos são determinadas.
- Os métodos de localização e crescimento de região são aplicados para detectar a posição e forma exatas dos defeitos. O resultado deste procedimento é uma imagem binária, aonde o fundo é branco e as indicações de defeitos são pretas.

Lashkia [31] descreve a metodologia *Fuzzy* adotada para a detecção de defeitos em seu artigo detalhadamente.

Padua [28] trabalha atualmente com perfis de nível de cinza para extração do cordão-de-solda de padrões radiográficos, num procedimento similar em objetivo à técnica de Liao [18], porém com um algoritmo distinto. Nesta metodologia, ele primeiramente faz uma suavização de ruído no sinal de nível de cinza utilizando o filtro de Savitzky-Golay. A escolha deste filtro Golay é baseada no fato de que este provoca uma diminuição menor de amplitude de um vale/pico de defeito que provocaria um filtro, por exemplo, do tipo média móvel. Após suavização, Germano [28] faz uma regressão não-linear no perfil suavizado usando curva de Gauss, realizando o que seria a obtenção do fundo da imagem no ponto do perfil. É importante ressaltar que esta técnica só é aplicável em cordões-de-solda com reforço, sendo necessário o emprego de outras curvas para cordões sem reforço, o que ainda não foi realizado [28]. A idéia deste método é extrair a parte do sinal referente unicamente ao cordão, aonde prováveis defeitos podem ser encontrados, usando os parâmetros de média e desvio padrão obtidos da curva Gaussiana. Com isso, resulta em um sinal limpo de informações irrelevantes existentes na radiografia, referentes ao metal de base. Neste trabalho também, em etapas iniciais de pesquisa, foi realizada uma avaliação de detecção dos defeitos nos perfis originais e processados usando-se redes neurais artificiais. Os resultados obtidos indicaram cerca de 80% de acerto para dados de teste empregando-se classificadores lineares, resultado ligeiramente melhor do que quando se usou os perfis sem processamento. Este resultado foi considerado satisfatório e promissor por se empregar classificadores lineares simples e porque poderá ser ainda melhor na utilização de classificadores não-lineares [28].

O trabalho de Nafaâ [32] difere dos demais até aqui discutidos nesta seção por não empregar perfis de níveis de cinza. Nafaâ [32], para detectar as bordas dos defeitos, utilizou janelas 3×3 pixels deslocadas ao longo do cordão-de-solda como entradas de

uma rede neural artificial supervisionada e com treinamento em *retropropagação* do erro. Neste caso, cada elemento desta janela era um nível de cinza correspondente ao pixel da imagem. A camada de saída possuía apenas um neurônio para classificar na saída a detecção ou não de uma borda/aresta de um defeito, formando ao final uma imagem segmentada (binária). Como pares de treinamento da rede, foram utilizados 28 padrões de contornos. Naffâ [32] ressaltou em sua publicação que os resultados só foram satisfatórios quando, antes de usar a rede neural para segmentar a imagem, se fez um tratamento de otimização do contraste das radiografias. Naffâ [32] testou seu sistema para radiografias com e sem a presença de ruídos, tendo chegado a conclusão que a rede suavizou os ruídos existentes nas imagens.

## **2.4. Classificação dos Defeitos de Soldagem**

A utilização de características dos defeitos é uma das técnicas mais empregadas para detecção e classificação de defeitos de soldagem [27]. Neste caso, a escolha adequada das características mais relevantes na identificação de cada classe é de fundamental importância no processo de reconhecimento dos defeitos pelo sistema inteligente. Esta escolha é feita frequentemente de forma análoga à interpretação dada por um inspetor que, na maioria das vezes, reconhece primeiramente um tipo de defeito de soldagem na radiografia por características visuais geométricas ou de intensidade, tais como: localização, forma, comprimento, densidade (nível de cinza), razão de aspecto, etc., além da observância também das condições de soldagem. Portanto, um estudo importante da morfologia do defeito à nível de imagem é exigido para otimizar o desempenho do sistema.

Um dos trabalhos mais importantes neste campo de pesquisa, no que se refere a discriminação das classes de defeitos através do emprego de características de forma, foi desenvolvido por Aoki [21], que trata a classificação dos defeitos segundo os critérios que são descritos a seguir.

Primeiramente, um defeito pode ser classificado pela forma geométrica com que se apresenta: circular ou linear. Por exemplo, quando um defeito possui a forma circular, este pode ser classificado entre porosidade e inclusão de escória pelo formato do contorno, contraste ou posição no cordão-de-solda. Quando um defeito tem formato linear e é localizado na borda do cordão, provavelmente trata-se de uma mordedura e, quando localizado no centro do cordão, este pode ser classificado como trinca ou falta

de penetração. No estudo de Aoki [21], são definidas 10 características para discriminação das classes de defeitos: porosidade, inclusão de escória, trinca, falta de penetração e mordedura. Estas características são descritas a seguir.


- C1: Posição. Localização do defeito no cordão-de-solda ( $C_1=h/H$ ).  $h$  é a distância do defeito ao centro do cordão e  $H$ , a metade da largura do cordão.
- C2: Razão entre o comprimento vertical e horizontal do defeito ( $C_2= Fh/Fv$ ).
- C3: Razão entre o comprimento (maior medida obtida no defeito) e a área do defeito ( $C_3=M/A$ ).
- C4: Razão entre o comprimento (menor medida obtida no defeito) e a área do defeito ( $C_4=N/A$ ).
- C5: Complexidade. Esta características mede o nível de complexidade do defeito pelo seu perímetro ( $C_5=L^2/A$ ).  $L$  é o perímetro do defeito.
- C6: Coeficiente de forma. Também mede a complexidade do defeito por outra fórmula ( $C_6=\pi d^2/4A$ ). Sendo  $d$  o diâmetro maior do defeito.  $A$  é a área do defeito.
- C7: Diâmetro Heywood. O diâmetro de um círculo de área similar à área do defeito ( $C_7=D=\sqrt{4A/\pi}$ ).
- C8: Média de intensidade. Média dos níveis de cinza do defeito.
- C9: Dispersão de intensidade. É a distribuição dos níveis de cinza no defeito.
- C10: Contraste. É a diferença de intensidade entre os níveis de cinza dentro e fora do defeito.

Para reconhecimento das classes de defeitos, Aoki [21] utilizou as redes neurais. Ele trabalhou com uma rede neural supervisionada com treinamento em *retropropagação* do erro, de 2 camadas, sendo 7 neurônios na camada oculta e 5 neurônios na camada de saída (5 classes de defeitos). Aoki [21] utilizou 35 padrões radiográficos e os dados foram previamente normalizados para estarem entre 0 e 1. O neurônio da camada de saída de maior valor indicava a classe de defeito.

Para verificar a efetividade de cada característica na discriminação das classes de defeitos estudadas, ele avaliou o desempenho da rede retirando uma característica de cada vez, tendo chegado a conclusão de que o melhor desempenho era para a situação em que todas as características foram usadas. Aoki [21] construiu um histograma com o desempenho da rede para cada situação (sem a presença de uma característica). Em 27

defeitos analisados, 25 foram corretamente classificados, dando um índice de 92,6% de acerto. A figura 2.3 mostra a arquitetura do sistema empregado por Aoki [21], sendo muito similar à maioria dos outros autores.

Jacobsen [20, 33], para classificação dos defeitos mordedura e trinca longitudinal em radiografias de aços inoxidáveis, usou redes neurais em algoritmo de treinamento com *retropropagação* do erro. Seus resultados indicaram uma taxa de acerto de 97,0% para trinca e 90,0% para mordedura com os dados de teste e, com os dados de treinamento, 82,58% para trinca e 88,74% para mordedura. Este resultado é singular e não foi explicado pelo autor, pois normalmente os melhores resultados acontecem para os dados de treinamento.



**FIGURA 2.3:** Arquitetura típica de uma sistema para classificação de defeitos de soldagem [21].

Jacobsen [33] realizou também um estudo de avaliação de relevância de características usando redes neurais, no qual variava o valor de uma característica e, então, verificava a mudança de resposta da rede para esta variação.

No trabalho desenvolvido por Kato [34], foram utilizadas 10 características para classificação dos defeitos: porosidade, falta de fusão, falta de penetração, trinca e inclusão de tungstênio. Segundo Kato [34], visualmente os defeitos podem ser

classificados em lineares ou circulares. Com base nisto, ele definiu as características: comprimento, largura, simetria, arredondamento e etc. Além desses, ele definiu também as características: ângulo (entre o eixo principal do defeito e a linha central do cordão), posição (em relação ao centro do cordão), densidade de nível de cinza do defeito e etc.

Kato [34] comenta a dificuldade de se encontrar características que caracterizam os defeitos típicos de soldagem com base somente em informações fornecidas pelos inspetores de radiografias, pois mesmo os mais experientes não justificam muitas vezes o uso de uma ou outra característica para discriminar uma dada classe de defeito. Por esta razão, ele realça a necessidade de utilização de outras informações como: material soldado, técnica de soldagem utilizada, condições de soldagem e técnica de inspeção radiográfica empregada.

No trabalho de Yue [35], são relacionadas algumas constatações a respeito da relação existente entre as características geométricas e classes de defeitos de soldagem segundo normas internacionais. São elas:

- se a relação comprimento/largura  $> 3$ , então o defeito é linear; caso contrário, globular.
- o defeito cujo contorno é suave, é porosidade; caso contrário, inclusão de escória globular.
- de acordo com a direção do defeito, pode-se identificar o defeito cuja direção não é horizontal como sendo trinca, caso contrário, defeito horizontal.

Algumas críticas podem ser colocadas a estas informações. Yue [35], embora cite que são considerações de normas internacionais, não coloca em seu trabalho a referência. Além disso, podemos dizer que a afirmação de que se o contorno do defeito não é suave, temos o caso de inclusão de escória, não leva em consideração o defeito falta de fusão, que também pode apresentar contorno rugoso. Quanto à terceira afirmação, cabe a pergunta: não existe trinca longitudinal ao cordão-de-solda? Segundo os padrões radiográficos IIW (*International Institute of Welding*), existem trincas longitudinais, transversais e oblíquas ao cordão-de-solda.

Lashkia [31] comenta que basicamente pode-se classificar os defeitos em três classes pelas características visuais: defeitos arredondados (porosidade, inclusão de escória, falta de penetração), defeitos longitudinais (falta de fusão, falta de penetração, trinca) e defeitos transversais (trinca). Na tabela 2.1, constam as relações entre os

defeitos de soldagem e as suas respectivas representações visuais segundo o ponto de vista deste autor.

**TABELA 2.1:** Defeitos e suas características visuais [31].

| Defeito             | Representação Visual                                                          |
|---------------------|-------------------------------------------------------------------------------|
| Porosidade          | Zona arredondada com alto contraste.                                          |
| Inclusão de escória | Zona larga.                                                                   |
| Falta de fusão      | Zona longa e estreita localizada entre a borda e o centro do cordão-de-solda. |
| Falta de penetração | Zona longa e estreita localizada no centro do cordão-de-solda.                |
| Trinca              | Zona muito estreita com baixo contraste.                                      |

Wen [36] descreve as característica dos defeitos de soldagem como sendo:

- porosidade: pontos esféricos e escuros no filme, contorno suave, níveis de cinza baixos (escuros) no centro e altos (claros) próximos à borda.
- inclusão: forma de uma “barra” alongada e esférica, níveis de cinza não uniformes, e as bordas não são suaves como as porosidades. Localização aleatória no cordão.
- falta de fusão: localização situada entre o centro e a borda do cordão, forma alongada e estreita de contorno irregular.
- falta de penetração: localiza-se no centro do cordão, tem forma alongada com contorno suave e regular.
- trinca: localização, tamanho e orientação não regulares na solda. Forma bem estreita e irregular.

Para reconhecimento dos defeitos, Naffã [32] recorreu aos momentos regulares das imagens digitais, conforme definido em seu trabalho. Usando combinação não linear dos momentos centrais normalizados, ele derivou um conjunto de 7 momentos de Hu, os quais tinham a propriedade de serem invariantes a translação, escalamento e rotação da imagem. Então, esses sete momentos foram usados como características de entrada numa rede neural do tipo *retropropagação* do erro, com duas camadas e

neurônios com função tangente hiperbólica. O número de neurônios na camada oculta foi determinado de forma empírica.

Liao [19], que provavelmente é o pesquisador com mais artigos publicados nesta área, publicou recentemente um artigo na revista *NDT&E International* [19], no qual descreve as características:

- distância ao centro do cordão: distância do centro do defeito a linha central do cordão.
- Raio médio, desvio padrão e circularidade : características para medir o grau de circularidade de um defeito, cujas equações de cálculo encontram-se em Liao[19].
- Arredondamento: outra característica para medir o grau esférico de um defeito.
- Eixo maior: orientação da extensão do defeito na solda, sendo calculada como o ângulo entre o comprimento maior do defeito e uma linha horizontal.
- Largura e Comprimento: largura e comprimento da menor caixa envolvente ao defeito.
- Elongação: uma característica de forma muito conhecida como razão de aspecto, ou seja, razão entre a largura e comprimento do defeito.
- Diâmetro Heywood: diâmetro de um círculo tendo área equivalente ao defeito.
- Intensidade média e desvio padrão de intensidade: informação sobre o brilho do defeito na radiografia.

Liao [19] utilizou esse conjunto de características para formar os dados de entrada de dois classificadores não-lineares: um utilizando uma rede neural de duas camadas e outro implementado pelo algoritmo *Fuzzy K-NN*. Nestes classificadores, Liao classificou 6 classes de defeitos: trinca, poro, porosidade, inclusão de hidrogênio, falta de fusão e falta de penetração. Liao ressalta em seu artigo que, por ter um conjunto de observações reduzido para estas classes, usou métodos como validação cruzada e *bootstrap* para verificar o desempenho de seus classificadores. Os resultados melhores obtidos pelas redes neurais e, similarmente, pelos classificadores *nebulosos*, foram de 92,3% em média de acerto para os dados de teste, índice considerado muito bom.

## 2.5. *Considerações Finais*

Analisando as principais publicações nesta área de pesquisa, fica evidente que não existem regras bem estabelecidas que, se seguidas, conduzam a um sistema automático de inspeção radiográfica. Várias técnicas são usadas pelos autores, algumas bastantes similares, como pôde ser visto nos resumos dos artigos citados.

De uma forma geral, quase todos autores [5, 12-14, 16, 19-22, 24, 27, 34-36] recorrem, primeiramente, às técnicas de melhoramento da qualidade da imagem, como aplicação de filtros digitais antes de partir para detecção e classificação dos defeitos. O que é bastante lógico, pois quanto melhor for a qualidade da imagem em termos de contraste e ausência de ruído, mais fácil será a etapa de segmentação, detecção dos defeitos, e posteriormente a classificação do tipo de defeito encontrado.

Para detecção dos defeitos, há trabalhos similares [18, 23, 28, 30] que empregam rotinas de programação para reconhecer características nos perfis de cinza traçados transversalmente ao cordão-de-solda. Neste caso, utiliza-se tanto lógica *Fuzzy* [18, 23, 28-30, 37-39], quanto redes neurais [18, 23, 28, 30]. Um ponto a ressaltar nessa etapa do desenvolvimento do sistema automático é que vários autores [18, 23, 38] recorrem primeiramente à extração da solda da imagem para diminuir a quantidade de informação a ser processada. Estas técnicas parecem ser bastantes promissoras, segundo resultados obtidos pelos autores até o presente momento.

O único trabalho que utiliza imagens como dados de entrada de uma rede neural para detecção e classificação dos defeitos é o trabalho de Nafaâ [32]. Embora o autor tenha concluído que é viável a utilização desta técnica, temos que realçar que o treinamento da rede é bem mais complicado quando os dados de entrada são matrizes cujos os valores são níveis de cinza, devido ao aumento considerável de informação que a rede terá que processar. Por este motivo, são mais freqüentes os trabalhos que empregam características extraídas dos perfis de cinza, e principalmente as características geométricas. Neste ponto, vale ressaltar o pioneirismo de Mery [27] usando características de textura para a identificação de defeitos em radiografias.

Em termos de classificação dos defeitos, a maioria dos trabalho está direcionada para o reconhecimento de características típicas de cada defeito usando redes neurais. Grande parte dos trabalhos [12-14, 19, 21, 34-36, 40-44] utiliza algumas considerações de forma dos defeitos para escolher as características mais relevantes à discriminação


dos defeitos usuais de soldagem. Liao [19] realça a escassez ainda existente de pesquisa nessa etapa do desenvolvimento da área, lembrando que até o presente momento, não se conhece a existência de um sistema automático de análise de radiografias de juntas que seja comercial. Há, entretanto, inegavelmente um crescimento do número de pesquisadores envolvidos no desenvolvimento de tal sistema, motivados pelas vantagens tecnológicas e econômicas que ele permitirá a quem vende e compra serviços e equipamentos de inspeção radiográfica.


Atualmente, pode-se citar o seguinte panorama geográfico das principais pesquisas nesta área:

- Departamento de Engenharia Industrial e Fabricação, Universidade de Louisiana, Baton Rouge, LA, USA: pesquisadores T. Warren Liao, Gang Wang, Damin Li e Jiawei Ni.
- Departamento de Engenharia Informática, Universidade de Santiago, Chile: pesquisador Domingo Mery.
- BAM, Berlim, Alemanha: os pesquisadores Carsten Jacobsen e Uwe Zscherpel.
- Departamento de Informática e Engenharia de Computação, Universidade de Okayama, Japão: o pesquisador V. Lashkia.
- Centro de Pesquisa em Soldagem e Ensaios Não-Destrutivos, Argélia: os pesquisadores Y. Cherfa e Y. Kabir.
- Seção de Tecnologia em Ensaios Não-Destrutivos, TWI, Cambridge, Inglaterra: não há pesquisa ainda publicada, mas está investindo em projetos novos de desenvolvimento de radiografia computadorizada e no sistema de análise automática de radiografias.
- LABOEND/PEMM/COPPE – Universidade Federal do Rio de Janeiro.

Finalizando, pode-se concluir, com bases em todos os artigos lidos, que é necessário ainda um desenvolvimento maior nas etapas de segmentação (detecção) e classificação dos defeitos, tendo em vista as dificuldades que ainda são encontradas, as quais certamente direcionarão as investigações futuras.

Como pôde-se notar, existem basicamente duas linhas de pesquisa nesta área: processamento de imagem e utilização de extração de características dos defeitos, ou emprego de perfil transversal de nível de cinza. A figura 2.4 mostra um fluxograma das etapas mais usuais dentro destas linhas de desenvolvimento.





**FIGURA 2.4:** Fluxograma das técnicas pesquisadas divididas basicamente em três partes do sistema de inspeção radiográfica computadorizado: aquisição, detecção e classificação de defeitos de soldagem.

## CAPÍTULO 3 – REVISÃO TEÓRICA SOBRE RECONHECIMENTO DE PADRÕES USANDO REDES NEURAIS

---

Neste capítulo, faz-se uma breve revisão teórica sobre redes neurais utilizadas para reconhecimento de padrões, visando principalmente fornecer uma base de conhecimento para pessoas ligadas à área de ensaios não-destrutivos e engenharia de inspeção de equipamentos, que normalmente são incipientes neste assunto, e permitir um entendimento mais claro das metodologias usadas no trabalho. Destaca-se, entretanto, que de forma alguma pretende-se abordar e discutir todos os aspectos e teorias sobre redes neurais artificiais e reconhecimento de padrões, tendo em vista a vasta e detalhada literatura existente, das quais toma-se como referência para escrever este capítulo: Haykin [4], Gonzalez [9], Wasserman [45], Bishop [46], Hertz, Krogh e Palmer [47] e Duda e Hart [48]. Portanto, os pesquisadores que possuírem conhecimentos fundamentais sobre redes neurais, certamente podem dispensar a leitura deste capítulo, sem detrimento da compreensão do trabalho de tese.

Primeiramente, faz-se uma pequena introdução ao reconhecimento de padrões com extração de características para formação dos vetores de entrada dos classificadores. Em seguida, descreve-se rapidamente o princípio do *perceptron* de uma camada como base para o entendimento das redes do tipo alimentação adiante (MLP–*Perceptron de Múltiplas Camadas*) com treinamento por *retropropagação* do erro, que serão descritas em termos de treinamento. Ressalta-se que a metodologia utilizada na tese para implementação dos classificadores lineares e não-lineares, empregando este tipo de rede, será descrita no capítulo 4.

### 3.1. O Que é um Padrão de uma Classe

A definição mais comum é a adotada por Gonzalez [9] e estabelece que: um padrão é uma descrição quantitativa ou estrutural de um objeto, ou de outra entidade de interesse em uma imagem ou em um sinal. Um padrão é em geral composto por um ou mais descritores, mais freqüentemente conhecidos como *características*. Uma *classe de*

*padrões* pode ser considerada como uma família de padrões que compartilhem algumas propriedades comuns [9].

O reconhecimento de padrões por máquinas envolve técnicas inteligentes para atribuição dos padrões às suas respectivas classes. Para se representar os padrões, usa-se normalmente a representação vetorial, sendo que em alguns casos emprega-se também a representação em cadeias e árvores, usadas para descrições estruturais [9].

Normalmente, um vetor padrão é representado por um vetor linha:

$$\underline{x} = (x_1, x_2, x_3 \cdots, x_n) \quad (3.1),$$

onde  $x_i$  representa cada componente, ou seja, a  $i$ -ésima característica, e  $n$  é o número de características. Embora o seu vetor transposto também possa ser usado [9, 48].


### 3.2. *Sistema de Reconhecimento de Padrões*

Um dos livros mais interessantes e conhecidos sobre reconhecimento de padrões é de autoria de Richard O. Duda e Peter E. Hart [48]. Neste livro, os autores atestam que os sistemas de reconhecimento de padrões seguem normalmente uma seqüência de etapas conforme a figura 3.1, na qual destaca-se em azul as etapas envolvidas neste trabalho. Cada uma destas etapas tem um grau de complexidade que varia de acordo com o problema de reconhecimento de padrão em questão. Certamente, para que o sistema funcione perfeitamente, será necessário o correto desenvolvimento e otimização de cada uma das etapas [48].

A primeira etapa é de aquisição dos sinais ou imagens, formando os dados de entrada para o sistema. Nesta etapa, recorre-se freqüentemente a procedimentos para pré-processamento e normalização de dados [48].

A segunda etapa é responsável pela segmentação, que de uma maneira simples para um sistema por exemplo envolvendo aquisição de imagens, define-se como a separação dos objetos de interesse na imagem dos outros objetos contendo informação irrelevante (*background*). Duda e Hart [48] afirmam que o problema de segmentação é um dos problemas mais complexos em reconhecimento de padrões, citando, por exemplo, a problemática existente em sistema de reconhecimento de voz [48].

A terceira etapa, extração de características, é responsável pela formação de um conjunto de medidas ou valores que sejam similares para objetos pertencentes a mesma classe, e diferentes para objetos de classes distintas. Um bom sistema de extração de características deverá facilitar o trabalho do classificador. Desta forma, é recomendável que seja feita uma seleção adequada de características a serem usadas para um dado sistema de reconhecimento de padrões. É importante a escolha de características realmente relevantes para a discriminação das classes estudadas e, preferencialmente, que sejam de extração fácil. Resumindo, um conjunto ideal de características deverá ser composto pelo menor número possível de características de extração fácil, sem detrimento do desempenho do classificador [48].



**FIGURA 3.1:** Ilustração das etapas normalmente envolvidas em um sistema de reconhecimento de padrão [48]. Destaque em azul para as etapas envolvidas no trabalho.

A quarta etapa, a classificação propriamente dita, tem como objetivo usar o vetor de entrada, formado pelas características, para atribuir um objeto à uma classe. O grau de dificuldade do problema de classificação está fortemente associado à variabilidade existente nos valores das características de objetos de mesma classe, e à diferença de valores das características de objetos de classes distintas. Existem diversos tipos de problemas envolvidos nesta etapa, mas os problemas principais são encontrar qual o tipo de classificador adequado para um dado problema, e obter o melhor desempenho possível [48].

A quinta etapa, que pode ou não existir em determinados sistemas, envolve normalmente uma tomada de decisão a partir do resultado da classificação.

A etapa de classificação pode ser desenvolvida usando-se várias técnicas, como as que empregam classificadores estatísticos [48, 49], as redes neurais artificiais, lógica difusa e sistemas híbridos. O que varia de um classificador para o outro é o algoritmo de treinamento ou aprendizagem. Na verdade, como dizem a maioria dos autores [4, 48], não há um classificador que seja melhor que outro, o que acontece é que para um determinado problema de separação de padrões, um classificador pode ter desempenho melhor, porque as suas características de funcionamento são mais adequadas para tal problema. Em alguns casos, somente um tipo de classificador pode ser usado.

### **3.3. O que são Redes Neurais Artificiais?**

O cérebro humano é constituído por unidades de processamento formadas por células computacionais denominadas neurônios, estes são conectados entre si e com as células sensoras e motoras por ligações sinápticas, também conhecidas como sinapses ou pesos sinápticos. Um cérebro em sua fase adulta possui normalmente bilhões de neurônios e trilhões de sinapses, formando uma rede neural biológica capaz de realizar as mais difíceis tarefas, dentre elas: reconhecimento de padrões, percepção, controle motor, etc. [30].

Especificamente, aproveitando o tema de tese proposto: um inspetor de radiografias realiza uma tarefa de reconhecimento perceptivo, reconhece um dado tipo de defeito de soldagem em uma radiografia, baseado em um processo de aprendizagem conhecido como *aprendizagem por experiência*.

Haykin [4] descreve assim uma *rede neural artificial*:

*Uma rede neural é um processador maciço, paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela se assemelha ao cérebro humano em dois aspectos:*

- 1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.*
- 2. Os pesos sinápticos são utilizados para armazenar o conhecimento adquirido.*

O processo de aprendizagem é realizado por um *algoritmo de aprendizagem*, que tem como função modificar os pesos sinápticos da rede de forma ordenada, visando alcançar um objetivo de projeto desejado.


Uma rede neural artificial é normalmente implementada utilizando componentes eletrônicos ou emulada por programação em computador.

Existem basicamente dois tipos de aprendizagem: aprendizagem supervisionada, que envolve a modificação dos pesos sinápticos da rede pela aplicação de um conjunto de dados de treinamento (composto por entradas e suas respectivas saídas desejadas), e a aprendizagem não-supervisionada, na qual não dispõe-se de uma saída desejada e a própria rede irá se ajustar às regularidades estatísticas dos dados de entrada, desenvolvendo a capacidade de formar representações internas para codificar as características da entrada e, desta maneira, de criar automaticamente as classes [4].

Para este trabalho de pesquisa, dispondo-se de conjuntos padrões de treinamento, recorreu-se às redes neurais tipo *feedforward* com algoritmo de treinamento supervisionado por *retropropagação* do erro para implementação dos classificadores.

### **3.4. Modelo de um Neurônio**

O neurônio é a unidade fundamental de processamento de uma rede neural. A figura 3.2 ilustra um modelo de um neurônio, base para elaboração de diversos tipo de arquitetura de redes neurais artificiais.



**FIGURA 3.2:** Modelo de um neurônio artificial [4].

Um neurônio é normalmente composto dos seguintes elementos:

- 1 – Um conjunto de sinapses, cada qual tendo o seu próprio peso ou peso sináptico. Uma 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.
- 2 – Um somador que soma os sinais de entradas da rede ponderados pelos respectivos pesos sinápticos do neurônio, executando uma combinação linear dos mesmos com um sinal de polarização  $b_j$ .
- 3 – 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 de  $[0, 1]$  ou  $[-1, 1]$ .

O modelo apresentado na figura 3.2 inclui uma polarização (ou *bias*  $b_j$ ) aplicado ao neurônio que pode ser representado por uma sinapse  $b_j$  conectada a uma porta de sinal fixa unitária. Este *bias* tem o efeito de aumentar ou diminuir a entrada da função de ativação, o que vai depender de ser ele positivo ou negativo.

