

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E**  
**INFORMÁTICA INDUSTRIAL – CPGEI**

**NEURY BOARETTO**

**CLASSIFICAÇÃO DE DEFEITOS DE SOLDAGEM EM IMAGENS**  
**RADIOGRÁFICAS PDVD DE TUBULAÇÕES DE PETRÓLEO: UMA**  
**ABORDAGEM COM ENSEMBLE DE EXTREME LEARNING**  
**MACHINES**

**TESE DE DOUTORADO**

**CURITIBA**

**2017**

**NEURY BOARETTO**

**CLASSIFICAÇÃO DE DEFEITOS DE SOLDAGEM EM IMAGENS  
RADIOGRÁFICAS PDVD DE TUBULAÇÕES DE PETRÓLEO: UMA  
ABORDAGEM COM ENSEMBLE DE EXTREME LEARNING  
MACHINES**

Tese de doutorado apresentada ao Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do título de Doutor em Ciências. Área de Concentração: Computação Aplicada.

Orientadora: Prof<sup>a</sup> Dr<sup>a</sup> Tania Mezzadri Centeno

**CURITIBA**

**2017**

Dados Internacionais de Catalogação na Publicação

---

B662c  
2017 Boaretto, Neury  
Classificação de defeitos de soldagem em imagens radiográficas PDVD de tubulações de petróleo: uma abordagem com ensemble de Extreme Learning Machines / Neury Boaretto.-- 2017. 123 f.: il.; 30 cm

Texto em português com resumo em inglês  
Disponível também via World Wide Web  
Tese (Doutorado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Curitiba, 2017  
Bibliografia: f. 118-123

1. Radiografia – Qualidade da imagem. 2. Radiografia – Processamento. 3. Trabalhos em metal. 4. Juntas soldadas. 5. Tubulações industriais – Inspeção. 6. Oleodutos de petróleo – Soldagem – Radiografia. 7. Oleodutos de petróleo – Soldagem – Defeitos. 8. Engenharia elétrica – Teses. I. Centeno, Tania Mezzadri. II. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial. III. Título.

---

CDD: Ed. 22 -- 621.3

Biblioteca Central da UTFPR, Câmpus Curitiba

Título da Tese Nº. 151

# **Classificação de defeitos de soldagem em imagens radiográficas PDVD de tubulações de petróleo: uma abordagem com *ensemble* de *Extreme Learning Machines***

por

**Neury Boaretto**

Orientadora: Prof.<sup>a</sup> Dr.<sup>a</sup> Tânia Mezzadri Centeno (UTFPR)

Esta tese foi apresentada como requisito parcial à obtenção do título de DOUTOR EM CIÊNCIAS – Área de Concentração: Engenharia de Computação pelo Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial – CPGEI – da Universidade Tecnológica Federal do Paraná – UTFPR, às 09h do dia 27 de abril de 2017. O trabalho foi aprovado pela Banca Examinadora, composta pelos doutores:

---

Prof.<sup>a</sup> Dr.<sup>a</sup> Tânia Mezzadri Centeno  
(Presidente – UTFPR)

---

Prof. Dr. David Menotti Gomes  
(UTFPR)

---

Prof. Dr. Julio Cesar Nievola  
(PUCPR)

---

Prof. Dr. Bogdan Tomoyuki Nassu  
(UTFPR)

---

Prof. Dr. Ricardo Dutra da Silva  
(UTFPR)

Visto da Coordenação:

---

Prof. Jean Carlos Cardozo da Silva, Dr.  
(Coordenador do CPGEI)

A folha de Aprovação assinada encontra-se na Coordenação do Programa.

Dedico este trabalho à minha esposa Leonilda e aos meus  
filhos Matheus e Julia.

## AGRADECIMENTOS

Agradeço a minha orientadora Prof<sup>a</sup>. Dr<sup>a</sup>. Tania Mezzadri Centeno, pelo grande apoio técnico e pela compreensão e sabedoria com que me guiou nesta trajetória, sem sua orientação, certamente eu não teria chegado aonde cheguei.

À Prof.<sup>a</sup> Dr.<sup>a</sup> Myriam Delgado que, sempre disposta a discutir técnicas e resultados me ajudou a avançar no desenvolvimento da pesquisa, principalmente referente aos seus conhecimentos em inteligência artificial.

Aos demais professores do CPGEI, pelo conhecimento recebido.

Aos pesquisadores do grupo de pesquisa e do laboratório LIVIC, Fernando, Rafael, Marlon e Célia pelo apoio técnico e pela amizade.

Aos meus colegas de sala.

Ao IFSC por realizar o convênio DINTER com a UTFPR e permitir o meu afastamento para capacitação.

Ao Centro de Pesquisa e Desenvolvimento Leopoldo Américo Miguez de Mello (CENPES) e a Petrobras por disponibilizar a biblioteca de imagens radiográficas de soldas em tubulações para utilização em trabalhos acadêmicos.

Gostaria de deixar registrado também, o meu reconhecimento à minha família, pois acredito que sem o apoio deles seria muito difícil vencer esse desafio.

Enfim, a todos os que por algum motivo contribuíram para a realização desta pesquisa.

Por vezes sentimos que aquilo que fazemos  
não é senão uma gota de água no mar. Mas o  
mar seria menor se lhe faltasse uma gota.

(Madre Teresa de Calcutá)

## RESUMO

BOARETTO, Neury. **Classificação de defeitos de soldagem em imagens radiográficas PDVD de tubulações de petróleo: uma abordagem com *ensemble* de *Extreme Learning Machines***. 123 folhas. Tese de Doutorado (Doutorado em Engenharia Elétrica e Informática Industrial) - Universidade Tecnológica Federal do Paraná. Curitiba, 2017.

A inspeção de defeitos de soldagem em imagens radiográficas de tubulações é bastante subjetiva e está sujeita a erros de interpretação por parte do inspetor laudista. Dentro deste contexto, nos últimos anos tem-se visto um grande esforço no desenvolvimento de métodos automáticos e semiautomáticos de detecção de defeitos em juntas soldadas. Este trabalho apresenta um método automatizado para detecção e classificação de defeitos em imagens radiográficas de juntas soldadas de tubulações obtidas pela técnica de exposição radiográfica parede dupla vista dupla (PDVD), obtidas em reais situações de campo e que, geralmente, têm uma qualidade mais baixa do que as imagens usadas em outros estudos. O método proposto identifica na imagem a região do cordão de solda, detecta as descontinuidades e classifica as mesmas em defeitos e não defeitos, destacando na imagem o resultado. São avaliados classificadores a partir de métodos de classificação por redes neurais *Multilayer Perceptron* (MLP), redes neurais *Extreme Learning Machines* (ELM) e classificador estatístico *Support Vector Machines* (SVM). O método proposto para identificação da região de interesse atingiu 100% de precisão na segmentação do cordão de solda. O classificador SVM apresentou um desempenho melhor que os classificadores MLP e ELM em todos os cenários testados. Com a utilização de *ensembles* de ELMs obteve-se um *F-score* de 85,7% para o banco de padrões de teste, resultados satisfatórios quando comparados com trabalhos semelhantes. O uso de *ensembles* de ELMs representa um ganho de apenas 0,5% no *F-score* em comparação com o melhor resultado da rede treinada individualmente, entretanto, com o uso de faixas de limiares de decisão do *ensemble*, o uso do método permite mostrar as descontinuidades sobre as quais o *ensemble* não tem certeza, destacando na imagem estas descontinuidades como região de incerteza, deixando para o especialista a avaliação final destas descontinuidades. A imagem resultante da aplicação do método serve como auxílio ao especialista na elaboração de laudos.

**Palavras-chave:** Imagens radiográficas. Ensaios não destrutivos. Classificação de descontinuidades. *Extreme Learning Machines*. Defeitos de soldagem.

## ABSTRACT

BOARETTO, Neury. **Classification of welding defects in radiographic images DWDI of pipeline: an approach with ensemble of Extreme Learning Machines.** 123 folhas. Tese de doutorado (Doutorado em Engenharia Elétrica e Informática Industrial) - Universidade Tecnológica Federal do Paraná. Curitiba, 2017.

The inspection of radiographic images of welded joints is very subjective and is subject to errors of interpretation by the inspector. In this context, a great effort has been made in the last years to develop automatic and semiautomatic methods for detecting defects in welded joints. This research work presents an automated method for the detection and classification of defects in radiographic images of welded joints of pipes obtained by the double wall double image (DWDI) exposure technique obtained in real field situations and which generally have a lower quality than the images used in other studies. The proposed method identifies the region of the weld bead, detects the discontinuities and classifies them as defects and non-defects, highlighting in the image the result. Classifiers are evaluated using methods of classification by multilayer perceptron (MLP) neural networks, extreme learning machines (ELM) neural networks, and Support Vector Machines (SVM). The proposed method for identifying the region of interest reached 100% precision in the segmentation of the weld bead. The SVM classifier performed better than the MLP and ELM classifiers in all scenarios tested. Using ELM ensembles, an F-score of 85.7% was obtained for a test patterns database, satisfactory results when compared to similar works. The use of ensembles of ELMs represents a gain of only 0.5% in the F-score compared to the best result of the individually trained network, however, with the use of ensemble decision threshold ranges, the presented method allows to show the discontinuities about which the ensemble is not sure, highlighting in the image these discontinuities as a region of uncertainty, leaving to the specialist the final evaluation of these discontinuities. The image resulting from the application of the method serves as an aid to the expert in the elaboration of reports.

**Keywords:** Radiographic images. Non-Destructive Testing. Classification of Discontinuities. Extreme Learning Machines. Welding Defects.

## LISTA DE ILUSTRAÇÕES

Figura 1 - Exemplo de imagens radiográficas de soldagem em tubulações de petróleo. (a) Imagem do cordão de solda obtida pela técnica PSVS. (b) Imagem do cordão de solda obtida pela técnica PDVD.....	18
Figura 2 - Técnica de exposição radiográfica PDVD.....	19
Figura 3 - Exemplo de imagem de entrada e saída do algoritmo proposto. (a) Imagem de entrada do método proposto. (b) Imagem de saída do método proposto.....	20
Figura 4 - Técnica geral de ensaios radiográficos na indústria.....	24
Figura 5 - Técnica de exposição PSVS. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante, com destaques do cordão de solda e outros artefatos usados na identificação.....	25
Figura 6 - Técnica de exposição PDVS. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante, com destaques do cordão de solda e outros artefatos usados na identificação.....	26
Figura 7 - Técnica de exposição PDVD. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante, com destaques do cordão de solda e outros artefatos usados na identificação .....	27
Figura 8 - Exemplo de uma imagem monocromática e a convenção utilizada para o par de eixos $(x, y)$ .....	31
Figura 9 - Expansão de histograma. (a) Imagem original. (b) Imagem realçada. (c) Histograma da imagem original. (d) Histograma da imagem expandida....	33
Figura 10 - Equalização de histograma. (a) Imagem original. (b) Imagem equalizada. (c) Histograma da imagem original. (d) Histograma da imagem equalizada.....	34
Figura 11 - Exemplos de elementos estruturantes. (a) Estrela 3x3. (b) Quadrado 3x3. (c) Octógono 5x5 .....	37
Figura 12 - Exemplo da aplicação da operação morfológica de erosão sobre uma imagem segmentada do cordão de solda. (a) Imagem antes da erosão. (b) Imagem após a erosão.....	37
Figura 13 - Exemplos da aplicação de extração de bordas de imagem binária. (a) Imagem binária. (b) Imagem binária com bordas extraídas por operador morfológico. (c) Bordas das discontinuidades realçadas sobre a imagem em tons de cinza.....	38
Figura 14 - Analogia entre os modelos de um neurônio (a) Biológico. (b) Artificial.....	45
Figura 15 - Modelo de um neurônio artificial.....	45
Figura 16 - Arquitetura de uma RNA simples.....	47
Figura 17 - Gráfico da função de ativação sigmoide.....	48
Figura 18 - Arquitetura da rede neural ELM.....	51

Figura 19 - Efeitos do sobreajuste e da regularização em uma RNA (a) Superfícies de separação para valores crescentes de $L$ . (b) Superfícies de separação para a rede com $L=L3$ , com diferentes valores para o fator de regularização $C$ ..	54
Figura 20 - Estrutura geral de um <i>ensemble</i> .....	55
Figura 21 - Possíveis hiperplanos de separação e hiperplano ótimo.....	57
Figura 22 - Exemplos de valores e situações da variável de folga $\xi$ .....	58
Figura 23 - Validação cruzada <i>leave-p-label-out</i> .....	63
Figura 24 - Modelo de matriz de confusão de duas classes.....	64
Figura 25 - Exemplo de resultado do método de Lawson e Parker. (a) Imagem original. (b) Extração do cordão de solda. (c) Detecção de defeitos. (d) Combinação de (b) e (c).....	67
Figura 26 - Exemplo de resultado do método de Mery. (a) Imagem original. (b) Janelas classificadas como defeitos. (c) Imagem em escala de cinza proporcional ao número de subjanelas detectadas. (d) Detecção final obtida pela limiarização de (c).....	68
Figura 27 - Perfil transversal ao cordão-de-solda. (a) Para a situação de presença de defeito no cordão. (b) Para a situação de ausência de defeito.....	68
Figura 28 - Imagens do cordão de solda. (a) Recorte da imagem original. (b) Laudo realizado pelo especialista sobre a mesma imagem.....	78
Figura 29 - Passos do algoritmo de detecção e classificação de defeitos .....	79
Figura 30 - Segmentação do cordão de solda. (a) Recorte da imagem original. (b) Imagem filtrada pelo filtro da média 300x300. (c) Imagem limiarizada. (d) Imagem erodida.....	80
Figura 31 - Imagens das etapas principais na identificação de defeitos candidatos. (a) Original. (b) Região de interesse. (c) Máscara de nitidez equalizada. (d) Imagem segmentada pela técnica de Otsu. (e) Segmentação final das discontinuidades. (f) Identificação dos defeitos candidatos na imagem equalizada.....	81
Figura 32 - Área de exclusão de defeitos candidatos da extremidade da imagem.....	82
Figura 33 - Exemplo de forma da discontinuidade com indicação dos parâmetros utilizados na extração das características geométricas. (a) Características 1 a 6. (b) Característica 7.....	83
Figura 34 - Rede neural MLP com $L$ neurônios na camada oculta.....	86
Figura 35 - Rede neural ELM proposta com 8 ou 13 entradas, $L$ neurônios na camada oculta e 2 neurônios na camada de saída.....	87
Figura 36 - <i>Ensemble</i> de redes neurais ELMs.....	88
Figura 37 - Discretização da saída da ELM em três faixas.....	89
Figura 38 - Saída do <i>ensemble</i> contínuo para 12 ELMs.....	90
Figura 39 - Localização da região do cordão de solda (ROI).....	93
Figura 40 - Extração de características para treinamento dos classificadores.....	95

Figura 41 - Matriz de confusão de treinamento e teste da rede neural com 10 neurônios na camada oculta na classificação de 05 tipos de defeitos.....	97
Figura 42 - Média do <i>F-score</i> dos dados de teste variando o número de neurônios na camada escondida.....	98
Figura 43 - Matriz de confusão de um treinamento da rede neural com 40 neurônios na camada oculta para as classes defeito e não defeito.....	98
Figura 44 - Critério de parada utilizado na rede neural.....	99
Figura 45 - Imagem após a classificação das discontinuidades: superior - automatizada com utilização do algoritmo; inferior esquerda - manual fornecida pelo especialista.....	100
Figura 46 - Resultados dos indicadores para <i>ensemble</i> discretizado em duas faixas.....	104
Figura 47 - Resultados dos indicadores para <i>ensemble</i> discretizado em três faixas .....	105
Figura 48 - Resultados dos indicadores para <i>ensemble</i> contínuo .....	106
Figura 49 - <i>Ensemble</i> contínuo com grau de incerteza de saída aplicado a imagem.....	107
Figura 50 - Resultados dos indicadores para <i>ensemble</i> de ELMs contínuo e banco de padrões de teste ampliado (6 imagens).....	110

## LISTA DE TABELAS

Tabela 1 - Principais descontinuidades encontradas em juntas soldadas.....	28
Tabela 2 - Funções de ativação de saída normalmente utilizadas.....	52
Tabela 3 - Visão geral sobre o desenvolvimento dos sistemas automático de detecção de defeitos de soldagem.....	72
Tabela 4 - Visão geral de técnicas de detecção de defeitos e tipos de características...	73
Tabela 5 - Banco de padrões com identificação do número de amostras de cada classe.....	96
Tabela 6 - Treinamento ELM não regularizada e com características geométricas.....	101
Tabela 7 - Treinamento ELM regularizada método 1 e com características geométricas.....	101
Tabela 8 - Treinamento ELM regularizada método 2 e com características geométricas.....	101
Tabela 9 - Treinamento ELM regularizada método 2, com características geométricas e de textura.....	102
Tabela 10 - Resultado individual dos dados de teste das ELMs para comporem o <i>ensemble</i> .....	103
Tabela 11 - Resultado individual das ELMs com aplicação da rede treinada e utilização de 100% do banco de dados.....	103
Tabela 12 - Banco de padrões ampliado com 17 imagens para treinamento e teste.....	107
Tabela 13 - Resultado individual dos dados de teste das ELMs para comporem o <i>ensemble</i> para o banco de padrões ampliado (11 imagens).....	108
Tabela 14 - Resultado individual das ELMs com aplicação da rede treinada para o conjunto de imagens inéditas de teste (6 imagens) do banco de padrões ampliado.....	109
Tabela 15 - Definição do número de componentes de ELMs para o <i>ensemble</i> .....	109
Tabela 16 - Indicadores de desempenho dos classificadores MLP, ELM e SVM.....	111

## LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

ABNT	Associação Brasileira de Normas Técnicas
ASME	American Society of Mechanical Engineers
BAM	Federal Institute for Materials Research and Testing
CENPES	Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello – PETROBRAS
CPGEI	Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial – UTFPR
ELM	Extreme Learning Machines
END	Ensaio Não-Destrutivo
FF	Falta de Fusão
FP	Falta de Penetração
IE	Inclusão de Escória
IFSC	Instituto Federal de Santa Catarina
IIW	International Institute of Welding
IT	Inclusão de Tungstênio
KNN	K-Nearest Neighbors
LIVIC	Laboratório de Imagens e Visão Computacional - CPGEI - UTFPR
MLP	Multilayer Perceptron
MO	Mordedura
NDT	Nondestructive Testing
NBR	Norma da Associação Brasileira de Normas Técnicas (ABNT)
PETROBRAS	Petróleo Brasileiro S.A.
PDVD	Parede Dupla Vista Dupla
PDVS	Parede Dupla Vista Simples
pixel	picture element
PO	Porosidade
PSVS	Parede Simples Vista Simples
RBF	Radial basis function
RC	Radiografia Computadorizada
RNA	Rede Neural Artificial
ROI	Region Of Interest
SLFN	Single-Hidden Layer Feedforward Network
SVM	Support Vector Machines
TIFF	Tagged Image File Format
TR	Trinca
UTFPR	Universidade Tecnológica Federal do Paraná