Usando formulação matemática, o neurônio  $j$  pode ser descrito funcionalmente por:

$$y_j = \sum_{i=1}^n w_{jn} x_n + b_j \quad (3.2),$$

e

$$U_j = \varphi(y_j) \quad (3.3),$$

onde  $x_1, x_2, \dots, x_n$  são as entradas do neurônio;  $w_{j1}, w_{j2}, \dots, w_{jn}$  são os pesos sinápticos do neurônio  $j$ ;  $y_j$  é a combinação linear das entradas e do *bias*  $b_j$  e  $\varphi$  é a função de ativação [4].

Usualmente, três tipo de funções de ativação são utilizadas em redes neurais, segundo Haykin [4]: função de limiar, função de limiar por partes e função sigmóide. A função sigmóide, cujo gráfico tem forma de  $S$ , é a mais empregada na construção de redes neurais artificiais. Um função deste tipo que é muito utilizada é a função tangente hiperbólica, definida por:

$$U = \varphi(y) = \tanh(y) \quad (3.4)$$

Esta função apresenta várias vantagens [4, 48] de utilização e entre elas destaca-se a propriedade de ser diferenciável em todo domínio, fator importante para o treinamento em *retropropagação* do erro que será abordado no item 3.6.1.

Neste trabalho, utiliza-se também o neurônio linear, cuja função de ativação é a identidade,  $U_j = y_j$ .

### 3.5. *Perceptrons de uma Camada*

A prova do teorema de aprendizagem do *perceptron* [4] demonstrou que o *perceptron* poderia aprender qualquer coisa que ele pudesse representar. É importante diferenciar representação de aprendizagem. Representação refere a habilidade de um *perceptron* (ou outra rede) para simular uma função específica. Aprendizagem requer a

existência de um procedimento sistemático para ajustar os pesos sinápticos para produzir uma função [4].

O *perceptron* é constituído por uma combinação linear das entradas  $x_1, x_2, \dots, x_n$  aplicada às suas sinapses  $w_1, w_2, \dots, w_n$ , um *bias*  $b$  é incorporado externamente. Quando o resultado desta operação é positivo, o neurônio produz uma saída +1, quando é negativo, a saída é -1, conforme a equação 3.5 [4].

$$y = \sum_{i=1}^n w_i x_i + b \quad (3.5)$$

$$\text{Se } y > 0 \Rightarrow U = +1$$

$$\text{Caso } y < 0 \Rightarrow U = -1$$


Segundo descreve Haykin [4], o objetivo do *perceptron* é classificar corretamente o conjunto de estímulos aplicados externamente  $x_1, x_2, \dots, x_n$  em uma de duas classes  $C_1$  ou  $C_2$ . A regra de decisão para classificação é atribuir o ponto representado pelas entradas  $x_1, x_2, \dots, x_n$  à classe  $C_1$ , se a saída do *perceptron* for +1, e à classe  $C_2$  se ela for -1.

Para que se compreenda melhor o comportamento de um classificador de padrões, geralmente traça-se um mapa das regiões de decisão no espaço de sinal  $n$ -dimensional abrangido pelas  $n$  variáveis de entrada  $x_1, x_2, \dots, x_n$ . Na forma mais simples do *perceptron*, existem duas regiões separadas por um hiperplano definido por [4, 48]:

$$\sum_{i=1}^n w_i x_i + b = 0 \quad (3.6)$$


A figura 3.3 ilustra o que acontece para o caso de duas variáveis  $x_1$  e  $x_2$ . Nesta situação, a fronteira de decisão toma forma de uma reta. Então, um ponto  $(x_1, x_2)$  que se encontra de um lado da linha de fronteira é atribuído à classe  $C_1$ , e um ponto  $(x_1, x_2)$

que está do outro lado da linha de fronteira, à classe  $C_2$ . É importante notar que a função do *bias*  $b$  é simplesmente deslocar a fronteira de decisão em relação à origem.



**FIGURA 3.3:** Ilustração do hiperplano (aqui, uma reta) como fronteira de decisão para um problema de classificação linear de padrões bidimensional de duas classes [4].

Para que um *perceptron* funcione adequadamente, as duas classes  $C_1$  e  $C_2$  devem ser linearmente separáveis. Então, padrões a serem classificados devem estar suficientemente separados entre si para garantir que a superfície de decisão consista de um hiperplano. A figura 3.4 é utilizada para facilitar a visualização de como se comportam classes linearmente separáveis e não linearmente separáveis. Na figura 3.4a, as classes são separadas facilmente por uma reta, ao contrário da figura 3.4b, quando se aproximando as duas classes, estas se tornam inseparáveis por uma reta, tornando a situação fora da capacidade de representação do *perceptron* [4].



**FIGURA 3.4:** (a) Padrões linearmente separáveis; (b) padrões não linearmente separáveis [4].

Haykin [4] relata o treinamento original do *perceptron* conforme proposto por Rosenblatt.

### 3.6. *Perceptrons de Múltiplas Camadas*


As redes de múltiplas camadas de neurônios “com alimentação adiante”, ou *feedforward*, ou sem realimentação, formam uma classe importante de redes neurais. Basicamente, estas redes consistem de uma *camada de entrada* (Haykin [4] denomina de *nós sensorias*) e uma ou mais *camadas intermediárias* (Haykin [4] denomina de *nós computacionais*). Neste tipo de rede, as entradas se propagam apenas para a frente, camada por camada. São também conhecidas como *perceptrons de múltiplas camadas*, sendo uma generalização do *perceptron de camada única*.

Os *perceptrons de múltiplas camadas* vêm sendo utilizados para solução de diversos tipos de problemas. O treinamento destas redes é do tipo supervisionado e o algoritmo mais empregado é o de *retropropagação do erro* (do inglês *error back-propagation*) baseado na regra de aprendizagem por correção de erro [4, 46, 48].

A aprendizagem por *retropropagação* de erro consiste, resumidamente, de duas etapas: um passo para frente, a propagação do sinal, e um passo para trás, a *retropropagação* do erro. Um vetor de entrada é fornecido à camada de entrada da rede

e seu efeito se propaga através da rede, camada por camada. Ao final da rede, um conjunto de saídas é produzido como resposta real da rede. Na etapa de propagação, os pesos sinápticos são mantidos fixos. Após esta etapa, a saída da rede é subtraída da saída desejada, produzindo um erro que é então *retropropagado* através da rede linearizada, sendo os pesos sinápticos ajustados de acordo com uma regra de correção de erro. O objetivo é aproximar ao máximo possível a saída real da rede da saída desejada, minimizando o erro.

A figura 3.5 ilustra a arquitetura de um perceptron de múltiplas camadas com duas camadas (uma camada intermediária/oculta e uma camada de saída) e totalmente conectada.



**FIGURA 3.5:** Arquitetura de uma rede múltipla camada com uma camada intermediária e uma camada de saída [4].

### 3.6.1. Algoritmo de Retropropagação do Erro

O erro calculado na saída do neurônio  $j$ , no passo  $n$  de iteração (quando é apresentado o  $n$ -ésimo exemplo de treinamento), é assim definido:

$$E_j(n) = d_j(n) - U_j \quad (3.7)$$

O valor no instante  $n$  da “energia” do erro é definido para o neurônio  $j$  como [4]:

$$\frac{1}{2}e_j^2(n) \quad (3.8)$$

Para sabermos a energia total  $E(n)$  do erro, basta somar todos os termos  $\frac{1}{2}e_j^2(n)$  de todos os neurônios da camada de saída. Então podemos escrever:

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (3.9)$$

Neste caso,  $C$  representa todos os neurônios da camada de saída da rede. Como  $n$  representa o número total de padrões contidos no conjunto de treinamento, a energia média do erro quadrado é calculada somando-se os  $E(n)$  para todos os  $n$  e depois dividindo o resultado por  $n$ , temos então:

$$E_{\text{média}}(n) = \frac{1}{n} \sum_{i=1}^n E(i) \quad (3.10)$$

A  $E_{\text{média}}(n)$  representa a função de custo como uma medida do desempenho do processo de aprendizagem da rede. O objetivo do processo de aprendizagem por *retropropagação* é ajustar os parâmetros livres da rede (pesos sinápticos e *bias*) para minimizar  $E_{\text{média}}(n)$ .

De uma maneira similar ao algoritmo LMS (*Least Mean Square*), descrito detalhadamente em Simon Haykin [4], o algoritmo de *retropropagação* aplica uma correção  $\Delta w_{ji}(n)$  ao peso sináptico  $w_{ji}(n)$ , que é proporcional à derivada parcial  $\frac{\partial E(n)}{\partial w_{ji}(n)}$ . Pela regra da cadeia, este gradiente pode ser expressado como sendo:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial U_j(n)} \frac{\partial U_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial w_{ji}(n)} \quad (3.11)$$

Derivando a equação (3.9) em relação a  $e_j(n)$ , a equação (3.7) em relação a  $U_j$ , a equação (3.3) em relação a  $y_j(n)$  e finalmente a equação (3.4) em relação a  $w_{ji}$ , substituindo os resultados encontrados em (3.11), obtém-se:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n) \phi'(y_j(n)) x_n(n) \quad (3.12)$$

Pela regra delta [4], a correção  $\Delta w_{ji}(n)$  aplicada a  $w_{ji}(n)$  é:

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (3.13),$$

onde  $\eta$  é a taxa de aprendizagem do algoritmo de *retropropagação*. É importante ressaltar que o sinal negativo representa a *descida do gradiente* no espaço de pesos (busca de uma direção para a atualização sináptica que reduza o valor de  $E(n)$ ). Substituindo (3.12) em (3.13):

$$\Delta w_{ji}(n) = \eta \delta_j(n) x_i(n) \quad (3.14),$$

sendo o gradiente local  $\delta_j(n)$  definido por [4]:

$$\delta_j(n) = -\frac{\partial E(n)}{\partial y_j(n)} = e_j(n) \phi_j'(y_j(n)) \quad (3.15)$$

Então a correção dos pesos sinápticos pode ser expresso pela equação:

$$w_{ji}(n+1) = w_{ji}(n) + \eta \delta_j(n) x_i(n) \quad (3.16)$$


Como se trata de um treinamento supervisionado, tem-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, os neurônios compartilham a responsabilidade pelos erros cometidos na saída da rede. A dificuldade é saber como recompensar ou penalizar estes neurônios pela sua parcela de responsabilidade [4].

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

O campo local induzido utilizado para o cálculo dos ajustes dos pesos sinápticos das camadas intermediárias é determinado pela equação [4]:

$$\delta_j(n) = \varphi'(y_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (3.17)$$

sendo  $j$  o índice do neurônio intermediário e  $k$  o índice do neurônio imediatamente à direita de  $j$ . A figura 3.6 ilustra o passo de propagação (linha contínua) e o passo de *retropropagação* do erro (linha pontilhada) de uma rede neural com três camadas.



**FIGURA 3.6 :** Rede em *retropropagação* do erro com três camadas [47].

Na vasta literatura existente sobre redes neurais artificiais, o método de minimização do erro descrito acima é conhecido como *gradiente descendente* [4, 46, 47].

Em resumo, um algoritmo de *retropropagação* do erro pode ser descrito pelos seguintes passos:

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

O algoritmo de *retropropagação* do erro apresenta algumas desvantagens, como por exemplo: lentidão de treinamento para superfícies de erros mais complexas e convergência para mínimos locais. Por este motivo, existem várias técnicas alternativas de treinamento que são usadas nos dias de hoje para solução destes problemas, como a utilização de momento,  $\eta$  variável, etc. Uma abordagem detalhada sobre elas é facilmente encontrada na literatura [4, 46-48].

## CAPÍTULO 4 – METODOLOGIA DE TRABALHO

---

Neste capítulo, descrevem-se os materiais e metodologias utilizados no trabalho, dividindo-se nas seções: filmes radiográficos, digitalização dos filmes, pré-processamento das imagens, exemplos das imagens radiográficas usadas por classes de defeito, extração das características dos defeitos, pré-processamento dos dados, classificadores lineares não-hierárquicos, hierárquicos e não-lineares, análise de correlação linear, critério de relevância com classificador linear e não-linear, probabilidade de acerto obtida com os classificadores e análise dos componentes principais de discriminação não-linear. Finalizando, descrevem-se algumas técnicas de estimação da acurácia de classificadores.

### 4.1. *Filmes Radiográficos*

Os filmes radiográficos utilizados no trabalho foram padrões do IIW (*International Institute of Welding*) que atestam a existência de determinada classe de defeito em cada filme. Estes padrões foram empregados de modo a dar maior confiabilidade aos resultados encontrados, pois são reconhecidamente aceitos pelos profissionais que trabalham com ensaio por radiografia. Os padrões IIW são radiografias de juntas soldadas de aço carbono e em cada filme são dadas as informações referentes aos parâmetros radiográficos empregados (tensão do aparelho, corrente empregada, tipo de solda existente, distância foco-filme, etc.), porém estes fatores não foram levados em consideração por não fazerem parte do escopo do trabalho proposto.

### 4.2. *Digitalização dos Filmes Radiográficos*

Para digitalização dos filmes, utilizou-se o escâner da marca UMAX, modelo Mirage II (3,0 densidade óptica máxima; 2000 dpi (pontos por polegadas) de resolução máxima em modo de transmissão). A resolução espacial empregada foi de 500 dpi, totalizando um tamanho médio (devido a uma pequena variação de tamanho entre os


padrões) das imagens em 2900 pixels (comprimento horizontal)  $\times$  950 pixels (comprimento vertical), o que resultou em um tamanho médio dos pixels de 50 $\mu$ m. Esta resolução foi adotada pois permite a detecção e a medição de defeitos do tamanho da ordem de centésimos de milímetros, o que, em termos práticos de inspeção radiográfica, é bem acima do que normalmente detectado pelo processo visual. A resolução em tons de cinza escolhida foi de 8 bits (256 níveis), pois este modelo de escâner não permite uma resolução maior. Entretanto, sabe-se que visualmente o ser humano não é capaz de notar diferença de tons de cinza acima de 128 níveis [9] e imagens com 10, 12 ou 16 bits tornam-se consideravelmente maiores em espaço de armazenamento, além de alguns formatos padrões de imagens não aceitarem esta resolução.

#### **4.3. *Pré-processamento das Imagens***

Após digitalização, os padrões radiográficos foram pré-processados. Aplicou-se um filtro do tipo mediana com tamanho de janela de operação 3 $\times$ 3 para suavização do ruído presente, e posteriormente extensão de histograma de níveis de cinza para melhorar o contraste das imagens. É importante destacar que, neste trabalho, não foram estudados os processos de segmentação visando a detecção dos defeitos de soldagem, sendo está feita de forma visual, neste caso, trabalhou-se em um processo semi-automático de detecção e classificação de defeitos em radiografias. Uma discussão mais detalhada sobre pré-processamento destas imagens é feita em Silva [10].

#### **4.4. *Imagens após Pré-processamento***

Alguns exemplos de imagens radiográficas obtidas após digitalização e pré-processamento são mostradas a seguir na figura 4.1. Veremos dois exemplos de imagem para cada classe de defeito estudada, dando as características comuns das classes possivelmente importantes para o desenvolvimento de um processo automático de classificação, e prováveis causas oriundas do processo de soldagem [50].





***Padrões com indicações de defeito mordedura (MO)***

**Característica na Imagem**

Caracterizado por uma região escura, tipicamente localizado na borda da solda e possuindo formato geométrico aleatório.

**Causa**

Falta de preenchimento do chanfro, normalmente ocasionado por excesso de velocidade da soldagem.




***Padrões com indicações de defeito falta de penetração (FP)***


**Característica na Imagem**

Região escura de formato linear, tipicamente localizado no centro do cordão, podendo ser contínuo ou intermitente.

**Causa**

Defeito ocasionado pela falta de fusão na raiz ou pela falta de enchimento com metal de solda.







***Padrões com indicações de defeito Porosidade (PO)***

Característica na Imagem

Região escura de formato arredondado ou fracamente alongado, localizado em qualquer posição do cordão-de-solda.

Causa

Aprisionamento de gás na solda.




***Padrões com indicações de defeito inclusão de escória linear (IEL)***


Característica na Imagem

Linhas escuras, irregulares na largura e normalmente paralelas às bordas do cordão-de-solda.

Causa

Cavidades alongadas contendo escória ou outro material de baixa densidade.





***Padrões com indicações de defeito inclusão de escória não-linear (IENL)***


**Característica na Imagem**

Área escura de formato não linear, localizada em posição aleatória dentro do cordão.



**Causa**


Cavidades não alongadas contendo escória ou outro material de baixa densidade.



***Padrões com indicações de defeito falta de fusão (FF)***


**Característica na Imagem**

Linhas alongadas ou pequenas regiões escuras, normalmente seguindo a direção longitudinal do cordão. Possui direção mais regular que a inclusão de escória.



**Causa**

Falta de fusão na parede do chanfro, formando vazios alongados entre o metal de solda e o metal de base.



***Padrões com indicações  
do defeito trinca  
(longitudinal e  
transversal)  
(TR)***


#### Característica na Imagem

Linha estreita escura, contínua ou intermitente ao longo do comprimento do cordão (longitudinal).

Linha estreita escura, reta ou irregular na direção transversal ao cordão (transversal).

#### Causa

Discontinuidade produzida pela falta de metal de solda.



**FIGURA 4.1:** Exemplos de padrões IIW após pré-processamento.


#### **4.5. Extração de Características**

A partir dos filmes digitalizados, em um processo visual de detecção dos defeitos e com base nas características típicas de cada classe [50], foram definidas 6 características para discriminação de 5 classes de defeitos: inclusão de escória não-linear (IENL), inclusão linear (IEL), porosidade (PO), falta de penetração (FP) e mordedura (MO). Para simplificação, usa-se no texto muitas vezes apenas estas siglas para identificação dos defeitos. Embora existam padrões radiográficos referentes às classes falta de fusão e trinca, estes defeitos não foram analisados por falta de dados suficientes para treinamento dos classificadores. A quantidade de dados utilizada foi composta por 15 amostras de mordedura, 14 de falta de penetração, 17 de porosidade,


24 de inclusão de escória não-linear, 25 de inclusão linear. Como a quantidade de dados era desigual entre as classes, duplicou-se aleatoriamente alguns dos dados das classes menos favorecidas até obter-se 25 amostras, maior quantidade disponível de uma classe, tendo como objetivo não favorecer, no treinamento da rede neural, o aprendizado de uma classe com maior quantidade de amostras. Entretanto, quando considerou-se a classe inclusão de escória (IE) como apenas uma classe, trabalhou-se com um total de 50 amostras. A figura 4.2 mostra um organograma do princípio utilizado para escolha das características visando a separação das classes de defeitos em estudo. Escolheu-se, aleatoriamente, um padrão radiográfico contendo a classe inclusão de escória para ilustrar as definições das características que são dadas a seguir na figura 4.3.

- Contraste: razão entre a variação de nível de cinza no defeito (diferença entre o máximo e o mínimo valor) e a variação de nível de cinza presente na imagem radiográfica. Esta característica foi escolhida partindo-se do princípio de que cada defeito normalmente absorve uma quantidade diferente de radiação, o que gera uma densidade óptica, ou intensidade de nível de cinza, diferente na imagem. Por exemplo: normalmente o defeito falta de penetração é mais enegrecido do que uma inclusão de escória. Pode-se destacar também, que dentro do processo de detecção do defeito na junta soldada radiografada, é analisando a diferença de contraste entre um defeito e o fundo da radiografia que se constata a sua presença.
- Posição ( $p=h/H$ ):  $h$  é distância do centróide do defeito ao centro do cordão que, neste caso, foi determinada medindo-se a metade de  $H$ . Utilizou-se  $H$  para normalizar a característica em relação às variações de espessura de cordão que ocorrem em juntas soldadas. Com esta característica, é possível separar falta de penetração, frequentemente localizada no centro do cordão, e mordedura, geralmente presente na borda.
- Razão de aspecto ( $a = L/e$ ): esta característica é empregada para separação das classes mais esféricas (poro), onde os valores giram próximos a 1, e as menos esféricas (falta de penetração e inclusão linear). Característica extraída automaticamente no programa de processamento de imagens utilizado, sendo “ $L$ ” o eixo maior da menor elipse que envolve o defeito e “ $e$ ” o eixo menor.

- Razão entre a largura e a Área ( $e/A$ ): razão entre o diâmetro mínimo [51] do defeito e sua área. Esta informação mede o grau de circunferência do defeito [21].
- Razão entre o comprimento: ( $L/A$ ): razão entre o diâmetro maior do defeito e sua área. Esta informação mede o grau de circunferência do defeito [21].
- Arredondamento (Roundness): mede a razão  $p^2/4\pi A$ , onde  $p$  é o perímetro e  $A$  a área do defeito [51]. Pela relação, observa-se que quando a forma do defeito se aproxima de uma circunferência, esta medida tenderá a 1, o que é útil na separação das classes esféricas como porosidade e inclusão de escória não-linear, e lineares como falta de penetração, inclusão linear e mordedura.



**FIGURA 4.2:** Organograma representando a separação das classes de defeitos através das características escolhidas.



**FIGURA 4.3:** Exemplo de padrão IIW utilizado indicando a presença de inclusão de escória; (b) ilustração para a definição das características utilizadas.

No prosseguimento deste trabalho, o vetor  $\underline{x}$  que caracteriza cada padrão de defeito será denominado “entrada” do sistema, e cada parâmetro, ou componente deste vetor, “componente de entrada” ou simplesmente “componente”; cada classe de defeito será denominada simplesmente “classe”.

#### 4.6. *Pré-processamento dos Dados*

Para que os dados extraídos sejam o mais representativos possíveis e não dificultem indevidamente a construção dos classificadores, é importante eliminar entradas atípicas (*outliers*) que estejam fora da representação verdadeira de uma classe. Com base nesta necessidade, as medidas de cada uma das componentes das entradas foram ajustadas em uma distribuição normal e as entradas atípicas, em que alguma das componentes distasse da média mais que três desvios padrões, foram excluídas do conjunto de dados.

#### 4.7. *Desenvolvimento dos Discriminadores Lineares Não-Hierárquicos e Hierárquicos que Compõem os Classificadores Lineares*

Cada entrada é representada por seis características, isto é, por um vetor  $\underline{x}$  de dimensão 6, ou geometricamente, por um ponto em um espaço de dimensão 6, chamado espaço de entradas. Um discriminador linear para classe  $C_j$  separa as entradas desta classe das demais através de uma inequação de primeira ordem, linear,

$$\underline{x} \in C_j \Leftrightarrow U_j > 0 \quad (4.1),$$

onde,

$$U_j = \sum_{i=1}^6 w_{ij} x_i + b_j = \underline{w}_j^t \underline{x} + b_j \quad (4.2)$$

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 no sentido de  $\underline{w}_j$ . Usualmente normaliza-se  $|\underline{w}_j| = 1$ , ajustando-se o valor de  $b_j$  de modo a não alterar a inequação (4.1). Neste caso,  $U_j$  mede a distância da entrada  $\underline{x}$  ao separador, e é uma medida 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 de *Discriminadores de Fisher* [48]. Uma forma prática de implementá-los é através de um rede neural com uma camada e, nesta camada, um único neurônio por classe, conforme descreve Haykin [4]. Esta técnica foi usada neste trabalho.

A visualização geométrica dos separadores em nosso caso é difícil devido a dimensão do espaço de entrada, mas em um espaço de dimensão 2, pode ser facilmente realizada. Considere a figura 4.4 em um exemplo hipotético, porém baseado no problema proposto de classificação de padrões de defeitos de soldagem, onde o


sombreado mostra o domínio das entradas de classes hipotéticas  $C_j$  e seus respectivos planos separadores  $S_j$  (que, neste caso, degeneram em retas).

Cada separador  $S_j$  divide o espaço de entrada em dois semi-espacos (neste caso dois semiplanos), um onde  $U_j > 0$  e outro onde  $U_j < 0$ . Entradas que pertencem à classe  $C_j$  e que são corretamente classificadas, são representadas por pontos no semiplano onde  $U_j$  é positivo. Note que existem regiões que se situam no semi-espaco positivo de dois ou mais separadores: uma entrada nesta região será alocada em duas ou mais classes; por outro lado, podem existir regiões que se situam no semi-espaco negativo de todos os separadores: uma entrada nesta região não será alocada em nenhuma classe. Nesta situação, pode-se usar o fato que  $U_j$  é medida da probabilidade de uma entrada pertencer à classe  $C_j$  e “desempatar” o resultado, tomando a classe com o maior  $U_j$ , a mais provável de conter a entrada, como sendo a resposta.

Nota-se também claramente que as classes mais “externas” são separáveis mais facilmente, enquanto que as “internas” são dificilmente separáveis, figura 4.4. Mas, se estas classes “externas” forem removidas, outras classes anteriormente “internas” tornam-se “externas”, e podem agora ser facilmente separáveis, figura 4.5. Isto leva ao conceito de classificação hierárquica, onde inicialmente são classificados as classes “externas”, ou seja, aquelas com alto grau de acerto, e somente após as “internas”.



**FIGURA 4.4:** As cinco classes  $C_j$ ,  $j = MO, FP, PO, IEL, IENL$ , e seus respectivos separadores não-hierárquicos  $S_j$  com as polaridades indicadas. As classes mais externas MO e FP são perfeitamente separadas e as mais internas IEL e IENL, muito imperfeitamente separadas.



**FIGURA 4.5:** (a) e (b): Após a exclusão das entradas classificadas como FP e MO, os demais discriminadores podem assumir posições muito mais eficazes na separação das classes restantes, principalmente  $S_{PO}$ , (c) e (d); o mesmo ocorre após a exclusão das entradas classificadas como PO.

#### 4.8. Classificadores Não-Hierárquicos e Hierárquicos

No caso dos 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 às 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 (figura 4.4).


O classificador hierárquico é obtido de maneira similar à anterior, mas para o treinamento de cada classe  $C_j$  retira-se do conjunto de treinamento as entradas que já foram classificadas como pertencentes a outras classes mais “externas”. O neurônio correspondente a cada classe já distinguida não participa dos treinamentos das classes seguintes. Assim, obtém-se primeiro os vetores  $\underline{w}$  para as classes mais facilmente separáveis, em um processo hierárquico. Verifica-se que as classes mais “internas” e que, portanto, são difíceis de serem separadas em um processo não-hierárquico, tornam-se mais facilmente separáveis neste processo como mostra a figura 4.5.

#### 4.8.1. *Classificador Não-Hierárquico*


O fluxograma do classificador é mostrado na figura 4.6. Os vetores entrada são multiplicados pelos vetores  $\underline{w}_j$  de cada classe e somado ao deslocador (*bias*)  $b_j$  correspondente, gerando  $U_j$ . O resultado desta operação que for maior do que zero corresponde à classe de defeito. Nesta situação, tem-se a possibilidade de que nenhuma classe seja indicada para um dado vetor de entrada (quando todas as saídas forem negativas), ou ocorrer mais de uma indicação (mais de uma saída ser maior do que zero). Neste caso, pode-se usar um critério de reclassificação ou “desempate”, na qual o maior valor de  $U_j$  indica a classe. Para ambos os casos, construiu-se as tabelas de confusão de defeito com base nos resultados obtidos, além da tabela de acertos, erros e não-classificação para esta estrutura de classificador.

#### 4.8.2. *Classificador Hierárquico*

Ao contrário do classificador não-hierárquico, o classificador hierárquico funciona classificando primeiro as classes mais facilmente separáveis. O algoritmo deste classificador é mostrado na figura 4.6. Verificou-se o desempenho de forma similar ao não-hierárquico. Os algoritmos do classificador não-hierárquico e hierárquico são comparados no capítulo 5 em termos de performance de acerto.