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>16</b>
1.1 JUSTIFICATIVA.....	19
1.2 OBJETIVOS.....	21
1.3 ESTRUTURA DO TRABALHO.....	22
<b>2 FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>23</b>
2.1 RADIOLOGIA INDUSTRIAL APLICADA A JUNTAS SOLDADAS.....	23
2.1.1 Técnicas de Inspeção para Ensaios Radiográficos de Soldas em Tubulações...	24
2.1.1.1 Técnica radiográfica parede simples vista simples (PSVS).....	25
2.1.1.2 Técnica radiográfica parede dupla vista simples (PDVS).....	25
2.1.1.3 Técnica radiográfica parede dupla vista dupla (PDVD).....	27
2.1.2 Classificação Estrutural das Descontinuidades em Juntas Soldadas.....	28
2.2 PROCESSAMENTO DIGITAL DE IMAGENS.....	30
2.2.1 Imagens Digitais.....	30
2.2.2 Histograma.....	32
2.2.2.1 Expansão de histograma.....	32
2.2.2.2 Equalização de histograma.....	33
2.2.3 Filtragem Espacial para Remoção ou Suavização de Ruídos.....	34
2.2.3.1 Filtragem pela média.....	35
2.2.3.2 Filtragem pela mediana.....	35
2.2.3.3 Filtro de Wiener.....	35
2.2.3.4 Seleção do filtro de remoção e suavização de ruídos.....	36
2.2.4 Processamento Morfológico de Imagens.....	36
2.2.4.1 Operações morfológicas de erosão, dilatação para imagens binárias.....	37
2.2.4.2 Extração de bordas em imagens binárias por operadores morfológicos.....	38
2.2.4.3 Abertura e fechamento em escala de cinza.....	39
2.2.4.4 Transformação <i>top-hat</i> e <i>bottom-hat</i> .....	39
2.2.5 Máscara de Nitidez e Filtragem <i>High-Boost</i> .....	39
2.2.6 Segmentação/Limiarização.....	40
2.2.6.1 Limiarização pela técnica de Otsu.....	41
2.2.6.2 Aplicação adaptativa de limiar.....	42
2.2.7 Rotulagem.....	43
2.3 REDES NEURAIS ARTIFICIAIS APLICADAS NO RECONHECIMENTO DE PADRÕES.....	43
2.3.1 Padrão de uma Classe .....	43

2.3.2 Redes Neurais Artificiais .....	44
2.3.3 Redes com Múltiplas Camadas.....	48
2.3.3.1 Algoritmo de Treinamento de MLP.....	48
2.3.4 Extreme Learning Machines.....	50
2.3.4.1 Treinamento de ELM.....	50
2.3.4.2 Ensemble de ELMs.....	55
2.4 SUPPORT VECTOR MACHINES .....	56
2.5 VALIDAÇÃO CRUZADA.....	61
2.5.1 Método <i>Holdout</i> .....	61
2.5.2 Método <i>K-fold</i> .....	62
2.5.3 Método <i>Leave-one-out</i> .....	62
2.5.4 Método <i>Leave-p-label-out</i> .....	62
2.6 MEDIDAS DE DESEMPENHO DE CLASSIFICADORES.....	63
2.7 CONSIDERAÇÕES FINAIS.....	65
<b>3 ESTADO DA ARTE.....</b>	<b>66</b>
3.1 DETECÇÃO E CLASSIFICAÇÃO DE DEFEITOS EM IMAGENS PSVS.....	66
3.2 DETECÇÃO E CLASSIFICAÇÃO DE DEFEITOS EM IMAGENS PDVD.....	74
3.3 CONSIDERAÇÕES FINAIS.....	75
<b>4 MATERIAIS E MÉTODOS.....</b>	<b>77</b>
4.1 MATERIAIS.....	77
4.2 MÉTODO.....	79
4.2.1 Localização da Região do Cordão de Solda.....	79
4.2.2 Detecção de Descontinuidades e Extração de Características.....	80
4.2.3 Normalização das Características ( <i>Features</i> ) de Entrada.....	84
4.2.4 Treinamento da Rede Neural MLP.....	84
4.2.5 Treinamento da Rede Neural ELM.....	86
4.2.6 Definição do <i>ensemble de ELMs</i> .....	87
4.2.6.1 <i>Ensemble de ELMs</i> discretizado em duas faixas.....	88
4.2.6.2 <i>Ensemble de ELMs</i> discretizado em três faixas.....	89
4.2.6.3 <i>Ensemble de ELMs</i> contínuo.....	90
4.2.7 Treinamento da SVM.....	90
4.2.8 Comparação entre Classificadores MLP, ELM e SVM.....	91
4.3 CONSIDERAÇÕES FINAIS.....	91
<b>5 RESULTADOS E DISCUSÕES.....</b>	<b>93</b>
5.1 EXTRAÇÃO DO BANCO DE DADOS PARA TREINAMENTO DAS RNAs	93

5.2 TREINAMENTO COM REDES NEURAIIS MLP.....	96
5.3 TREINAMENTO COM REDES NEURAIIS ELM.....	100
5.3.1 Definição do <i>ensemble</i> ELM.....	102
5.3.1.1 <i>Ensemble</i> de ELMs discretizado em duas faixas.....	104
5.3.1.2 <i>Ensemble</i> de ELMs discretizado em três faixas.....	104
5.3.1.3 <i>Ensemble</i> de ELMs contínuo.....	105
5.3.1.4 Análise e aplicação de <i>Ensemble</i> de ELMs.....	106
5.4 TREINAMENTO REDE NEURAL ELM COM BANCO DE PADRÕES AMPLIADO.....	107
5.5 TREINAMENTO DO CLASSIFICADOR SVM.....	110
5.6 COMPARAÇÃO ENTRE CLASSIFICADORES MLP, ELM E SVM.....	111
5.7 CONSIDERAÇÕES FINAIS.....	112
<b>6 CONCLUSÃO.....</b>	<b>114</b>
<b>REFERÊNCIAS.....</b>	<b>118</b>

## 1 INTRODUÇÃO

Os ensaios não destrutivos (ENDs) são uma importante ferramenta para inspeção de estruturas utilizada na indústria de petróleo e gás. Técnicas de inteligência artificial e de visão computacional podem auxiliar na interpretação dos resultados dos ENDs e fornecer uma estimativa de diagnóstico do material inspecionado.

Uma variedade de ENDs é utilizada para a detecção e avaliação de defeitos em juntas soldadas de tubulações, sendo o ultra-som e a radiografia os mais relevantes (LOPES et al., 2010). Dentre os ENDs, o ensaio radiográfico é amplamente utilizado na indústria para inspecionar juntas soldadas de tubulações (BALAKRISHNAN, 2009). Nesta técnica, a análise e interpretação de imagens radiográficas são realizadas por especialistas, e fornecem um registro visível e permanente da inspeção volumétrica de materiais (QUINN; SIGL, 1980). Os ensaios radiográficos baseiam-se na absorção diferenciada da radiação penetrante pela peça que está sendo inspecionada (ANDREUCCI, 2003).

Com o advento da radiografia computadorizada (RC), a radiologia industrial ganhou novo espaço devido aos benefícios proporcionados por esta tecnologia. Dentre as vantagens se destacam: possibilidade de redução do tempo de exposição radiográfica, obtenção direta de imagens digitais, eliminação do uso de produtos químicos e a possibilidade de reutilização dos detectores (placas de fósforo) (MARINHO, 2009).

Na prática, a inspeção radiográfica de soldagem é realizada por especialistas, conhecidos como inspetores laudistas, que realizam a interpretação de imagens radiográficas com base em normas especificadas por instituições reguladoras e certificadoras de cada país. Segundo Silva et al. (2001), a interpretação correta da imagem de raios-X irá depender essencialmente da qualidade da imagem e da experiência do inspetor. No Brasil, por exemplo, a especificação dos critérios para a qualificação e certificação de inspetores de soldagem é feita através da norma NBR 14842 (2003) definida pelo Comitê Brasileiro de Soldagem da Associação Brasileira de Normas Técnicas (ABNT), descrevendo as atribuições e responsabilidades dos inspetores laudistas.

A inspeção de radiografias industriais exige ampla experiência do inspetor laudista, muitas vezes dando margem à subjetividade, exigindo acuidade visual e conhecimento da técnica empregada. Além disso, o grande volume de imagens a serem laudadas pode gerar dificuldades na análise, tornando a inspeção longa e fatigante, aumentando a possibilidade de erros (FELISBERTO, 2007; GODOI et al., 2005; LOPES et al., 2010).

Durante a inspeção radiográfica de juntas soldadas realizada por inspetores, vários parâmetros são controlados, a fim de produzir uma imagem que permita a detecção de defeitos de soldagem existentes no cordão de solda. Problemas como a presença de ruído e contraste insuficiente são frequentemente encontrados em imagens radiográficas, dificultando sua análise (SILVA et al., 2001).

Por se tratar de uma tarefa extremamente repetitiva, a inspeção não automática apresenta inconvenientes de consumir muito tempo, ter alto custo, além da efetividade da inspeção diminuir significativamente no decorrer da jornada de trabalho, ocasionando a falta de precisão devido a diversos fatores ambientais e pessoais.

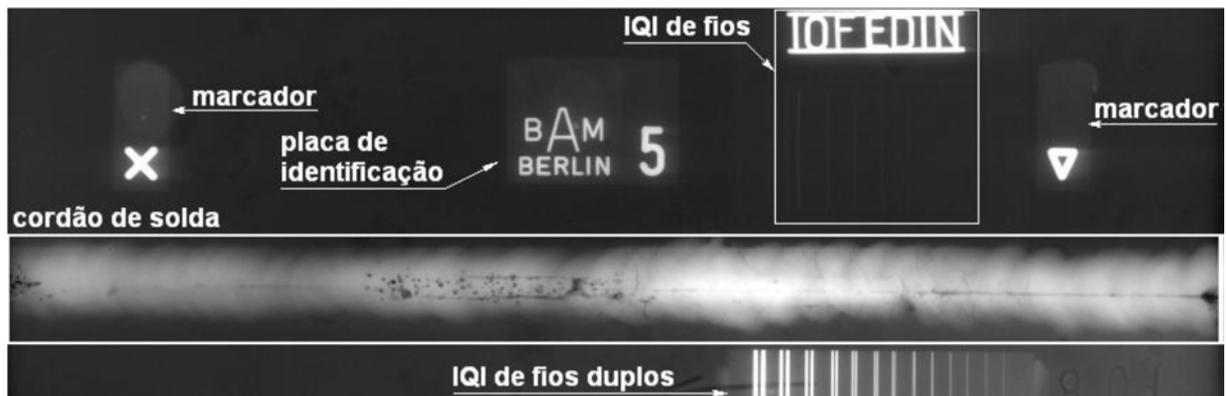
Estudos sobre a confiabilidade da rotina de interpretação humana em END através de filmes radiográficos foram desenvolvidos por Fücsök et al. (2002), baseando-se em um grupo de 35 inspetores laudistas com experiência entre 6 meses e 35 anos. Esses estudos citaram uma taxa média de acerto na indicação de defeitos de 68% e 17% de falsos positivos.

Apesar da subjetividade e da especialização necessárias para a inspeção de imagens radiográficas, busca-se desenvolver técnicas automatizadas capazes de auxiliar na detecção de defeitos em juntas soldadas (LAWSON; PARKER, 1994; LIAO; NI, 1998; SILVA, 2003; PADUA, 2004; FELISBERTO, 2007; VALAVANIS; KOSMOPOULOS, 2010; ZAPATA; VILAR; RUIZ, 2011; MERY, 2011; KROETZ et al., 2012; SUYAMA, 2015). Dentro deste contexto, nos últimos anos tem-se visto um grande esforço no desenvolvimento de métodos automáticos e semi-automáticos de detecção de defeitos em juntas soldadas (cordões de solda) a partir de imagens radiográficas.

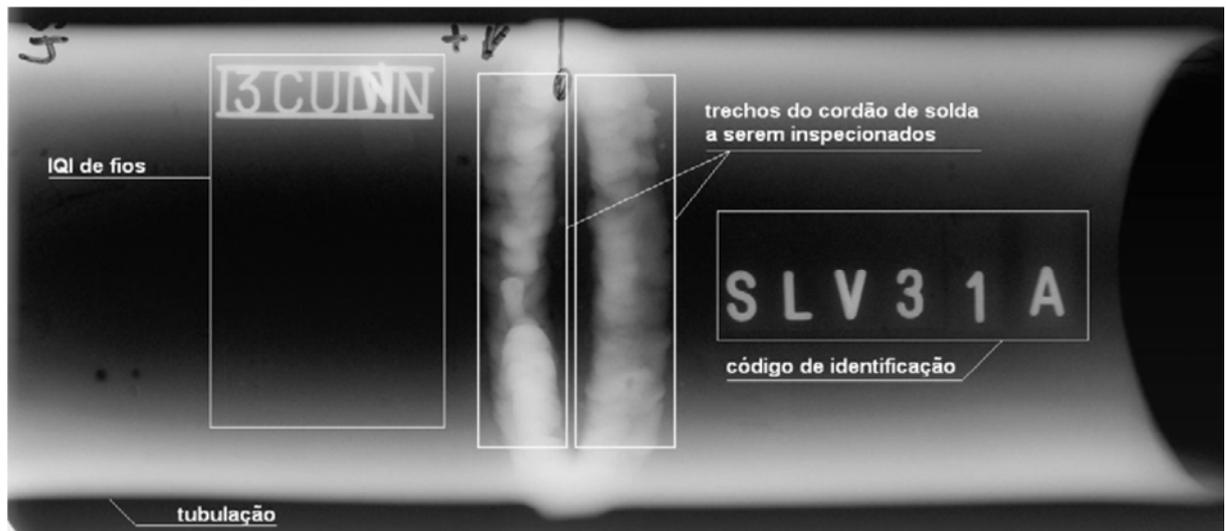
Trabalhos como os descritos por Lawson e Parker (1994), Padua (2004), Mery (2011), Zapata, Vilar e Ruiz (2011), Valavanis e Kosmopoulos (2010) e Sikora et al. (2012) utilizam imagens obtidas pela técnica de exposição parede simples vista simples (PSVS). Os trabalhos apresentados por Kroetz (2012), Kroetz et al. (2012), Fylyk e Centeno (2012) e Suyama (2015) se diferenciam dos demais por utilizarem imagens obtidas pela técnica de exposição parede dupla vista dupla (PDVD).

A técnica de exposição PDVD é um arranjo adotado para obtenção de imagens radiográficas de tubulação com um diâmetro igual ou inferior a 90 milímetros, assim, não permitindo qualquer acesso interno para a inserção da fonte de radiação (BALAKRISHNAN, 2009). A Figura 1(a) mostra a imagem resultante de um ensaio radiográfico obtido pela técnica de exposição radiográfica PSVS e a Figura 1(b) a imagem resultante de um ensaio radiográfico obtido pela técnica de exposição radiográfica PDVD. Observa-se nesta figura a

diferença no formato da imagem do cordão de solda, com formato linear na técnica PSVS e elíptico na técnica PDVD.



(a)

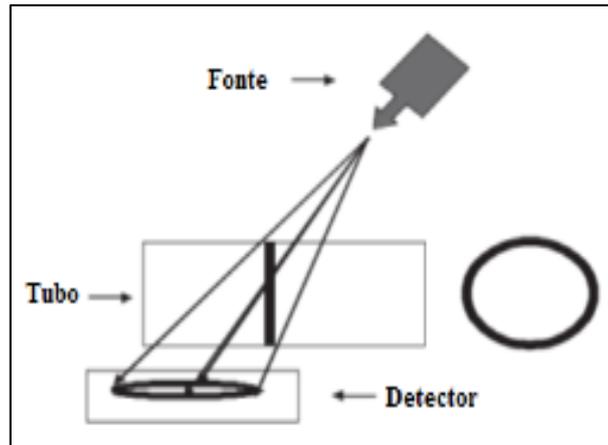


(b)

**Figura 1 – Exemplos de imagens radiográficas de soldagem em tubulações de petróleo. (a) Imagem do cordão de solda obtida pela técnica PSVS. (b) Imagem do cordão de solda obtida pela técnica PDVD.**

Fonte: Felisberto (2007) cedida pelo Federal Institute for Materials Research and Testing (BAM).

Na técnica PDVD, como é mostrado na Figura 2, o feixe de radiação passa através de ambas as paredes do tubo, aumentando o espalhamento. Uma pesquisa conduzida por Edalati et al. (2006) foi realizada para medir a sensibilidade radiográfica dos raios gama ou raios-x para tubos e chapas e comparar os resultados com os requisitos de sensibilidade dos padrões. As experiências revelaram que a sensibilidade requerida era alcançável para a técnica PSVS, mas não pode ser facilmente obtida pela técnica PDVD, devido à elevada dispersão. Portanto, a detecção de defeitos de baixo contraste em radiografia PDVD de tubos é uma tarefa desafiadora para as inspeções (EDALATI et al., 2006).



**Figura 2 – Técnica de exposição radiográfica PDVD.**  
**Fonte: Adaptado de Balakrishnan (2009).**

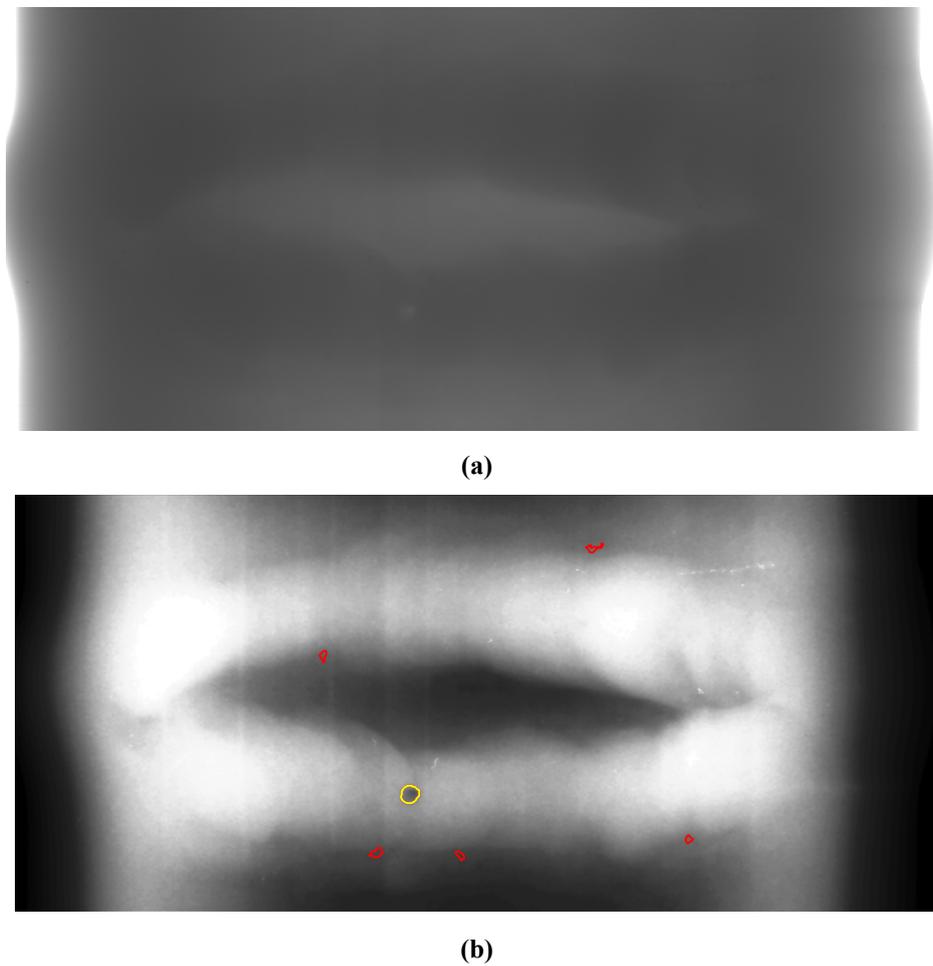
## 1.1 JUSTIFICATIVA

A radiografia é um ensaio não destrutivo amplamente utilizado para identificação de defeitos de soldas em tubulações. Um grande número de imagens radiográficas é analisado por inspetores laudistas, tornando a inspeção longa e fatigante, o que pode conduzir a uma interpretação subjetiva com o risco potencial de erros na identificação dos defeitos. Muitos esforços têm sido feitos para a concepção e construção de sistemas de inspeção automática, destinada a apoiar a interpretação de imagens radiográficas de solda e, portanto, melhorar a robustez, precisão e velocidade do processo de inspeção. Apesar do grande número de publicações de pesquisa nesta área, há poucos estudos que investigam inspeção automática de imagens radiográficas PDVD, especialmente utilizando imagens reais de campo.

Uma das diferenças deste trabalho em relação às demais pesquisas publicadas é que normalmente estas utilizam imagens de radiografias de cordões de solda, obtidas principalmente pela técnica parede simples vista simples (PSVS). A técnica de exposição radiográfica PDVD proporciona o processamento simultâneo das duas vistas da junta soldada, enquanto que nas imagens radiográficas obtidas pela técnica de exposição do tipo PSVS apenas uma vista da soldagem necessita ser processada.

Nesta pesquisa, um algoritmo para detecção e classificação automática de defeitos em imagens de juntas soldadas de tubulações de petróleo é proposto, utilizando técnicas de processamento de imagens e com classificadores de padrões com base em redes neurais MLP (*Multilayer Perceptron*), redes neurais ELM (*Extreme Learning Machines*) e o classificador estatístico SVM (*Support Vector Machines*). A ideia básica é tentar imitar a forma como um inspetor humano inspeciona as imagens radiográficas: primeiro o cordão de solda é

localizado, seguido pela etapa de detecção de descontinuidades (defeitos potenciais) na região do cordão de solda e, em seguida, tais descontinuidades são classificadas. Um conjunto de características é extraído das descontinuidades detectadas para ser usado como entrada do classificador. Os experimentos foram realizados com imagens radiográficas PDVD obtidas em reais de situações de campo e que, geralmente, têm uma qualidade mais baixa do que as imagens usadas em outros estudos. A Figura 3 ilustra um exemplo para as imagens de entrada e saída do método proposto, na Figura 3(a) é mostrada a imagem original com baixo contraste e na Figura 3(b) a imagem realçada de saída, onde as descontinuidades detectadas são identificadas através da marcação do contorno e classificadas por cores.



**Figura 3 – Exemplo de imagem de entrada e saída do algoritmo proposto. (a) Imagem de entrada do método proposto. (b) Imagem de saída do método proposto.**

Classificadores com base em redes neurais ELMs são explorados com mais detalhes nesta pesquisa por apresentarem as seguintes características: rapidez no treinamento, simplicidade de configuração e bom desempenho na generalização (HUANG et al., 2015; SILVESTRE, 2015). Além disso, não foram encontradas na literatura científica aplicações de

ELMs como classificador de defeito em imagens radiográficas de juntas soldadas. A ELM se diferencia dos métodos tradicionais de aprendizagem por selecionar de forma aleatória, arbitrária e a priori, os pesos dos neurônios da camada escondida e, posteriormente, determinar de forma analítica os pesos da camada de saída (HUANG; ZHU; SIEW, 2004; HUANG; ZHU; SIEW, 2006).

A ideia inicial da pesquisa era obter um classificador multiclasse para os defeitos Porosidade (PO), Inclusão de Escória (IE), Falta de Fusão (FF) e Trincas (TR). Como o conjunto de amostras de padrões obtidos através das imagens não resultou em um grupo balanceado de amostras entre as classes, partiu-se para um classificador binário, separando nas classes de defeitos e não defeitos. O classificador multiclasse somente foi testado para a rede neural MLP, comprovando através dos resultados a não aplicabilidade deste método para o conjunto de amostras disponibilizado.

Numa primeira fase da pesquisa um conjunto com oito imagens obtidas pelo sistema de aquisição Dürr foi utilizado para testar o classificador multiclasse a partir de rede neural MLP. Este conjunto também foi utilizado na definição da arquitetura de treinamento da rede neural MLP e ELM e no *ensemble* ELM para um cenário de treinamento e teste intra-sensor. Posteriormente foram incluídas a este conjunto mais nove imagens obtidas pelo sistema de aquisição GE. Com este conjunto de imagens ampliado foi possível expandir o banco de padrões e reservar uma parte destas imagens para os testes do *ensemble* de ELMs, os quais foram realizados no cenário multi-sensor. A ampliação do conjunto de imagens possibilitou também a realização de treinamentos nos cenários intra, inter e multi-sensor, permitindo comparar os classificadores MLP, ELM e SVM nos três cenários.

## 1.2 OBJETIVOS

O objetivo geral deste trabalho foi desenvolver um método automatizado para detecção e classificação de defeitos de soldagem em imagens radiográficas PDVD de tubulações de petróleo, com imagens de campo obtidas a partir de condições reais de operação. O método serve de auxílio à inspeção industrial realizada por especialistas.

Além do objetivo principal, este trabalho teve como objetivos específicos:

- Identificar a Região de Interesse (ROI), excluindo descontinuidades encontradas fora desta região, permitindo a redução do espaço de busca e o tempo de processamento do classificador;

- Segmentar as discontinuidades que representam potenciais defeitos, as quais serão posteriormente usadas na classificação dos defeitos de soldagem;
- Gerar um banco de padrões de defeitos e não defeitos, a partir de um conjunto de imagens com discontinuidades laudadas por especialistas. O banco de padrões será usado no treinamento de classificadores;
- Treinar classificadores a partir de redes neurais *Perceptron* de múltiplas camadas (*Multilayer Perceptron*) (MLP), Máquinas de Aprendizado Extremo (*Extreme Learning Machines*) (ELMs) e o classificador estatístico (*Support Vector Machines*) (SVM);
- Aprofundar os testes com redes neurais ELMs, utilizando métodos de regularização;
- Definir critérios para garantir diversidade e qualificação das componentes do *ensemble* de ELMs;
- Testar e avaliar três combinações no ajuste dos dados e no critério de decisão do *ensemble* de redes neurais ELMs.

### 1.3 ESTRUTURA DO TRABALHO

No Capítulo 2, descrevem-se os conceitos sobre radiologia industrial aplicada a juntas soldadas de tubulações, técnicas de obtenção de imagens radiográficas e a classificação das principais discontinuidades encontradas nas juntas soldadas, bem como fundamentos básicos de processamento digital de imagens e de classificadores com aprendizagem supervisionada. O Capítulo 3 expõe o estado da arte em relação às metodologias utilizadas para detecção e classificação de defeitos em soldas de tubulações. O Capítulo 4 descreve os materiais e os métodos utilizados neste trabalho, onde se detalha a proposta para detecção e classificação automática de defeitos em juntas soldadas. O Capítulo 5 mostra os resultados do método proposto, e por fim, o último capítulo apresenta a conclusão sobre os resultados e propostas de melhorias.

## 2 FUNDAMENTAÇÃO TEÓRICA

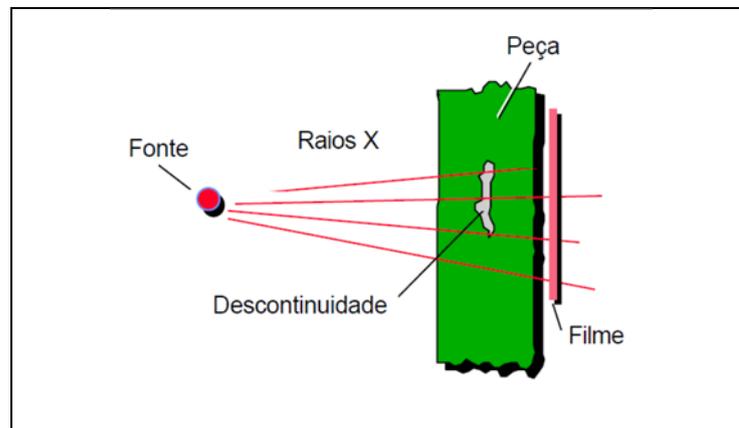
O objetivo principal deste capítulo é introduzir conceitos fundamentais importantes para a compreensão do método proposto. A primeira seção apresenta as técnicas de inspeção radiográfica e as principais descontinuidades encontradas nas imagens radiográficas de soldas em tubulações. Esta seção foi incluída para esclarecer princípios do ensaio radiográfico de juntas soldadas de tubulações e fornecer informações para a compreensão do conteúdo gráfico das imagens que foram disponibilizadas para este estudo. A Seção 2.2 apresenta conceitos e técnicas de processamento digital de imagens utilizadas no pré-processamento, na segmentação, na identificação das descontinuidades e na extração das características. A Seção 2.3 descreve os princípios das redes neurais artificiais e apresenta dois tipos de redes utilizadas como classificadores de defeitos, *Multilayer Perceptron* (MLP) e *Extreme Learning Machines* (ELM), com seus respectivos algoritmos de treinamento. Também são apresentadas nesta seção algumas técnicas de combinação para *ensemble* de ELMs. A Seção 2.4 apresenta a teoria do funcionamento das máquinas de vetores suporte (*Support Vector Machines*) (SVM). A Seção 2.5 descreve os métodos de validação cruzada utilizados na divisão do banco de padrões em conjuntos de treinamento, validação e/ou teste. Por fim, a Seção 2.6 apresenta as medidas de desempenho de classificadores que são utilizadas para validar o método proposto.

### 2.1 RADIOLOGIA INDUSTRIAL APLICADA A JUNTAS SOLDADAS

A Radiologia Industrial é um ensaio não destrutivo (END) usado em inspeção industrial para detectar variações de regiões de materiais que apresentam diferenças em sua espessura ou densidade quando comparada com uma região vizinha, e que permitem identificar com boa sensibilidade defeitos volumétricos (descontinuidades). Esta técnica baseia-se na absorção diferenciada da radiação penetrante pela peça que está sendo inspecionada (ANDREUCCI, 2003).

A Figura 4 ilustra um exemplo de ensaio radiográfico. A absorção diferenciada da radiação pode ser detectada através de um filme radiográfico ou através de uma placa de fósforo, indicando a existência de uma falha interna ou defeito no material. A região defeituosa possui uma densidade volumétrica diferente da densidade do material ao seu redor,

sendo assim, absorve menos radiação, levando à formação de manchas que podem ser observadas nas imagens radiográficas (ANDREUCCI, 2003; FELISBERTO, 2007).



**Figura 4 - Técnica geral de ensaios radiográficos na indústria.**  
**Fonte: Andreucci (2003).**

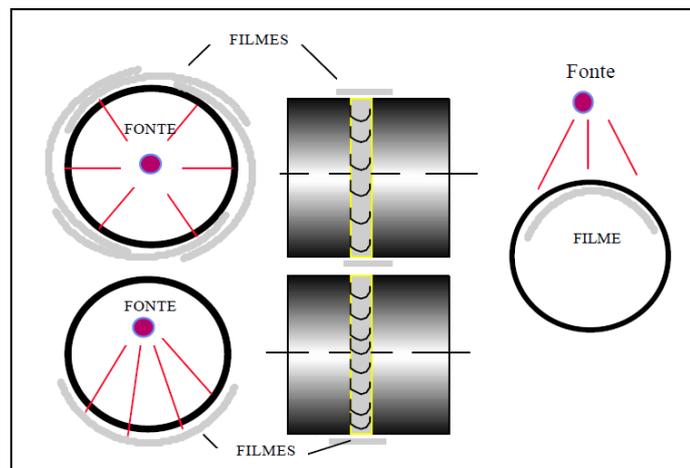
A densidade óptica de uma imagem radiográfica é uma função do número total de fótons que atingem cada ponto. O número total de fótons resulta da soma do número de fótons que atravessam o objeto e do número de fótons espalhados (difração) que atravessam o objeto. Os fótons que passam através do objeto fornecem a imagem e os fótons espalhados resultam no aumento de ruído, borrando e reduzindo o contraste da imagem. Por isso, a radiação dispersa que atinge o filme é uma causa importante de redução da qualidade da imagem (EDALATI et al., 2006).

### 2.1.1 Técnicas de Inspeção para Ensaios Radiográficos de Soldas em Tubulações

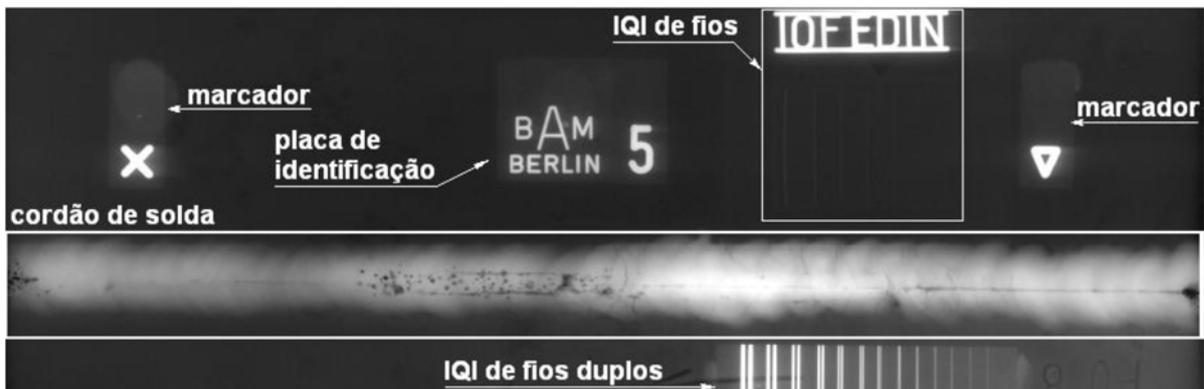
A seguir estão descritas algumas técnicas utilizadas e recomendadas por normas internacionais como ASME (*American Society of Mechanical Engineers*). Estas técnicas mostram os diferentes arranjos entre a fonte de radiação e a peça, e permitem a obtenção das imagens radiográficas. As Figuras 5, 6 e 7 mostram os arranjos entre a fonte-peça-filme para cada técnica apresentada, e exemplos de radiografias obtidas com estas técnicas (ANDREUCCI, 2003; FELISBERTO, 2007). A técnica utilizada depende do tipo do tubo e do acesso para realizar o ensaio.

### 2.1.1.1 Técnica radiográfica parede simples vista simples (PSVS)

Na técnica PSVS (Figura 5) somente a seção da peça que está próxima ao filme é inspecionada. A radiação emitida pela fonte atravessa a parede da tubulação por apenas um lado (de dentro para fora ou vice-versa). É a técnica utilizada em chapas e tubulações nas quais pode-se posicionar internamente o filme ou a fonte. A imagem resultante é um cordão linear, com uma qualidade melhor do que as obtidas em outras técnicas, o que torna mais fácil sua interpretação.



(a)



(b)

Figura 5 - Técnica de exposição PSVS. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante, com destaques do cordão de solda e outros artefatos usados na identificação.

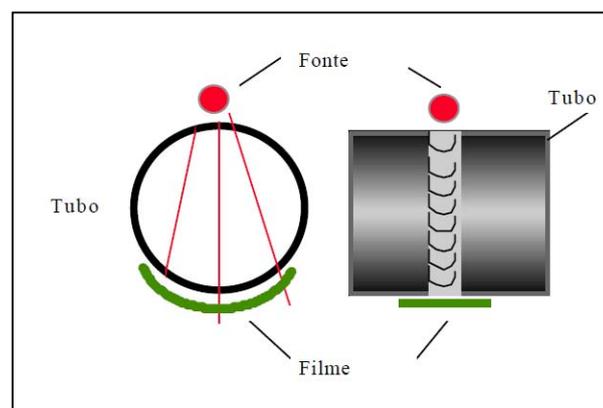
Fonte: Adaptado de Andreucci (2003).