**FIGURA 4.6:** Algoritmo do classificador não-hierárquico.



**FIGURA 4.7:** Algoritmo do classificador hierárquico.


Estes algoritmos foram implementados no *software* MATLAB após desenvolvimento dos discriminadores lineares também no MATLAB, usando os recursos disponíveis na caixa de ferramentas de redes neurais. Os discriminadores lineares de cada classe foram obtidos com uma rede de apenas um neurônio do tipo tangente hiperbólica em treinamento de *retropropagação* do erro [4]. Algumas variações de treinamento foram testadas, sendo que a utilização de  $\alpha$  variável decrescente após 1000 épocas foi a que proporcionou o melhor resultado; em termos de convergência do erro. É importante ressaltar que para não haver favorecimento das classes predominantes (IEL e IENL) no processo de treinamento da rede, os dados das classes com menor quantidade foram duplicados para igualar a 25 amostras (maior

quantidade disponível de uma classe), totalizando 125 amostras no conjunto de treinamento da rede.

#### 4.9. *Classificadores Não-Lineares*

Os classificadores não-lineares foram desenvolvidos usando redes neurais com duas camadas, uma camada intermediária e uma de saída. Para encontrar o número ótimo de neurônios na camada intermediária, variou-se o número de neurônios nesta camada, acompanhando o desempenho e o erro 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. Os resultados encontrados são dispostos em gráficos do número de neurônios versus desempenho e erro de classificação. Trantando-se de uma rede de classificação de padrões, o número de neurônios da camada de saída corresponde ao número de classes estudadas (conforme capítulo 3), neste trabalho, 5 neurônios na saída, considerando-se inclusão subdividida em duas classes: inclusão linear e não-linear. Todas as funções de ativação adotadas para os neurônios foram do tipo tangente hiperbólica e com presença de *bias* [4]. Testaram-se vários tipos de parâmetros de treinamento, como: treinamento com  $\alpha$  fixo, variável, variável decrescente, utilizando momento ( $\beta=0,9$ ), etc., com treinamento em batelada. Estes classificadores também foram implementados usando funções disponíveis na caixa de ferramentas do programa MATLAB [51]. Na prática, a utilização de  $\alpha$  variável e momento foi a que proporcionou a melhor convergência da superfície de erro após 4000 épocas (repetiu-se o treinamento com a mesma configuração pelo menos três vezes). A figura 4.8 ilustra a arquitetura do classificador não-linear para o trabalho proposto.

## CLASSIFICADOR NÃO-LINEAR



**FIGURA 4.8:** Arquitetura da rede neural utilizada para implementação do classificador não-linear.

### 4.10. Avaliação da Relevância das Características por Matriz dos Coeficientes de Correlação Linear

As seis características escolhidas foram correlacionadas entre si e com as classes de defeito: inclusão de escória, porosidade, falta de penetração e mordedura. A correlação entre as características e cada classe de defeito foi avaliada, analisando-se o coeficiente de correlação linear, bem conhecido em estatística e calculado pela fórmula [8, 52]:

$$C(x, y) = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{\sigma_x} \right) \left( \frac{y_i - \bar{y}}{\sigma_y} \right) \quad (4.3),$$

$C(x, y)$ : correlação linear entre as variáveis  $x$  e  $y$ .

$\bar{x}$  e  $\bar{y}$ : valor esperado das variáveis  $x$  e  $y$  respectivamente.

$\sigma_x$  e  $\sigma_y$ : desvios padrões das variáveis  $x$  e  $y$  respectivamente.

Os valores encontrados para os coeficientes de correlação são mostrados em matrizes 6×10/11 (seis características + quatro/cinco classes de defeitos) para facilitar a visualização dos resultados. Para verificar a confiabilidade da correlação entre as características ou entre as características e as classes de defeitos, utilizou-se o critério de que valores de correlação da ordem de  $2/\sqrt{N}$ , sendo  $N$  o número de amostras de cada característica/classe, têm 95,0% de probabilidade de indicar correlação efetiva entre os dados analisados [52].

Após determinação das características mais correlacionadas com as classes de defeitos, provavelmente aquelas que têm maior relevância na discriminação de uma dada classe, estes foram descorrelacionados das características menos relevantes, seguindo a relação 2 apresentada na equação 4.4 [53]:

$$y' = y - \left( \frac{E(xy)}{E(x^2)} \right) x \quad (4.4)$$

$E(xy)$ : valor esperado do produto das variáveis.

$E(x^2)$ : valor esperado do quadrado da variável  $x$ .

Feita a descorrelação, uma nova matriz com as características descorrelacionadas foi calculada.

#### 4.11. Critério de Relevância

Uma outra técnica para avaliar o quanto o desempenho de um classificador depende de uma dada características/variável é calculada através da equação (4.5) descrita por Seixas [54]:

$$R(x_i) = \frac{1}{N} \sum_{j=1}^N \|\tilde{y}(\underline{x}_j) - \tilde{y}(\underline{x}_{ji})\|^2 \quad (4.5)$$

$R(x_i)$ : relevância da componente  $\underline{x}_i$  dos vetores de entrada  $\underline{x}$  ;

$N$  : número de padrões (treinamento ou teste);

$\tilde{y}(\underline{x}_j)$ : vetor de saída da rede neural para cada padrão  $\underline{x}_j$  de entrada apresentado;

$\underline{x}_{ji}$ : vetor de entrada  $\underline{x}_j$ , em que a  $i$ -ésima componente foi substituída pelo seu valor médio tomado sobre todos os vetores de entrada;

$\tilde{y}(\underline{x}_{ji})$ : saída da rede para a entrada  $\underline{x}_{ji}$ .

Neste caso, procura-se por mudanças na resposta do classificador quando o valor de uma característica é substituído pelo valor médio desta característica tomado sobre todos os padrões de entrada. Quanto maior for a diferença entre as respostas fornecidas pelo classificador para essas duas entradas, maior será a relevância da característica para o sistema de classificação. Neste critério, não tem-se um valor limite para considerar uma característica como importante ou não para a classificação, assim, faz-se apenas uma comparação entre as características usadas no vetor de entrada para conhecer aquelas que têm maior relevância.

Neste trabalho, utiliza-se este critério desenvolvido com um classificador neural linear e não-linear, implementados de forma similar aos classificadores já explicados. Os resultados são mostrados em tabelas no capítulo a seguir.

#### 4.12. *Generalização dos Classificadores Lineares Não-Hierárquicos e Hierárquicos e Não-Lineares*

##### 4.12.1. *Distribuição Normal ou Gaussiana*

Considera-se, primeiramente, o caso dos classificadores lineares não-hierárquicos: os valores dos  $U$ 's encontrados para cada classe, segundo cálculo explicado anteriormente, foram distribuídos em gráficos de frequência e adotou-se a distribuição normal como modelo. Para atestar se os valores de  $U$  seguiam mesmo uma distribuição normal, foram usados testes de Qui-Quadrado e Komolgorov-Smirnov [55] para todas as situações explicadas a seguir. O teste de Qui-Quadrado é bastante conhecido em estatística [53, 55] e não será descrito aqui, entretanto, por não ser amplamente conhecido, descrevemos a seguir o teste de Komolgorov-Smirnov [55].

##### 4.12.2. *Teste de Distribuição de Komolgorov-Smirnov (K-S)*

O teste de distribuição de Komolgorov-Smirnov envolve basicamente a comparação entre a distribuição acumulativa de frequência experimental e a função teórica de distribuição assumida. Se a discrepância é grande com respeito ao que é normalmente esperado para um dado número de amostras, o modelo teórico é rejeitado.


Esquemáticamente, tem-se: para uma amostra de tamanho  $n$ , ordena-se o conjunto de dados em ordem crescente. Do conjunto de dados ordenados, é desenvolvida uma função acumulativa do seguinte modo [55]:

$$S_n(x) = \begin{cases} 0 & x < x_1 \\ \frac{k}{n} & x_k \leq x < x_{k+1} \\ 1 & x \geq x_n \end{cases} \quad (4.6),$$

onde  $x_1, x_2, \dots, x_n$  são os valores ordenados do conjunto de dados, e  $n$  é o número de dados. A figura 4.9 mostra a distribuição de  $S_n(x)$  e também a função de distribuição teórica  $F(x)$ . No teste de Komolgorov, a máxima diferença entre  $S_n(x)$  e  $F(x)$  em toda

extensão de  $x$  é a medida de discrepância entre o modelo teórico e os dados observados. Esta diferença pode ser denotada por [55]:

$$D_n = \max_x \|F(x) - S_n(x)\| \quad (4.7)$$



**FIGURA 4.9:** Distribuição de frequência acumulativa  $S_n(x)$  e a função de distribuição teórica  $F(x)$  [55].

Teoricamente,  $D_n$  é uma variável aleatória cuja distribuição depende de  $n$ . Assim como em outros testes de distribuição, o teste de K-S compara a máxima diferença observada pela equação (4.7) com um valor crítico  $D_n^\alpha$ , o que é definido por:

$$P(D_n \leq D_n^\alpha) = 1 - \alpha \quad (4.8)$$

Quando o  $D_n$  calculado é menor do que o valor crítico  $D_n^\alpha$ , a distribuição proposta é aceitável a um dado nível de significância  $\alpha$ , caso contrário, rejeita-se a

distribuição assumida [55]. A vantagem do teste de Komolgorov sobre o teste de Qui-quadrado é que neste caso não é necessário dividir os dados em faixas de frequência, então o problema existente no teste de Qui-quadrado para um pequeno número de dados, exatamente a situação presente, é suprimido.

Além de ajustar a distribuição normal para os  $U$ 's da classe de dados em questão, fez-se também a distribuição normal para os  $U$ 's resultantes dos neurônios referentes às outras classes. Com estas distribuições, é possível calcular a probabilidade de classificação correta para cada classe, ou seja, quando o  $U$  da classe for maior do que zero, o que denomina-se de verdadeiro positivo (VP), e ainda, a probabilidade de haver erro de classificação, quando o  $U$  da classe for menor do que zero, o que denominamos de falso negativo (FN). Levando-se em consideração que pode haver o caso de um  $U$  de uma outra classe ser maior também do que zero para a mesma entrada, denominando-se assim de falso positivo (PF), pode-se calcular a probabilidade de haver confusão entre as duas classes calculando-se a união entre estas duas probabilidades,  $P(FN \cup PF)$ , o que é feito através da equação (4.9) [55], já que  $P(FN)$  e  $P(PF)$  são probabilidades não mutualmente exclusivas.

$$P(FN \cup PF) = P(FN) + P(PF) - P(FN \cap PF) \quad (4.9)$$


$P(FN \cup PF)$ : probabilidade de ocorrer confusão entre as duas classes;

$P(FN)$ : probabilidade de ocorrer falso negativo;

$P(PF)$ : probabilidade de ocorrer falso positivo;

$P(FN \cap PF)$ : probabilidade de interseção entre as duas classes.

A figura 4.10 a seguir ilustra a forma de calcular estas probabilidades, mostrando a distribuição dos  $U$ 's da classe 1 e da classe 2 hipotéticas, para um conjunto de dados referentes à classe 1. A probabilidade de haver confusão entre estas duas classes é a soma da área hachurada de falso negativo (FN) com área de falso positivo (PF), dividida pela área total, que neste caso é 2 (soma da área sob a curva normal das duas distribuições).



**FIGURA 4.10:** Distribuição normal dos  $U$ 's de duas classes hipotéticas 1 e 2 mostrando as probabilidades de classificação correta, e de haver confusão de classificação entre estas duas classes, soma das áreas hachuradas na figura dividida pela área total que é 2.

Entretanto, esta situação é para o caso dos classificadores não hierárquicos e sem critério de reclassificação, ou seja, quando é considerado haver classificação correta apenas quando  $U$  da classe for maior do que zero. Esta situação não foi a que apresentou melhor desempenho de classificação, conforme será visto no capítulo 5, onde o melhor desempenho foi obtido com critério de reclassificação, tomando-se o  $U$  maior como indicador da classe. Por este motivo, não mostram-se os resultados obtidos com estas probabilidades, já que não representam os desempenhos melhores obtidos com estes classificadores, sendo esta metodologia de cálculo explicada até aqui apenas para facilitar a compreensão do que será exposto a seguir: probabilidade de haver classificação correta usando os classificadores lineares não-hierárquicos e hierárquicos com critério de reclassificação.

#### 4.12.3. *Probabilidade de Classificação Correta Usando os Classificadores Lineares*


Quando utilizado o critério de reclassificação, adotou-se o maior valor de  $U$  para indicar a classe de defeito. Para o sistema de classificação não-hierárquica, ressaltando-se mais uma vez, pode existir o caso de mais de uma saída positiva (mais de um  $U$  positivo), ou nenhuma saída positiva (todos os  $U$ 's menores do que zero). Então, a probabilidade que deseja-se calcular é a probabilidade de que o  $U$  da classe seja maior

do que os  $U$ 's das outras classes, equação (4.10). Para tal, adota-se o maior valor de  $U$  dentre os  $U$ 's das outras classes, calcula-se a diferença entre o  $U$  da classe e este valor, segundo a equação (4.11). Ajustando-se uma nova distribuição normal para os resultados destas diferenças, pode-se calcular a área sob a curva cuja a probabilidade da diferença é maior do que zero, o que indicará a probabilidade de classificação correta com critério de reclassificação. Para ilustrar este conceito, apresenta-se uma situação hipotética, mostrada na figura 4.11. Na figura 4.11, mostra-se o caso para quando houver mais de uma classe positiva, figura 4.11a, neste caso calcula-se a diferença entre o  $U$  da classe A em questão, e o maior  $U$  das outras classes, representado na figura pelo  $U$  da classe B. A figura 4.11b mostra o mesmo princípio, só que para quando todos os  $U$ 's forem negativos.


A figura 4.12 ilustra a curva distribuição normal para a diferença calculada na figura 4.11a, mostrando a probabilidade de haver classificação correta e de ocorrer erro de classificação.

$$P(U_{\text{classe}}) > P(U_{\text{Outras classes}}) \quad (4.10)$$

$$U = U_{\text{classe}} - U_{\text{máximo das outras classes}} \quad (4.11)$$



**FIGURA 4.11:** (a) cálculo da diferença entre o  $U_A$  e  $U_B$  para quando há mais de um  $U$  positivo. (b) cálculo da diferença entre o  $U_A$  e  $U_B$  para quando todos os  $U$ 's são negativos.



**Figura 4.12:** Distribuição normal que permite calcular a probabilidade de ocorrer classificação correta usando o critério de reclassificação.

É importante destacar que para o classificador hierárquico os cálculos das probabilidades são similares, apenas não havendo ocorrência de situação em que haja mais de um  $U$  positivo, pelo próprio princípio de funcionamento deste classificador, explicado anteriormente. Este mesmo princípio foi usado para o cálculo das probabilidades de acerto estimadas usando os classificadores não-lineares.

Os resultados destes cálculos serão mostrados em duas tabelas, uma para as probabilidades do classificador não-hierárquico e outra para o classificador hierárquico.

#### 4.13. Componentes Principais de Discriminação Não-Linear

A técnica de análise das componentes principais (PCA) é amplamente conhecida como uma das técnicas mais utilizadas para redução da dimensionalidade de um conjunto de dados multivariáveis. Originalmente [4], é uma técnica de mapeamento linear de dados multidimensionais em um número menor de componentes, minimizando a perda de informação. Entretanto, por ser um método linear de mapeamento, se torna inadequado em muitos problemas de engenharia que são não-lineares, pois as componentes de ordem menor podem conter informações importantes e que portanto não devem ser descartadas [56]. Por este motivo, recorre-se a análise das componentes principais não-lineares [56].

Uma das maneiras de se desenvolver as componentes principais é utilizando as redes neurais artificiais, conforme descreve Haykin [4] para o caso de auto-


representação. Neste caso, elas podem ser usadas tanto para redução das componentes de representação, quanto para discriminação de classes de padrões, a partir da projeção do espaço original de dados na base de componentes principais. No presente trabalho, recorre-se às componentes principais para discriminação não-linear, implementadas com as redes neurais, sendo estas desenvolvidas com o algoritmo de *retropropagação* do erro. Três tipos de desenvolvimento das componentes principais são estudados: as componentes de atuação independente e as de atuação cooperativa, estas divididas em dois tipos.

Como o vetor de entrada inicial é composto por 6 componentes, 6 características dos defeitos, foram utilizadas as duas primeiras componentes principais independentes e não-lineares de discriminação para visualizar o problema de separação das classes de defeitos em duas dimensões. Além disso, as componentes principais encontradas com as três formas de atuação são utilizadas como entradas do classificador não-linear para se avaliar o desempenho deste em uma situação de dimensão reduzida. Descreve-se a seguir a metodologia desenvolvida.

Imagina-se que um sistema de classificação de padrões tenha um vetor  $\underline{x}$  de dimensão  $n$  como entrada, deseja-se então reduzir a dimensão do vetor de entrada para um vetor  $\underline{z}$  de dimensão  $m$ ,  $m < n$ , contendo somente as informações mais relevantes do conjunto de dados, temos a representação:

$$\underline{x} (\dim n) \rightarrow \underline{z} (\dim m) \quad m < n \quad (4.12)$$

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



**FIGURA 4.13:** Projeção  $p_1 \underline{w}_1$  de  $\underline{x}$  na direção principal de discriminação.

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

$$p_1 = \underline{x}^t \underline{w}_1 \quad (4.13),$$

onde,

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

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

$$\underline{x} \cong p_1 \underline{w}_1 \quad (4.14)$$

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

$$\underline{x} = p_1 \underline{w}_1 + \underline{x}_1 \quad (4.15)$$


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

$$\underline{x} = p_1 \underline{w}_1 + p_2 \underline{w}_2 + p_3 \underline{w}_3 + \dots + p_m \underline{w}_m + \underline{\varepsilon} \quad (4.16)$$

onde  $\underline{\varepsilon}$  é o vetor erro residual [56] para representação usando  $m$  componentes principais.

A primeira componente de discriminação não-linear pode ser obtida treinando-se uma rede de três camadas em *retropropagação* do erro como mostra a figura 4.14. A primeira camada é composta por apenas um neurônio do tipo linear e as demais por neurônios do tipo tangente hiperbólica.

O ajuste dos vetores sinápticos das três camadas é feito pelo método do gradiente descendente usando a função do erro médio quadrático como função objetivo [4]. Após treinamento, o vetor  $\underline{w}_1$  representa a direção principal de discriminação não-linear das classes de padrões estudadas.



**FIGURA 4.14:** Rede para implementação da primeira componente principal de discriminação não-linear.

Um caso especial de desenvolvimento das demais componentes consiste em torná-las ortogonais, ou seja,  $\underline{w}_1 \perp \underline{w}_2 \perp \underline{w}_3 \dots \perp \underline{w}_m$ . Para tal, retreina-se a rede após obtenção de  $\underline{w}_1$  da mesma maneira, mas a nova entrada utilizada será  $\underline{x}_1$ , obtida da equação (4.15), procede-se sucessivamente até a componente  $m$  (normalmente  $m < n$ ). Aqui denominamos estas como componentes principais de atuação independente, uma vez que cada componente trabalha com o ruído  $\underline{x}_j$  da informação não utilizada pelas anteriores:

$$\underline{x}_j = \underline{x} - \sum_{k=1}^{j-1} p_k \underline{w}_k, \quad (4.17),$$

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

Uma outra forma de obtenção das componentes é considerando que a classificação é feita utilizando um processo de atuação cooperativa, isto é, a classificação é realizada utilizando a componente que está sendo calculada, e todas as anteriormente extraídas. Este caso pode ser subdividido em dois:

- Tipo I: após obter-se  $\underline{w}_1$ , a segunda componente é encontrada adicionando-se um segundo neurônio linear na primeira camada. Porém, faz-se  $\underline{w}_1$  fixo durante o treinamento, treinando apenas  $\underline{w}_2$  e os pesos sinápticos das outras camadas. Neste caso, a entrada continua sendo  $\underline{x}$  pois as componentes não são independentes. O objetivo neste caso é encontrar a segunda componente de discriminação ótima para trabalhar em cooperação com a primeira. O procedimento é similar para a obtenção da terceira, quarta ou  $m$ -ésima componente, mantendo-se fixos  $\underline{w}_1, \underline{w}_2, \underline{w}_3, \dots, \underline{w}_{m-1}$ . Uma forma de acelerar o processo é usar  $\underline{x}$  como entrada do primeiro neurônio, e  $\underline{x}_{j-1}$  como entrada do  $j$ -ésimo neurônio linear da primeira camada. Isto é possível porque, na entrada de cada neurônio do tipo tangente hiperbólica da segunda camada, a excitação é uma combinação linear das entradas da rede.
- Tipo II: pode-se também obter as duas componentes treinando-as simultaneamente, ou seja, as duas cooperam entre si durante o treinamento da rede. De forma similar, o mesmo pode ser feito para três, quatro ou  $m$  componentes. Neste caso, apenas cria-se uma base para o espaço de entrada reduzido e otimizado para a classificação.

Em um conjunto de dados de várias dimensões, é difícil se visualizar a dimensão do problema de separação entre as classes, portanto, através do emprego das duas primeiras componentes principais de discriminação não-lineares é possível se ter uma visualização otimizada da disposição das classes de padrões. Desta maneira, recorreu-se às duas principais componentes de discriminação em atuação independente para visualizar os gráficos de separação das quatro e cinco classes tratadas conjuntamente. Estas componentes foram obtidas com uma rede neural conforme figura 4.14, treinada utilizando *retropropagação* do erro, momento e taxa de aprendizagem variável [4].

#### 4.14. *Metodologia Complementar*

Em se tratando de classificação de padrões, é freqüente a falta de quantidade de dados suficientes para se garantir de forma precisa a capacidade de generalização dos classificadores. No caso presente, fica evidente também que apenas 95 amostras sem duplicamento é uma quantidade pequena para se fazer todos os testes possíveis de avaliação da generalização dos classificadores. Por este motivo, se recorreu aos cálculos de probabilidade de acerto (acurácia dos classificadores), conforme descrito na seção 4.12, o que gerou resultados satisfatórios que serão vistos no capítulo seguinte. Entretanto, com a aquisição de um conjunto novo de padrões radiográficos, também do IIW, e outro do BAM, foi possível a formação de um conjunto de dados com quantidade maior de amostras para fazer uma avaliação nova dos classificadores, usando as metodologias que foram apresentadas até aqui. Nas seções seguintes, descreve-se a quantidade de radiografias utilizadas, assim como a quantidade de amostras das características obtidas a partir destas (novos vetores de entradas formados). Além de outras técnicas de avaliação da acurácia de classificadores de padrões que foram usadas somente com este segundo conjunto de dados.

##### 4.14.1. *Coleção de Radiografias*

Com o objetivo de utilizar a maior quantidade possível de radiografias, a coleção nova de filmes radiográficos utilizados para a extração dos vetores novos de entrada dos classificadores foi composta de:

- Coleção IIW usada anteriormente, contendo 86 radiografias e que foram escaneadas segundo seção 4.2.
- Coleção recentemente adquirida de padrões IIW (IIW 1290- ano 95) contendo 67 radiografias de tamanho 225×50mm. Estas radiografias foram escaneadas em 2000dpi com o escâner Microtek 9800 XL, o que permitiu uma resolução média de 12,5  $\mu$ m, e 8 bits de níveis de cinza. Este escâner tem limite nominal máximo de densidade de 3,7 O.D., sendo, na prática, um limite baixo para digitalização de radiografias industriais de alta densidade. Para solucionar este problema, projetou-se


uma caixa de luz com potência de iluminação maior do que o adaptador de transparência do escâner.

- Coleção fornecida pelo BAM contendo 67 radiografias escaneadas no escâner LS 85 SDR da Lumisys/Kodak de densidade máxima de 4,1 O.D. Estas radiografias foram escaneadas em 12 bit de níveis de cinza e posteriormente convertidas para 8 bits, sem perda de informação dos defeitos. A resolução espacial de digitalização foi de 630 dpi (40,3  $\mu\text{m}$ ). A identificação e classificação dos defeitos seguiram a norma EN 26 520.
- Coleção IIW fornecida pela Universidade Politécnica de Cartagena (Espanha) contendo 74 radiografias, mas com vários filmes idênticos aos primeiros padrões utilizados. Deste conjunto, 5 radiografias novas referentes à classe trinca foram digitalizadas em resolução de 2000 dpi (12,8 $\mu\text{m}$ ).

#### 4.14.2. *Extração de Características*


A partir de uma quantidade maior de radiografias, foi possível a extração de dados dos defeitos falta de fusão (FF) e trinca (TR), o que anteriormente não havia sido feito por falta de quantidade de radiografias contendo estas classes. Neste caso, foram extraídas 7 características geométricas dos defeitos, sendo quatro já explicadas: P (posição), a (razão de aspecto), e/A (espessura sobre área) e R (arredondamento), e três características novas (figura 4.15):

- Ângulo ( $\theta$ ): ângulo entre o eixo maior do defeito e a vertical (figura 15a);
- área/retângulo ( $A/A_r$ ): razão entre a área do defeito e a área do menor retângulo que envolve o defeito (figura 15b).
- retângulo ou “caixa” W/H: razão entre a largura e a altura do menor retângulo que envolve o defeito (figura 15b).



**FIGURA 4.15:** Ilustração das três características novas extraídas.

Após extração das características, o conjunto novo de dados ficou composto de um total de 646 amostras, com as distribuições por classes mostradas na figura 4.16.



**FIGURA 4.16:** Distribuição das classes de defeitos no conjunto total de amostras.

#### 4.14.3. *Acurácia dos Classificadores*

O desempenho de um classificador pode ser medido pela sua acurácia, que é definida como sendo o seu grau de acerto na classificação de amostras não usadas no seu desenvolvimento [57]. A *verdadeira acurácia* de um classificador  $\theta$  é definida como a probabilidade de acerto de uma classe para amostras sorteadas aleatoriamente, que pode ser calculada como a razão entre o número de amostras classificadas corretamente e o número total de amostras quando o classificador é testado na população. Porém, na maioria das situações reais de classificação de padrões, as amostras são relativamente pequenas, fazendo com que a estimação da “verdadeira”, mas não conhecida, acurácia de um classificador, seja uma tarefa extremamente difícil[57].

A maneira mais simples para estimação da acurácia “verdadeira” é usar o conjunto total de dados para treinamento e teste. Esta estimação da acurácia é conhecida na literatura como *acurácia aparente* [57], tendo sido está a acurácia estimada anteriormente. É claro que a acurácia aparente  $\hat{\theta}_c$  é um estimador otimista, principalmente em situações em que haja supertreinamento (*overfitting*). Normalmente, estimações de acurácia são realizadas construindo conjuntos disjuntos de amostras de treinamento e teste, usando técnicas de amostragem [57].

Diamantidis [57] relata que há três métodos principais que têm sido aplicados para estimação da acurácia de classificadores:

1. Avaliação com amostragem aleatória ;
2. Validação-Cruzada;
3. Bootstrap.

Estas três técnicas são baseadas em amostragem aleatória e existem algumas variações de implementação de cada uma delas na estimação da acurácia de classificadores. Duas propriedades são importantes na avaliação da eficiência de um estimador, o seu *Bias* e a sua variância que são definidos nas equações abaixo.

$$Bias = E[\hat{\theta}] - \theta \quad (4.18),$$

$$Var(\hat{\theta}) = E\left[\left(\hat{\theta} - E[\hat{\theta}]\right)^2\right] \quad (4.19)$$

Um estimador é dito confiável se possui valores baixos de *Bias* (tendência) e de variância. Entretanto, na prática, uma relação apropriada entre ambos é desejável quando se almeja um objetivo mais realístico [57].

No método simples de avaliação com amostragem aleatória, o conjunto original de dados (com  $n$  amostras) é particionado aleatoriamente em dois conjuntos: um conjunto de treinamento contendo  $p \times n$  amostras, e outro de teste contendo  $(1 - p) \times n$  amostras (os valores de  $p$  são escolhidos variavelmente de caso a caso). Este processo é repetido um número de vezes e o valor médio de acurácia é calculado. Diamantidis [57] destaca que a desvantagem desta técnica é que ela faz normalmente uso ineficiente dos dados, porque tipicamente uma proporção grande de amostras é usada para teste. O resultado de acurácia estimada pode ser altamente pessimista [57].