### 2.1.1.2 Técnica radiográfica parede dupla vista simples (PDVS)

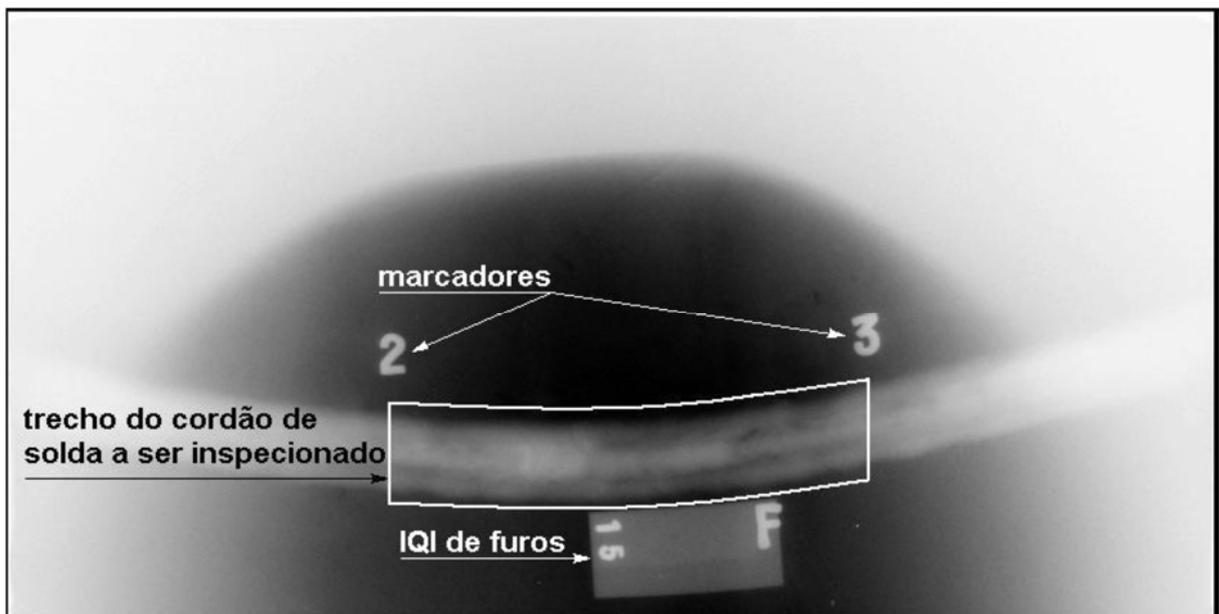
A técnica PDVS (Figura 6) é utilizada quando não se tem acesso ao interior da tubulação. A fonte e o filme são posicionados externamente e o feixe de radiação atravessa as

duas espessuras da peça, projetando no filme somente a seção da peça que está mais próxima ao mesmo. Como a radiação atravessa duas espessuras da peça o tempo de exposição e a difração serão maiores que na aquisição da imagem pela técnica de parede simples, afetando a qualidade da imagem (EDALATI et al., 2007). Quando a fonte de radiação está inclinada, a projeção do cordão de solda pode ter aspecto curvo.

Esta técnica é utilizada nas inspeções de juntas soldadas em tubulações com diâmetros maiores que 3½ polegadas (90mm), vasos fechados, e outros componentes que não permitam acesso interno.



(a)



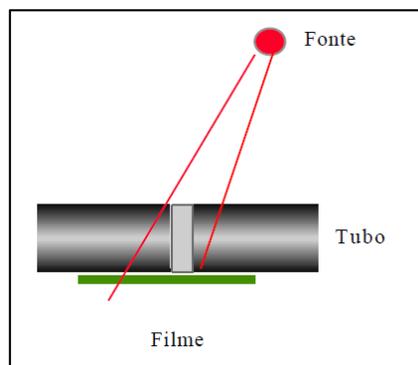
(b)

**Figura 6 - Técnica de exposição PDVS. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante, com destaques do cordão de solda e outros artefatos usados na identificação.**

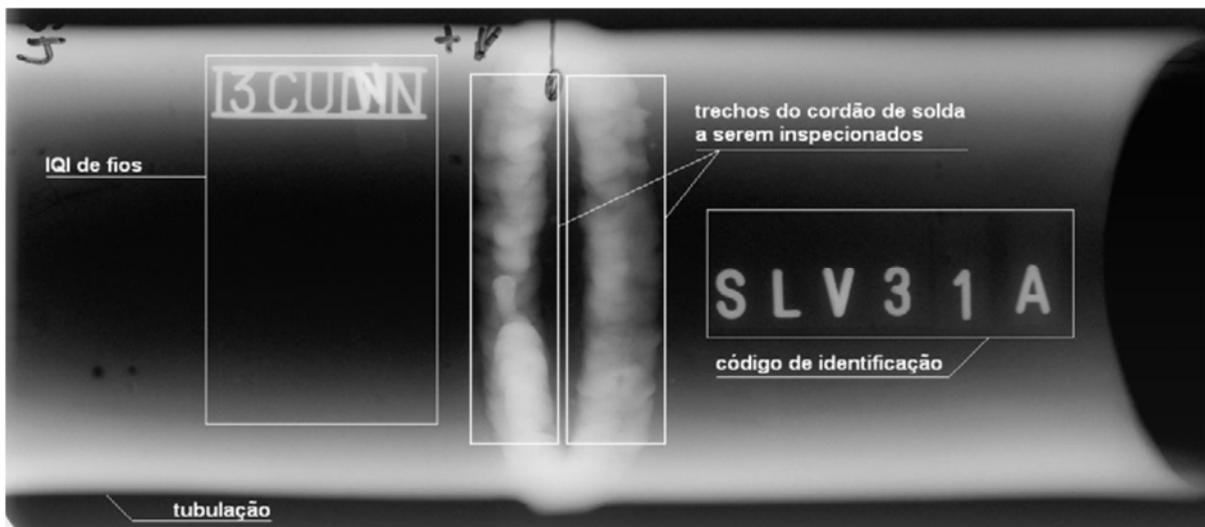
Fonte: Adaptado de Andreucci (2003).

### 2.1.1.3 Técnica radiográfica parede dupla vista dupla (PDVD)

Na técnica PDVD (Figura 7) a fonte fica posicionada a uma distância maior da peça e o feixe de radiação também atravessa duas espessuras, projetando no filme a imagem de duas seções da peça. A fonte de radiação pode ser posicionada alinhada ao cordão de solda ou com ligeira inclinação. No primeiro caso as projeções do cordão de solda das duas paredes da tubulação se apresentam sobrepostas, no segundo caso, as projeções dos dois cordões de solda formam uma elipse.



(a)



(b)

**Figura 7 - Técnica de exposição PDVD. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante, com destaques do cordão de solda e outros artefatos usados na identificação.**

Fonte: Adaptado de Andreucci (2003).

Nesta técnica o cálculo do tempo de exposição deve levar em conta as duas espessuras das paredes que serão atravessadas pela radiação. Esta técnica é utilizada em

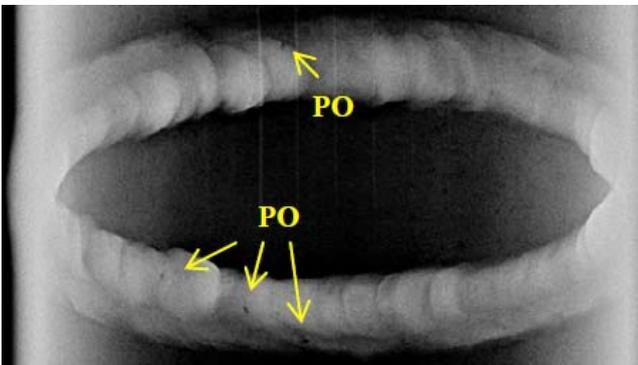
tubulações com diâmetros menores que 3½ polegadas (90mm), assim, não permitindo qualquer acesso interno para a inserção da fonte de radiação (BALAKRISHNAN, 2009; ANDREUCCI, 2003). Como o feixe de radiação atravessa o dobro de material, a difração (espalhamento) de raios-X é mais intensa, prejudicando a qualidade da imagem (EDALATI et al., 2007).

Neste trabalho, são utilizadas somente imagens PDVD, obtidas a partir de condições reais de operação. Estas duas situações combinadas afetam duplamente a qualidade da imagem, originada pela maior difração de raios-X, bem como pelas condições ambientais diversas na obtenção das imagens. A combinação destes dois fatores aumenta a incidência de ruídos e o aparecimento de manchas que podem ser entendidas como possíveis defeitos.

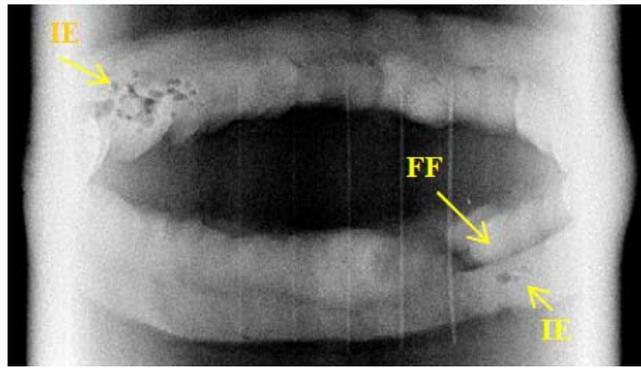
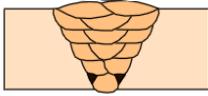
### 2.1.2 Classificação Estrutural das Descontinuidades em Juntas Soldadas

As descontinuidades encontradas na região soldada são classificadas em relação à falta de material ou à presença de materiais estranhos. A Tabela 1 apresenta as principais descontinuidades encontradas em juntas soldadas de tubulações e os efeitos que estes problemas causam nas imagens radiográficas utilizando a técnica de PDVD. Na primeira coluna aparece uma representação esquemática das descontinuidades, na segunda coluna, imagens processadas manualmente e laudadas por especialistas, com indicação dos tipos de descontinuidades presentes nas mesmas, e na terceira coluna uma descrição da causa e do efeito que estas produzem nas imagens (ANDREUCCI, 2003; FELISBERTO, 2007; MARINHO, 2009; MARQUES, 1991; WAINER; BRANDI; MELLO, 1992).

**Tabela 1 – Principais descontinuidades encontradas em juntas soldadas.**

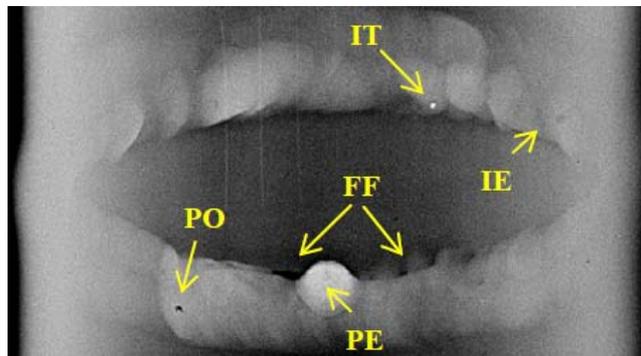
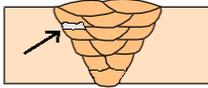
Representação	Imagem	Descrição
<p>Porosidade (PO)</p> 		<p>Durante a fusão da solda, a presença de impurezas na região da junta, como umidade, óleo, graxa ou a presença de correntes de ar, pode resultar no aprisionamento de bolhas de gases. Sua aparência radiográfica é sob a forma de manchas escuras.</p>

Inclusão de escória (IE)



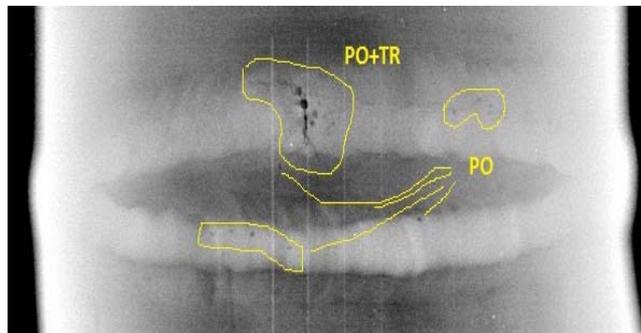
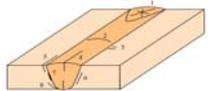
Causado pelo aprisionamento de escória ou materiais estranhos durante o processo de soldagem, devido à falta de limpeza de um determinado passe. Na imagem o aspecto é irregular.

Falta de fusão (FF)



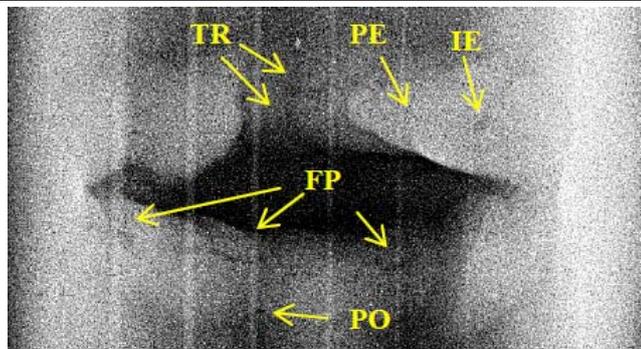
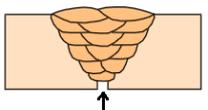
Descontinuidade provocada pela falta de fusão entre o metal depositado e o metal base ou entre as camadas de solda. Na imagem radiográfica o defeito falta de fusão forma manchas escuras, paralela ao eixo da solda, em ambos os lados. Os defeitos Inclusão de Tungstênio (IT) e Penetração Excessiva (PE) não foram explorados nesta pesquisa.

Trincas (TR)

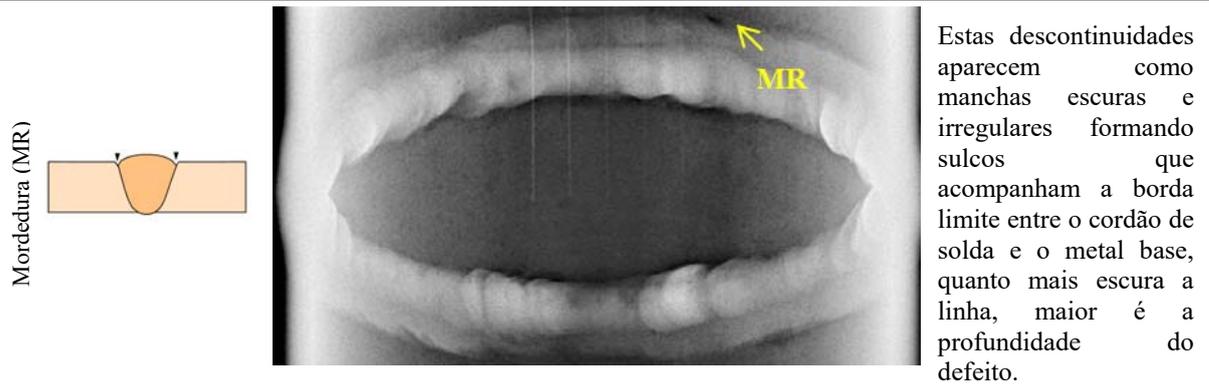


As trincas são produzidas por rupturas no metal como resultado de tensões produzidas durante a soldagem. A trinca produz uma imagem radiográfica na forma de uma linha escura com direção irregular. A largura desta linha dependerá da largura da trinca.

Falta de penetração (FP)



A falta de penetração é causada pela falta de material depositado na raiz da solda. A aparência radiográfica é uma linha escura e alongada, intermitente ou contínua, no centro do cordão.



Estas discontinuidades aparecem como manchas escuras e irregulares formando sulcos que acompanham a borda limite entre o cordão de solda e o metal base, quanto mais escura a linha, maior é a profundidade do defeito.

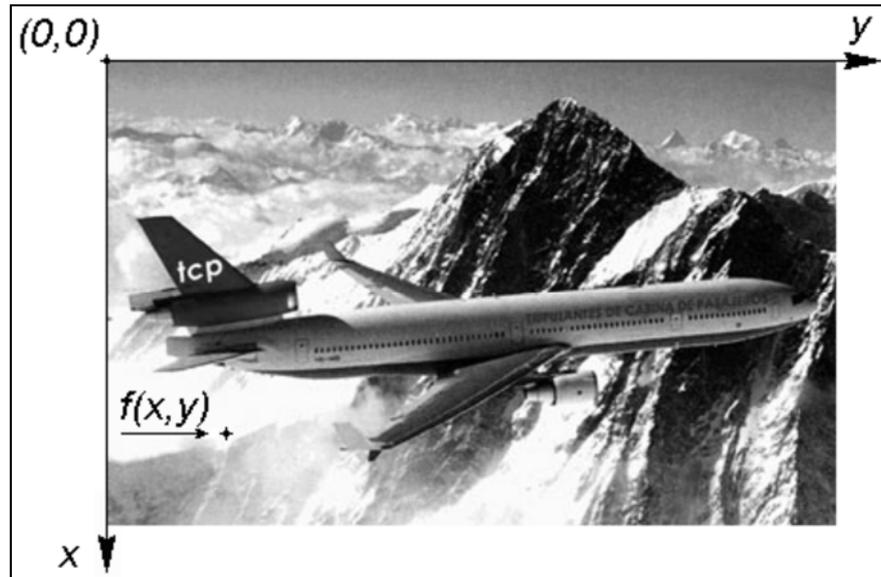
Fonte: Adaptado de Andreucci (2003), Felisberto (2007), Marinho (2009), Marques (1991), Wainer, Brandi e Mello (1992).

## 2.2 PROCESSAMENTO DIGITAL DE IMAGENS

O objetivo desta seção é apresentar uma série de conceitos e técnicas de processamento digital de imagens que serão utilizados ao longo deste trabalho, com a finalidade de auxiliar na compreensão do método proposto nesta tese. A diversificação das técnicas empregadas na etapa de processamento digital de imagens radiográficas é constatada nos diversos trabalhos que estão apresentados no Capítulo 3.

### 2.2.1 Imagens Digitais

Uma imagem pode ser definida como uma função bidimensional,  $f(x, y)$ , em que  $x$  e  $y$  são coordenadas espaciais (plano), e  $f$  é a amplitude em qualquer par de coordenadas  $(x, y)$ , também denominada de intensidade de nível de cinza ou ainda brilho da imagem nesse ponto, como ilustra a Figura 8. Em processamento de imagens a notação  $(x, y)$  pode ser entendida como (*linha, coluna*) (MARQUES FILHO; VIEIRA NETO, 1999). Quando  $x, y$  e os valores de intensidade de  $f$  são quantidades finitas e discretas, o resultado desta função é uma imagem digital (GONZALEZ; WOODS, 2010).



**Figura 8 – Exemplo de uma imagem monocromática e a convenção utilizada para o par de eixos  $(x, y)$ .**

**Fonte: Felisberto (2007)**

Pixel é o termo mais utilizado para representar o menor elemento constituinte de uma imagem digital. O termo resulta da aglutinação das palavras inglesas ‘*picture element*’ ou elemento de imagem e é indexado por uma posição  $(x, y)$  a partir da origem da imagem, (SOLOMON; BRECKON, 2013). No processo de digitalização de uma imagem as informações mais relevantes são: a amostragem das coordenadas  $x$  e  $y$  (resolução), e a quantização dos níveis de cinza de cada elemento.

A amostragem das coordenadas pode ser compreendida como a partição do plano que forma a imagem em uma grade. Dessa forma é comum analisar uma imagem digital como uma matriz de  $C$  colunas e  $R$  linhas, que representa o número de amostras existentes em uma imagem (número de pixels), ou seja, matriz  $C \times R$  (por exemplo,  $640 \times 480$ ,  $800 \times 600$ , etc.) (SOLOMON; BRECKON, 2013).

Da mesma forma, a quantização consiste em atribuir valores inteiros para cada elemento dessa grade (pixel). Em processamento de imagens o número de valores usualmente é assumido como potência de dois, como mostra a equação (1):

$$L=2^k \quad (1)$$

onde  $L$  é o número máximo de níveis distintos de cinza do elemento  $f(x,y)$ .

As imagens radiográficas utilizadas neste trabalho são puramente monocromáticas, fornecidas no formato digital e com 65536 tons de cinza.

## 2.2.2 Histograma

O histograma de uma imagem digital com níveis de intensidade no intervalo  $(0, L-1)$  é uma função discreta  $h(r_k)=n_k$ , onde  $r_k$  é o  $k$ -ésimo valor de intensidade e  $n_k$  é o número de pixels da imagem com intensidade  $r_k$  (GONZALEZ; WOODS, 2010). Técnicas de manipulação de histograma podem ser utilizadas para o realce de imagens. A Seção 2.2.2.1 e 2.2.2.2 apresentam duas técnicas de manipulação de histograma usadas nesta tese.

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 (KEHOE; PARKER, 1990). A etapa de melhoramento do contraste das radiografias é posterior à eliminação de ruídos, para que estes não sejam realçados conjuntamente com o contraste.

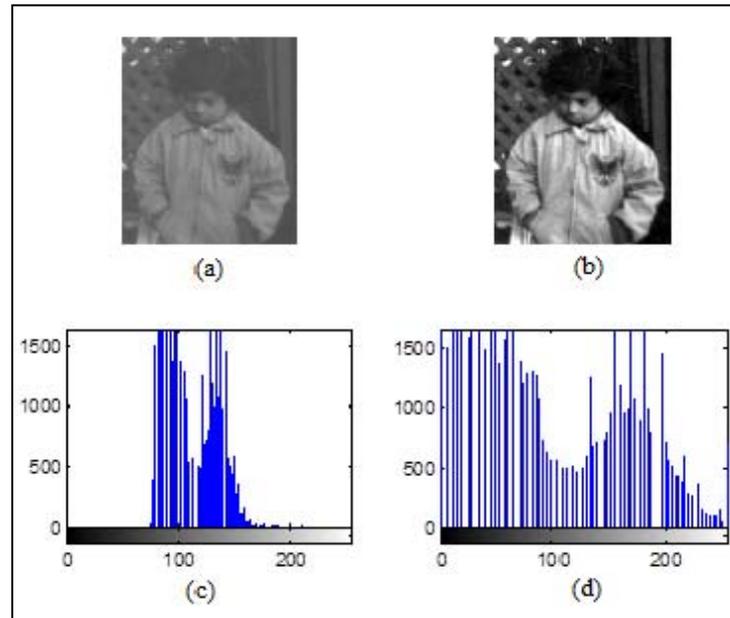
### 2.2.2.1 Expansão de histograma

A expansão de histograma é uma operação que alonga a faixa de intensidade de pixel da imagem de entrada para que a imagem de saída tenha uma faixa dinâmica mais larga. A técnica de expansão de histograma aumenta o contraste da imagem ocupando toda a faixa de cinza da imagem. Foi utilizada no realce da imagem radiográfica desta pesquisa somente para visualização e apresentação final do resultado, mas não para segmentação das discontinuidades.

Para efetuar o alongamento, devem-se conhecer os limites superior e inferior dos valores de pixels, respectivamente denotados por  $a$  e  $b$  ao longo dos quais a imagem deve ser expandida. A operação de alongamento determina o maior e o menor valor de nível de cinza da imagem, respectivamente denotados por  $c$  e  $d$ . Com base nesses quatro valores, a faixa de valores de saída do pixel é alongada segundo a equação (2) (SOLOMON; BRECKON, 2013).

$$g(x, y) = (f(x, y) - c) \left( \frac{b-a}{d-c} \right) + a \quad (2)$$

A Figura 9 apresenta o resultado do aprimoramento de contraste utilizando a expansão de histograma. Abaixo de cada imagem estão representados os seus respectivos histogramas.



**Figura 9 – Expansão de histograma. (a) Imagem original. (b) Imagem realçada. (c) Histograma da imagem original. (d) Histograma da imagem expandida.**

#### 2.2.2.2 Equalização de histograma

Outra maneira de aprimorar o contraste é realizando uma equalização do histograma. O objetivo desta operação é redistribuir os níveis de cinza de maneira mais uniforme, o que é realizado através da função discreta de distribuição acumulada  $s_k$ , definida pela equação (3) (GONZALEZ; WOODS, 2010):

$$s_k = \sum_{j=0}^k \left( \frac{n_j}{n_T} \right), \text{ para } 0 \leq n_j \leq n_T \text{ e } k = 0, 1, \dots, L-1 \quad (3)$$

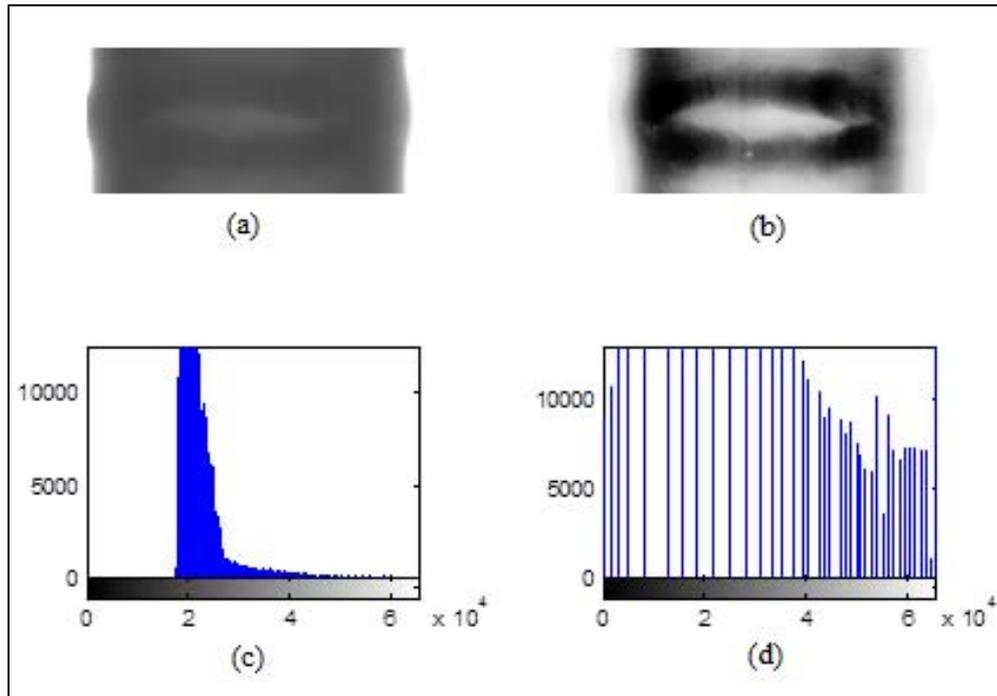
onde:  $s_k$  corresponde ao novo valor a ser atribuído aos *pixels* de tom de cinza  $k$ ,

$n_j$  é a quantidade de *pixels* no tom de cinza  $j$ ,

$n_T$  é o total de *pixels* na imagem,

$(n_j/n_T)$  é a probabilidade de um *pixel* qualquer ser no tom de cinza  $j$ .

A Figura 10 permite visualizar o resultado da equalização do histograma para uma imagem radiográfica de solda de 16 bits que apresenta baixo contraste. A equalização de histograma pode criar dados na imagem, como ruídos ou artefatos (GONZALEZ; WOODS, 2010).



**Figura 10 – Equalização de histograma. (a) Imagem original. (b) Imagem equalizada. (c) Histograma da imagem original. (d) Histograma da imagem equalizada.**

### 2.2.3 Filtragem Espacial para Remoção ou Suavização de Ruídos

Filtros de suavização espacial são operações de redução de ruídos de alta frequência e detalhes de pequena escala, normalmente aplicados na imagem radiográfica antes da detecção de objetos de maior escala, como cordão de solda ou discontinuidades. O efeito final produzido pelos filtros é suavizar (borrar) uma imagem (GONZALEZ; WOODS, 2010). A aplicação dos filtros deve ser realizada com critérios para que as informações relevantes não sejam perdidas, o que pode gerar, por exemplo, o sub-dimensionamento de um defeito ou até mesmo a sua exclusão da imagem (SILVA, 2003).

A ideia por trás dos filtros de suavização espacial é simples: a substituição dos valores de um determinado pixel por uma média ponderada do seu valor e dos pixels vizinhos, cujos pesos são definidos por uma máscara (*kernel*, janela) de suavização (GONZALEZ; WOODS, 2010). O resultado deste processo, ou seja, a forma e intensidade com que detalhes e ruídos são eliminados da imagem original, dependem do formato e dos valores definidos na máscara utilizada.

### 2.2.3.1 Filtragem pela média

No filtro da média cada pixel é substituído pela média da sua vizinhança. Convolui-se a imagem por uma máscara cujos coeficientes são todos iguais a 1 e divide-se o resultado pelo total de pixels da máscara. As máscaras mais usadas são de 3x3, 5x5 e 7x7. Máscaras maiores podem ser usadas, porém a imagem sofrerá grande atenuação. Na escolha do tamanho da máscara deve-se ter em mente que quanto maior a máscara, maior o grau de borramento da imagem resultante.

O filtro de média é razoavelmente eficaz na remoção de ruído gaussiano, à custa de perda de detalhes de alta frequência da imagem (bordas) (SOLOMON; BRECKON, 2013).

### 2.2.3.2 Filtragem pela mediana

Uma das principais limitações do filtro da média em situações onde o objetivo é remoção de ruídos em imagens é causar a perda de nitidez atenuando bordas e detalhes finos da imagem (MARQUES FILHO; VIEIRA NETO, 1999). Para contorná-la, uma técnica alternativa é o filtro da mediana.

No filtro da mediana cada pixel-alvo é substituído pela mediana estatística dos valores NxM da sua vizinhança (SOLOMON; BRECKON, 2013). Uma das principais características do filtro da mediana é o seu efeito mais brando em borrar as regiões de contorno de objetos, preservando detalhes relevantes (GONZALEZ; WOODS, 2010).

Wang e Liao (2002) relatam que o filtro de mediana com janela de 3x3 e 5x5 é o mais adequado para ser aplicado nas radiografias de juntas soldadas.

### 2.2.3.3 Filtro de Wiener

O filtro de Wiener é um filtro adaptativo baseado em estatísticas estimadas de uma vizinhança local de cada pixel. No método de Wiener a imagem usa janelas de tamanho NxN para estimar a média local da imagem, o desvio padrão através de média local e a variância em torno de cada pixel. A suavização aplicada à imagem é inversamente proporcional à variância (GONZALEZ; WOODS, 2010; PRATT, 1972). O filtro adaptativo de Wiener busca preservar as bordas e outras discontinuidades de alta frequência em uma imagem. Zapata,

Vilar e Ruiz (2011) utilizam o método de Wiener com janelas de tamanho 7x7 na filtragem de ruídos de imagens radiográficas de tubulações.

#### 2.2.3.4 Seleção do filtro de remoção e suavização de ruídos

Liao (1996) destaca a dificuldade existente para suavização de ruídos em imagens radiográficas, devido à grande variação de níveis de cinza existente neste tipo de imagens, sendo difícil a escolha de um filtro ou uma técnica de suavização que possa ser utilizada em todas as imagens radiográficas.

Segundo Marques Filho e Vieira Neto (1999) a interpretação de qual filtro de suavização é mais adequado normalmente é subjetiva e depende de conhecimento prévio do observador a respeito das imagens analisadas.

Partindo destes pressupostos, a definição do filtro de suavização se deu através de testes e análise para o conjunto de imagens disponibilizado para esta pesquisa. Neste trabalho utilizaram-se os filtros de média, mediana e Wiener. O filtro de Wiener foi utilizado na etapa de segmentação das descontinuidades, por permitir a redução de falsos positivos (não defeitos). Quando o objetivo era segmentar um objeto maior, no caso o cordão de solda, foi utilizado o filtro de mediana. O filtro de média foi utilizado para borrar a imagem e obter a máscara de nitidez, técnica apresentada na Seção 2.2.5.

#### 2.2.4 Processamento Morfológico de Imagens

O princípio de funcionamento de um algoritmo morfológico é a extração de informações da forma ou estrutura de um determinado conjunto conhecido (imagem) através de transformações a partir de outro conjunto conhecido (elemento estruturante). A Figura 11 apresenta alguns exemplos de elementos estruturantes. Nesta figura o ponto mais escuro indica a origem de seu sistema de coordenadas, ou seja, a posição do pixel em que o resultado será atribuído.

As operações morfológicas agem sobre uma determinada vizinhança dos pixels, cuja forma e extensão são definidas pela sobreposição do elemento estruturante sobre cada pixel da imagem. O novo valor de cada pixel da imagem depende dos valores dos pixels na vizinhança definida pelo elemento estruturante.

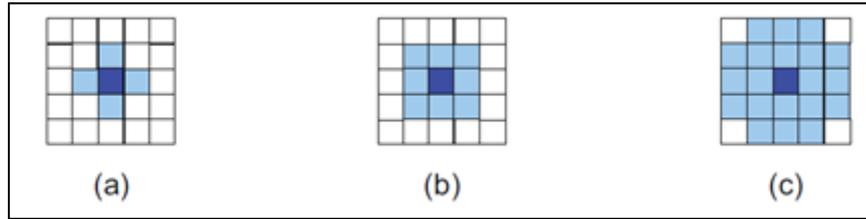


Figura 11 – Exemplos de elementos estruturantes. (a) Estrela 3x3. (b) Quadrado 3x3. (c) Octógono 5x5.  
Fonte: Adaptado de Gonzalez e Woods (2010).

Operações morfológicas podem ser aplicadas a imagens de todos os tipos, no processamento de imagens binárias e em imagens de tons de cinza.

#### 2.2.4.1 Operações morfológicas de erosão e dilatação para imagens binárias

A erosão é definida pela equação (4), onde  $A$  é a imagem de entrada e  $B$  é o elemento estruturante. Assim,  $A \ominus B$ , consiste de todos os pontos  $x$  para os quais a translação de  $B$  por  $x$  está contida em  $A$  (GONZALEZ; WOODS, 2010).

$$A \ominus B = \{ x : B_x \subset A \} \quad (4)$$

A Figura 12 ilustra o resultado da aplicação da operação morfológica de erosão sobre uma imagem segmentada do cordão de solda. Na Figura 12(b) observa-se que a erosão ocorre sobre a parte da imagem da Figura 12(a) com nível 1 (parte branca da imagem). Esta operação aumenta a abrangência da região de interesse (ROI).



Figura 12 – Exemplo da aplicação da operação morfológica de erosão sobre uma imagem segmentada do cordão de solda. (a) Imagem antes da erosão. (b) Imagem após a erosão.

A dilatação é definida pela equação (5). Essa equação baseia-se na reflexão de  $B$  em torno de sua origem, seguida da translação dessa reflexão por  $x$ . Dessa forma a dilatação de  $A$

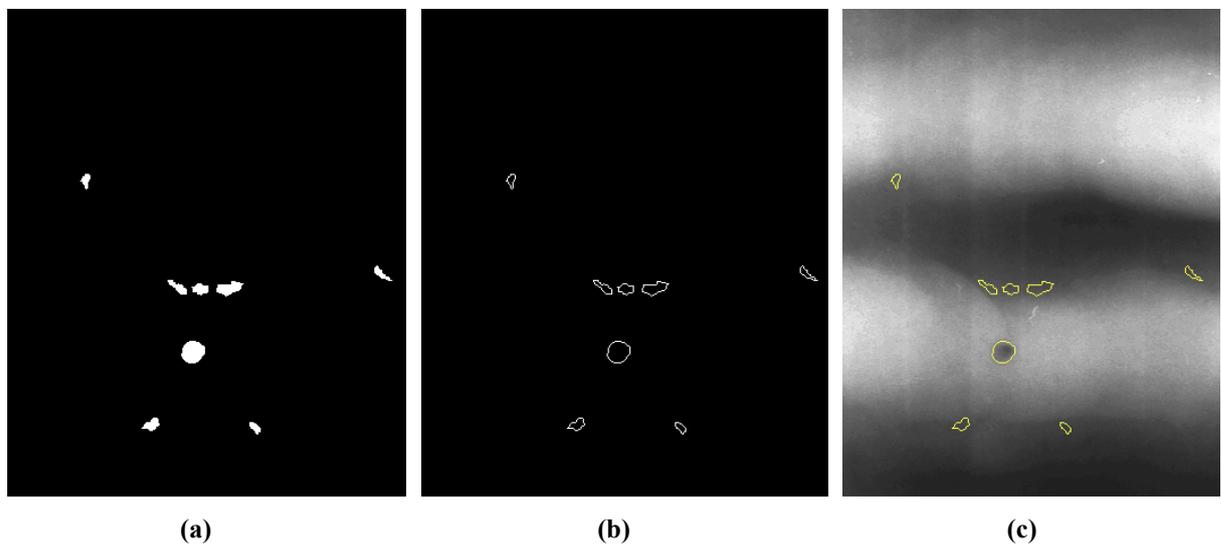
por B é o conjunto de todos os deslocamentos de  $x$ , de forma que B e A se sobreponham pelo menos por um elemento (GONZALEZ; WOODS, 2010).

$$A \oplus B = \{x \in A : B_x \cap x \neq \emptyset\} \quad (5)$$

#### 2.2.4.2 Extração de bordas em imagens binárias por operadores morfológicos

Uma das formas para obter a fronteira ou perímetro de um objeto em uma imagem binária é através da subtração entre a imagem original e a erosão da imagem com um elemento estruturante apropriado. Para uma imagem binária A e um elemento estruturante B, a fronteira  $A_p$  é definida como  $A_p = A - A \ominus B$  (GONZALEZ; WOODS, 2010).

A Figura 13 ilustra o resultado da aplicação da operação morfológica de extração de bordas sobre um recorte da imagem segmentada do cordão de solda. Na imagem resultante, mostrada na Figura 13(c), as bordas das discontinuidades detectadas são plotadas sobre uma imagem em tons de cinza. Este procedimento serve para representar as discontinuidades detectadas. Numa etapa posterior, após a etapa de classificação, estas discontinuidades são representadas com o uso de cores diferentes para cada classe.



**Figura 13 – Exemplos da aplicação de extração de bordas de imagem binária. (a) Imagem binária. (b) Imagem binária com bordas extraídas por operador morfológico. (c) Bordas das discontinuidades realçadas sobre a imagem em tons de cinza.**

#### 2.2.4.3 Abertura e fechamento em escala de cinza

Abertura é o nome dado à operação morfológica de erosão seguida de dilatação com o mesmo elemento estruturante. A abertura aplicada em imagens em tons de cinza tem o efeito geral de remover pequenos detalhes brilhantes da imagem e deixar regiões escuras inalteradas.

Fechamento é o nome dado à operação morfológica de dilatação seguida de erosão com o mesmo elemento estruturante. O fechamento aplicado em imagens em tons de cinza tende a suprimir pequenas regiões escuras.