O método de *validação-cruzada* é uma das técnicas utilizadas para resolver esta desvantagem. Em uma das suas variações, conhecida em inglês como *k-fold*, o conjunto de dados é aleatoriamente dividido em  $k$  subconjuntos disjuntos, de aproximadamente mesmo tamanho  $d$  ( $d \approx n/k$ ). O classificador é treinado e testado em  $k$  vezes. Na  $k$ -ésima vez, o conjunto de treinamento é formado pelo conjunto inicial sem o  $k$ -ésimo subconjunto, o qual é utilizado como conjunto de teste. O estimador  $\hat{\theta}_{(i)}$  é a razão entre o número de amostras corretamente classificadas e o número total de amostras de teste na  $k$ -ésima avaliação. O estimador  $\hat{\theta}_k$  da acurácia do classificador é calculado como sendo [57,58]:

$$\hat{\theta}_k = \sum_{i=1}^k \hat{\theta}_{(i)} / k \quad (4.20)$$

Uma segunda técnica de implementação da validação-cruzada consiste em fazer com que a distribuição das classes nos subconjuntos seja aproximadamente igual a distribuição observada no conjunto original de dados. Alguns autores destacam que esta técnica normalmente resulta num *Bias* menor em comparação à técnica de amostragem aleatória (primeiro método) [57].

É importante destacar que, na técnica de validação cruzada, a relação entre o *Bias* e a variância depende do número  $k$  de subconjunto utilizados. Um número pequeno de subconjuntos normalmente resulta em uma variância pequena e um *Bias* grande. Neste caso, como em cada treinamento e teste do classificador, uma porção menor de amostras é usada para treinamento, a estimação da acurácia é mais pessimista. Por outro lado, um número grande de subconjuntos ( $k$  elevado), o *Bias* se torna reduzido, mas a variância cresce. Como exemplo para este caso, usando-se a técnica conhecida como *leave one out*, na qual cada subconjunto contém apenas uma amostra, o estimador é praticamente não-enviesado, mas a sua variância é relativamente alta [57, 58].

O terceiro método citado, a técnica de *bootstrap*, é de uso mais recente na estimação da acurácia de classificadores de padrões. A técnica de *bootstrap*<sup>\*</sup> foi criada em 1979 por Bradley Efron [59] como um método computacional para estimação do erro padrão de um estimador  $\hat{\theta}$ . É uma técnica completamente automática que pode ser usada independentemente do estimador que tiver sendo computado [59]. Um conjunto de *bootstrap* de amostras (de tamanho  $n$ ), na própria definição de Efron [59], é formado por  $x_1^*, x_2^*, \dots, x_n^*$  amostras, obtidas de forma aleatória e com reposição, de um conjunto original de dados  $x_1, x_2, \dots, x_n$  (também de tamanho  $n$ ). Desta forma, é possível que algumas amostras apareçam uma, duas, três,  $n$  vezes, ou nenhuma vez [59].

Com esta técnica, o classificador implementado usando o  $i$ -ésimo conjunto de treinamento é testado com as amostras que não foram utilizadas na formação deste conjunto, resultando em um estimador de acurácia  $\hat{\theta}_i$ . Isto é repetido  $b$  vezes. Uma forma de estimação de acurácia  $\hat{\theta}_b$  de classificadores de padrões freqüentemente utilizada é definida pela equação:

$$\hat{\theta}_b = \frac{1}{b} \sum_{i=1}^b (0,632\hat{\theta}_i + 0,368\hat{\theta}_c) \quad (4.21),$$

onde  $\hat{\theta}_c$  é a acurácia aparente definida previamente. O detalhamento do porquê da utilização dos pesos 0,632 e 0,368 como fatores de ponderação das acurácias de teste e treinamento encontra-se nas referências [59] ou [60].

---

\* Por curiosidade, neste caso, o termo *bootstrap* está relacionado à expressão em inglês *to pull oneself up by one's bootstrap*.

Alguns autores [57, 59] destacam, entretanto, que este estimador tende a resultar em um *Bias* elevado, porque o fator ponderador da acurácia de teste não é suficiente, ou seja, um fator maior de ponderação da acurácia de teste tende a convergir para valores menores de *Bias* [57, 59]. Neste caso, fazendo uma adaptação deste estimador, a equação (4.21) pode ser rescrita:

$$\hat{\theta}_B^* = \frac{1}{b} \sum_{i=1}^b (\hat{\omega} \hat{\theta}_i + (1 - \hat{\omega}) \hat{\theta}_c) \quad (4.22),$$

onde o peso  $\hat{\omega}$  varia entre 0,632 e 1. Este estimador  $\hat{\theta}_B^*$  proporciona uma relação mais adequada entre o estimador pessimista  $\hat{\theta}_i$  e o estimador otimista  $\hat{\theta}_c$  [57]. Existem outras variações de implementação destes estimadores de *bootstrap*, como a técnica que é associada ao *leave one out* da validação-cruzada, as quais o livro de Efron [59, 60] aborda detalhadamente.

Com o conjunto novo de dados, calcularam-se os estimadores de acurácia dos classificadores, especificamente dos classificadores não-lineares e não-hierárquicos, usando as técnicas:

1. Sorteio aleatório das amostras para formar os conjuntos de treinamento e teste; dividindo-se em aproximadamente 80,0% para treinamento e 20,0% para teste.
2. Técnica de *bootstrap* para construção dos conjuntos de treinamento e teste, calculando os estimadores de acurácia segundo as equações (4.21) e (4.22).

## CAPÍTULO 5 - APRESENTAÇÃO E DISCUSSÕES DOS RESULTADOS

---

### 5.1. *Classificadores Lineares*

#### 5.1.1. *Classificadores Não-Hierárquicos*

Neste tipo de classificador, cada classe deve ser discriminada de todas as demais, independentemente de ser ou não linearmente separável. A tabela 5.1 a seguir mostra os resultados encontrados com o primeiro conjunto de dados para o classificador sem critério de desempate na saída (reclassificação). Neste caso, também são apresentados os valores percentuais para quando nenhuma classe foi identificada ou houve mais de uma classe ativada. Pela tabela 5.1, observa-se que quanto ao defeito mordedura (MO), o acerto é de 100%, indicando ser esta classe separável por um discriminador linear. Este resultado deve-se ao fato de que esta classe de defeito possui a característica posição bem distinta das demais, situando-se na margem do cordão-de-solda ou próximo a este. Quanto ao defeito falta de penetração (FP), o resultado mostra que 14,0% das observações resultaram em um valor maior do que zero em mais de uma saída da rede, indicando pertinência a mais de uma classe. Para porosidade (PO), o acerto é de 77,0%, com 17,0% de casos de classificação múltipla, havendo também 6,0% de percentual para o caso de nenhuma classe indicada. Os resultados encontrados para as classes inclusão de escória não-linear (IENL) e linear (IEL) comprovam que a separação destas por um processo linear não- hierárquico é complicado e o resultado é pouco satisfatório. Esta constatação condiz com o fato de que as classes PO, IEL e IENL têm formatos geométricos geralmente similares, e posições aleatórias no cordão-de-solda, sendo portanto de classificação mais difícil.

Na tabela 5.2, são mostrados os percentuais de desempenho do classificador com o critério de desempate baseado no maior valor de saída (reclassificação). Neste caso, é fácil observar que o desempenho do classificador melhora, mantendo o acerto de 100% para MO, aumentado o de PO para 100%, o de FP para 93,0% , IEL para 64,0%, e IENL para 63,0%, obtendo um resultado bom para este tipo de classificação. Como no ensaio

radiográfico, esta distinção entre inclusão linear e não-linear muitas vezes não é feita, sendo ambas classificadas normalmente como inclusões de escória simplesmente, verificou-se o percentual de acerto para estas classes unidas, tendo este percentual atingido o valor de 90,0%.

**TABELA 5.1:** Tabela de Confusão (%).

*Classificador Linear Não-Hierárquico (Sem reclassificação)*

|      | MO  | FP   | PO   | IEL  | IENL | Mais de uma | Nenhuma |
|------|-----|------|------|------|------|-------------|---------|
| MO   | 100 |      |      |      |      | 0           | 0,0     |
| FP   |     | 86,0 |      |      |      | 14,0        | 0,0     |
| PO   |     |      | 77,0 |      |      | 17,0        | 6,0     |
| IEL  |     |      | 4,0  | 36,0 | 8,0  | 0,0         | 52,0    |
| IENL |     |      | 4,0  | 8,0  | 42,0 | 4,0         | 42,0    |

**TABELA 5.2:** Tabela de Confusão (%).

*Classificador Linear Não-Hierárquico (Com reclassificação)*

|      | MO  | FP   | PO  | IEL  | IENL |
|------|-----|------|-----|------|------|
| MO   | 100 |      |     |      |      |
| FP   |     | 93,0 |     |      | 7,0  |
| PO   |     |      | 100 |      |      |
| IEL  | 4,0 |      | 4,0 | 64,0 | 28,0 |
| IENL |     | 4,0  | 8,0 | 25,0 | 63,0 |

A tabela 5.3 resume o desempenho destes classificadores em termos de quantidade de observações corretamente classificadas, erros e saídas sem classificação (todas as saídas de rede negativas ou mais de uma positiva). Primeiro para o caso sem critério de desempate na saída (reclassificação), e posteriormente com classificação pelo maior valor (tabela 5.4). Desta forma, foi possível chegar ao desempenho geral deste tipo de algoritmo de classificação. O percentual encontrado foi de 80,0% de acerto, bastante interessante levando-se em consideração a arquitetura do classificador empregada e a quantidade de dados utilizada.

**TABELA 5.3:** Tabela de Acertos e Erros.

*Classificador Linear Não-Hierárquico (Sem reclassificação)*

|       | ACERTOS    | ERROS    | SEM CLASSIFICAÇÃO |
|-------|------------|----------|-------------------|
| MO    | 15         | 0        | 0                 |
| FP    | 12         | 0        | 2                 |
| PO    | 13         | 0        | 4                 |
| IEL   | 9          | 3        | 13                |
| IENL  | 10         | 3        | 11                |
| TOTAL | 59 (62,0%) | 6 (6,0%) | 30 (32,0%)        |

**TABELA 5.4:** Tabela de Acertos e Erros.

*Classificador Linear Não-Hierárquico (Com reclassificação)*

|       | ACERTOS    | ERROS      |
|-------|------------|------------|
| MO    | 15         | 0          |
| FP    | 13         | 1          |
| PO    | 17         | 0          |
| IEL   | 16         | 9          |
| IENL  | 15         | 9          |
| TOTAL | 76 (80,0%) | 19 (20,0%) |

#### 5.1.2. *Classificadores Hierárquicos*

A tabela 5.5 apresenta os primeiros resultados encontrados para o classificador hierárquico. O desempenho deste classificador é melhor que a do classificador não-hierárquico, mesmo no critério mais exigente (classificação apenas quando somente uma saída for maior do que zero). Os índices de 100% de acerto para MO e FP comprovam serem as duas classes linearmente discrimináveis das demais para este caso. Para PO obteve-se 94,0% de acerto, existindo confusão de 6,0% das observações com IEL. Para IEL e IENL atingiu-se 72,0 e 75,0% de classificações corretas, respectivamente. Há cerca de 20,0% de confusão entre estas duas classes, valor

justificado pelo fato das mesmas apresentarem características bem similares. Os resultados conseguidos com critério de desempate na saída da rede, mostrados na tabela 5.6, são os mesmos que no caso anterior, não havendo aumento do percentual de acerto. Ao contrário, a confusão entre a classe IEL e PO aumenta de 4,0 para 8,0%, e entre IENL e IEL aumenta de 17 para 21,0%. Isto aconteceu porque nos casos em que houve mais de uma saída positiva no classificador, ao usar o critério de maior valor de saída para desempate, a classe indicada foi errada. Entretanto, não é possível concluir que este critério não forneça melhores resultados porque o número de amostras que causaram este resultado é estatisticamente insuficiente.

Comparando o classificador não-hierárquico com o hierárquico, fica evidente que os resultados deste último são melhores, principalmente em relação às classes IEL e IENL. Neste caso, interpretando as inclusões de escória unidas em apenas uma classe, o resultado foi de 97,0% de acerto para a tabela 5.5 e 94,0% para tabela 5.6. As tabelas 5.7 e 5.8 representam os resultados gerais deste tipo de classificador. O índice de 85,0% de acerto da tabela 5.7 é consideravelmente maior do que os 62,0% da tabela 5.3, aumentando também dos 80,0% da tabela 5.4 para 85,0% da tabela 5.8. Este resultado pode ser considerado muito bom, considerando que foi utilizado um critério de discriminador linear para classificação dos defeitos e que Aoki [21] obteve 92,0% de acerto para um sistema de discriminação não-linear com redes neurais de duas camadas, recorrendo a 10 características dos defeitos trinca, inclusão (sem separação entre classes linear e não-linear), mordedura, porosidade e falta de penetração. Liao [19], em uma das suas publicações mais recentes, obteve também um índice geral de acerto entorno de 92,0% (dados de teste) com um classificador neural não-linear e com um algoritmo *Fuzzy K-NN*, usando um vetor de entrada composto por 12 características. Porém, as classes de Liao [19] eram compostas de: trinca, falta de fusão, falta de penetração, porosidade e inclusão de hidrogênio, portanto com algumas classes diferentes deste trabalho. É importante lembrar que em nosso estudo as classes de defeito de soldagem trinca e falta de fusão não foram analisadas por falta de quantidade de dados suficientes para treinamento e teste da rede neural. Outro ponto importante a esclarecer é a respeito do critério de reclassificação; na prática, todos os valores de U considerados maiores eram a partir da primeira ou segunda casa decimal (numa precisão de 4 casas decimais).

**TABELA 5.5:** Tabela de Confusão (%).

*Classificador Linear Hierárquico (Sem reclassificação)*

|      | MO  | FP  | PO   | IEL  | IENL | Nenhuma |
|------|-----|-----|------|------|------|---------|
| MO   | 100 |     |      |      |      | 0       |
| FP   |     | 100 |      |      |      | 0       |
| PO   |     |     | 94,0 | 6,0  |      | 0       |
| IEL  |     |     | 4,0  | 72,0 | 20,0 | 4,0     |
| IENL |     |     | 4,0  | 17,0 | 75,0 | 4,0     |

**TABELA 5.6:** Tabela de Confusão (%).

*Classificador Linear Hierárquico (Com reclassificação)*

|      | MO  | FP  | PO   | IEL  | IENL |
|------|-----|-----|------|------|------|
| MO   | 100 |     |      |      |      |
| FP   |     | 100 |      |      |      |
| PO   |     |     | 94,0 | 6,0  |      |
| IEL  |     |     | 8,0  | 72,0 | 20,0 |
| IENL |     |     | 4,0  | 75,0 | 75,0 |

**TABELA 5.7:** Tabela de Acertos e Erros.

*Classificador Linear Hierárquico (Sem reclassificação)*

|       | ACERTOS    | ERROS      | NÃO CLASSIFICAÇÃO |
|-------|------------|------------|-------------------|
| MO    | 15         | 0          | 0                 |
| FP    | 14         | 0          | 0                 |
| PO    | 16         | 1          | 0                 |
| IEL   | 18         | 6          | 1                 |
| IENL  | 18         | 5          | 1                 |
| TOTAL | 81 (85,0%) | 12 (13,0%) | 2 (2,0%)          |

**TABELA 5.8:** Tabela de Acertos e Erros  
*Classificador Linear Hierárquico (Com reclassificação)*

|              | ACERTOS    | ERROS      |
|--------------|------------|------------|
| <b>MO</b>    | 15         | 0          |
| <b>FP</b>    | 14         | 0          |
| <b>PO</b>    | 16         | 1          |
| <b>IEL</b>   | 18         | 7          |
| <b>IENL</b>  | 18         | 6          |
| <b>TOTAL</b> | 81 (85,0%) | 14 (15,0%) |

## 5.2. Avaliação da Relevância dos Características: Matriz dos Coeficientes de Correlação Linear e Critério de Relevância usando um classificador linear implementado por redes neurais

### 5.2.1. Matriz dos Coeficientes de Correlação Linear

A tabela 5.9 mostra os valores obtidos dos coeficientes de correlação entre os 6 parâmetros característicos (ou somente *características*, termo mais usado pelos pesquisadores e que a partir de agora iremos usar) entre si, e com as 4/5 classes de defeitos analisadas. O critério utilizado para verificar a existência de correlação segue a razão  $2/\sqrt{N}$ . Para as características, como o número total de dados era de 95 (sem duplicação), valores maiores do que (0,20) indicam mais que 95,0% de probabilidade de correlação (células hachuradas). Nesta tabela, encontram-se também os valores  $2/\sqrt{N}$  para cada classe de defeito. Será feita discussão da correlação das características para cada classe de defeito com base na tabela 5.9.

- Mordedura (MO): a característica P (posição) mostrou a maior correlação com esta classe, seguido da razão L/A.
- Falta de penetração (FP): nesta classe as características a, R e P mostraram os coeficientes mais altos de correlação, embora ainda abaixo do limite.

- Porosidade (PO): a característica e/A mostrou-se a de correlação mais alta (0,56), seguido da característica R (arredondamento: *roundness*), embora esta ainda abaixo do valor limite.
- Inclusão de Escória Linear (IEL): a única característica que apresentou um coeficiente próximo ao limite foi L/A.
- Inclusão de Escória Não-Linear (IENL): a característica P foi a que resultou em um coeficiente mais próximo da razão  $2/\sqrt{N}$ .
- Inclusão de escória (IE): para esta classe a característica P também apresentou a maior correlação, assim como L/A em segundo lugar.

Destas observações, concluiu-se que a característica P tem alta relevância nas discriminações das classes mordedura e falta de penetração, o que era esperado tendo em vista que ambas as classes apresentam comportamento bem típico e distinto de posição dentro do cordão-de-solda, sendo que P também possui relevância na discriminação de inclusão de escória. Como a razão e/A apresentou relevância alta na discriminação de porosidade, constatou-se que as características P e e/A eram as mais relevantes para discriminação das classes estudadas, tendo em vista que foram as que os coeficientes de correlação ultrapassaram o limite calculado.

Na tabela 5.9, verificou-se também que as características L/A e R apresentavam correlação com P, assim como a, R e C com e/A. Deste modo, estas características foram descorrelacionadas, segundo equação 4.4 (capítulo 4), de P e e/A respectivamente.

A tabela 5.10 apresenta a matriz dos coeficientes de correlação obtida com as características descorrelacionadas. Pode-se observar que, neste caso, apenas as características P e e/A mantiveram-se correlacionadas com as classes de defeitos. Por esta razão, estas características foram usadas como dados de entrada em um classificador linear hierárquico de padrões.

Os resultados mostraram um índice de 100% de acerto para as classes mordedura e falta de penetração. Em relação à porosidade o desempenho foi de 76,0% de acerto, com 24,0% dos dados sendo confundidos com inclusão de escória. Para inclusão, o classificador acertou 85,0% dos dados e confundiu 15,0% com porosidade.

Analisando o desempenho geral deste tipo de classificador tendo as características P e e/A como dados de entrada, o índice de acerto foi de 88,0%. Este índice apresenta uma diferença considerável em relação aos 97,0% de acerto quando foram utilizadas as seis características para classificação das mesmas classes de defeitos (MO, FP, PO e IE). Os resultados mostraram que a utilização destas duas características foi suficiente para separação das classes mordedura e falta de penetração, porém para porosidade e inclusão o desempenho foi inferior, quando comparado ao obtido com seis características, nos quais obteve-se um índice de 94,0% de acerto para porosidade e 96,0% para inclusão. O que descarta a possibilidade de utilização apenas destas características para classificação linear das 4 classes de defeitos. Portanto, testou-se também o classificador linear hierárquico tendo como dados de entrada três características, sendo elas: C, e/A e P e a, e/A e P. Escolheu-se as características C e a, porque pela tabela 5.9 verificou-se que ambas ainda apresentavam uma pequena correlação com a classe inclusão de escória. Para estas duas condições, o índice geral de acerto não se alterou, mantendo os mesmos 88,0% obtidos com e/A e P. A inclusão de a como dado de entrada conjuntamente com e/A e P, resolveu o problema de acerto da classe porosidade, pois obteve-se um índice de 100% de acerto para esta classe, mas quanto à inclusão de escória, o percentual de acerto abaixou em relação às condições que tiveram como dados de entrada e/A e P ou C, e/A e P. Por este motivo, criou-se uma nova entrada com quatro características: C, a, e/A e P. Neste caso, teve-se 100% de acerto para as classes mordedura, falta de penetração e porosidade, e 85,0% de acerto para inclusão de escória, com 15,0% de confusão com inclusão de escória. O índice geral de acerto foi de 94,0%, ficando bem próximo dos 97,0% obtidos com as seis características, usando um classificador hierárquico e critério de reclassificação.

Com este resultado, pode-se discutir o emprego de um número menor de características para classificação destas classes de defeito. Embora o índice de acerto seja maior para uma quantidade maior de características utilizadas, sabe-se que a extração destas características das imagens radiográficas não é uma tarefa fácil, podendo levar também normalmente a ocorrência de um erro no processo de medida. Então, a questão que surge é descobrir qual a melhor relação custo benefício, ou seja, obter o melhor índice de acerto, da maneira mais prática possível (menor quantidade de características e maior facilidade de extração destas).

Em termos de revisão bibliográfica, há basicamente dois trabalhos: um trabalho de Aoki [21] e outro de Mery [27]. Aoki [21] avaliou a relevância de 10 características

para discriminar as classes de defeito mordedura, falta de penetração, porosidade, inclusão de escória e trinca, chegando a conclusão de que o desempenho da rede decrescia quando retirava-se uma característica como dado de entrada. Porém, Aoki [21] recorreu somente ao método da exclusão em um classificador não-linear implementado com 3 camadas, não tendo feito um estudo prévio de correlação das características. Mery [27] estudou a relevância de características empregando técnicas como o critério de Fisher e curvas ROC.

**TABELA 5.9:** Matriz de correlação linear com as características correlacionadas.

| CARACTERÍSTICAS |       |       |       |       |       |      | DEFEITOS |       |       |       |       |       |
|-----------------|-------|-------|-------|-------|-------|------|----------|-------|-------|-------|-------|-------|
| $2/\sqrt{N}$    | 0,20  |       |       |       |       |      | 0,28     | 0,41  | 0,40  | 0,48  | 0,53  | 0,51  |
|                 | C     | a     | L/A   | e/A   | R     | P    | IE       | IENL  | IEL   | PO    | FP    | MO    |
| C               | 1,00  |       |       |       |       |      | 0,19     | -0,07 | 0,28  | -0,30 | -0,02 | 0,08  |
| a               | 0,15  | 1,00  |       |       |       |      | -0,07    | -0,22 | 0,14  | -0,38 | 0,50  | 0,02  |
| L/A             | -0,19 | 0,03  | 1,00  |       |       |      | 0,28     | -0,03 | 0,34  | 0,06  | -0,02 | -0,44 |
| e/A             | -0,23 | -0,53 | 0,60  | 1,00  |       |      | 0,06     | 0,05  | 0,01  | 0,56  | -0,34 | -0,33 |
| R               | 0,13  | 0,78  | 0,14  | -0,50 | 1,00  |      | 0,02     | -0,13 | 0,15  | -0,42 | 0,46  | -0,04 |
| P               | -0,06 | -0,16 | -0,39 | -0,14 | -0,24 | 1,00 | -0,34    | -0,26 | -0,13 | 0,11  | -0,48 | 0,82  |

**Tabela 5.10:** Matriz de correlação com as características descorrelacionadas.

| CARACTERÍSTICAS |       |      |      |       |      |      | DEFEITOS |       |       |       |       |       |
|-----------------|-------|------|------|-------|------|------|----------|-------|-------|-------|-------|-------|
| $2/\sqrt{N}$    | 0,20  |      |      |       |      |      | 0,28     | 0,41  | 0,40  | 0,48  | 0,53  | 0,51  |
|                 | C     | a    | L/A  | e/A   | R    | P    | IE       | IENL  | IEL   | PO    | FP    | MO    |
| C               | 1,00  |      |      |       |      |      | 0,20     | -0,06 | 0,29  | -0,18 | -0,10 | 0,01  |
| a               | 0,01  | 1,00 |      |       |      |      | -0,15    | -0,32 | 0,14  | -0,06 | 0,24  | 0,03  |
| L/A             | -0,10 | 0,36 | 1,00 |       |      |      | 0,16     | -0,14 | 0,32  | 0,11  | -0,22 | -0,12 |
| e/A             | 0,00  | 0,00 | 0,60 | 1,00  |      |      | 0,06     | 0,06  | 0,01  | 0,56  | -0,34 | -0,33 |
| R               | -0,02 | 0,66 | 0,46 | 0,00  | 1,00 |      | -0,07    | -0,23 | 0,15  | -0,11 | 0,16  | 0,05  |
| P               | -0,10 | 0,00 | 0,00 | -0,14 | 0,00 | 1,00 | -0,34    | -0,26 | -0,14 | 0,11  | -0,48 | 0,82  |

### 5.2.2. Critério de Relevância com um Classificador Linear

A tabela 5.11 mostra os resultados obtidos com o critério de relevância aplicado segundo a equação 4.5 (capítulo 4), usando para tal um classificador linear. Observa-se que este resultado é coerente com o obtido com os coeficientes de correlação linear. A característica P é relevante para a discriminação das classes MO e FP, e a característica e/A é relevante para a discriminação da classe PO, como já havia sido constatado nas tabelas 5.9 e 5.10. A característica **a** apresentou relevância em relação às classes FP e PO (tabela 5.11). De acordo com a tabela 5.9, pode-se observar que, embora os coeficientes encontrados para estas classes não tenham excedido os limites que foram calculados e mostrados na tabela, eles estão próximos a estes o que não descarta a possibilidade de relevância. Para a característica R, a situação é similar a característica a, mostrando relevância nas classes FP e PO. A característica e/A é importante na discriminação da classe PO (tabela 5.11).

Outro resultado importante desta tabela é que a característica C não mostra relevância para discriminação das classes estudadas. Desta forma, o desempenho do classificador hierárquico com as entradas a, e/A, R e P foi verificado. O resultado mostrou 97,0% de acerto, o mesmo encontrado para as seis características, o que mostra a possibilidade de descartar as características C e L/A e manter o mesmo desempenho de classificação.

**TABELA 5.11:** Critério de Relevância usando um Classificador Linear.

|            | MO    | FP    | PO    | IEL   | IENL  | IE    |
|------------|-------|-------|-------|-------|-------|-------|
| <b>C</b>   | 0     | 0     | 0     | 0     | 0     | 0     |
| <b>a</b>   | 0,001 | 0,157 | 0,226 | 0,003 | 0,045 | 0,016 |
| <b>L/A</b> | 0,158 | 0,009 | 0,003 | 0,068 | 0,003 | 0,101 |
| <b>e/A</b> | 0,055 | 0,078 | 0,262 | 0,001 | 0,002 | 0,005 |
| <b>R</b>   | 0,023 | 0,150 | 0,335 | 0,006 | 0,012 | 0,014 |
| <b>P</b>   | 0,606 | 0,545 | 0,004 | 0,006 | 0,021 | 0,067 |


### 5.3. Generalização dos Classificadores Lineares

A figura 5.1 mostra as curvas de distribuição normal obtidas para o classificador não-hierárquico com critério de reclassificação. Todas as curvas foram testadas para verificar se seguiam uma distribuição normal, segundo dois testes: teste de Qui-quadrado e teste de Kolmogorov-Smirnov [54]. Os testes comprovaram que o modelo de distribuição normal é o mais adequado para os valores de  $U$  obtidos através da equação 4.11 (capítulo 4). Isto pode ser também justificado porque na região aonde é mais provável que ocorram erros, isto é, quando o módulo da entrada de um neurônio é muito pequeno, a melhor escolha para a distribuição de  $P(U)$  é uma Gaussiana, uma vez que os neurônios estão provavelmente operando em uma região linear. Então, através das curvas de distribuição, calculou-se as probabilidades de acerto de classificação para as classes mordedura (MO), falta de penetração (FP), porosidade (PO), inclusão de escória linear (IEL), inclusão de escória não-linear (IENL), e para a situação em que as duas classes de inclusão são tratadas como apenas uma classe: inclusão de escória (IE). Pela figura 5.1a, fica comprovada que a probabilidade de acerto para a classe mordedura, área da curva situada à direita do zero, é de aproximadamente 100%, concordando com o valor obtido com os dados de treinamento. Na figura 5.1b, apresenta-se a classe falta de penetração, a probabilidade de acerto calculada foi de 93,5%, também coerente com os 93,0% obtidos com os dados de treinamento. Para porosidade, figura 5.1c, o percentual de acerto foi de 90,5%, índice um pouco abaixo do obtido com os dados de treinamento. Para as inclusões, na linear mostrada na figura 5.1d, o índice de probabilidade de acerto caiu para 70,0%, e na não-linear, mostrada na figura 5.1e, o índice de probabilidade de classificação correta previsto é de 58,0%, índices também muito próximos dos conseguidos com os dados de treinamento. Quando interpreta-se as duas classes de inclusões juntas, construindo o classificador para tal situação, o percentual estimado de acerto de classificação sobe para 87,0% (figura 5.1f). É bom ressaltar, que esta separação muitas vezes não é feita em se tratando de inspeção radiográfica, sendo tratada aqui porque os padrões radiográficos do IIW (*International Institute of Welding*) utilizados nestes trabalhos fazem esta separação. Estes valores de probabilidade de acerto encontrados para este classificador são esquematizados na tabela 5.12.


**Tabela 5.12:** Probabilidades Estimadas de Acerto (%).

*Classificador Linear Não-Hierárquico (Com critério de Reclassificação)*


|             | $U_{classe} > U_{outras\ classes}$ |
|-------------|------------------------------------|
| <b>MO</b>   | 100                                |
| <b>FP</b>   | 93,5                               |
| <b>PO</b>   | 90,5                               |
| <b>IEL</b>  | 70,0                               |
| <b>IENL</b> | 58,0                               |
| <b>IE</b>   | 87,0                               |




(a)




(b)




(c)



(d)




(e)



(f)

**FIGURA 5.1:** Curvas de distribuição normal obtidas com o resultado da subtração entre o valor de  $U$  de uma classe e o maior valor de  $U$  das demais classes, representando assim o cálculo de probabilidade de acerto do *classificador não-hierárquico com critério de reclassificação*. De (a) a (f), as classes: mordedura, falta de penetração, porosidade, inclusão de escória linear, inclusão de escória não-linear e inclusão de escória, respectivamente.

A figura 5.2 mostra as curvas de distribuição resultantes para o classificador hierárquico. Neste caso, a probabilidade estimada de acerto de classificação para classe mordedura com este classificador é igual à probabilidade do classificador não-hierárquico (100%), pois esta classe é a primeira a ser classificada no critério de hierarquia. A figura 5.2a apresenta distribuição obtida para a classe de defeito falta de penetração com o critério de classificação hierárquica. Nota-se que a probabilidade estimada de acerto na classificação é cerca de 100%, não existindo área sob a curva a esquerda do zero. Para porosidade, figura 5.2b, obteve-se um pequeno índice de erro estimado em 0,3%, o que resulta em 99,7% de acerto esperado para esta classe. Com IEL, o índice de acerto estimado é de 74,0%, figura 5.2c. Percebe-se que estes resultados obtidos com o classificador hierárquico para estas duas classes, PO e IEL, são melhores que os obtidos com o classificador sem critério de hierarquia. O que realça e comprova os resultados apresentados com os dados de treinamento abordados no trabalho anterior. Para a classe IENL, figura 5.2d, isto fica ainda mais evidenciado, pois a probabilidade estimada de acerto é de 85,0%, índice significativamente maior do que os 58,0% obtidos com o classificador não-hierárquico (tabela 5.12). Fazendo-se a média entre os índices de acerto prováveis para cinco classes: MO, FP, PO, IEL e IENL, o resultado é cerca de 91,0% de acerto, desempenho melhor que os 85,0% obtidos com os dados de treinamento. Considerando-se as inclusões como somente uma classe, o percentual de acerto esperado sob para 95,0% (figura 5.2e). Calculando-se a média de acerto com 4 classes: MO, FP, PO e IE, o resultado é de 98,0%, índice compatível com os 97,0% obtidos com os dados de treinamento. A tabela 5.13 contém os valores de probabilidade obtidos.



**FIGURA 5.2:** Curvas de distribuição normal obtidas com o resultado da subtração entre o valor de  $U$  de uma classe e o maior valor de  $U$  das demais classes, representando assim o cálculo probabilidade de acerto do *classificador hierárquico com critério de reclassificação*. De (a) a (f), as classes: mordedura, falta de penetração, porosidade, inclusão de escória linear, inclusão de escória não-linear e inclusão de escória, respectivamente.

**TABELA 5.13:** Probabilidades Estimadas de Acerto (%).

*Classificador Linear Hierárquico (Com critério de Reclassificação)*


|             | $U_{classe} > U_{outras\ classes}$ |
|-------------|------------------------------------|
| <b>MO</b>   | 100                                |
| <b>FP</b>   | 100                                |
| <b>PO</b>   | 99,7                               |
| <b>IEL</b>  | 74,0                               |
| <b>IENL</b> | 85,0                               |
| <b>IE</b>   | 95,0                               |

#### 5.4. Classificadores Não-Lineares


Partindo-se do ponto término dos trabalhos anteriores, as características **C** e **L/A** foram descartadas dos dados de entrada do classificador e, portanto, os resultados apresentados aqui referem-se a um novo vetor de entrada composto das quatro características restantes (a-e/A-R-P).

Para encontrar o número ótimo de neurônios a serem utilizados na camada oculta do classificador não-linear (desenvolvido conforme figura 4.8 – capítulo 4), utilizou-se o critério empírico de aumentar gradativamente o número de neurônios nesta camada e, consecutivamente, observar o erro e o desempenho de classificação. Isto foi realizado considerando-se a classe de inclusão dividida em inclusão linear e não-linear (total de cinco classes), figura 5.3a, e inclusão considerada como apenas uma classe (total de quatro classes), figura 5.3b. Constatou-se que para o primeiro caso, 5 classes, o classificador atingia o máximo de desempenho (99,2%) e o mínimo de erro com os dados de treinamento com 17/18 neurônios na camada oculta (figura 5.3a). Para a condição de quatro classes, o desempenho máximo atingindo (100%) ocorreu para 10 neurônios. As tabelas de confusão 5.14 e 5.15 mostram a quantidade numérica e percentual de acertos obtidos para as condições: sem critério de reclassificação e com critério de reclassificação para a condição de cinco classes, respectivamente. Observou-se que apenas uma entrada de inclusão não-linear (IENL) não foi classificada primeiramente, sendo depois confundida com a classe falta de penetração (FP). Para a

condição de 4 classes, o desempenho de 100% obtido foi conseguido sem critério de reclassificação, sendo portanto desnecessária a apresentação de tabelas de confusão. Os valores são mostrados para os dados duplicados.



(a)



(b)

**FIGURA 5.3:** (a) e (b) Gráficos de otimização do número de neurônios na camada oculta da rede neural para obter o melhor desempenho com o classificador não-linear tendo como entrada as características: a, e/A, R e P, para inclusão dividida e não dividida, respectivamente.

**TABELA 5.14:** Tabela de Confusão obtida para as características a-e/A-R-P.

*Sem critério de reclassificação.*

|      | MO       | FP       | PO       | IEL      | IENL    | <i>mais de uma</i> | <i>nenhuma</i> |
|------|----------|----------|----------|----------|---------|--------------------|----------------|
| MO   | 25(100%) | 0        | 0        | 0        | 0       | 0                  | 0              |
| FP   | 0        | 25(100%) | 0        | 0        | 0       | 0                  | 0              |
| PO   | 0        | 0        | 25(100%) | 0        | 0       | 0                  | 0              |
| IEL  | 0        | 0        | 0        | 25(100%) | 0       | 0                  | 0              |
| IENL | 0        | 0        | 0        | 0        | 24(96%) | 0                  | 1(4%)          |


**TABELA 5.15:** Tabela de Confusão obtida para as características a-e/A-R-P.

*Com critério de reclassificação.*


|      | MO       | FP       | PO       | IEL      | IENL    | <i>Acerto Total</i> |
|------|----------|----------|----------|----------|---------|---------------------|
| MO   | 25(100%) | 0        | 0        | 0        | 0       | 124(99,2%)          |
| FP   | 0        | 25(100%) | 0        | 0        | 4       |                     |
| PO   | 0        | 0        | 25(100%) | 4        | 0       |                     |
| IEL  | 0        | 0        | 0        | 25(100%) | 0       |                     |
| IENL | 0        | 1        | 0        | 0        | 24(96%) |                     |

Como a quantidade de amostras era pequena, para se dividir o conjunto de dados em um conjunto de treinamento e teste, visando-se avaliar a capacidade de generalização [4] do classificador, mais uma vez recorreu-se as ferramentas de inferência estatística. As saídas obtidas no classificador para esta condição foram também avaliadas segundo teste de Qui-quadrado e Komolgorov-Smirnov [55] para verificar se seguiam uma distribuição normal. Como o teste de Qui-quadrado depende muito do intervalo de frequência adotado, houve algumas distribuições que dependendo do valor de intervalo escolhido, havia aprovação ou reprovação do teste. Entretanto, isto não ocorre para o caso do teste de Kolmogorov [55], tendo em vista que considera-se a distribuição acumulativa. Neste caso, o modelo de distribuição normal foi aprovado para todas as distribuições e, como isso, foi possível calcular a probabilidade de acerto com critério de reclassificação para o classificador não-linear. Considerando-se que em apenas uma observação nenhuma classe foi indicada (todas as saídas negativas – tabela


5.14), as diferenças numéricas entre as saídas da classe indicada (positiva) e as demais classes (negativas), resultaram em uma distribuição distante de zero para todas as classes. Portanto, as probabilidades estimadas de acerto para todas as classes são de aproximadamente 100%. A figura 5.4 contém as distribuições obtidas para as cinco classes de defeitos.




(a)




(b)



(c)



(d)



(e)

**FIGURA 5.4:** Distribuições resultantes para a diferença entre a saída obtida no classificador para uma dada classe e a maior saída entre as outras classes.

### 5.5. Critério de Relevância com um Classificador Não-Linear

Uma avaliação nova da relevância das características foi feita, implementando-se o critério descrito com um classificador não-linear (uma rede de dupla camada – figura 4.8 – capítulo 4). A tabela 5.16 mostra os valores atuais de relevância encontrados para as seis características originalmente estudadas. É bom explicar que recorreu-se novamente às seis características porque a baixa relevância encontrada para o classificador linear em relação as características C e L/A, não implica diretamente também em baixa relevância para um classificador não-linear.

Com o resultado, observou-se então que a característica P apresentava relevância alta com quase todas as classes, exceto com IENL, definitivamente comprovando ser uma característica muito importante para discriminação das classes de defeitos consideradas. As características R, a e e/A apresentaram relevância maior na discriminação da classe PO, resultado compatível com os anteriormente conseguidos com o critério linear, e que pode ser também justificado pelo fato de serem características de forma geométrica do defeito, que para a classe PO sabe-se que o aspecto esférico é bastante comum. Entretanto, as características C e L/A tiveram baixo grau de relevância comparadas com as demais características usadas no trabalho.

**Tabela 5.16:** Critério de Relevância usando um Classificador Não-Linear.


|            | MO   | FP   | PO   | IEL  | IENL | IE   |
|------------|------|------|------|------|------|------|
| <b>C</b>   | 0,23 | 0,16 | 0,11 | 0,14 | 0,14 | 0,21 |
| <b>a</b>   | 0,10 | 0,24 | 0,58 | 0,07 | 0,15 | 0,36 |
| <b>L/A</b> | 0,12 | 0,07 | 0,14 | 0,11 | 0,05 | 0,15 |
| <b>e/A</b> | 0,18 | 0,17 | 0,38 | 0,10 | 0,11 | 0,25 |
| <b>R</b>   | 0,11 | 0,33 | 0,58 | 0,11 | 0,19 | 0,28 |
| <b>P</b>   | 0,62 | 0,65 | 0,34 | 0,54 | 0,25 | 0,71 |

Com base nestes resultados, algumas combinações de entradas usando estas características foram testadas como vetores de entrada para o classificador não-linear. A figura 5.5 ilustra os resultados obtidos para estas combinações entre características. O

resultado obtido com o vetor de entrada a-e/A-P, descartando a característica R, foi equivalente as duas situações (4 e 5 classes) ao obtido com as quatro características, mostrando que pode-se ainda reduzir a dimensão do vetor de entrada para 3, sem detrimento do desempenho do classificador. Estudou-se também a possibilidade de uso de apenas duas características, como mostra a figura 5.5, e, embora o desempenho tenha caído em relação ao uso de 4 ou 3 características, os valores de acerto em classificação são superiores a 90,0% quando utiliza-se um classificador não-linear. Este resultado é contrário ao encontrado por Aoki [21] em seu trabalho, no qual utilizando um vetor de entrada com dez características em um classificador não-linear para classificação das classes: MO, FP, PO, TR e IE, o desempenho foi maior do que quando descartou uma ou outra característica. Embora Aoki [21] tenha trabalhado com algumas características diferentes das empregadas neste trabalho, embora similares em algumas delas, comprova-se que na verdade a dimensão do vetor de entrada dos classificadores pode ser significativamente reduzida, se as características irrelevantes forem descartadas.

Kato et al [34] usaram também dez características para classificar os defeitos trinca, falta de fusão, falta de penetração, porosidade e inclusão. A escolha das características relevantes para serem usadas no sistema de classificação de padrão inteligente obedeceu um critério baseado em entrevistas feitas com inspetores de radiografias. Nestas entrevistas, Kato et al [34] concluíram que é difícil escolher características por este método, porque o critério é muito subjetivo, e cada inspetor adota um aspecto característico de forma ou geometria do defeito para categorização.

Mery [61, 62] avaliou também a relevância de várias características de forma, textura, contraste, etc., para classificação das classes defeito e estrutura regular em radioscopias de roda de alumínio. Para tal, usou os conceitos de discriminação de *Fisher* e curva ROC. Inicialmente, ele chegou a conclusão de que apenas 28 características eram realmente relevantes em um total inicial de 405 características.



**FIGURA 5.5:** Gráfico com os desempenhos obtidos com os classificadores não-lineares alimentados com as combinações de características indicadas, para as duas situações: 4 e 5 classes. Note que a origem do eixo vertical está deslocada.


#### 5.6. Componentes Principais de Discriminação Não-Linear

A figura 5.6 mostra os dois gráficos bidimensionais construídos com as duas principais componentes não-lineares de discriminação em atuação independente. A figura 5.6a, referente à situação de separação para quatro classes, mostra que as classes MO e FP apresentam regiões bem definidas e portanto são fáceis de serem separadas por separadores não-lineares. As classes PO e IE apresentam uma região de confusão no gráfico com algumas amostras de IE se posicionando na região de PO. Isto já havia sido detectado quando foram usados classificadores lineares, pois os erros de classificação eram referentes a estas classes. Como agora foram usados classificadores não-lineares, a possibilidade de separação destas classes se tornou viável pois as redes neurais são capazes de desenvolver superfícies de separação bastantes complexas e permitir um desempenho alto de acerto, como foi comprovado. Entretanto, existe o problema de generalização [4, 46] da rede. Os gráficos obtidos para distribuição das saídas do classificador não-linear mostraram que a probabilidade de acerto para dados não utilizados durante o treinamento é alta, porém, para que estes resultados sejam ainda mais confiáveis, é necessário a utilização de padrões de teste, o que não foi realizado


por falta de dados suficientes. O mesmo ocorre para figura 5.6b, cinco classes, aonde a confusão entre as IENL, IEL e PO é ainda maior. Neste caso, o problema de falta de generalização se torna mais propenso de ocorrer.

A utilização destes gráficos de visualização usando as componentes principais é bastante útil para sistemas de dimensões elevadas, como o de Mery [61, 62], que usou inicialmente 405 características para separar as classes defeito real e estrutura.

Em todas as referências bibliográficas estudadas sobre o tema, não há existência de uso similar destas componentes para tal propósito.




(a)



**FIGURA 5.6:** (a) e (b) : gráficos formados pelas duas componentes principais de discriminação não-linear de atuação independente para as quatro classes (a classe de inclusão sendo considerada como apenas uma classe) e cinco classes (inclusão subdividida em inclusão linear e não-linear).

O gráfico da figura 5.7 representa os resultados de desempenho obtidos quando utilizou-se apenas a primeira componente  $P_1$  como vetor de entrada do classificador, assim como  $(P_1 + P_2)$  independentes (vetor bidimensional) e  $(P_1 + P_2)$  cooperativas (para os dois tipos). Os resultados mostraram que usando apenas a primeira componente o índice de acerto chega a 92,0% para os dados de treinamento com quatro classes, caindo logicamente para a situação mais complexa de cinco classes (66,4%). Com duas componentes, os índices chegam a ser bem próximos aos obtidos quando usou-se quatro ou três características (seção 5.5). Além disso, pode-se afirmar também que não houve diferenças significativas de desempenho entre os tipos de componentes utilizados. Estes resultados comprovam a eficiência das componentes principais para reduzir a dimensão dos dados originais, mantendo a mesma capacidade de acerto de classificação. Para o caso estudado, a redução de 3 ou 4 dimensões para a duas dimensões não representa uma redução de dimensão tão acentuada. Entretanto, os resultados são motivadores de estudos similares a serem feitos em sistema de dimensão maior, como o de Mery [61, 62] por exemplo. O mesmo pode também ser feito para quando são utilizados perfis de cinza de cordões-de-solda, como no trabalho de Liao [18, 23], onde os dos vetores de entrada do classificador podem conter 500 ou mais componentes. Estas técnicas de desenvolvimento das componentes de discriminação são de uso recente e não se encontrou, até o presente momento, uso similar aplicado às pesquisas para desenvolvimento de um sistema automático de reconhecimento de padrões de defeitos em radiografias industriais.



**FIGURA 5.7:** Gráfico mostrando os desempenhos obtidos, quando utilizou-se como entrada do classificador, as componentes principais de discriminação não-linear com atuação independente e de forma cooperativa. Note que a origem do eixo vertical está deslocada.

### 5.7. Resultados Complementares

A partir do segundo conjunto de dados, o objetivo principal era reavaliar as metodologias usadas com o primeiro, principalmente no que se refere à acurácia verdadeira dos classificadores, tendo em vista que inicialmente disponha-se somente de 95 amostras, além de estudar as classes de defeitos trinca e falta de fusão que ainda não haviam sido estudadas. Mais um aspecto importante a ser destacado em relação ao segundo conjunto, como foi dito composto originalmente de 646 amostras, é que a extração das características e a formação do conjunto de dados foram realizadas por outro operador, com o intuito também de permitir a “generalização” da primeira etapa do sistema (extração das características).


Primeiramente, as duas componentes principais independentes de discriminação não-linear (CPDNL) foram calculadas, conforme explicação da seção 4.13, com o objetivo de visualização em duas dimensões do problema de separação entre as classes. Obteve-se as duas componentes principais para o caso de classificação envolvendo as 6 classes, com os rótulos já conhecidos: MO, FP, PO, IE, TR e FF. Neste caso, o

treinamento foi implementado com uma camada intermediária composta por 10 neurônios.


Pelo gráfico de  $P_1$  e  $P_2$  - figura 5.8a, constatou-se que as classes PO, FF, TR e IE eram as classes pertencentes às regiões de maior confusão. Com isso, construiu-se os gráficos de  $P_1$  e  $P_2$  para a situação de classificação de uma dessas quatro classes contra às demais 5 classes. A figura 5.8b fornece uma avaliação prévia da separação da classe FF das demais, assim como a figura 5.8c, o mesmo para a classe IE, a figura 5.8d para a classe PO, e a figura 5.8e para a classe TR. Por estes gráficos, percebe-se que a classe IE é a de maior região de confusão com as outras classes, porque se localiza em uma região de sobreposição com amostras de outras classes. A classe falta de fusão também situa-se em uma região com distribuição de amostras das outras classes, sendo estas as duas de maior confusão observando as duas componentes principais de discriminação, embora a classificação seja feita normalmente com mais de duas componentes.

Para análise e comparação com o primeiro conjunto de dados, quando tinha-se 4 classes considerando a classe de inclusão não-subdividida, repetiu-se o procedimento de construção dos gráficos de  $P_1$  e  $P_2$  para as classes FP, IE, PO e MO, conforme mostram as figuras 5.9b, 5.9c, 5.9d e 5.9e, respectivamente. A figura 5.9a representa as duas componentes para as 4 classes conjuntamente. Observando os gráficos, nota-se que as classes MO e FP novamente são as de separação mais “fácil”, mesmo sendo por enquanto, uma análise apenas visual das regiões de distribuição de cada classe. A figura 5.9c comprova que a classe IE tem uma região bastante confusa de separação com as outras classes (MO, FP e PO), mesmo após a retirada das classes trinca e falta de fusão.


Com essa análise prévia das regiões de distribuição das classes, o próximo passo foi implementar os classificadores lineares para constatar a possibilidade de separação linear de algumas classes, tendo em vista que os discriminadores lineares são mais fáceis de implementação, e não apresentam os problemas de mínimos locais dos discriminadores não-lineares. Neste caso, recorreu-se diretamente ao classificador linear hierárquico, porque foi o que tinha resultado em melhores resultados com o primeiro conjunto de dados, como será visto na seção seguinte.




(a)




(b)



(c)




(d)




(e)


**FIGURA 5.8:** (a) Espaço de representação bidimensional representado pelas duas CPDNL independentes, considerando todas as classes; (b)-(e), mesma representação, mas apenas considerando uma classe contra as demais.




(a)




(b)



(c)



(d)



(e)

**FIGURA 5.9** : (a) Espaço de representação bidimensional representado pelas duas CPDNL independentes, descartando, neste caso, as classes TR e FF; (b)-(e), mesma representação, mas apenas considerando uma classe contra as demais.

### 5.7.1. *Classificador Linear-Hierárquico*

A tabela de confusão 5.17 fornece os resultados de desempenho obtidos com o classificador linear hierárquico para as 6 classes de defeitos. Nesta tabela, a ordem hierárquica de classificação foi determinada com o classificador não-hierárquico, que foi utilizado apenas para determinar a ordem que seria utilizada para fins de classificação com o classificador hierárquico, recorrendo mais uma vez a um espaço de classificação delimitado por duas classes: uma classe dentre as 6 e as 5 classes restantes. Denominou-se esta hierarquia de 1ª Ordem de Classificação. Neste caso, também fez-se duplicamento das classes menos favorecidas em população de amostras, como as classes trinca (27 amostras) e falta de fusão (56 amostras) por exemplo, para amenizar a tendência do treinamento do classificador para classificar as classes com maior população, embora seja uma solução meramente paliativa para classes com distribuição de amostrais diferentes. Como a classe PO era a que tinha maior quantidade de amostras (196), todas as demais classes foram equalizadas para esta quantidade de amostras, escolhendo-se amostras de duplicamento de forma aleatória.

Analisando a tabela 5.17, o primeiro ponto a ser destacado é que não houve casos de “nenhuma classe indicada”, como ocorreu freqüentemente com o primeiro conjunto de dados, o que dispensou o critério de reclassificação. As classes MO e FP mais uma vez são as que apresentam o maior índice de acerto, e poucas amostras destas classes são confundidas com as outras classes. Com o primeiro conjunto de dados, essas classes resultaram em 100% de acerto para esse tipo de classificador, entretanto a quantidade de amostras era significativamente menor do que o número de amostras destas classes no conjunto atual de dados, e os percentuais de acerto de 96,5% e 98,0% para MO e FP, respectivamente, confirmam que essas classes podem ser separadas em um sistema de classificação de defeitos de soldagem usando um classificador linear, se forem utilizadas as características geométricas usadas neste trabalho.

A classe PO resultou em 88,3 % de acerto, o que pode ser considerado um bom resultado, porque é uma classe que tem regiões de confusão no espaço de representação, principalmente com a classe IE, como pôde ser notado na figura 5.8a, e que é confirmado com as 22 amostras (11,2%) desta classe confundidas com IE.

Com a classe trinca (TR), somente agora estudada, o resultado de 92,8% de acerto é um índice satisfatório de acurácia, tendo em vista a pouca quantidade de

amostras disponíveis para essa classe (27 amostras). Os 7,2% de confusão com FP são compatíveis com os aspectos geométricos destas duas classes, e posicionamento no cordão-de-solda, pois no caso de ocorrência de trinca longitudinal, sua posição é bem próxima, normalmente, da posição de um defeito do tipo falta de penetração. Ressalta-se que as 27 amostras desta classe continham amostras tanto de trincas transversais, quanto de trincas longitudinais. Não subdividiu-se o conjunto, porque certamente tornaria as subclasses ainda mais desfavorecidas em termos de quantidade amostras.

Para a classe FF, o resultado de acerto foi extremamente baixo, a maioria das amostras foi confundida com as classes TR ou IE, o que comprovou ser bastante difícil a separação desta classe de TR e IE por um discriminador linear.

A classe IE teve um índice de acerto razoável, 56,7%, devido a sua confusão com quase todas as classes, exceto MO, o que tinha sido observado na figura 5.8a. Há que se destacar que, esta classe é certamente a que tem a maior variabilidade de forma geométrica entre as classes de defeitos. Neste novo conjunto de dados, foi considerado na análise das imagens, o maior número possível de variações de forma de IE, e não somente as inclusões lineares ou não-lineares como tinha sido feito com o primeiro conjunto. Com isso, o objetivo era tentar otimizar a classificação de IE na condição mais crítica possível, o que facilitaria a implementação de classificadores, pois tem-se um número menor de classes a serem tratadas, aliado a um número pequeno de características utilizadas. O percentual total de acurácia obtido com este classificador foi de 74,0%, inferior aos 80,0/85,0% obtidos anteriormente, mas outra vez, ratifica-se que o número de amostras agora é consideravelmente mais significativo e a separação é entre 6 classes, e não entre apenas 4 classes.

**TABELA 5.17** : Tabela de Confusão.*Classificador Linear-Hierárquico na 1ª Ordem de Classificação*

|                  | MO        | FP        | PO        | TR        | FF      | IE        |
|------------------|-----------|-----------|-----------|-----------|---------|-----------|
| MO               | 189/96,5% | 0         | 0         | 2/1,0%    | 0       | 5/2,5%    |
| FP               | 0         | 192/98,0% | 0         | 4/2,0%    | 0       | 0         |
| PO               | 0         | 1/0,5%    | 173/88,3% | 0         | 0       | 22/11,2%  |
| TR               | 0         | 14/7,2    | 0         | 182/92,8% | 0       | 0         |
| FF               | 0         | 0         | 0         | 152/77,5% | 23/11,8 | 21/10,7%  |
| IE               | 0         | 5/2,5%    | 36/18,3%  | 41/21,0%  | 3/1,5%  | 111/56,7% |
| TOTAL DE ACERTOS |           |           | 870/74,0% |           |         |           |

Outra forma de ordenar as classes hierarquicamente, e certamente a mais correta do ponto de vista do princípio de funcionamento do classificador hierárquico, é escolhendo a próxima classe a ser classificada, como sendo aquela que resulta em melhor desempenho de classificação após a retirada das amostras que foram indicadas positivas (saídas positivas) na separação da classe anterior. Para exemplificar: considere primeiramente a classe MO como sendo a primeira em ordem de hierarquia na classificação, após a retirada das amostras/entradas de MO que foram já classificadas, ou de amostras das outras classes que foram classificadas, ainda que erroneamente como MO, a próxima classe a ser escolhida do processo de hierarquia é aquela que resulta em melhor desempenho de classificação no espaço de distribuição das amostras restantes. Procede-se desta maneira até a última classe. A esse segundo método de hierarquia denominou-se de 2ª ordem de classificação. O resultado obtido com esta hierarquia usando o classificador linear é mostrado na tabela 5.18, nele, fica evidenciado o aumento de acerto em quase todas as classes, principalmente PO que teve praticamente todas as amostras classificadas corretamente. Entretanto, a classe IE teve uma queda brusca de acurácia em relação a 1ª ordem de classificação, o que acabou resultando em um percentual geral de acurácia desta ordem quase idêntico à primeira ordem. Isto não invalida a escolha preferencial da segunda ordem em relação à primeira, porque como foi dito, é a ordem mais coerente com o critério de classificação do classificador hierárquico. Evidentemente, que excluindo MO e FP e tratando apenas as 4 classes restantes, é possível desenvolver 4! (4 fatorial) permutações desta classe e

verificar o desempenho do classificador, entretanto, existe pouca probabilidade de uma destas permutações resultar em um desempenho melhor que o obtido com a 2ª ordem.