#### 2.2.4.4 Transformação *top-hat* e *bottom-hat*

A transformação *top-hat* para imagens em tons de cinza é definida por Solomon & Breckon (2013) como a diferença entre uma imagem original  $I$  e a imagem que resulta da abertura com o elemento estruturante  $b$ , ou seja,  $I - (I \circ b)$ . A diferença entre o original e a imagem aberta tende a realçar os detalhes claros na presença de sombras.

Por essa razão, a transformação *top-hat* é útil na recuperação de detalhes que se tornaram invisíveis devido à variação de iluminação ou sombreamento da imagem (SOLOMON; BRECKON, 2013). Nas imagens radiográficas utilizadas, os defeitos são objetos claros sobre um fundo escuro, portanto, a aplicação desta operação resulta no realce dos defeitos.

A transformação *bottom-hat* é o resultado do fechamento de uma imagem e posterior subtração entre este resultado e a própria imagem original e tem a propriedade de extrair da imagem seus vales e detalhes escuros.

#### 2.2.5 Máscara de Nitidez e Filtragem *High-Boost*

A máscara de nitidez é utilizada para aumentar a nitidez de imagens e consiste em subtrair uma versão não nítida (suavizada) de uma imagem pela sua imagem original. Esse processo, chamado de máscara de nitidez (GONZALES; WOODS, 2010) consiste nos seguintes passos:

1. Borrar a imagem original, com utilização de um filtro de média, por exemplo.

2. Subtrair a imagem borrada da original (a diferença resultante é chamada de máscara).
3. Adicionar a máscara à imagem original.

Com  $f_s(x, y)$  denotando a imagem borrada e  $f(x, y)$  a imagem original, a máscara de nitidez é expressa na forma da equação (6).

$$g_{máscara}(x, y) = f(x, y) - f_s(x, y) \quad (6)$$

Depois, é adicionada uma porção ponderada da máscara de nitidez à imagem original, com a inclusão de um peso,  $k$  ( $k \geq 0$ ), representado pela equação (7).

$$g(x, y) = f(x, y) + k * g_{máscara}(x, y) \quad (7)$$

Se  $k \geq 1$ , o processo é chamado de filtragem *high-boost*. Escolher  $k < 1$ , atenua a contribuição da máscara de nitidez.

### 2.2.6 Segmentação/Limiarização

A limiarização é uma técnica de segmentação de imagem que visa separar o objeto de interesse do fundo da imagem (GONZALEZ; WOODS, 2010). As imagens de saída obtidas pela aplicação desta técnica podem ser de diferentes níveis de cinza, mas geralmente são binárias. Neste caso a limiarização consiste em converter imagens em tons de cinza para imagens binárias. O objetivo principal é a eliminação de informações irrelevantes, restando apenas os objetos de interesse na imagem, como por exemplo, as descontinuidades existentes no cordão de solda que possam representar defeitos de soldagem. Na operação de limiarização binária, uma imagem de entrada  $f(x, y)$  com N tons de cinza produz à saída uma imagem  $g(x, y)$  chamada imagem limiarizada ou binarizada, definida pela equação (8):

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) \geq T \\ 0 & \text{se } f(x, y) < T \end{cases} \quad (8)$$

onde  $T$  é um valor de nível de cinza denominado limiar (GONZALEZ; WOODS, 2010).

Se apenas um único limiar é utilizado para toda a imagem a limiarização é denominada de global. Quando a imagem é sub-dividida em várias sub-imagens e um limiar é definido para cada sub-região, a limiarização é denominada local ou adaptativa.

A segmentação das imagens radiográficas nem sempre conduz a resultados satisfatórios. A maioria das técnicas empregadas, se não forem devidamente controladas, podem causar a eliminação de informações importantes na imagem, provocando, por exemplo, o subdimensionamento de defeitos solda, e prejudicando desta maneira etapas posteriores de extração de características e classificação (SILVA, 2003).

A limiarização é um processo simples, porém a maioria das aplicações requer que o valor de  $T$  seja determinado automaticamente. Algumas das técnicas utilizadas para encontrar tal valor são descritas a seguir:

#### 2.2.6.1 Limiarização pela técnica de Otsu

Otsu (1979) propõe uma técnica não paramétrica (não estima parâmetros do modelo) e não supervisionada para a seleção automática do limiar visando a segmentação da imagem.

A aplicação do limiar global de Otsu trata o histograma da imagem como uma função densidade de probabilidade discreta definida pela equação (9).

$$Pr(r_q) = n_q/n \quad , \quad q = 0, 1, 2, \dots, L-1 \quad (9)$$

Onde:

$n$  = número total de pixels da imagem

$n_q$  = número de pixels com intensidade  $r_q$

$L$  = número total dos possíveis níveis de intensidade da imagem

Um valor  $k$  para o limiar pode ser escolhido tal que:

$C_0$  seja a classe de pixels com níveis entre  $[0, k-1]$  e

$C_1$  seja a classe de pixels com níveis entre  $[k, L-1]$

O método de Otsu escolhe um valor de  $k$  que maximize a variância inter-classes definida pela equação (10).

$$\sigma_B^2 = \omega_0 (\mu_0 - \mu_T)^2 + \omega_1 (\mu_1 - \mu_T)^2 \quad (10)$$

Os parâmetros da equação (10) são descritos nas equações (11) a (15):

$$\omega_0 = \sum_{q=0}^{k-1} p_r(r_q) \quad (11)$$

$$\omega_1 = \sum_{q=k}^{L-1} p_r(r_q) \quad (12)$$

$$\mu_0 = \sum_{q=0}^{k-1} qp_r(r_q)/\omega_0 \quad (13)$$

$$\mu_1 = \sum_{q=k}^{L-1} qp_r(r_q)/\omega_1 \quad (14)$$

$$\mu_T = \sum_{q=0}^{L-1} qp_r(r_q) \quad (15)$$

Um limiar ótimo é selecionado de forma automática e estável, baseado em propriedades globais do histograma. O método de Otsu pressupõe que o histograma contém uma mistura de Gaussianas bimodal, ou seja, ele trabalha com a suposição de que existem duas classes distintas, e que as probabilidades ao redor da intensidade média de cada classe seguem distribuições normais (GONZALEZ; WOODS, 2010).

#### 2.2.6.2 Aplicação adaptativa de limiar

A aplicação adaptativa de limiar usa um limiar global sobre a máscara de nitidez definida na Seção 2.2.5. O limiar é fixo, porém, influenciado pelos valores dos pixels na vizinhança do pixel em consideração.

O algoritmo de limiarização proposto por Solomon e Breckon (2013) aplica o filtro da média com uma máscara  $N \times N$  sobre a imagem e em seguida soma uma constante  $C$  (definida empiricamente) sobre esta imagem para obter uma imagem mais clara. A escolha de  $N$  é importante e seu valor deve ser suficientemente grande para, em cada ponto, cobrir um número adequado de pixels do objeto e do fundo, mas não deve ser demasiadamente grande a ponto de permitir que as deficiências de iluminação global afetem a limiarização. Em seguida, a imagem resultante é subtraída da imagem original. Essa operação gera baixos valores de

níveis de cinza. Segundo Solomon e Breckon (2013) a região limiarizada é obtida convertendo para o nível máximo os valores que estão acima de zero e para o nível mínimo os valores iguais a zero.

### 2.2.7 Rotulagem

O algoritmo de rotulagem encontra as componentes conectadas em uma imagem e atribui um único rótulo (*label*) a todos os pontos da mesma componente.

A seguir estão descritas as etapas de um algoritmo sequencial utilizado para rotular objetos em imagens binárias (GONZALEZ; WOODS; EDDINS, 2004).

1. Varrer a imagem da esquerda para a direita e de cima para baixo.
2. Se o pixel é igual a 1, então analisam-se os vizinhos superior e o da esquerda:
  - a. Se apenas um dos vizinhos, tem *label*, copia-se o *label*.
  - b. Se ambos tem o mesmo *label* então copia-se o *label*.
  - c. Se os *labels* são diferentes então copia-se o *label* superior e colocam-se os 2 *labels* em uma tabela de equivalência como o mesmo *label*.
  - d. Em outro caso atribui-se um novo *label* para este pixel.
3. Se há mais pixels, vá ao passo 2.
4. Varrer novamente a imagem. Substituir cada *label* pelo *label* de valor inferior na tabela de equivalência. Isso é realizado com uma estrutura de dados clássica conhecida como *union-find*.

## 2.3 REDES NEURAIAS ARTIFICIAS APLICADAS NO RECONHECIMENTO DE PADRÕES

### 2.3.1 Padrão de uma Classe

A definição mais comum para Padrão de uma Classe é a adotada por Gonzales e Woods (2010) 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 frequentemente conhecidos como características. Uma classe de padrões pode ser considerada como uma família de padrões que compartilhem algumas propriedades comuns (GONZALES; WOODS, 2010).

O reconhecimento de padrões por máquinas envolve técnicas de atribuição de padrões às suas respectivas classes de forma automática e com a menor intervenção humana possível (GONZALES; WOODS, 2010).

Os vetores de características (*feature vector*) são representados por letras minúsculas em negrito, como  $\mathbf{x}$ ,  $\mathbf{y}$ , e  $\mathbf{z}$ , e assumem a forma apresentada na equação (16).

$$\mathbf{x} = (x_1, x_2, x_3, \dots, x_n) \quad (16)$$

Onde  $x_i$  representa cada componente de entrada, ou seja, a  $i$ -ésima característica, e  $n$  é o número de características.

### 2.3.2 Redes Neurais Artificiais

Em termos intuitivos, redes neurais artificiais (RNAs) são modelos inspirados nos princípios de funcionamento dos neurônios biológicos e na estrutura do cérebro. Estes modelos têm capacidade de adquirir, armazenar e utilizar conhecimento experimental e buscam simular computacionalmente habilidades humanas tais como aprendizado, generalização, associação e abstração (GOLDSCHMIDT, 2010).

A Figura 14 apresenta uma analogia entre os modelos de neurônios biológico e artificial. Como o cérebro humano é capaz de aprender e tomar decisões baseadas na aprendizagem, as redes neurais artificiais devem fazer o mesmo. Assim, uma rede neural pode ser interpretada como um esquema de processamento capaz de armazenar conhecimento baseado em aprendizagem (experiência) e disponibilizar este conhecimento para solução de problemas (GOLDSCHMIDT, 2010).

Fazendo uma analogia com o tema de tese proposto: um inspetor de imagens radiográficas de soldas em tubulações 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.

Segundo Haykin (2001), uma rede neural artificial se assemelha ao cérebro humano em dois aspectos:

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

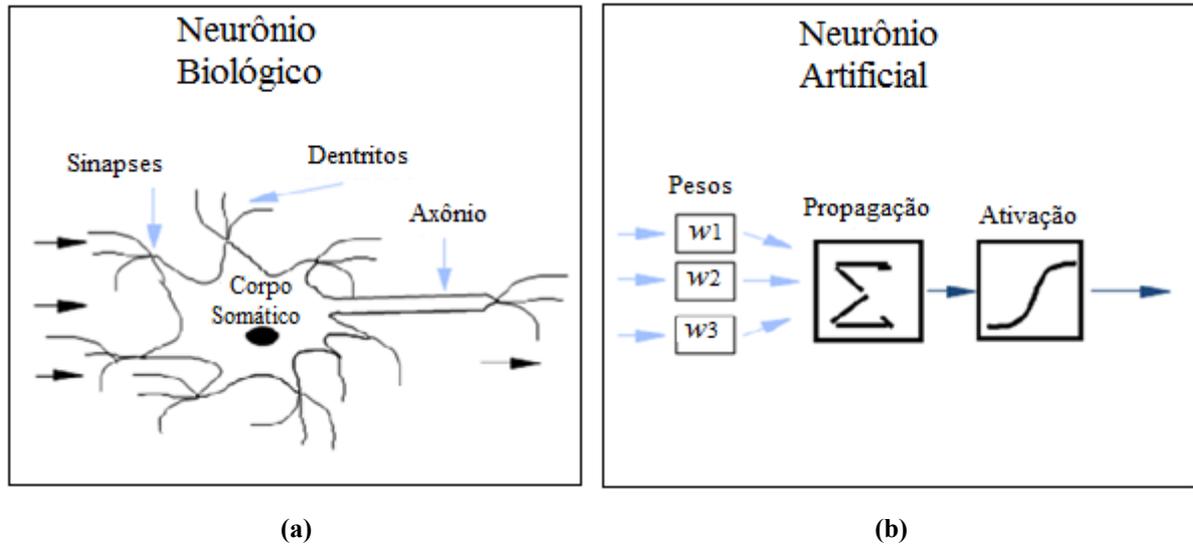


Figura 14 - Analogia entre os modelos de um neurônio. (a) Biológico. (b) Artificial.  
Fonte: Adaptado de Goldschmidt (2010).

O neurônio artificial possui diversas entradas, que correspondem às conexões sinápticas com outros neurônios e uma saída, que é a soma das entradas multiplicadas por pesos. Conforme mostrado na Figura 14, o processo sináptico é representado pelos pesos ( $w$ ) que amplificam/atenuam cada um dos sinais de entrada recebidos. O neurônio é a unidade fundamental de processamento de uma rede neural. A Figura 15 ilustra um modelo de um neurônio artificial, base para elaboração de diversos tipos de arquitetura de redes neurais artificiais.

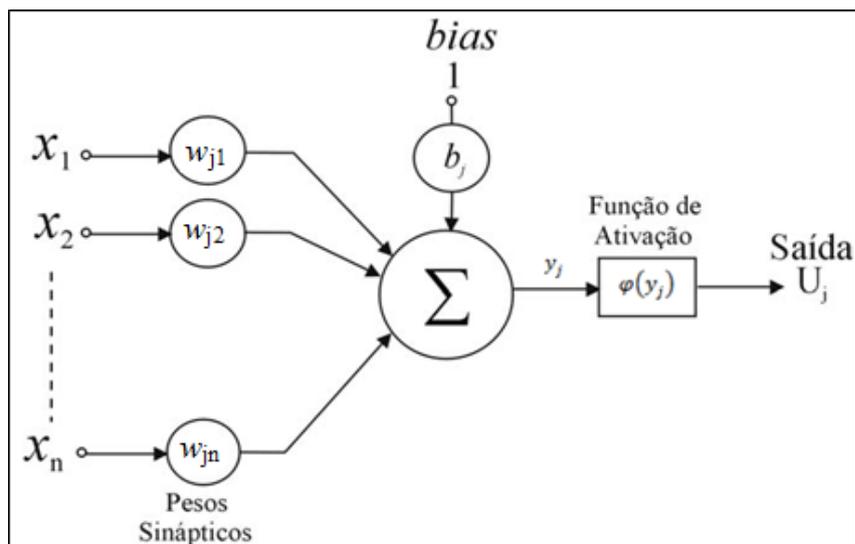


Figura 15 – Modelo de um neurônio artificial.  
Fonte: Haykin (2001).

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 15 inclui uma polarização (ou *bias*  $b_j$ ) aplicada 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 pelas equações (17) e (18):

$$y_j = \sum_{i=1}^n w_{ji}x_i + b_j \quad (17)$$

$$U_j = \varphi(y_j) \quad (18)$$

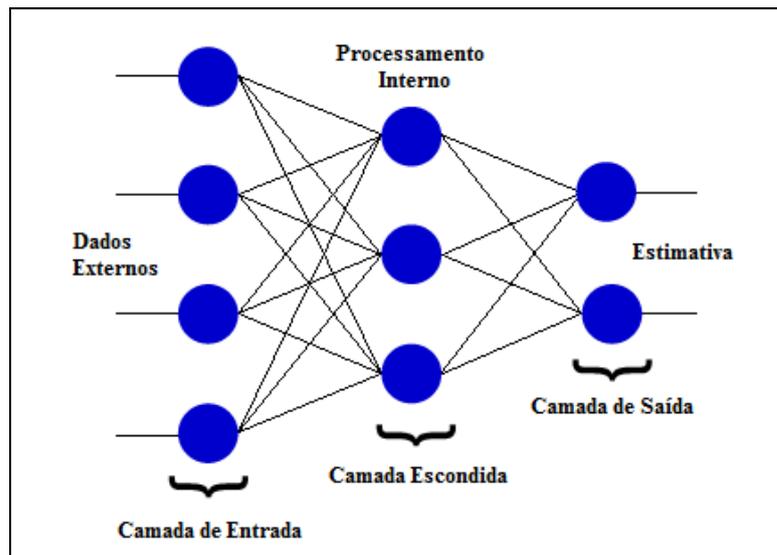
Onde  $x_1, x_2, x_3, \dots, x_n$  são as entradas do neurônio;  $w_{j1}, w_{j2}, w_{j3}, \dots, w_{jn}$  são os pesos sinápticos do neurônio  $j$ ;  $y_j$  é a combinação linear das entradas e do *bias*  $b_j$  e  $\varphi$  é a função de ativação (HAYKIN, 2001).

A função de ativação modela a forma como o neurônio responde ao nível de excitação, limitando e definindo a saída da rede neural. Ela também determina o novo valor do estado de ativação deste neurônio, e pode assumir várias formas: linear, rampa, degrau, sigmoide ou tangente hiperbólica.

A arquitetura de uma rede neural pode ser organizada de diversas formas, dependendo da necessidade da aplicação. Basicamente os itens que compõem a rede neural são:

- Quantidade de neurônios e número de camadas intermediárias
- Formas de conexão
- Função de ativação
- Algoritmo de treinamento

Em uma RNA os neurônios são dispostos em camadas, com conexões entre elas. A Figura 16 ilustra graficamente a arquitetura de uma RNA simples. Os círculos representam os neurônios e as linhas representam os pesos das conexões. Por convenção, a camada que recebe os dados é a camada de entrada e a camada que fornece o resultado é a de camada de saída. A camada interna, onde ocorre o processamento interno da rede, é a camada escondida ou oculta. Uma RNA pode conter uma ou várias camadas escondidas, de acordo com a complexidade do problema (GOLDSCHMIDT, 2010).



**Figura 16– Arquitetura de uma RNA simples.**  
**Fonte: Adaptado de Goldschmidt (2010).**

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.

Para este trabalho de pesquisa, como dispomos de um conjunto de padrões de defeitos para treinamento, foi utilizada a aprendizagem supervisionada, que envolve a modificação dos pesos sinápticos da rede pela aplicação de um conjunto de dados composto por entradas (vetores de características) e suas respectivas saídas desejadas (classes).

### 2.3.3 Redes com Múltiplas Camadas

*Perceptrons* de Múltiplas Camadas (MLP – *Multi-Layer Perceptron*) são redes que consistem de múltiplas camadas de unidades computacionais, em geral completamente interconectadas (*feedforward*). Isso quer dizer que cada neurônio em uma camada tem conexões com todos os neurônios da camada seguinte, não havendo conexões entre neurônios de uma mesma camada, ou conexões com uma camada anterior.