**TABELA 5.18** : Tabela de Confusão.

*Classificador Linear-Hierárquico na 2ª Ordem de Classificação*

|                  | MO        | FP        | TR       | FF       | PO        | IE       |
|------------------|-----------|-----------|----------|----------|-----------|----------|
| MO               | 190/97,0% | 0         | 0        | 0        | 3/1,5%    | 3/1,5%   |
| FP               | 0         | 192/98,0% | 4/2,0%   | 0        | 0         | 0        |
| TR               | 0         | 14/7,2%   | 182/92,8 | 0        | 0         | 0        |
| FF               | 0         | 0         | 89/45,4% | 76/38,8% | 9/4,6%    | 22/11,2% |
| PO               | 0         | 1/0,5%    | 0        | 0        | 195/99,5% | 0        |
| IE               | 0         | 6/3%      | 10/5,1%  | 3/1,5%   | 143/73,0% | 34/17,4% |
| TOTAL DE ACERTOS |           | 869/73,9% |          |          |           |          |

Para comparar mais precisamente os novos resultados deste tipo de classificador com os resultados obtidos anteriormente, a mesma avaliação foi realizada com as 4 classes: MO, FP, PO e IE. Na tabela 5.19, apresenta-se o resultado obtido para o classificador linear hierárquico com o conjunto de amostras contendo somente estas classes, sem a classe TR e FF, na ordem adotada pelo segundo método de hierarquia. O resultado mostra que as três classes FP, MO e PO são facilmente separáveis por um discriminador linear hierárquico, tendo ocorrido apenas 2,5% de erro de classificação para a classe FP, enquanto MO e PO tiveram todas as suas amostras corretamente classificadas. Entretanto, a classe IE novamente teve um índice baixo de acerto, pois a maioria de suas amostras foi confundida com PO, o que comprovou decididamente a impossibilidade de separação linear desta classe das demais classes, principalmente da classe PO. De fato, constata-se que no cotidiano de interpretação e laudo de radiografias pelo método convencional, este tipo de confusão certamente está entre os mais freqüentes pelos aspectos de forma similares existentes entre IE e PO, em situações em que IE é não-linear. Por este motivo, o percentual total de acerto de 77,30% ficou relativamente baixo quando comparado ao primeiro conjunto de dados.

Estas avaliações com o classificador linear hierárquico foram feitas com os próprios dados de treinamento utilizados na implementação dos discriminadores, entretanto, como se trata de um discriminador linear, aonde não há ocorrência de

mínimos locais, não há preocupação com a ocorrência de supertreinamento dos dados, o que permite se fazer uma medição de acurácia do classificador apenas com os dados de treinamento, o que não ocorre com os classificadores não-lineares que serão vistos na seção seguinte.

**TABELA 5.19** : Tabela de Confusão.

*Classificador Linear-Hierárquico na 2ª Ordem de Classificação*


|                        | FP         | MO         | PO         | IE       |
|------------------------|------------|------------|------------|----------|
| FP                     | 196/100,0% | 0,0        | 0,0        | 0,0      |
| MO                     | 0,0        | 191/97,5%  | 2/1,0%     | 3/1,5%   |
| PO                     | 0,0        | 0,0        | 196/100,0% | 0,0      |
| IE                     | 0,0        | 1/0,5%     | 172/87,8%  | 23/11,7% |
| <b>TOTAL DE ACERTO</b> |            | 606/77,30% |            |          |

### 5.7.2. Classificador Não-Linear e Não-Hierárquico

O primeiro passo a ser tomado no desenvolvimento do classificador não-linear foi a otimização do número de neurônios utilizados na camada intermediária de forma a se obter a melhor acurácia possível. Variando o número de neurônios na camada intermediária e verificando o acerto percentual e erro após treinamento com 3000 épocas, para os dados de treinamento, o número de neurônios que resultou em melhor resultado foi 16/17 neurônios, como pode ser visto na figura 5.10. Entretanto, dividindo-se o conjunto de dados em pares de treinamento e teste de forma aleatória, neste caso sem duplicamento, os melhores resultados de teste foram obtidos com 8 neurônios na camada oculta. A partir destes resultados iniciais, os treinamentos e testes realizados com o classificador não-linear e não-hierárquico foram todos realizados com 8 neurônios na camada intermediária para o conjunto contendo as 6 classes.

Inicialmente, algumas variações de parâmetros de rede foram testadas, como: taxa de treinamento variável ( $\alpha$ ) com momento ( $\beta=0,9$ ), taxa de treinamento fixa em 0,1 e sem momento, e taxa fixa em 0,1 e momento fixo em 0,9. A inicialização das sinapses e *bias* foi pelo método de Nguyn-Widrow [51]. Todas essas variações de treinamento resultaram em convergência para a mesma faixa de erro, entretanto, os parâmetros

ajustados para  $\alpha$  variável e momento fixo resultaram sempre em convergência mais rápida do erro de treinamento. Observou-se que após 3000 épocas, normalmente, havia estabilização do erro, tendo se escolhido este número de época para os treinamentos realizados com o classificador não-linear.



**FIGURA 5.10:** Otimização do número de neurônios na camada intermediária para permitir o melhor resultado de teste.

#### 5.7.2.1. Estimadores de Acurácia do Classificador Não-Linear e Não-Hierárquico

Para estimar a acurácia verdadeira destes classificadores, foram formados 10 pares de conjunto de treinamento e teste com os sorteios dos pares aleatórios como foi explicado na seção 4.14.3 – capítulo 4. A tabela 5.20 mostra os resultados obtidos para os 10 pares de conjuntos formados em cada condição avaliada: sem e com duplicamento. As siglas SR e R correspondem aos critérios de sem reclassificação e com reclassificação, respectivamente. Além de testar as condições de classificação para 6 classes e as 4 classes iniciais do trabalho de tese, estimou-se também a acurácia do classificador para a classificação de 5 classes envolvidas, sem a presença da classe IE, que foi a que tinha dado os piores resultado com o classificador linear hierárquico.

Na tabela 5.20, a média indica a acurácia estimada para cada seleção de 10 pares de conjunto de testes. Para 6 classes, com os dados com a quantidade original de amostras por cada classe (sem duplicamento), a acurácia estimada foi de 71,6% com critério de reclassificação. Embora este percentual esteja abaixo dos índices obtidos com

os conjuntos de treinamento, que oscilaram na faixa de 85,0-90,0%, não há ocorrência de supertreinamento, porque o número de neurônios na camada intermediária foi otimizado propositadamente para que este problema não ocorresse. O índice máximo de acerto com dados de teste, para este caso, foi de 72,9% sem reclassificação e 75,2% com reclassificação. Para verificar os índices de acerto de cada classe para este mesmo conjunto, numa forma de constatar o que ocorreu separadamente em cada classe nesta situação de classificação (6 classes e conjunto sem duplicamento), construiu-se as tabelas de confusão 5.21 (sem reclassificação) e 5.22 (com reclassificação) para resultados obtidos com os dados de treinamento, e o mesmo para as tabelas 5.23 e 5.24, respectivamente, com os resultados obtidos com os dados de teste. Como o número total de amostras sem duplicamento era de 646, dividido-se em cerca de 80,0% de amostras para treinar e 20,0% para teste, o conjunto de treinamento ficou com 517 amostras e o de teste com 129. Observando as tabelas 5.21 e 5.22, nota-se que todas as classes têm índices elevados de acerto, exceto a classe IE que teve cerca de 23,0% de confusão com a classe PO (tabela 5.22), e a classe falta de fusão que teve 16,3% de confusão com o defeito inclusão de escória (IE). Para a tabela 5.22, 460 amostras foram classificadas corretamente de um total de 517, resultando em cerca de 89,0% de acurácia aparente. É importante destacar que este resultado obtido com os dados de treinamento não foi o melhor entre os resultados de treinamento, mas sim aquele que permitiu o melhor resultado com os dados de teste.

As tabelas 5.23 e 5.24, resultados do conjunto de teste, mostram que a classe MO teve 94,3% de acerto, PO 92,9% e FP 72,7%, sendo estas as classes de maior acerto. A classe que resultou em pior índice de acerto com os dados de teste foi TR, mas apenas 4 amostras foram usadas para teste do total de 27 contidas nesta classe, sendo portanto, um resultado com pouca significância estatística. A classe IE novamente apresenta-se como a de maior confusão com as outras classes. Voltando a análise da acurácia estimada para esta situação de classificação, os 71,6% obtidos podem ser considerados satisfatórios, tendo em vista a quantidade de classes analisada agora, e principalmente a presença da classe IE que neste conjunto novo de dados apresenta larga faixa de confusão com as outras classes, fato justificado pela abrangência de variações de forma que se considerou desta vez na formação do conjunto de amostras desta classe.

Fucsok [3], que calculou curvas ROC [48] para estimar a probabilidade de detecção correta de defeito em filmes radiográficos pelo método convencional de inspeção - interpretação humana dos filmes - chegou ao resultado de 68,0% de indicações certas para todos os tipos de defeitos, e 64,0% para defeitos que excederam aos limites de aceitação da norma utilizada (EN 12515:1998) [3]. Desta forma, os 71,6% estão acima destes valores. Evidentemente que, o número de classes de defeitos encontrados nos filmes utilizados no trabalho de Fucsok [3] continha classes que ainda não foram avaliadas por estes classificadores, como: inclusão de hidrogênio, inclusão de tungstênio, desalinhamento, concavidade, porosidade vermiforme, etc., mas as classes estudadas neste trabalho são as de maior ocorrência em termos de defeitos de soldagem e as que provocam maiores erro de interpretação.

Dentro do mesmo problema de classificação envolvendo 6 classes, 10 pares de treinamento e teste também foram formados, mas com duplicamento dos dados para igualar o número de amostras contidas em cada classe. Neste caso, cada classe passou a conter 196 amostras, número de amostras da classe PO. Na tabela 5.20, verifica-se que a acurácia estimada foi de 76,7% sem o critério de reclassificação, e 79,8% com reclassificação, índices superiores ao caso anterior. Este aumento de índice é justificado no fato de que classes com menor distribuição de amostras, como TR (27), FF (56) e FP (56) tiveram amostras idênticas usadas tanto para treinamento, quanto para teste, devido ao processo de duplicamento. Entretanto, a classe PO com 196 amostras não duplicadas, foi treinada e testada com conjuntos completamente dissimilares. A classe MO com 174 amostras, embora possa ter tido amostras iguais usadas para treinar e testar, isto ocorreu com pouca frequência porque apenas 22 amostras foram duplicadas para esta classe. O mesmo ocorrendo para a classe IE, só que para esta classe 59 amostras foram duplicadas aleatoriamente do total de 137, havendo portanto maior proporção de teste sendo realizado com amostra usada também para treinar.

As tabelas de confusão 5.25 e 5.26, mostram os resultados obtidos para o conjunto treinamento referentes ao conjunto de teste de máximo acerto (máximo da tabela), comprovando que quando há duplicamento de amostras, os índices de acerto aumentam praticamente para todas as classes. Com os dados de teste, as tabelas 5.27 e 5.28 ratificam de forma ainda mais evidente o aumento nos índices de acurácia de quase todas as classes, exceto a classe MO que agora teve 93,0 de acerto (tabela 5.28), e anteriormente tinha atingido 94,3%, mas com uma diferença insignificante diante do

aumento percentual das outras classes. O que gerou um índice máximo de acerto de 88,5% sem reclassificação (SR) e 89,4% com reclassificação (R).

**TABELA 5.20:** Estimadores de Acurácia dos Classificadores Não-Lineares e Não-Hierárquicos para Cada Condição de Classificação.

*Resultados Percentuais Obtidos Somente com os Conjuntos de Teste*

|           | Conjuntos        | RESULTADOS (%) |      |        |      |       |      |        |     |
|-----------|------------------|----------------|------|--------|------|-------|------|--------|-----|
|           |                  | Máximo         |      | Mínimo |      | Média |      | Desvio |     |
|           |                  | SR             | R    | SR     | R    | SR    | R    | SR     | R   |
| 6 Classes | Sem duplicamento | 72,9           | 75,2 | 65,9   | 67,5 | 69,0  | 71,6 | 2,2    | 1,3 |
|           | Com duplicamento | 88,5           | 89,4 | 69,4   | 71,0 | 76,7  | 79,8 | 5,9    | 5,6 |
| 4 Classes | Sem duplicamento | 83,0           | 83,9 | 74,1   | 75,0 | 77,8  | 79,0 | 2,7    | 2,7 |
|           | Com duplicamento | 84,0           | 85,3 | 62,8   | 63,5 | 81,4  | 82,5 | 7,3    | 7,3 |
| 5 Classes | Sem duplicamento | 93,1           | 94,1 | 63,3   | 63,3 | 84,0  | 85,0 | 8,7    | 9,3 |
|           | Com duplicamento | 97,0           | 97,5 | 77,0   | 79,1 | 85,3  | 86,4 | 6,4    | 5,9 |

\* As células em azul correspondem às tabelas de confusão apresentadas a seguir para os conjuntos de teste.

A tabela 5.20 também contém os estimadores de acurácia obtidos para conjuntos de teste contendo apenas as 4 classes inicialmente estudadas no trabalho: FP MO, IE e PO. Para conjuntos sem duplicamento, a média foi de 77,8 (SR) e 79,0 (R). Entretanto, com duplicamento de amostras, atingiu-se 81,4 (SR) e 82,5 (R). Estes resultados são bastante satisfatórios, mesmo que abaixo dos quase 100,0% que se obtinha para o primeiro conjunto de dados (estimados pelo cálculo de probabilidade), porque a situação atual é muito mais representativa em termos de número de amostras e radiografias utilizadas. O maior índice de acerto para um conjunto com 4 classes foi de 85,3 (R) e 84,0 (SR) com as amostras duplicadas. Para estes conjuntos, vale notar que existe pouca diferença percentual dos estimadores entre conjuntos duplicados ou não-duplicados, isto explica-se porque dentre estas 4 classes, apenas a classe FP tem poucas amostras (56)

comparadas às demais, então o duplicamento de amostras não teve tanto efeito no aumento da acurácia dos conjuntos.

**TABELA 5.21** : Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Sem reclassificação)*

*Sem Duplicamento – Dados de Treinamento*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>IE</b> | <b>PO</b> | <i>Mais de uma</i> | <i>Nenhuma</i> |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|--------------------|----------------|
| <b>FF</b> | 34/79,1   | 0,0       | 0,0       | 0,0       | 7/16,3    | 0,0       | 0,0                | 2/4,6          |
| <b>FO</b> | 0,0       | 45/100    | 0,0       | 0,0       | 0,0       | 0,0       | 0,0                | 0,0            |
| <b>MO</b> | 4/2,9     | 0,0       | 131/94,2  | 0,0       | 2/1,5     | 1/0,7     | 0,0                | 1/0,7          |
| <b>TR</b> | 1/4,5     | 0,0       | 0,0       | 19/86,5   | 1/4,5     | 0,0       | 0,0                | 1/4,5          |
| <b>IE</b> | 0,0       | 0,0       | 1/0,9     | 0,0       | 81/71,1   | 24/21,0   | 0,0                | 8/7,0          |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 10/6,5    | 141/91,6  | 0,0                | 3/1,9          |

**TABELA 5.22:** Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Com reclassificação)*

*Sem Duplicamento – Dados de Treinamento*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>IE</b> | <b>PO</b> |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| <b>FF</b> | 35/81,4   | 0,0       | 1/2,3     | 0,0       | 7/16,3    | 0,0       |
| <b>FO</b> | 0,0       | 45/100    | 0,0       | 0,0       | 0,0       | 0,0       |
| <b>MO</b> | 4/2,9     | 0,0       | 131/94,2  | 0,0       | 2/1,5     | 1/0,7     |
| <b>TR</b> | 1/4,5     | 0,0       | 0,0       | 20/91,0   | 1/4,5     | 0,0       |
| <b>IE</b> | 2/1,7     | 0,0       | 1/0,9     | 0,0       | 85/74,6   | 26/22,8   |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 11/7,1    | 143/92,9  |

**TABELA 5.23:** Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Sem reclassificação)*

*Sem Duplicamento – Dados de Teste*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>IE</b> | <b>PO</b> | <i>Mais de uma</i> | <i>Nenhuma</i> |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|--------------------|----------------|
| <b>FF</b> | 6/46,1    | 2/15,4    | 2/15,4    | 0,0       | 0,0       | 0,0       | 0,0                | 3/23,1         |
| <b>FO</b> | 0,0       | 8/72,7    | 2/18,2    | 1/9,1     | 0,0       | 0,0       | 0,0                | 0,0            |
| <b>MO</b> | 1/2,7     | 1/2,7     | 33/94,3   | 0,0       | 0,0       | 0,0       | 0,0                | 0,0            |
| <b>TR</b> | 1/20,0    | 0,0       | 2/40,0    | 1/20,0    | 1/20,0    | 0,0       | 0,0                | 0,0            |
| <b>IE</b> | 0,0       | 0,0       | 4/17,4    | 1/4,4     | 7/30,4    | 6/26,1    | 0,0                | 5/21,7         |
| <b>PO</b> | 0,0       | 0,0       | 3/7,1     | 0,0       | 0,0       | 39/92,9   | 0,0                | 0,0            |

**TABELA 5.24:** Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Com reclassificação)*

*Sem Duplicamento – Dados de Teste*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>IE</b> | <b>PO</b> |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| <b>FF</b> | 7/53,8    | 2/15,4    | 2/15,4    | 0,0       | 0,0       | 0,0       |
| <b>FO</b> | 0,0       | 8/72,7    | 2/18,2    | 1/9,1     | 0,0       | 0,0       |
| <b>MO</b> | 1/2,7     | 1/2,7     | 33/94,3   | 0,0       | 0,0       | 0,0       |
| <b>TR</b> | 1/20,0    | 0,0       | 2/40,0    | 1/20,0    | 1/20,0    | 0,0       |
| <b>IE</b> | 1/4,4     | 0,0       | 4/17,4    | 2/8,7     | 9/39,1    | 7/30,4    |
| <b>PO</b> | 0,0       | 0,0       | 3/7,1     | 0,0       | 0,0       | 39/92,9   |

**TABELA 5.25 :** Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Sem reclassificação)*

Com Duplicamento – Dados de Treinamento

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>IE</b> | <b>PO</b> | <i>Mais de uma</i> | <i>Nenhuma</i> |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|--------------------|----------------|
| <b>FF</b> | 134/84,3  | 0,0       | 0,0       | 2/1,2     | 14/8,8    | 0,0       | 0,0                | 9/5,7          |
| <b>FO</b> | 0,0       | 148/98,0  | 0,0       | 2/1,3     | 0,0       | 0,0       | 0,0                | 1/0,7          |
| <b>MO</b> | 2/1,3     | 0,0       | 147/96,1  | 0,0       | 2/1,3     | 0,0       | 0,0                | 2/1,3          |
| <b>TR</b> | 0,0       | 0,0       | 0,0       | 151/95,6  | 0,0       | 0,0       | 0,0                | 7/4,4          |
| <b>IE</b> | 1/0,6     | 0,0       | 0,0       | 1/0,6     | 126/75,4  | 27/16,2   | 0,0                | 12/7,2         |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 15/9,8    | 136/88,9  | 0,0                | 2/1,3          |

**TABELA 5.26:** Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Com reclassificação)*

Com Duplicamento – Dados de Treinamento

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>IE</b> | <b>PO</b> |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| <b>FF</b> | 139/87,4  | 0,0       | 1/0,6     | 2/1,3     | 17/10,7   | 0,0       |
| <b>FO</b> | 0,0       | 148/98,0  | 0,0       | 1/0,7     | 2/1,3     | 0,0       |
| <b>MO</b> | 2/1,3     | 0,0       | 147/96,1  | 0,0       | 4/2,6     | 0,0       |
| <b>TR</b> | 0,0       | 0,0       | 0,0       | 158/100   | 0,0       | 0,0       |
| <b>IE</b> | 4/2,4     | 1/0,6     | 0,0       | 1/0,6     | 131/78,4  | 30/18,0   |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 15/9,8    | 138/90,2  |

**TABELA 5.27** : Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Sem reclassificação)*

*Com Duplicamento – Dados de Teste*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>IE</b> | <b>PO</b> | <i>Mais de uma</i> | <i>Nenhuma</i> |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|--------------------|----------------|
| <b>FF</b> | 23/62,2   | 0,0       | 0,0       | 2/5,4     | 6/16,2    | 0,0       | 2/5,4              | 4/10,8         |
| <b>FO</b> | 0,0       | 43/95,6   | 0,0       | 2/4,4     | 0,0       | 0,0       | 0,0                | 0,0            |
| <b>MO</b> | 2/4,7     | 0,0       | 40/93,0   | 0,0       | 1/2,3     | 0,0       | 0,0                | 0,0            |
| <b>TR</b> | 0,0       | 0,0       | 0,0       | 38/100    | 0,0       | 0,0       | 0,0                | 0,0            |
| <b>IE</b> | 0,0       | 0,0       | 0,0       | 2/6,9     | 22/75,9   | 4/13,8    | 0,0                | 1/3,4          |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 1/2,3     | 42/97,7   | 0,0                | 0,0            |

**TABELA 5.28**: Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Com reclassificação)*

*Com Duplicamento – Dados de Teste*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>IE</b> | <b>PO</b> |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| <b>FF</b> | 24/64,9   | 0,0       | 2/5,4     | 4/10,8    | 7/18,9    | 0,0       |
| <b>FP</b> | 0,0       | 43/95,6   | 0,0       | 2/4,4     | 0,0       | 0,0       |
| <b>MO</b> | 2/4,7     | 0,0       | 40/93,0   | 0,0       | 1/2,3     | 0,0       |
| <b>TR</b> | 0,0       | 0,0       | 0,0       | 38/100    | 0,0       | 0,0       |
| <b>IE</b> | 0,0       | 0,0       | 0,0       | 2/6,9     | 23/79,3   | 4/13,8    |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 1/2,3     | 42/97,7   |

Pelos resultados apresentados, constatou-se que a classe IE é a classe que teve maiores índices de confusão com as outras classes, principalmente com a classe PO. Por este motivo, estimou-se a acurácia do classificador não-linear para um conjunto não contendo a classe IE (contendo somente as demais 5 classes). Na tabela 5.20, nota-se que a acurácia estimada é de 84,0 (SR) e 85,0 (R) para o conjunto sem duplicamento. Com duplicamento, obteve-se 85,3 (SR) e 86,4 (R). Estes índices de acerto estimado estão acima dos índices obtidos com 6 e 4 classes, quando a classe IE estava presente, resultado que ratifica que a classe IE é de fato a que possui maiores índices de erro de classificação. Outro fator importante a ser destacado deste resultado é que há pouca diferença também dos resultados do conjunto sem duplicamento, para o com duplicamento, isto prova que o classificador é bem desenvolvido mesmo para distribuições amostrais desiguais entre as classes. Embora a classe trinca seja uma exceção à essa conclusão, como será discutido a seguir.

Para 5 classes, as tabelas 5.29 e 5.30 referem-se aos resultados de acerto e confusão de classes obtidos com o conjunto de treinamento, sem duplicamento, correspondente ao conjunto de teste de maior índice de acerto (93,1% e 94,1% - tabela 5.20). É fácil notar que com 5 classes os acertos são maiores que os acertos obtidos para 6 e 4 classes, mesmo para o conjunto de teste (tabelas 5.31 e 5.32), exceto a classe trinca (TR), que como foi testada com apenas 4 amostras e neste caso 2 confundiram com FF e 2 com FP, teve um índice “zero” de acerto, mas sem nenhuma significância estatística pela pouca quantidade de amostras utilizadas. As tabelas 5.33 a 5.36 contêm os resultados de acerto para o conjunto com duplicamento que permitiu o melhor resultado de teste (97,0% e 97,5% - tabela 5.20). Neste caso, os resultados são ainda melhores como era esperado pelo duplicamento das amostras.

Analisando de forma geral os resultados atingidos para os estimadores de acurácia com o sorteio aleatório de 10 pares de conjuntos, os índices obtidos podem ser considerados satisfatórios, pois sabe-se que a classificação de 6 classes de defeitos tão variantes em formato, especialmente FF e IE, e usando um número reduzido de características como foi utilizado neste trabalho, é extremamente difícil. Outros autores, como Liao [19], embora tenham obtido índices um pouco maiores de acurácia, utilizaram normalmente 10/12 características para classificação de classes com formatos e aspectos de contraste mais típicos, como inclusão de hidrogênio por exemplo, e que portanto, são mais fáceis de classificação. O estudo de acurácia destas 6 classes estudadas ( sem sombra de dúvida as mais importantes ) com um conjunto de 646 amostras é inovador em

comparação às referências bibliográficas citadas nesta área, especialmente em relação aos trabalhos de classificação de defeitos envolvendo características geométricas de fácil extração.