Segundo Haykin (2001) a função sigmoide é a mais empregada na construção de redes neurais MLP. Goldschmidt (2010) também afirma que em muitas aplicações, essas redes utilizam a função sigmoide como função de ativação. A função sigmoide é definida por Haykin (2001) como uma função estritamente crescente que exibe um balanceamento adequado entre comportamento linear e não-linear. A função de ativação sigmoide definida na equação (19), apresenta uma saída no intervalo [0; 1] (Figura 17).

$$\varphi(y_j) = 1/(1 + \exp(-y_j)) \quad (19)$$

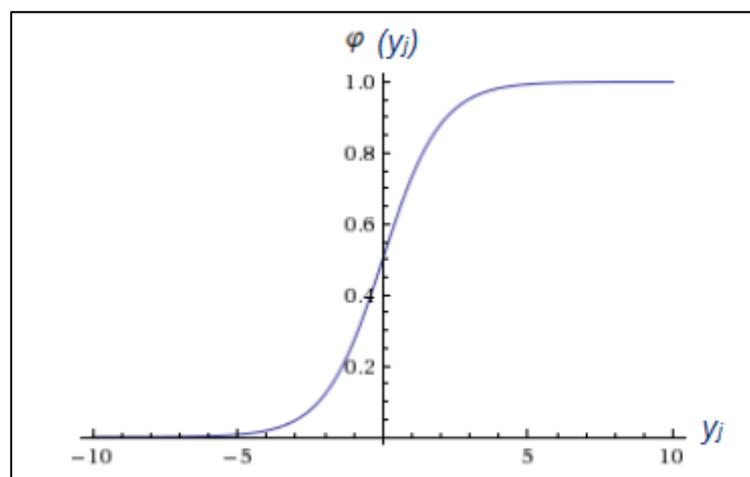


Figura 17 – Gráfico da função de ativação sigmoide

#### 2.3.3.1 Algoritmo de treinamento de MLP

A forma tradicional de treinamento de redes *Perceptron* de Múltiplas Camadas - *Multi-Layer Perceptron* (MLP) - consiste em ajustar todos os pesos da rede. Em geral, esse ajuste leva em consideração os sinais de erro obtidos na unidade de saída da rede.

O algoritmo de treinamento supervisionado de redes MLP mais conhecido é o *backpropagation* (retropropagação do erro) (HAYKIN, 1999). Este algoritmo procura achar iterativamente a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural, ajustando os pesos entre as camadas através da retropropagação do erro encontrado em cada iteração.

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 (HAYKIN, 1999).

No algoritmo *backpropagation* pode ser utilizado o gradiente conjugado escalonado, que utiliza pares de entrada e saída, ajustando os pesos da rede por meio da correção de erros, e tem o objetivo de minimizar o tempo de convergência e otimizar a rede. O algoritmo combina o modelo de Levenberg-Marquardt com o gradiente conjugado e baseia-se em informações da derivada de segunda da ordem da função de erro (MØLLER, 1993). Estes passos se repetem enquanto o erro quadrático médio de saída da rede com os vetores de validação não diminuir durante um número de iterações pré-definidos.

O erro quadrático médio (*Mean Squared Error*) (MSE) é definido pela equação (20), onde  $y$  é saída obtida pela rede,  $t$  é saída esperada alvo e  $N$  é quantidade de amostras de entrada da rede.

$$MSE = \sum_{k=1}^N (y_k - t_k)^2 / N \quad (20)$$

Para Goldschmidt (2010), o objetivo do treinamento de uma RNA é fazer com que a aplicação de um conjunto de entradas produza um conjunto de saídas desejado ou, no mínimo, um conjunto de saídas próximas ao desejado.

### 2.3.4 Extreme Learning Machines

*Extreme Learning Machines* (ELMs) utilizam as redes *Single-hidden Layer Feedforward Network* (SLFNs). As SLFNs são consideradas um caso especial das redes MLP, por apresentarem apenas uma camada escondida (SILVESTRE, 2015).

A essência da ELM é que a camada escondida da SLFN não precisa ser ajustada (HUANG; ZHU; SIEW, 2004, 2006). Nas redes neurais ELMs, os pesos iniciais da camada escondida são escolhidos aleatoriamente, e não há treinamento para ajustá-los. O treinamento consiste em ajustar, de forma analítica, os pesos da camada de saída, conforme será visto na seção 2.3.4.1.

A dimensão da camada escondida de uma ELM, isto é, o número de neurônios nessa camada, é consideravelmente maior do que o de uma SLFN treinada com um algoritmo como o de retropropagação de erros.

As principais características das ELMs são (HUANG et al., 2015; SILVESTRE, 2015):

- Rapidez do treinamento: por não envolver um processo iterativo, como no caso de algoritmos de treinamento de MLPs, o tempo necessário para o treinamento costuma ser significativamente menor que aquele despendido por outras técnicas.
- Simplicidade de configuração: já que o único parâmetro relevante a ser especificado e definido é o número de neurônios da camada escondida.
- Desempenho na generalização: a boa capacidade de generalização também é uma característica importante das ELMs. Entende-se por capacidade de generalização a habilidade de responder adequadamente a amostras não utilizadas durante a fase de treinamento da rede neural.

#### 2.3.4.1 Treinamento de ELMs

A Figura 18 apresenta a estrutura de uma rede neural ELM, onde os dados de entrada  $\mathbf{x}$ , representados por uma matriz com  $N$  vetores de treinamento e  $d$  características, são multiplicados pelos pesos  $\mathbf{a}$  dos  $L$  neurônios da camada escondida, pesos estes que são definidos aleatoriamente formando uma matriz  $L$ -dimensional (HUANG et al., 2015). A constante  $b$ , denominada *bias*, tem o efeito de aumentar ou diminuir a entrada da função de ativação. O número de neurônios da camada de entrada  $d$  é igual ao número de características

dos vetores de treinamento e o número de neurônios da camada escondida  $L$  pode ser determinado empiricamente através de experimentos.

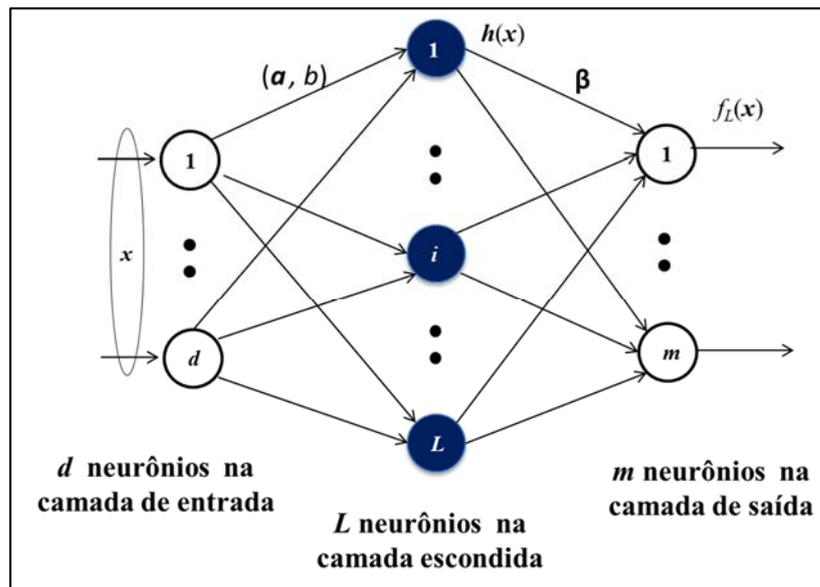


Figura 18 – Arquitetura da rede neural ELM.  
Fonte: Adaptado de Huang e Chen (2007).

A equação (21) descrita em Huang et al. (2015) representa a saída de um neurônio da rede ELM. Para determinar o resultado de saída  $f_L(x)$  de cada neurônio da camada escondida é aplicada uma função de ativação comum a todos os neurônios, definida por  $\mathbf{h}(x)$ . Este resultado é utilizado como entrada dos  $m$  neurônios da camada de saída, cujos pesos  $\beta$  são definidos analiticamente durante o treinamento da rede.

$$f_L(\mathbf{x}) = \sum_{i=1}^L \beta_i h_i(\mathbf{x}) = \mathbf{h}(\mathbf{x})\beta \quad (21)$$

Onde,  $\beta = [\beta_1, \dots, \beta_L]^T$  é o vetor dos pesos dos neurônios da camada de saída para os  $L$  nós da camada escondida e para  $m \geq 1$  neurônios, o identificador  $T$  representa a matriz transposta do vetor  $\beta$ ,  $\mathbf{h}(\mathbf{x}) = [h_1(\mathbf{x}), \dots, h_L(\mathbf{x})]$  são as saídas dos nós escondidos para a entrada de  $\mathbf{x}$  e  $h_i(\mathbf{x})$  representa a saída do  $i$ -ésimo nó escondido após a aplicação da função de ativação, com o  $h_i(\mathbf{x})$  sendo definido pela equação (22).

$$h_i(\mathbf{x}) = G(\mathbf{a}_i, b_i, \mathbf{x}), \quad \mathbf{a}_i \in \mathbf{R}^d, \quad b_i \in \mathbf{R} \quad (22)$$

Onde,  $G(\mathbf{a}, b, \mathbf{x})$  é uma função contínua não-linear aproximada por uma função linear por partes satisfazendo o teorema de aproximação universal (HUANG; CHEN, 2008; HUANG; CHEN; SIEW, 2006).

O número de neurônios  $L$  da camada escondida normalmente é escolhido de forma empírica e o número de neurônios da camada de saída  $m$  é igual ao número de classes de saída da rede.

Segundo Huang et al. (2015), a ELM é um método de treinamento que simplifica o processo de aprendizagem de uma SLFN, sendo realizado em duas etapas principais.

Na primeira etapa, a ELM inicializa aleatoriamente os pesos dos neurônios da camada escondida e utiliza uma das funções de ativação de saída listadas na Tabela 2. No treinamento da ELM, os parâmetros do nó escondido peso e *bias* ( $\mathbf{a}$ ,  $b$ ) são gerados aleatoriamente em vez de ser explicitamente treinados.

**Tabela 2 – Funções de ativação de saída normalmente utilizadas.**  
Fonte: Huang et al. (2015).

Função de Ativação	Equação
Sigmoide	$G(\mathbf{a}, b, \mathbf{x}) = 1/(1 + \exp(-(\mathbf{a} \cdot \mathbf{x} + b)))$
Tangente hiperbólica	$G(\mathbf{a}, b, \mathbf{x}) = (1 - \exp(-(\mathbf{a} \cdot \mathbf{x} + b)))/(1 + \exp(-(\mathbf{a} \cdot \mathbf{x} + b)))$
Gaussiana	$G(\mathbf{a}, b, \mathbf{x}) = \exp(-b\ \mathbf{x} - \mathbf{a}\ )$
Degrau	$G(\mathbf{a}, b, \mathbf{x}) = \begin{cases} 1, & \text{se } \mathbf{a} \cdot \mathbf{x} + b \leq 0 \\ 0, & \text{caso contrário} \end{cases}$
Cosseno	$G(\mathbf{a}, b, \mathbf{x}) = \cos(\mathbf{a} \cdot \mathbf{x} + b)$

Na segunda etapa de aprendizagem das ELMs, os pesos de ligação entre a camada oculta e a camada de saída, indicado por  $\beta$ , são resolvidos através da minimização do erro quadrático, utilizando a equação (23):

$$\min_{\beta \in \mathbf{R}^{L \times m}} \|\mathbf{H}\beta - \mathbf{T}\|^2 \quad (23)$$

Onde,  $\mathbf{H}$  é a matriz de saída da camada oculta (matriz com valores dos pesos dos neurônios selecionados de forma aleatória), definido pela equação (24):

$$\mathbf{H} = \begin{bmatrix} \mathbf{h}(\mathbf{x}_1) \\ \vdots \\ \mathbf{h}(\mathbf{x}_N) \end{bmatrix} = \begin{bmatrix} h_1(\mathbf{x}_1) & \dots & h_L(\mathbf{x}_1) \\ \vdots & \vdots & \vdots \\ h_1(\mathbf{x}_N) & \dots & h_L(\mathbf{x}_N) \end{bmatrix} \quad (24)$$

e  $\mathbf{T}$  é a matriz de dados de treino alvo (esperado), definido pela equação (25):

$$\mathbf{T} = \begin{bmatrix} \mathbf{t}_1^T \\ \vdots \\ \mathbf{t}_N^T \end{bmatrix} = \begin{bmatrix} t_{11} & \dots & t_{1m} \\ \vdots & \vdots & \vdots \\ t_{N1} & \dots & t_{Nm} \end{bmatrix} \quad (25)$$

e  $\|\cdot\|$  denota a norma Frobenius, representando a raiz quadrada da soma dos quadrados dos elementos (GOLUB; VAN LOAN, 1996; SERRE, 2002).

A solução ideal para a equação (21) é dada pela equação (26):

$$\boldsymbol{\beta}^* = \mathbf{H}^\dagger \mathbf{T} \quad (26)$$

Onde,  $\mathbf{H}^\dagger$  é a pseudoinversa de Moore-Penrose da matriz  $\mathbf{H}$  (SERRE, 2002). Diferentes métodos podem ser utilizados para calcular a matriz pseudoinversa de Moore-Penrose, o método de projeção ortogonal pode ser utilizado em dois casos:  $\mathbf{H}^\dagger = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T$  se  $\mathbf{H}^T \mathbf{H}$  é não singular ou  $\mathbf{H}^\dagger = \mathbf{H}^T (\mathbf{H} \mathbf{H}^T)^{-1}$  se  $\mathbf{H} \mathbf{H}^T$  é não singular (RAO; MITRA, 1971, HUANG et al., 2012).

De acordo com Huang et al. (2012) e tomando com base a teoria de regressão, pode-se adicionar um valor positivo para a diagonal de  $\mathbf{H}^T \mathbf{H}$  ou  $\mathbf{H} \mathbf{H}^T$ , com isso o resultado tende a um melhor desempenho na generalização.

Se  $\mathbf{H}$  tem mais linhas que colunas, neste caso, se o número de vetores (padrões) de treinamento  $N$  é maior que o número de neurônios ocultos  $L$  ( $N > L$ ), Huang et al. (2012, 2015) propõem uma versão regularizada para o cálculo dos pesos dos neurônios de saída, na qual a otimização dos pesos é realizada através do fator de regularização  $C$ , onde os pesos da camada de saída  $\boldsymbol{\beta}$  são calculados analiticamente com a equação (27):

$$\boldsymbol{\beta}^* = (\mathbf{H}^T \mathbf{H} + \mathbf{I}/C)^{-1} \mathbf{H}^T \mathbf{T} \quad (27)$$

Onde,  $\mathbf{I}$  é uma matriz de identidade de dimensão  $L$ .

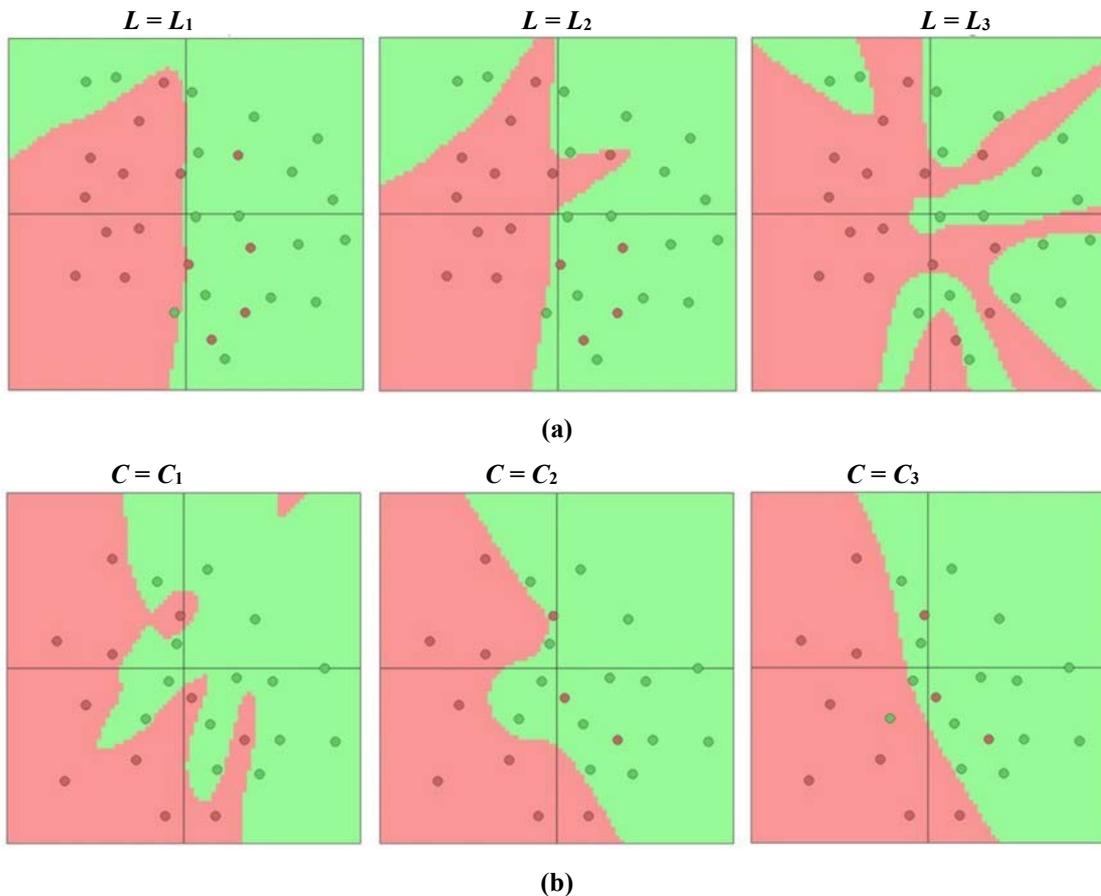
Se o número de vetores (padrões) de treinamento  $N$  é menor que o número de neurônios ocultos  $L$ ,  $N < L$ , Huang et al. (2012, 2015) propõem calcular os pesos da camada de saída  $\boldsymbol{\beta}$  com a equação (28):

$$\boldsymbol{\beta}^* = \mathbf{H}^T (\mathbf{H} \mathbf{H}^T + \mathbf{I}/C)^{-1} \mathbf{T} \quad (28)$$

Onde,  $\mathbf{I}$  é uma matriz de identidade de dimensão  $N$ .

Neste caso, o treinamento da ELM ocorre em apenas um passo para resolver a equação (27) ou equação (28), e pode ser facilmente generalizado para uma rede com várias saídas. Técnicas de regularização são usadas para controlar a suavidade e, conseqüentemente, incrementar o desempenho de classificação da ELM (SILVESTRE, 2015).