**TABELA 5.29** : Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Sem reclassificação)*

*Sem Duplicamento – Dados de Treinamento*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>PO</b> | <i>Mais de uma</i> | <i>Nenhuma</i> |
|-----------|-----------|-----------|-----------|-----------|-----------|--------------------|----------------|
| <b>FF</b> | 43/97,8   | 0,0       | 0,0       | 0,0       | 0,0       | 0,0                | 1/2,2          |
| <b>FP</b> | 0,0       | 44/95,7   | 0,0       | 2/4,3     | 0,0       | 0,0                | 0,0            |
| <b>MO</b> | 3/2,2     | 0,0       | 130/97,0  | 0,0       | 0,0       | 0,0                | 1/0,8          |
| <b>TR</b> | 1/4,3     | 1/4,3     | 0,0       | 18/78,3   | 0,0       | 0,0                | 3/13,1         |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 161/100   | 0,0                | 0,0            |

**TABELA 5.30**: Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Com reclassificação)*

*Sem Duplicamento – Dados de Treinamento*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>PO</b> |
|-----------|-----------|-----------|-----------|-----------|-----------|
| <b>FF</b> | 43/97,8   | 0,0       | 0,0       | 0,0       | 1/2,2     |
| <b>FP</b> | 0,0       | 44/95,7   | 0,0       | 2/4,3     | 0,0       |
| <b>MO</b> | 3/2,2     | 0,0       | 131/97,8  | 0,0       | 0,0       |
| <b>TR</b> | 3/13,0    | 1/4,3     | 0,0       | 19/82,7   | 0,0       |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 161/100   |

**TABELA 5.31** : Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Sem reclassificação)*

*Sem Duplicamento – Dados de Teste*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>PO</b> | <i>Mais de uma</i> | <i>Nenhuma</i> |
|-----------|-----------|-----------|-----------|-----------|-----------|--------------------|----------------|
| <b>FF</b> | 9/75,0    | 0,0       | 2/17,0    | 0,0       | 0,0       | 0,0                | 1/8            |
| <b>FP</b> | 0,0       | 10/100    | 0,0       | 0,0       | 0,0       | 0,0                | 0,0            |
| <b>MO</b> | 0,0       | 0,0       | 40/100    | 0,0       | 0,0       | 0,0                | 0,0            |
| <b>TR</b> | 2/50,0    | 2/50,0    | 0,0       | 0,0       | 0,0       | 0,0                | 0,0            |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 35/100    | 0,0                | 0,0            |

**TABELA 5.32:** Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Com reclassificação)*

*Sem Duplicamento – Dados de Teste*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>PO</b> |
|-----------|-----------|-----------|-----------|-----------|-----------|
| <b>FF</b> | 10/83,0   | 0,0       | 2/17,0    | 0,0       | 0,0       |
| <b>FP</b> | 0,0       | 10/100    | 0,0       | 0,0       | 0,0       |
| <b>MO</b> | 0,0       | 0,0       | 40/100    | 0,0       | 0,0       |
| <b>TR</b> | 2/50,0    | 2/50,0    | 0,0       | 0,0       | 0,0       |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 35/100    |

**TABELA 5.33:** Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Sem reclassificação)*

*Com Duplicamento – Dados de Treinamento*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>PO</b> | <i>Mais de uma</i> | <i>Nenhuma</i> |
|-----------|-----------|-----------|-----------|-----------|-----------|--------------------|----------------|
| <b>FF</b> | 155/96,9  | 0,0       | 0,0       | 0,0       | 0,0       | 0,0                | 5/3,1          |
| <b>FP</b> | 0,0       | 150/99,4  | 0,0       | 1/0,6     | 0,0       | 0,0                | 0,0            |
| <b>MO</b> | 4/2,5     | 0,0       | 153/96,9  | 0,0       | 0,0       | 0,0                | 1/0,6          |
| <b>TR</b> | 0,0       | 0,0       | 0,0       | 152/96,2  | 0,0       | 0,0                | 6/3,8          |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 156/99,4  | 0,0                | 1/0,6          |

**TABELA 5.34:** Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Com reclassificação)*

*Com Duplicamento – Dados de Treinamento*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>PO</b> |
|-----------|-----------|-----------|-----------|-----------|-----------|
| <b>FF</b> | 158/98,8  | 0,0       | 0,0       | 0,0       | 2/1,2     |
| <b>FP</b> | 0,0       | 150/99,4  | 0         | 1/0,6     | 0,0       |
| <b>MO</b> | 5/3,1     | 0,0       | 153/96,9  | 0,0       | 0,0       |
| <b>TR</b> | 6/3,8     | 0,0       | 0,0       | 152/96,2  | 0,0       |
| <b>PO</b> | 0,0       | 0,0       | 1/0,6     | 0,0       | 156/99,4  |

**TABELA 5.35:** Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Sem reclassificação)*

*Com Duplicamento – Dados de Teste*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>PO</b> | <i>Mais de uma</i> | <i>Nenhuma</i> |
|-----------|-----------|-----------|-----------|-----------|-----------|--------------------|----------------|
| <b>FF</b> | 35/97,2   | 0,0       | 0,0       | 0,0       | 0,0       | 0,0                | 1/2,8          |
| <b>FP</b> | 0,0       | 43/95,6   | 0,0       | 2/4,4     | 0,0       | 0,0                | 0,0            |
| <b>MO</b> | 2/5,3     | 0,0       | 36/94,7   | 0,0       | 0,0       | 0,0                | 0,0            |
| <b>TR</b> | 0,0       | 0,0       | 0,0       | 37/97,4   | 0,0       | 0,0                | 1/2,6          |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 39/100    | 0,0                | 0,0            |

**TABELA 5.36:** Tabela de Confusão (%).

*Classificador Não-Linear e Não-Hierárquico (Com reclassificação)*

*Com Duplicamento – Dados de Teste*

|           | <b>FF</b> | <b>FP</b> | <b>MO</b> | <b>TR</b> | <b>PO</b> |
|-----------|-----------|-----------|-----------|-----------|-----------|
| <b>FF</b> | 35/97,2   | 0,0       | 0,0       | 0,0       | 1/2,8     |
| <b>FP</b> | 0,0       | 43/95,6   | 0,0       | 2/4,4     | 0,0       |
| <b>MO</b> | 2/5,3     | 0,0       | 36/94,7   | 0,0       | 0,0       |
| <b>TR</b> | 0,0       | 0,0       | 0,0       | 38/100    | 0,0       |
| <b>PO</b> | 0,0       | 0,0       | 0,0       | 0,0       | 39/100    |

Usando a técnica de *bootstrap* para gerar amostras de forma aleatória e com reposição, foram gerados 50 conjuntos de treinamento e 50 conjunto de teste respectivos para estimação da acurácia do classificador não-linear e não-hierárquico. A tabela 5.37 mostra os resultados obtidos para estes estimadores de acurácia. Com os 50 conjuntos formados, a estimação de acurácia empregando a equação (4.21) é de 76,0% sem reclassificação e 78,9% com reclassificação. Entretanto, observou-se que havia pares de treinamento e teste com resultados de acurácia extremamente diferentes, diferença acima de 15,0%. Portanto, provavelmente, estes conjuntos estariam em uma situação de supertreinamento dos dados, o que impossibilita sensivelmente a generalização do classificador [4]. Neste caso, considerou-se somente os pares de treinamento e teste cuja diferença de acurácia fosse menor do que 15,0%, resultando em um total de 20 pares. Para estes conjuntos, a acurácia estimada foi de 77,8% (SR) e 80,6% (R) com o estimador 0,632 [59]. Como o estimador 0,632 é considerado otimista, porque pondera de forma acentuada os resultados dos dados de treinamento [57], calculou-se também o estimador pela equação generalizada (4.22), ponderando os dados de teste com um fator de 0,7 e treinamento com 0,3 (tabela 5.37). O que, obviamente, provoca uma ligeira queda nos valores estimados de acurácia. Destacando que estes resultados são para conjuntos contendo as 6 classes de defeitos. Comparando estes resultados com os resultados obtidos por Liao [19], os índices de acurácia estão abaixo dos 92,0 % atingidos em seu trabalho. Porém, alguns aspectos devem ser destacados em relação ao seu trabalho:

- Liao [19] usou apenas 5 conjuntos de *bootstrap*, o que pode ser considerado um número pequeno, porque segundo Efron [59], se  $n \rightarrow \infty \Rightarrow E(\hat{\theta}) = \theta$ , embora Efron [59] relate que na prática entre 25 e 250 amostras é um número suficiente a ser utilizado no cálculo do erro padrão de um estimador [59, 60].
- Liao [19] usou apenas 12 amostras, de um total de 149 amostras contendo 6 classes de defeitos como conjunto de teste, o que é extremamente insuficiente para estimação da acurácia de uma classificador de padrão tão complexo. Embora tenha usado 27 amostras para validação, ele empregou um classificador não-linear com 48 neurônios na camada intermediária, o que pode ter provocado supertreinamento dos dados.

- Para considerar como acerto um dado de teste, Liao [19] trabalhou com uma margem de quase 50,0% de erro. Embora este texto em seu artigo não esteja muito compreensível [19].
- Liao[19], embora tenha trabalhado também com 6 classes, a distribuição de suas amostras continha classes como inclusão de hidrogênio e poro (*Gas hole*), que são classes de características mais específicas e mais fáceis de serem classificadas. Além disso, a classe falta de penetração continha apenas 4 amostras e falta de fusão 8 amostras.

De forma alguma, deseja-se subestimar os resultados do trabalho de Liao [19], que destaca-se de forma marcante entre os pesquisadores da área, mas pode-se afirmar que os resultados conseguidos neste trabalho estão mais próximos da verdadeira acurácia destes classificadores para a classificação das classes mais importantes e freqüentes em defeitos de soldagem, aonde índices de 92,0% de acerto para dados de testes podem ser considerados extremamente otimistas, principalmente quando partem de implementação de classificadores não-lineares com tão poucas amostras.

**TABELA 5.37:** Estimadores de Acurácia por *Bootstrap* para o Classificador Não-Linear e Não-Hierárquico com as 6 classes, cada classe com a sua população original de amostras.

| Conjuntos de Amostras | Critério de Classificação | <i>Bootstrap 0,632</i> $\hat{\theta}_B$ |      |      |       | <i>Bootstrap 0,700</i> $\hat{\theta}_B^*$ |      |      |       |
|-----------------------|---------------------------|-----------------------------------------|------|------|-------|-------------------------------------------|------|------|-------|
|                       |                           | Máx.                                    | Mín. | Méd. | Desv. | Máx.                                      | Mín. | Méd. | Desv. |
| 50                    | SR (%)                    | 81,4                                    | 64,6 | 76,0 | 3,5   | 80,4                                      | 62,5 | 74,9 | 3,9   |
|                       | R (%)                     | 83,9                                    | 69,0 | 78,9 | 3,0   | 83,2                                      | 67,1 | 77,8 | 3,3   |
| 20                    | SR (%)                    | 81,2                                    | 73,4 | 77,8 | 2,1   | 80,4                                      | 72,5 | 77,0 | 2,2   |
|                       | R (%)                     | 83,9                                    | 74,8 | 80,6 | 2,1   | 83,2                                      | 74,0 | 79,8 | 2,2   |

Calculou-se também os mesmos estimadores de acurácia para o conjunto contendo apenas 5 classes. Neste caso, chega-se a atingir 88,0% de acerto com critério de reclassificação para o estimador 0,632. Há de se destacar que todos estes estimadores foram calculados partindo-se do conjunto original de amostras sem duplicamento, embora cada conjunto de *bootstrap* possa conter amostras “duplicadas”.

**TABELA 5.38:** Estimadores de Acurácia por *Bootstrap* para o Classificador Não-Linear e Não-Hierárquico com as 5 classes, cada classe com a sua população original de amostras.

| Conjuntos de Amostras | Critério de Classificação | <i>Bootstrap 0,632</i> $\hat{\theta}_B$ |      |      |       | <i>Bootstrap 0,700</i> $\hat{\theta}_B^*$ |      |      |       |
|-----------------------|---------------------------|-----------------------------------------|------|------|-------|-------------------------------------------|------|------|-------|
|                       |                           | Máx.                                    | Mín. | Méd. | Desv. | Máx.                                      | Mín. | Méd. | Desv. |
| 20                    | SR (%)                    | 93,3                                    | 79,8 | 86,7 | 4,1   | 92,6                                      | 78,7 | 85,4 | 4,4   |
|                       | R (%)                     | 93,6                                    | 80,5 | 88,0 | 3,8   | 93,0                                      | 79,5 | 86,9 | 4,1   |

### 5.7.3. Classificador Não-Linear Hierárquico

Uma provável solução para aumentar os índices de acerto obtidos com o classificador não-linear seria a implementação de um classificador não-linear, mas em sistema de classificação hierárquica, conforme feito com os lineares. Alguns testes iniciais foram realizados e obteve-se índice de cerca de 83,0% de acerto para 6 classes com os dados de treinamento e, 85,0% para as 4 classes inicialmente estudadas no trabalho. Como são classificadores de implementação mais complexa que os não-hierárquicos, e não tendo resultado em índices maiores de acerto em um estudo preliminar, não se apresentará as tabelas de confusão para este classificador. Em trabalhos futuros, pretende-se estudar de maneira mais aprofundada estes tipos de classificadores para verificar se podem ser usados para aumentar os índices de acerto das classes mais “confusas”.

### 5.7.4. Seleção de Características e Redução de Dimensionalidade

Em reconhecimento de padrão, sabe-se que existe uma relação muito grande, e muitas vezes bastante complexa, entre o número de características utilizadas e o desempenho do classificador. Normalmente, conforme descreve Duda [48], espera-se que quanto maior o número de características, maior será o desempenho do classificador. Entretanto, na prática, isso nem sempre acontecerá, especialmente se existem características que contêm pouca informação relevante para a discriminação das classes de padrões existentes. Frequentemente, destaca Duda [48], a adição de novas

características traz mais problemas ao sistema de classificação do que um aumento de desempenho do classificador. Em relação à generalização e ao supertreinamento, em problemas que contenham poucas amostras, aumentar a dimensão dos dados certamente aumenta o risco de ocorrer supertreinamento e pouca generalização [48].

Com o primeiro conjunto de dados, após os estudos de relevância de características, chegou-se a conclusão que 3 ou 4 características poderiam ser usadas sem prejuízo do desempenho do classificador, descartando-se as características irrelevantes e correlatas às demais.

Neste novo conjunto de dados, adicionou-se três características que não haviam sido usadas, partindo-se do pressuposto que com a adição das classes TR e FF, provavelmente, seria necessário um número maior de características. As características adicionadas tinham comprovado relevância no trabalho de Carvalho [63].

Dando seguimento ao objetivo de usar o menor número de características possível e de fácil extração sem prejudicar sensivelmente o desempenho do classificador, os estudos de correlação linear e critério de relevância foram novamente aplicados aos dados atuais, para verificar a possibilidade de redução da quantidade de características utilizadas.

#### 5.7.4.1. *Matriz dos Coeficientes de Correlação Linear*

A tabela 5.39 contém os coeficientes de correlação obtidos com o conjunto atual de dados para um intervalo de confiança de 95,0%. Analisando a correlação das características entre si, observa-se que todas as características se mostraram correlacionadas (células hachuradas), pois todos os coeficientes se situam dentro dos limites do intervalo. Entre características e classes de defeitos, todos os coeficientes de correlação obtidos também estão dentro do intervalo de confiança, mostrando que a priori, há relevância destas características na discriminação das classes. Entretanto, a tabela 5.40 contém os mesmos coeficientes, mas os valores marcados são os que estão próximos ao limite  $2/\sqrt{N}$ , limite usado anteriormente [52]. Pela tabela 5.40, percebe-se que a característica ângulo é a única que não apresenta correlação às classes de defeitos, pois os coeficientes estão abaixo dos limites calculados por classe.

As características P, e/A, R e a novamente comprovam correlação com as classes, exceto a classe trinca (TR) que, pela tabela 5.40, mostra ter apenas a característica A/A<sub>r</sub> como correlata.

Uma maneira de estimar estes coeficientes de correlação é empregando amostras de *bootstrap* [59]. A tabela 5.41 mostra os coeficientes estimados para correlação entre características e classes, usando 200 replicações de amostras de *bootstrap*. Existe um questionamento quanto ao número exato de amostras que deve ser usado, mas escolheu-se 200 replicações aleatoriamente, porque um número maior de amostras aumenta consideravelmente o cálculo computacional [59]. A tabela mostra também os valores de máximo e mínimo obtidos para os coeficientes, assim como o desvio padrão calculado para um estimador não-viesado [59].

Pela tabela 5.41, constata-se que a característica ângulo novamente não apresenta correlação com as classes de defeitos, pois os valores dos coeficientes de correlação estimados estão todos abaixo dos limites  $2/\sqrt{N}$ .

A tabela 5.42 apresenta os valores estimados dos coeficientes de correlação entre características. Observa-se que excetuando a característica ângulo, todas as demais apresentam-se correlatas, pois os valores estimados de correlação excedem o limite de 0,08 ( $2/\sqrt{646}$ ).

Com base nestas tabelas, a primeira idéia que surgiu foi a exclusão de ângulo e verificação do desempenho dos classificadores como forma de comprovar a possibilidade de eliminação desta característica. Entretanto, faltava ainda verificar, sob o recurso do critério de relevância, a possibilidade de haver correlação não-linear desta características com as classes de defeitos estudadas, o que é descrito na seção 5.7.4.2 após a apresentação das tabelas 5.39 a 5.42.

**TABELA 5.39:** Matriz com os coeficientes de correlação. As células hachuradas correspondem aos valores que estão contidos dentro do intervalo de confiança de 95,0%.

|                                                                                                                                  | Ângulo  | A/Ar    | a       | R       | e/A     | P       | W/H     | FF      | FP      | MO      | TR      | IE      | PO      |
|----------------------------------------------------------------------------------------------------------------------------------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|
| <i>Valores dos Coeficientes de Correlação – Os valores das células hachuradas estão dentro do intervalo de confiança de 95%.</i> |         |         |         |         |         |         |         |         |         |         |         |         |         |
| Ângulo                                                                                                                           | 1       | -0,07   | -0,0112 | -0,0034 | 0,00458 | -0,0468 | -0,0216 | -0,0069 | -0,0021 | -0,0634 | 0,122   | 0,00791 | 0,00654 |
| A/Ar                                                                                                                             | -0,07   | 1       | -0,5178 | -0,5914 | 0,48014 | 0,08695 | -0,4917 | -0,2724 | -0,2566 | -0,0817 | -0,4258 | 0,10988 | 0,49024 |
| a                                                                                                                                | -0,0112 | -0,5178 | 1       | 0,95203 | -0,2447 | -0,1994 | 0,86829 | 0,20221 | 0,45529 | -0,1063 | 0,09188 | -0,1501 | -0,2065 |
| R                                                                                                                                | -0,0034 | -0,5914 | 0,95203 | 1       | -0,2531 | -0,2067 | 0,85496 | 0,20693 | 0,41545 | -0,11   | 0,20098 | -0,1597 | -0,2203 |
| e/A                                                                                                                              | 0,00458 | 0,48014 | -0,2447 | -0,2531 | 1       | -0,1602 | -0,3049 | -0,2122 | -0,2414 | -0,383  | -0,1317 | -0,0565 | 0,75478 |
| P                                                                                                                                | -0,0468 | 0,08695 | -0,1994 | -0,2067 | -0,1602 | 1       | -0,1864 | -0,03   | -0,435  | 0,77629 | -0,2261 | -0,2526 | -0,1414 |
| W/H                                                                                                                              | -0,0216 | -0,4917 | 0,86829 | 0,85496 | -0,3049 | -0,1864 | 1       | 0,26895 | 0,47326 | -0,0873 | 0,12429 | -0,1867 | -0,2581 |

**TABELA 5.40:** Tabela com a matriz dos coeficientes de correlação. As células hachuradas contêm os valores próximos ao limite de  $2/\sqrt{N}$ .

|                            | Ângulo  | A/Ar    | a       | R       | e/A     | P       | W/H     | FF          | FP          | MO          | TR          | IE          | PO          |
|----------------------------|---------|---------|---------|---------|---------|---------|---------|-------------|-------------|-------------|-------------|-------------|-------------|
| <b>0,08 (646 amostras)</b> |         |         |         |         |         |         |         | <b>0,26</b> | <b>0,26</b> | <b>0,15</b> | <b>0,38</b> | <b>0,17</b> | <b>0,14</b> |
| Ângulo                     | 1       | -0,07   | -0,0112 | -0,0034 | 0,00458 | -0,0468 | -0,0216 | -0,0069     | -0,0021     | -0,0634     | 0,122       | 0,00791     | 0,00654     |
| A/Ar                       | -0,07   | 1       | -0,5178 | -0,5914 | 0,48014 | 0,08695 | -0,4917 | -0,2724     | -0,2566     | -0,0817     | -0,4258     | 0,10988     | 0,49024     |
| a                          | -0,0112 | -0,5178 | 1       | 0,95203 | -0,2447 | -0,1994 | 0,86829 | 0,20221     | 0,45529     | -0,1063     | 0,09188     | -0,1501     | -0,2065     |
| R                          | -0,0034 | -0,5914 | 0,95203 | 1       | -0,2531 | -0,2067 | 0,85496 | 0,20693     | 0,41545     | -0,11       | 0,20098     | -0,1597     | -0,2203     |
| e/A                        | 0,00458 | 0,48014 | -0,2447 | -0,2531 | 1       | -0,1602 | -0,3049 | -0,2122     | -0,2414     | -0,383      | -0,1317     | -0,0565     | 0,75478     |
| P                          | -0,0468 | 0,08695 | -0,1994 | -0,2067 | -0,1602 | 1       | -0,1864 | -0,03       | -0,435      | 0,77629     | -0,2261     | -0,2526     | -0,1414     |
| W/H                        | -0,0216 | -0,4917 | 0,86829 | 0,85496 | -0,3049 | -0,1864 | 1       | 0,26895     | 0,47326     | -0,0873     | 0,12429     | -0,1867     | -0,2581     |

**TABELA 5.41:** Correlações entre características/classes para 200 amostras de *bootstrap*.

| <b>Correlação<br/>Característica/Classe</b> | <b><math>2/\sqrt{N}</math></b> | <b>Correlação para 200 Amostras de Bootstrap</b> |               |               |               |
|---------------------------------------------|--------------------------------|--------------------------------------------------|---------------|---------------|---------------|
|                                             |                                | <b>Média</b>                                     | <b>Desvio</b> | <b>Máximo</b> | <b>Mínimo</b> |
| <b>Ângulo-FF</b>                            | <b>0,26</b>                    | -0,0068                                          | 0,0131        | 0,0315        | -0,0399       |
| <b>A/A<sub>r</sub>-FF</b>                   |                                | -0,2744                                          | 0,0403        | -0,1457       | -0,3794       |
| <b>a-FF</b>                                 |                                | 0,2037                                           | 0,0561        | 0,4039        | 0,0648        |
| <b>R-FF</b>                                 |                                | 0,2080                                           | 0,0548        | 0,3813        | 0,0632        |
| <b>e/A-FF</b>                               |                                | -0,2123                                          | 0,0232        | -0,1641       | -0,2781       |
| <b>P-FF</b>                                 |                                | -0,0265                                          | 0,0194        | 0,0271        | -0,0763       |
| <b>W/H-FF</b>                               |                                | 0,2705                                           | 0,0532        | 0,4259        | 0,1343        |
| <b>Ângulo-FP</b>                            | <b>0,26</b>                    | -0,0029                                          | 0,0320        | 0,0964        | -0,0814       |
| <b>A/A<sub>r</sub>-FP</b>                   |                                | -0,2571                                          | 0,0431        | -0,1457       | -0,3668       |
| <b>a-FP</b>                                 |                                | 0,4548                                           | 0,0466        | 0,572         | 0,3180        |
| <b>R-FP</b>                                 |                                | 0,4126                                           | 0,0525        | 0,5430        | 0,2723        |
| <b>e/A-FP</b>                               |                                | -0,2446                                          | 0,0169        | -0,1969       | -0,3014       |
| <b>P-FP</b>                                 |                                | -0,4367                                          | 0,6066        | 0,8137        | -0,5082       |
| <b>W/H-FP</b>                               |                                | 0,4725                                           | 0,0478        | 0,5794        | 0,3472        |
| <b>Ângulo-MO</b>                            | <b>0,15</b>                    | -0,0638                                          | 0,0294        | 0,0245        | -0,1468       |
| <b>A/A<sub>r</sub>-MO</b>                   |                                | -0,0809                                          | 0,0371        | -0,0031       | -0,1943       |
| <b>a-MO</b>                                 |                                | -0,1047                                          | 0,0165        | -0,0565       | -0,1506       |
| <b>R-MO</b>                                 |                                | -0,1085                                          | 0,0166        | 0,3499        | -0,1509       |
| <b>e/A-MO</b>                               |                                | -0,3819                                          | 0,0191        | -0,334        | -0,4349       |
| <b>P-MO</b>                                 |                                | 0,7743                                           | 0,0149        | 0,8136        | 0,7245        |
| <b>W/H-MO</b>                               |                                | -0,0846                                          | 0,1106        | 0,2764        | -0,1376       |
| <b>Ângulo-TR</b>                            | <b>0,38</b>                    | 0,1233                                           | 0,0531        | 0,2827        | -0,0466       |
| <b>A/A<sub>r</sub>-TR</b>                   |                                | -0,4247                                          | 0,0416        | -0,3086       | -0,5191       |
| <b>a-TR</b>                                 |                                | 0,0919                                           | 0,0298        | 0,1808        | 0,0275        |
| <b>R-TR</b>                                 |                                | 0,2034                                           | 0,0519        | 0,3499        | 0,0945        |
| <b>e/A-TR</b>                               |                                | -0,1319                                          | 0,0186        | 0,0336        | -0,17037      |
| <b>P-TR</b>                                 |                                | -0,2257                                          | 0,0268        | -0,1545       | -0,3059       |
| <b>W/H-TR</b>                               |                                | 0,1257                                           | 0,0427        | 0,2764        | 0,0192        |
| <b>Ângulo-IE</b>                            | <b>0,17</b>                    | 0,0080                                           | 0,0412        | 0,1291        | -0,0999       |
| <b>A/A<sub>r</sub>-IE</b>                   |                                | 0,1111                                           | 0,0278        | 0,2016        | 0,0149        |
| <b>a-IE</b>                                 |                                | -0,1514                                          | 0,0125        | -0,1210       | -0,1809       |
| <b>R-IE</b>                                 |                                | -0,1608                                          | 0,0111        | -0,1322       | -0,1894       |
| <b>e/A-IE</b>                               |                                | -0,0595                                          | 0,0248        | 0,0337        | -0,1345       |
| <b>P-IE</b>                                 |                                | -0,2481                                          | 0,0271        | -0,0552       | -0,3183       |
| <b>W/H-IE</b>                               |                                | -0,1886                                          | 0,0133        | -0,1546       | -0,2243       |
| <b>Ângulo-PO</b>                            | <b>0,14</b>                    | 0,0063                                           | 0,0477        | 0,1379        | -0,1188       |
| <b>A/A<sub>r</sub>-PO</b>                   |                                | 0,4908                                           | 0,0218        | 0,5516        | 0,4339        |
| <b>a-PO</b>                                 |                                | -0,2090                                          | 0,0177        | -0,1612       | -0,2543       |
| <b>R-PO</b>                                 |                                | -0,2225                                          | 0,0149        | -0,1738       | -0,2669       |
| <b>e/A-PO</b>                               |                                | 0,7587                                           | 0,0154        | 0,7996        | 0,7141        |
| <b>P-PO</b>                                 |                                | -0,1387                                          | 0,0324        | -0,0552       | -0,2130       |
| <b>W/H-PO</b>                               |                                | -0,2621                                          | 0,0175        | -0,2224       | -0,3113       |

**TABELA 5.42:** Valores de correlações entre as características encontrados para as 200 amostras de *bootstrap*.

| Correlação entre as Características | Valor Limite 0,08 |        |         |         |
|-------------------------------------|-------------------|--------|---------|---------|
|                                     | Média             | Desvio | Máximo  | Mínimo  |
| $\hat{\text{Ângulo}} - A/A_r$       | -0,0717           | 0,0427 | 0,0423  | -0,1667 |
| $\hat{\text{Ângulo}} - a$           | -0,0113           | 0,0121 | 0,0187  | -0,0433 |
| $\hat{\text{Ângulo}} - R$           | -0,0032           | 0,0125 | 0,0297  | -0,0341 |
| $\hat{\text{Ângulo}} - e/A$         | 0,0093            | 0,0462 | 0,1414  | -0,1287 |
| $\hat{\text{Ângulo}} - P$           | -0,0447           | 0,0333 | 0,0305  | -0,1377 |
| $\hat{\text{Ângulo}} - W/H$         | -0,0218           | 0,0167 | 0,0205  | -0,0615 |
| $A/A_r - a$                         | -0,5237           | 0,0327 | -0,4165 | -0,6168 |
| $A/A_r - R$                         | -0,5968           | 0,0265 | -0,5191 | -0,6824 |
| $A/A_r - e/A$                       | 0,4825            | 0,1999 | 0,5378  | 0,4370  |
| $A/A_r - P$                         | 0,0888            | 0,0427 | 0,1956  | -0,0074 |
| $A/A_r - W/H$                       | -0,5090           | 0,0363 | -0,4106 | -0,6028 |
| $a - R$                             | 0,9518            | 0,0183 | 0,9870  | 0,8902  |
| $a - e/A$                           | -0,2481           | 0,0188 | -0,2045 | -0,2992 |
| $a - P$                             | -0,1991           | 0,5384 | 0,9595  | -0,2698 |
| $a - W/H$                           | 0,8734            | 0,0479 | 0,9595  | 0,7553  |
| $R - e/A$                           | -0,2557           | 0,0156 | -0,2150 | -0,2953 |
| $R - P$                             | -0,2064           | 0,0291 | -0,1291 | -0,2735 |
| $R - W/H$                           | 0,8587            | 0,3300 | 0,9478  | 0,7589  |
| $e/A - P$                           | -0,1558           | 0,0327 | -0,0720 | -0,2285 |
| $e/A - W/H$                         | -0,3099           | 0,0179 | -0,2712 | -0,3513 |
| $P - W/H$                           | -0,1855           | 0,0348 | -0,1017 | -0,2641 |

#### 5.7.4.2. Critério de Relevância

Os valores encontrados para o critério de relevância usando um classificador não-linear são mostrados na tabela 5.43. Relembrando, neste tipo de avaliação de relevância não há um valor limite para que uma característica seja considerada importante na discriminação de uma classe, o critério é apenas comparativo. Analisando a tabela, constatou-se que, ângulo possui valores baixos de relevância quando comparados aos valores obtidos para as demais características. Embora para TR, IE e PO os valores tenham sido similares aos obtidos com W/H.

**TABELA 5.43:** Critério de relevância usando um classificador não-linear.

|               | FF    | FP     | MO    | TR    | IE    | PO    |
|---------------|-------|--------|-------|-------|-------|-------|
| <b>Ângulo</b> | 0,003 | 0,082  | 0,020 | 0,112 | 0,100 | 0,110 |
| <b>A/Ar</b>   | 0,056 | 0,0166 | 0,116 | 0,180 | 0,033 | 0,201 |
| <b>a</b>      | 0,105 | 0,106  | 0,160 | 0,128 | 0,094 | 0,159 |
| <b>R</b>      | 0,080 | 0,116  | 0,066 | 0,200 | 0,125 | 0,255 |
| <b>e/A</b>    | 0,047 | 0,111  | 0,055 | 0,036 | 0,139 | 0,443 |
| <b>P</b>      | 0,157 | 0,365  | 0,477 | 0,175 | 0,065 | 0,115 |
| <b>W/H</b>    | 0,117 | 0,116  | 0,109 | 0,121 | 0,118 | 0,116 |

#### 5.7.4.3. Redução da Dimensionalidade

Com base nas análises de relevância das características, visando reduzir o número de características utilizadas, o primeiro passo foi a retirada de ângulo do conjunto de dados para fazer um teste de desempenho com o classificador não-linear. Como forma de acelerar esta avaliação, senão haveria necessidade de exclusão de ângulo dos 80 de conjuntos utilizados ao todo para 5 e 6 classes, escolheu-se os conjuntos de teste, e correspondente conjuntos de treinamento, que tinham resultado em maior índice de acurácia para 5 e 6 classes – os valores máximos da tabela 5.20. A tabela 5.44 mostra os índices de acertos atingidos usando apenas as 6 características sem a presença de ângulo. Para 6 classes, células hachuradas, os índices de acerto com os dados de teste foram maiores que os obtidos com a presença de ângulo, tanto para os conjuntos sem duplicamento de amostras, quanto para os conjuntos com amostras duplicadas. Para 5 classes, os índices de acerto em teste foram um pouco inferiores aos índices de acerto com todas as características, resultando em uma diferença na faixa de

3,0-4,0%, sendo que para os dados de treinamento, essa diferença foi ainda menor. Embora esta avaliação tenha sido feita apenas com um conjunto, isto prova que a exclusão de ângulos dos vetores de entrada não provoca redução acentuada dos índices de acerto para 5 classes, e para 6 classes sua utilização é ainda mais irrelevante.

Como seguimento dos estudos e avaliações com este conjunto de dados, pretende-se repetir o procedimento de criação de conjuntos aleatórios de treinamento e teste, partindo de um conjunto de amostras não contendo ângulo, para comprovar mais seguramente a possibilidade do descarte desta característica.

**TABELA 5.44:** Tabela de Acurácia do Classificador NL e NH Usando 6 Características (Sem Ângulo). Valores Numéricos e Percentuais.

|           | Conjuntos        | Treinamento |           | Teste     |           |
|-----------|------------------|-------------|-----------|-----------|-----------|
|           |                  | SR          | R         | SR        | R         |
| 5 Classes | Sem Duplicamento | 394/96,6%   | 395/96,8% | 90/89,1%  | 91/90,1%  |
|           | Com Duplicamento | 756/96,4%   | 757/96,6% | 182/92,9% | 183/93,4% |
| 6 Classes | Sem Duplicamento | 439/84,9%   | 449/86,8% | 103/79,8% | 107/82,9% |
|           | Com Duplicamento | 803/85,3%   | 826/87,8% | 205/87,2% | 207/88,1% |

Uma outra forma de redução de dimensionalidade dos dados de entrada em reconhecimento de padrões é usando as componentes principais de discriminação (CPD) ou da sigla em inglês MDA (*Multiple Discriminant Analysis*) [48]. Mais uma vez, calculou-se as componentes principais independentes de discriminação não-linear para os dados atuais. A tabela 5.45 mostra os índices de acerto - neste caso seriam as acurácias aparentes [57], porque os classificadores foram testados com os próprios dados de treinamento. Com 4 componentes atingiu-se cerca de 95,0% de acerto para 5 classes, e 85,0% para 6 classes, valores similares aos atingidos usando as 7 características correlatas dos dados originais duplicados. Embora não tenha sido feita avaliação com conjuntos de teste - o que certamente será realizado em trabalhos futuros - estes resultados comprovam que é possível se reduzir a dimensão do conjunto de dados substituindo as características originais por componentes principais de discriminação não-correlatas.

**TABELA 5.45:** Tabela de Acurácia Aparente do Classificador NL e NH Usando como Entradas as CPDNL Independentes.

|                  | CPDNL Independentes                                                  | Sem Reclassificação(%) | Reclassificação(%) |
|------------------|----------------------------------------------------------------------|------------------------|--------------------|
| <b>5 Classes</b> | <b>P<sub>1</sub></b>                                                 | 67,0                   | 69,5               |
|                  | <b>P<sub>1</sub> + P<sub>2</sub></b>                                 | 88,7                   | 89,5               |
|                  | <b>P<sub>1</sub> + P<sub>2</sub> + P<sub>3</sub></b>                 | 90,7                   | 92,8               |
|                  | <b>P<sub>1</sub> + P<sub>2</sub> + P<sub>3</sub> + P<sub>4</sub></b> | 95,2                   | 95,8               |
| <b>6 Classes</b> | <b>P<sub>1</sub></b>                                                 | 46,7                   | 55,6               |
|                  | <b>P<sub>1</sub> + P<sub>2</sub></b>                                 | 66,2                   | 71,6               |
|                  | <b>P<sub>1</sub> + P<sub>2</sub> + P<sub>3</sub></b>                 | 82,0                   | 84,0               |
|                  | <b>P<sub>1</sub> + P<sub>2</sub> + P<sub>3</sub> + P<sub>4</sub></b> | 82,9                   | 85,1               |

### 5.8. Discussões Gerais e Artigos Publicados

Com o conjunto inicial de dados, foi possível implementar praticamente todos os algoritmos dos classificadores e critérios de relevância de características, muitos resultados foram obtidos e muitas discussões geradas, servindo de base para interpretação e experiência com as metodologias que foram empregadas. Embora seja um conjunto reduzido de amostras, sua dimensão de amostras é similar à utilizada em conjuntos de trabalhos de outros autores, muitos deles renomados neste área de pesquisa, como o trabalho de Liao [19] que foi tão citado. Com este conjunto, um artigo foi publicado primeiramente na revista *Insight* em 2001 e ganhou o prêmio *The Ron Halmshaw Award* de melhor artigo na área de radiografia e radiologia do ano de 2001 desta revista [64] (apêndice). Posteriormente, um segundo artigo foi publicado na revista *Insight* em 2002 [65] (apêndice), contendo os resultados sobre correlação de características, critério de relevância e probabilidade de acerto de classificação. Parte destes resultados foi apresentada também na 8<sup>th</sup> Conferência Européia de Ensaios Não-Destrutivos (Barcelona) [66]. A partir dos resultados obtidos com os classificadores não-lineares e CPDNL, um artigo foi apresentado na 3<sup>rd</sup> Conferência Pan-americana de Ensaios Não-Destrutivos (Rio de Janeiro) [67], sendo também submetido à revista *NDT&E Internacional* e aceito para publicação (apêndice).

Em um trabalho de colaboração com Mery, no qual parte das metodologias usadas na tese foram implementadas para o seu conjunto de dados, que são referentes ao reconhecimento de defeitos em rodas fundidas de automóveis, publicou-se um terceiro artigo na revista *Insight* em 2003 [61] (apêndice).

Em relação ao segundo conjunto de dados, conseguido somente há poucos dias após um grande esforço de coletânea de padrões, os resultados foram satisfatórios e provam que é possível usar características geométricas dos defeitos, não necessariamente em número elevado, para classificar as principais classes de defeitos de soldagem. Fica claro, entretanto, que muito ainda pode ser feito não somente com os dados atuais, como também na formação de um terceiro conjunto que possa ter mais amostras, principalmente das classes trinca, falta de penetração e falta de fusão. Em relação à classe IE, que mostrou ser a mais problemática em termos de classificação, uma solução futura pode ser o acréscimo de novas características que possam ser mais relevantes na sua discriminação, especialmente em relação à PO. Outra solução, mantendo-se a linha de pensamento de usar o menor número possível de características, pode-se subdividi-la em subclasses de forma que a discriminação possa ser feita com as características já usadas.

Não existe, até o presente momento, um sistema de análise automática ou semi-automática de defeitos de soldagem, como bem destaca Liao [19], os esforços são grandes neste sentido e, certamente, muito ainda terá que ser pesquisado e estudado para o seu desenvolvimento, mas as metodologias usadas neste trabalho, assim como as discutidas no capítulo 2, são “ferramentas” que comprovadamente poderão ser usadas na implementação final deste sistema.

## CAPÍTULO 6 – CONCLUSÕES E TRABALHOS FUTUROS

---

A partir do desenvolvimento e do estudo de classificadores de padrões de defeitos de soldagem, implementados por redes neurais artificiais e usando características geométricas dos defeitos, pôde-se chegar as seguintes conclusões principais:

- Existem classes de defeitos de soldagem, como mordedura (MO) e falta de penetração (FP), que podem ser classificadas com um classificador linear, quando utiliza-se características geométricas relevantes, o que facilita o processo de classificação, por serem classificadores de implementação e solução mais simples. Neste tipo de classificador, o processo de hierarquia permitiu a obtenção de resultados melhores.
- Defeitos mais difíceis de serem classificados, como porosidade, falta de fusão, trinca e principalmente, inclusão de escória, requerem classificadores não-lineares para serem discriminados com melhor desempenho.
- Em termos de classificação não-linear, a estimação da acurácia verdadeira usando métodos de amostragem aleatória, mesmo os mais simples, resulta em estimadores satisfatórios considerando a complexidade de separação de algumas classes, e o número reduzido de amostras que normalmente está disponível. A metodologia proposta de estimação com sorteio aleatória de 10 pares de conjuntos é nova nesta área, embora tão amplamente divulgada em outros campos de pesquisa há bastante tempo. A técnica de *bootstrap* é uma solução de fácil implementação e pode ser usada de forma eficiente na estimação da acurácia verdadeira de um classificador. Embora já tivesse sido usada por outro autor [19], a quantidade de amostras usadas neste trabalho é consideravelmente mais significativa.
- As avaliações de relevância de características usando tanto os coeficientes de correlação, ou o critério empregando os classificadores implementados por redes neurais, comprovaram ser eficientes no estudo de determinação preliminar de qual

característica poderá ser excluída no conjunto de dados. Estes tipos de técnicas ainda não haviam sido usadas em reconhecimento de padrões de defeitos de soldagem.

- Em termos de características relevantes, fica comprovado que o importante é a “qualidade” da característica a ser usada, e não a quantidade de características utilizadas. Isto foi provado não somente com os dados usados na tese, como também em trabalhos de colaboração com outros pesquisadores [62].
- As componentes principais de discriminação, sejam elas lineares ou não-lineares, podem ser usadas com eficiência na visualização em duas dimensões do problema de separação de classes de padrões de defeitos. Além de poderem ser usadas como componentes não-correlatas de entrada dos classificadores, substituindo as características originais, normalmente correlatas entre si.
- Destaca-se, entretanto, que existe ainda muito a se fazer em termos de classificação de padrões de defeitos de soldagem, para se alcançar o desenvolvimento final do sistema automático ou semi-automáticos de interpretação de radiografias, mas as metodologias empregadas neste trabalho, assim como as discutidas nas referências bibliográficas, são “ferramentas” promissoras na realização deste sistema.

Em termos de seguimento a esse trabalho, especificamente com o segundo conjunto de dados, algumas sugestões podem ser colocadas:

- Quanto à estimação da acurácia dos classificadores: outras metodologias como as de validação-cruzada do tipo *leave one out*, ou até mesmo a separação dos conjuntos de treinamento e teste a partir de treinamento não-supervisionado prévio, podem ser usadas futuramente.
- Os estimadores de acurácia de cada classe podem ser calculados usando os resultados de cada conjunto de treinamento e teste separadamente.
- Outros testes com os classificadores podem ser feitos para verificar a possibilidade de exclusão de mais alguma característica além de ângulo.
- Para solucionar o desempenho ainda não satisfatório para a classificação de inclusão de escória, duas soluções pode ser empregadas: subdivisão da classe em classes mais fáceis de separação, ou o acréscimo de outra característica relevante para sua discriminação.

## CAPÍTULO 7 - REFERÊNCIAS BIBLIOGRÁFICAS

---

- [1] HALMSHAW, R., *Industrial Radiography*, Agfa-Gevaert N.V., Mortsel, Belgium.
- [2] FUCSOK, F., SCHARMACH, M., “Human Factors: The NDE Realibility of Routine Radiographic Film Evaluation”. *15<sup>th</sup> World Conference on Non-Destructive Testing*, Rome, October 15-21 2000.
- [3] FUCSOK, F., MULLER, C., SCHARMACH, M., “Reliability of Routine Radiographic Film Evaluation – An Extended ROC Study of the Human Factor”. In: *8<sup>th</sup> European Conference on Non Destructive Testing*, Barcelona, June 17-21 2002.
- [4] HAYKIN, S., *Redes Neurais – Princípios e Prática*, 2 ed., Porto Alegre, Bookman, 2001.
- [5] KEHOE, A., PARKER, G.A., “Image Processing for Industrial Radiographic Inspection: Image Enhancement”, *British Journal of NDT*, v. 32, n.4., pp.183-190, April 1990.
- [6 ] MORE, J. D., GUIMARÃES, A. S., XEXÉO, G. B., “Modelo Fuzzy para Avaliação da Confiabilidade Humana do Inspetor de Ensaio Não-Destrutivo Tipo Ultra-Som”. In: *3<sup>rd</sup> Pan-American Conference for Nondestructive Testing (PANNDT)*, pp. 1-8, Rio de Janeiro, 2-5 June 2003.
- [7] RUSS, J.C., *The Image Processing Handbook*, CRC Press, 2<sup>nd</sup> edition, 1995.
- [8] CASTLEMAN, K.R., *Digital Image Processing*, New Jersey, Prentice-Hall, 1996.
- [9] GONZALEZ, R.C., WOODS, R. E., *Digital Image Processing*, 1<sup>a</sup> edição, U.S.A, Addison-Wesley Publishing Company, 1992.

[10] SILVA, R.R., *Processamento de Imagens Radiográficas de Análise de Defeitos em Cordão-de-Solda*. Tese de M.Sc., PEMM/COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, Abril 1999.

[11] ASME V, ARTIGO III, MANDATORY APPENDIX, appendix II, *Digital Image Acquisition, Display, and Storage for Radiography and Radioscopy*, pp. 71-72.

[12] AOKI, K., SUGA, Y., “Intelligent Image Processing for Abstraction and Discrimination of Defect Image in Radiographic Film”. In: *Proceeding of the Seventh International Offshore and Polar Engineering Conference*, Honolulu, USA, pp. 527-531, 25-30 May 1997.

[13] SUGA, Y., KOJIMA, K., TOMINAGA, T., “Detection of Weld Defects by Computer- Aided X-Ray Radiography Image Processing”, In : *International Journal of Offshore and Polar Engineering*, v. 5, n.2, pp. 142-146 June 1995.

[14] MURAKAMI, K., “Image Processing for Non-destructive Testing”, *Welding International*, v.4, n.2, pp.144-149, 1998.

[15] [www.agfa.com](http://www.agfa.com)

[16] [www.limisys.com](http://www.limisys.com)

[17] CHERFA, Y., KABIR, Y., DRAI, R., “X-Rays Image Segmentation for NDT of Welding Defects”. In: *Proceeding of the 7<sup>th</sup> congress European Conference On Nondestructive Testing*, Copenhagen, May 26-29 1998.

[18] LIAO, T.W., 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.

[19] WANG, G, LIAO, T. W., “Automatic Identification of Different Types of Welding Defects in Radiographic Images”, *NDT&E International*, v.35, pp.519-528, 2002.

- [20] JACOBSEN, C., ZSCHERPEL, U., NOCKEMANN, C., “Crack Detection in Digitized Radiographs with Neuronal Methods”. In: *7<sup>th</sup> European Conference on Non-Destructive Testing*, pp. 2717-2724, Copenhagen, May 26-29 1998.
- [21] AOKI, K., SUGA, Y., “Application of Artificial Neural Network to Discrimination of Defect Type Automatic Radiographic Testing of Welds”. In: *ISIJ International*, v. 39, n.10, pp.1081-1087, 1999.
- [22] MAKLASHEVSKY, V.Y., FILINOV, V.N., FILINOV, M.V., “Digital Processing of Roentgenographic and X-ray Television Image in Aerospace Radiographic testing”. In: *7<sup>th</sup> European Conference on Non Destructive Testing*, pp. 326-333, Copenhagen, 26-29 May 1998.
- [23] LIAO, T.W., NI, J., “An Automated Radiographic NDT System for Weld Inspection: Part II – Flaw Detection”, *NDT&E International*, v. 31, n.3, pp.183-192, 1998.
- [24] MERENYI, R., HELLER, W.G., “Video Data Enhancement for Nondestructive Evaluation”. In: *Review of Progress in Quantitative Nondestructive Evaluation*, v.7, Plenum Press, pp.705-712, 1988.
- [25] MERY, D., FILBERT, D., “Automated Flaw Detection in Aluminium Casting Based on the Tracking of Potential Defects in a Radioscopic Image Sequence”. In: *IEEE Transactions on Robotic and Automation*, vol. 20, December 21 2002.
- [26] “Analyzing and Enhancing Images”. *Image Processing Toolbox for Use with MATLAB – User’s Guide Version 4*. Chapter 10, USA, The MathWorks, 2003.
- [27] MERY, D., BERTI, M.A., “Automatic Detection of Welding Defects Using Textures Features”. In: *International Symposium on Computed Tomography Processing for Industrial Radiology*, pp. 1-10, Berlin, 23-25 June 2003.

- [28] PADUA G. X., SILVA. R.R., REBELLO, J.M.A., CALOBÂ, L.P. Extração do Cordão-de-Solda e Detecção de Defeitos em Radiografias Usando Redes Neurais. In: *3<sup>rd</sup> Panamerican Conference for Nondestructive Testing (PANNDT)*, pp. 1-8, Rio de Janeiro, 2-5 June 2003.
- [29] LI, D., LIAO, T.W., “Applications of Fuzzy K-NN in Weld Recognition and Tool Failure Monitoring”. In: *Proceedings of the Annual Southeastern Symposium on System Theory*, IEEE, pp.222-226, 1996.
- [30] LIAO, W., TANG, K., “Automated Extraction of Welds from Digitized Radiographic Images Based on MLP Neural Networks”, *Applied Artificial Intelligence*, v.11, n.13, p.197-218, April-May 1997.
- [31] LASHKIA, V., “Defect detection in X-ray images using fuzzy reasoning”, *Image and Vision Computing*, n.19, pp.261-269, 2001.
- [32] NAFAAÂ, N., REDOUANE, D., “Weld Defect Extraction and Classification in Radiographic Testing Based Artificial Neural Networks”, In: *15<sup>o</sup> WCNDT*, Roma, 2000.
- [33] JACOBSEN, C., ZSCHERPEL, U., PERNER, P., “A comparison between Neural Networks and Decision Trees”, In: *Institute of Computer Vision and Applied Computer Sciences*, Leipzig, Germany.
- [34] KATO Y., OKUMURA, T., AND MATSUI, S. et al, “Development of an Automatic Weld Defect Identification System for Radiographic Testing”, *Welding in the Word*, v. 30, n.7/8, pp.182-188, 1992.
- [35] YUE, L., XIAOHONG, L., DAHAU, R. et al, “Computer Vision Application for Weld Defect Detection and Evaluation”, In: *Proceeding of the 1998 Conference on Automated Optical Engineering*, v.3558, pp.354, Bellingham, WA, USA, 1998.

- [36] WEN, K.L., LIANG, L.J., SHING, C. S., “Computer Aided X-ray Radiographic Image Processing Inspection for Welding”. In: *Proceedings of the Third International Offshore and Polar Engineering Conference*, pp.462-466, Singapore, June 6-11, 1993.
- [37] LIAO, T.W., “Classification of Welding Flaw Types With Fuzzy Expert Systems”, *Expert Systems With Applications*, pp. 101-111, 2003.
- [38] LIAO, T.W., LI, D. AND LI, Y., “Extraction of Welds from Radiographic Images using Fuzzy Classifiers”, *Information Sciences*, v.126, pp. 21-40, 2000.
- [39] LIAO, T. W., LI, D., LI, Y., “Detection of Welding Flaws from Radiographic Images with Fuzzy Clustering Methods”, *Fuzzy sets and Systems*, v.108, pp. 145-158, 1999.
- [40] JUST, T., THALE, W., CHAUSEN, R., “Interpretation of Radiographs by Digital Image Processing”. In: *7<sup>th</sup> European Conference on Non Destructive Testing*, pp. 1325-1331, Copenhagen, 26-29 May 1998.
- [41] JAGANNATHAN, N., BHASKAR, P., SRIRAMAN, C.N., “A Step Towards Automatic Defect Pattern Analysis and Evaluation in Industrial Radiography using Digital Image Processing”. In: *15<sup>th</sup> World Conference on Non-Destructive Testing*, Rome, October 15-21 2000.
- [42] JAGANNATHAN, S., “Automatic Inspection of Wave Soldered Joints Using Neural Networks”, *Journal of Manufacturing Systems*, v. 16, n.6, pp.389-398, 1997.
- [43] SANKARAN, V., CHARTRAND, B. and MILLARD D. et al., “Automated Inspection of Solder Joints-A neural Network Approach”, *European Journal Mechanical Engineering* , v. 43, n.3, pp.129-153.
- [44] ZHANG, Z., BASART, P., “Feature Extraction and Classification in Automated Inspection of NDE Images”, *Review of Progress in Quantitative Nondestructive Evaluation*, v.14, pp.741-746, 1995.

[45] WASSERMAN, P.D., *Neural Computing Theory and Practice*, New York, Van Nostrand Reinhold, 1989.

[46] BISHOP, C.M., *Neural Networks for Pattern Recognition*, New York, Oxford University Press, 1995.

[47] HERTZ J., KROGH A. AND PALMER R.G., *Introduction to the Theory of Neural*, USA, Addison Wesley, 1991.

[48] DUDA, R.O., HART, P.E., STORK, D.G., *Pattern Classification*, 2<sup>nd</sup> edition, U.S.A., John Wiley & Sons, 2001.

[49] FUKUNAGA, K., *Introduction to Statistical Pattern Recognition*, 2<sup>nd</sup> edition, U.S.A., Academic Press, 1990.

[50] BHAKTA, R. N., *Radiographic Patterns*, Indian Society of Nondestructive Testing, Kodak Copyright, 2000.

[51] BEALE, M., “Backpropagation”, *Neural Network Toolbox for Use with Matlab User’s Guide Version 4*, The MathWorks, 2001.

[52] CHATFIELD, C., *The Analysis of Time Series – An Introduction*, USA, Chapman and Hall, 4<sup>th</sup> edition, 1989.

[53] SPIEGEL, M.R., *Probabilidade e Estatística*, Coleção Schaum, São Paulo, McGraw-Hill, 1979.

[54] SEIXAS, J.M., CALÔBA, L.P., DELPINO, I., “Relevance Criteria for Variance Selection in Classifier Designs”. In: *International Conference on Engineering Applications of Neural Networks*, pp.451-454, 1996.

- [55] ANG, A.H.S., TANG, W. H., *Probability Concepts in Engineering Planning and Design*, vol. 1, Canada, Basic Principles, John Wiley & Sons, 1975.
- [56] DONG, D., THOMAS, J.M., “Nonlinear Principal Component Analysis – Based on Principal Curves and Neural Networks”, *Computers Chemical Engineering*, v. 20, n.1, pp.65-78, 1996.
- [57] DIAMANTIDIS, N.A., KARLIS, D., GIAKOUMAKIS, E.A., “Unsupervised Stratification of Cross-Validation for Accuracy Estimation”, *Artificial Intelligence*, v. 116, pp. 1-16, 2000.
- [58] DERKS, E.P.P.A., BUYDENS, L.M.C., “Aspects of Neural Networks Training and Validation on Noisy Data Part 2. Validation Aspects”, *Chemometrics and Intelligent Laboratory Systems*, v. 41, pp.185-193, 1998.
- [59] EFRON, B., TIBSHIRANI, R. J., *An Introduction to the Bootstrap*, New York, Chapman & Hall/CRC, 1993 .
- [60] 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>.
- [61] MERY, D., SILVA, R.R., CALÔBA, L.P. et al., “Pattern Recognition in the Automatic Inspection of Aluminium Castings. Insight”, *Insight*, v.45, n.7, pp. 1-9, July 2003.
- [62] MERY, D., SILVA, R. R., CALÔBA, L. P. et al, “Detección de Fallas en Piezas Fundidas Usando Una Metodología de Reconocimiento de Patrones”. In: 3<sup>rd</sup> Panamerican Conference for Nondestructive Testing – PANNDT, pp.1-13, Rio de Janeiro, 2-5 June 2003.

[63] ALVES, A. C., SILVA, R.R., REBELLO, J.M.A. et al, "Evaluation of the Relevant Features of Welding Defects in Radiographic Inspection", *Materials Research*, v.6, n. 10, pp. 427-432, 2003.

[64] Silva, R.R., Siqueira, M. H. S., Calôba, L.P. et al., "Radiographics Pattern Recognition of Welding Defects using Linear Classifiers", *Insight*, v.43, n.10, pp. 669-674, October 2001.

[65] SILVA, R.R., SIQUEIRA, M.H.S., REBELLO, J.M.A., et al., "Evaluation of the Revelant Characteristic Parameters of Welding Defects and Probability of Correct Classification using Linear Classifiers", *Insight*, V.44, n.10, pp. 616-622, October, 2002.

[66] SILVA, R.R, REBELLO, J.M.A, CALÔBA, L.P, et al., "Contribution to the Development of a Radiographic Inspection Automated System". In: *8<sup>th</sup> European Conference on Non Destructive Testing*, pp. 386, Barcelona, June 17-21 2002.

[67] SILVA. R.R., CALOBÂ, L.P., SIQUEIRA, M.H.S et al., "Patterns Nonlinear Classifiers of Weld Defects in Industrial Radiographs". In: *3<sup>rd</sup> Pan-American Conference for Nondestructive Testing (PANNDT)*, pp. 1-11, Rio de Janeiro, 2-5 June 2003.

## APÊNDICE

---

1º Artigo – Publicado na revista *Insight*, edição de outubro de 2001, ganhador do prêmio *The Ron Halmshaw Award* por ter sido considerado o melhor artigo sobre radiografia do ano de 2001 da revista. Prêmio concedido pelo BINDT (*British Institute of Non-Destructive Testing*).

2º Artigo – Publicado na revista *Insight*, edição de outubro de 2002.

3º Artigo – Artigo aceito para publicação na revista *NDT&E International* (prova corrigida).

4º Artigo – Publicado na revista *Insight*, edição julho de 2003, resultante de um trabalho de colaboração com o professor Domingo Mery da Universidade de Santiago do Chile.