Karpathy (2016) e Silvestre (2015) abordam em seus trabalhos sobre o efeito do sobreajuste (*overfitting*) e o efeito da regularização em uma RNA. Partindo de um problema de classificação binária, estes efeitos são esboçados na Figura 19, onde os pontos de cada uma das duas classes são representados por uma cor diferente. Nesta figura também são apresentadas as superfícies de separação para situações diferentes de números de neurônios e de fator de regularização. A Figura 19(a) apresenta o efeito do sobreajuste devido ao aumento no número de neurônios ( $L$ ) na camada escondida ( $L_3 > L_2 > L_1$ ). À medida que o número de neurônios aumenta, a superfície de separação tende a perder a suavidade. Já na Figura 19(b), obtida a partir da rede com  $L_3$  neurônios na camada escondida, pode-se observar o efeito da regularização, especialmente para o valor mais adequado do fator de regularização  $C$  quando se deseja obter uma superfície com alto grau de suavidade, representado em  $C=C_3$ .



**Figura 19 - Efeitos do sobreajuste e da regularização em uma RNA (a) Superfícies de separação para valores crescentes de  $L$ . (b) Superfícies de separação para a rede com  $L = L_3$ , com diferentes valores para o fator de regularização  $C$ .**

Fonte: Silvestre (2015).

As ELMs têm recebido atenção da comunidade científica nos últimos anos, devido ao baixo custo computacional, simplicidade e rapidez de treinamento (SILVESTRE, 2015). Além disso, poucos parâmetros precisam ser especificados (função de ativação, fator de regularização  $C$  e número de neurônios da camada escondida  $L$ ) e, dado um número suficiente de neurônios ocultos, apenas o fator de regularização  $C$  precisa ser ajustado de acordo com o problema (HUANG et al., 2012).

#### 2.3.4.2 *Ensemble* de ELMs

A combinação de um número de ELMs (*ensemble* de ELMs) para a tomada de decisão final de saída da rede pode reduzir o risco de sobreajuste (*overfitting*) da rede neural e conduzir a um melhor desempenho na generalização (HANSEN; SALAMON, 1990; HUANG et al., 2015). Intuitivamente, a combinação de múltiplos componentes é vantajosa, uma vez que componentes diferentes podem implicitamente representar aspectos distintos e, ao mesmo tempo, relevantes para a solução de um dado problema (COELHO, 2006, COELHO; VON ZUBEN, 2006). Coelho (2006) destaca em seu trabalho que, na prática, nem sempre os ganhos obtidos com o uso de *ensembles* são tão expressivos, podendo até mesmo não haver melhoras frente ao melhor classificador individual. A Figura 20 apresenta a estrutura geral de um *ensemble*. Neste trabalho, cada componente será um classificador de rede neural ELM, proposto independentemente e capaz de atuar isoladamente. Para cada conjunto de dados de entrada, os  $n$  componentes gerarão  $n$  saídas que serão então combinadas para produzir uma solução final do *ensemble*.

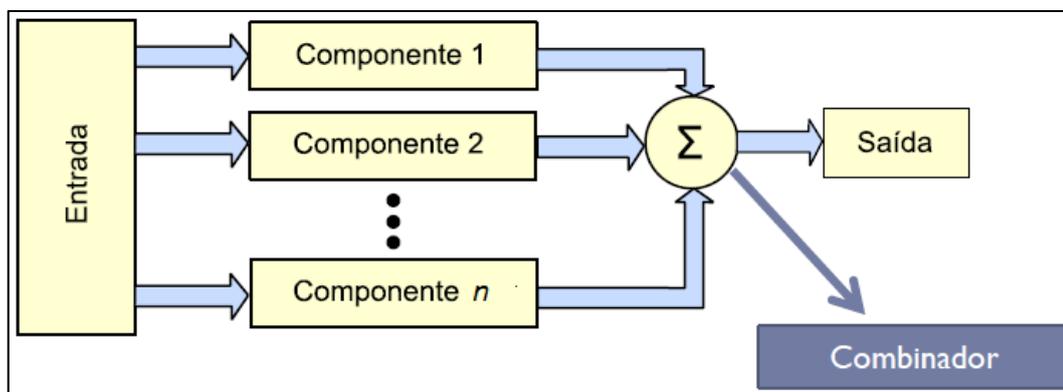


Figura 20 - Estrutura geral de um *ensemble*.  
Fonte: Adaptado de Coelho (2006).

Para que o uso de *ensembles* seja capaz de promover melhorias de desempenho para um dado problema, as componentes do *ensemble* devem apresentar bom desempenho individualmente e, ao mesmo tempo, devem ter comportamentos diversos entre si (HANSEN; SALAMON, 1990; COELHO, 2006).

Outro ponto importante na construção de *ensembles* é a maneira como as saídas de cada componente serão combinadas em uma única saída (a saída do *ensemble*). Neste trabalho, no capítulo 3 são propostas três técnicas de combinação de componentes de ELMs para decisão do *ensemble*. Estas técnicas foram norteadas pelas técnicas média simples e voto majoritário, estas duas técnicas retiradas da literatura são descritas a seguir.

A técnica de combinação conhecida como média simples, foi utilizada por Lan, Soh e Huang (2009) na solução um *ensemble* de várias ELM com o mesmo número de nós e com a mesma função de ativação na camada escondida, com objetivo de reduzir a falta de estabilidade apresentada por uma rede isolada. Os autores propõem como resultado do *ensemble* a média simples dos valores de cada ELM que o compõe. Aqui, a saída do *ensemble* é dada pela média simples entre as saídas de cada um de seus componentes antes da conversão para os rótulos das classes, equação (29).

$$y^k = \frac{1}{n} \sum_{i=1}^n y_i^k \quad (29)$$

Onde  $n$  é o número de componentes no *ensemble*,  $y_i^k$  é a  $k$ -ésima saída do  $i$ -ésimo componente e  $y^k$  é a  $k$ -ésima saída do *ensemble*.

A técnica de combinação conhecida como voto majoritário, utilizada por Coelho (2006) é um método de combinação não-linear onde, dada uma amostra do conjunto de dados, cada componente do *ensemble* apontará uma classe para esta amostra e a classe que receber o maior número de votos (for apontada pelo maior número de componentes), corresponderá ao rótulo atribuído a esta amostra pelo *ensemble*.

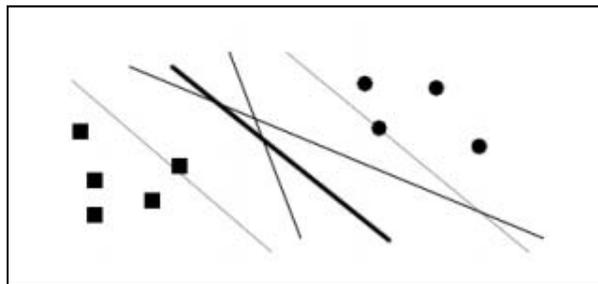
## 2.4 SUPPORT VECTOR MACHINES

Fundamentada na Teoria da Aprendizagem Estatística, a Máquina de Vetores de Suporte, do inglês *Support Vectors Machine* (SVM), foi desenvolvida por Vapnik (1995), com o intuito de resolver problemas de classificação de padrões.

Os algoritmos de aprendizagem de máquina SVM têm como objetivo a determinação de limites de decisão que produzam uma separação ótima entre classes por meio da minimização dos erros (VAPNIK, 1995). Essa classificação é baseada no princípio de separação ótima entre classes, tal que se as classes são separáveis, a solução é escolhida de forma a separar o máximo as classes.

Assumindo que as amostras de treinamento das diferentes classes são linearmente separáveis, a função de decisão mais adequada é aquela para a qual a distância entre os conjuntos das amostras de treinamento é maximizada. Neste contexto, a função de decisão que maximiza esta separação é denominada de ótima. Já para padrões não-linearmente separáveis, busca-se uma função de mapeamento apropriada para tornar o conjunto mapeado linearmente separável.

Considerando o exemplo da Figura 21, nela existe um conjunto de classificadores lineares que separam duas classes, mas apenas um (em destaque) que maximiza a margem de separação (distância da instância mais próxima ao hiperplano de separação das duas classes em questão). O hiperplano com margem máxima é chamado de hiperplano ótimo, que será o objeto de busca do treinamento do classificador.



**Figura 21 – Possíveis hiperplanos de separação e hiperplano ótimo.**

Seja  $\mathbf{x}_i$  ( $i=1, 2, \dots, M$ ) um conjunto de treinamento em um problema que consiste de duas classes linearmente separáveis ( $\omega_1$  e  $\omega_2$ ). Para cada amostra fica associado um rótulo:  $y_i=1$  se  $\mathbf{x}_i \in \omega_1$ ,  $y_i=-1$  se  $\mathbf{x}_i \in \omega_2$ , onde  $\mathbf{x}_i$  é o dado de entrada para a amostra  $i$  e  $y_i$  é a correspondente resposta desejada. Nesse caso a função de decisão linear adquire a forma:

$$D(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b \quad (30)$$

onde  $\mathbf{w}$  é um vetor  $m$ -dimensional (pesos) e  $b$  é o termo independente, para  $i=1, 2, \dots, M$ .

Porém, frequentemente as duas classes não são linearmente separáveis, isto é, a separação entre as amostras de treinamento das duas classes requer uma função não-linear. A

solução mais simples nestes casos consistiria na adoção de polinômios de grau mais elevado. Entretanto, esta abordagem apresenta, segundo Duda et al. (2000), o risco de excesso de ajuste (*overfitting*), o qual resulta em perda de generalização do classificador.

Para tratar dos casos não-linearmente separáveis, se introduz o conceito chamado de margem suave (*soft margin*). Isso pode ser feito introduzindo a variável de folga (*slack variable*)  $\xi_i (\geq 0)$  (Figura 22). Neste caso, amostras de treinamento  $x_i$ , para as quais  $0 < \xi_i < 1$ , são corretamente classificadas, embora sem a margem de separação máxima. Amostras  $x_i$  para as quais  $\xi_i \geq 1$ , são classificadas erroneamente pelo hiperplano ótimo. Neste caso, o hiperplano de separação ótimo pode ser obtido seguindo-se uma abordagem semelhante àquela adotada para o caso de amostras linearmente separáveis.

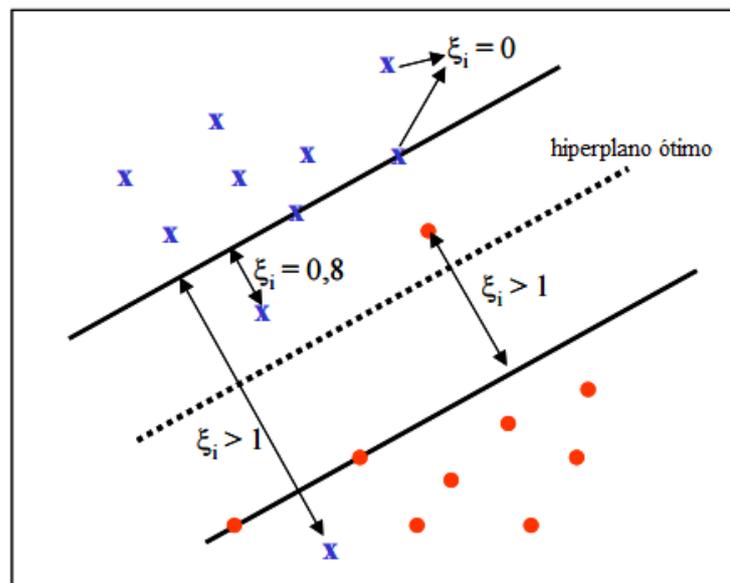


Figura 22 - Exemplos de valores e situações da variável de folga  $\xi$ .  
Fonte: Adaptado de Semolini (2002).

Outra alternativa, nestes casos, consiste em mapear os dados para um espaço de dimensão mais alta, no qual os dados passam a ser linearmente separáveis, segundo Fukunaga (1990). No contexto de SVM, esse espaço é denominado de espaço característico (*feature space*).

Representando por  $g(\mathbf{x}) = (g_1(\mathbf{x}), \dots, g_l(\mathbf{x}))^T$  uma função de transformação que mapeia as amostras  $x_i$  do espaço original para um espaço característico de dimensão mais elevada ( $l$ ), a nova função de decisão neste novo espaço passa a ser dada por:

$$D(\mathbf{x}) = \mathbf{w}^T g(\mathbf{x}) + b \quad (31)$$

onde  $\mathbf{w}$  é um vetor  $l$ -dimensional e  $b$  é o termo independente (*bias*).

De acordo com a teoria de Hilbert-Schmidt, se uma função simétrica  $H(x, x')$  satisfaz a seguinte condição:

$$\sum_{i,j=1}^M h_i h_j H(x_i, x_j) \geq 0 \quad (32)$$

para todo  $M$ ,  $x_i$  e  $h_i$ , onde  $M$  é um número natural e  $h_i$  é um número real, então existe uma função de mapeamento  $g(\mathbf{x})$ , que mapeia  $\mathbf{x}$  no espaço característico, tal que:

$$H(x, x') = g^T(x)g(x') \quad (33)$$

A condição (32) é chamada condição de *Mercer* e a função que satisfaz essa condição chama-se *Mercer kernel* ou simplesmente *kernel* (Abe, 2005). O teorema de *Mercer* permite saber quando uma função candidata a *kernel* é de fato um produto interno em algum espaço.

Este teorema, entretanto, não indica como obter  $H(x, x')$ . A vantagem do uso de *kernels* é que não se precisa lidar com o espaço característico de alta-dimensão explicitamente: usa-se  $H(x, x')$  no treinamento e classificação ao invés de  $g(\mathbf{x})$ .

Usando o *kernel*, o problema de separação de um par de classes no espaço pode ser resolvido maximizando:

$$Q(\alpha) = \sum_{i=1}^M \alpha_i - \frac{1}{2} \sum_{i,j=1}^M \alpha_i \alpha_j y_i y_j H(x_i, x_j) \quad (34)$$

sujeito às restrições:

$$\sum_{i=1}^M y_i \alpha_i = 0 \text{ e } 0 \leq \alpha_i \leq C \text{ para } i = 1, \dots, M \quad (35)$$

Na qual  $C$  é um parâmetro de custo a ser escolhido pelo usuário, tendo em conta que um  $C$  maior corresponde a assumir uma penalidade maior para os erros. O parâmetro  $C$  controla a relação entre a complexidade do algoritmo e o número de amostras de treinamento classificadas incorretamente. Ele pode ser visto como um parâmetro de penalização.

Pode-se mostrar que neste caso, a função de decisão assume a seguinte forma:

$$D(x) = \sum_{i \in S} \alpha_i y_i H(x_i, x_j) + b \quad (36)$$

sendo o coeficiente linear  $b$  dado por:

$$b = \frac{1}{|U|} \sum_{j \in S} (y_j - \alpha_j y_j H(x_j, x_j)) \quad (37)$$

e  $U$  representa o sub-conjunto composto pelos *support vectors* denominados de *unbounded*, isto é, aqueles para os quais  $(0 \leq \alpha_i \leq C)$ .

A forma da função discriminante depende do *kernel* adotado (escolhido a priori). Um exemplo comum de *kernel* é a Função Base Radial (RBF), dado por:

$$H(x, x') = \exp(-||x-x'||^2/2\sigma^2) \quad (38)$$

onde o parâmetro  $\sigma$  (interpretado como variância da RBF) é determinado através de experimentos, buscando os melhores indicadores de desempenho no treinamento do classificador.

A regra de classificação é:

$$\begin{aligned} D(x) > 0 & \quad x_i \in \omega_1 \\ D(x) < 0 & \quad x_i \in \omega_2 \end{aligned} \quad (39)$$

Se  $D(x)=0$ , então  $x$  está sobre o hiperplano separador e não é classificado. Quando as amostras de treinamento são linearmente separáveis, a região  $\{x \mid 1 > D(x) > -1\}$  é a região de generalização.

Finalmente, deve-se mencionar que o classificador SVM só pode ser utilizado na separação de um par de classes a cada vez. O SVM implementa um mapeamento não-linear (executado por um produto interno *kernel* escolhido a priori) dos dados de entrada para um espaço característico de alta-dimensão, em que um hiperplano ótimo é construído para separar os dados linearmente em duas classes (SEMOLINI, 2002).

O SVM envolve poucos parâmetros livres que precisam ser ajustados pelo usuário, outro destaque é que a arquitetura de SVM não é encontrada por experimentação. Para avaliar a capacidade de generalização do classificador SVM, pode ser usada a técnica de validação cruzada descrita a seguir.

## 2.5 VALIDAÇÃO CRUZADA

A validação cruzada é uma técnica para avaliar a capacidade de generalização de um modelo, a partir de um conjunto de dados (KOHAVI, 1995). Esta técnica busca estimar o seu desempenho para um novo conjunto de dados. O conceito central das técnicas de validação cruzada é o particionamento do conjunto de dados em subconjuntos mutuamente exclusivos, e posteriormente, utiliza-se alguns destes subconjuntos para a estimação dos parâmetros do modelo (dados de treinamento) e o restante dos subconjuntos (dados de validação e/ou de teste) são empregados na validação do modelo.

Diversas formas de realizar o particionamento dos dados são sugeridas na literatura, sendo as três mais utilizadas: o método *holdout*, o *k-fold* e o *leave-one-out* (KOHAVI, 1995).

### 2.5.1 Método *Hold-out*

Este método consiste em dividir o conjunto total de dados em dois subconjuntos mutuamente exclusivos, um para treinamento (estimação dos parâmetros) e outro para teste (validação). O conjunto de dados pode ser separado em quantidades iguais ou não. Uma proporção muito comum é considerar 2/3 dos dados para treinamento e o 1/3 restante para teste (KOHAVI, 1995).

Após o particionamento, a estimação do modelo é realizada e, posteriormente, os dados de teste são aplicados e o erro de predição e a acurácia do modelo são calculados.

Esta abordagem é indicada quando está disponível uma grande quantidade de dados. Caso o conjunto total de dados seja pequeno, o erro calculado na predição pode sofrer muita variação.

Com o objetivo de obter uma estimativa de erro mais precisa pode-se fazer múltiplas execuções de *hold-out* (*Random Subsampling*), com diferentes partições treinamento-teste escolhidas de forma aleatória obtendo-se, assim, uma estimativa média do *hold-out*.

### 2.5.2 Método *K-fold*

O método de validação cruzada denominado *k-fold* consiste em dividir o conjunto total de dados aleatoriamente em  $k$  subconjuntos mutuamente exclusivos do mesmo tamanho e, a partir disto, um subconjunto é utilizado para teste e os  $k-1$  restantes são utilizados para estimação dos parâmetros. Este processo é realizado  $k$  vezes alternando de forma circular o subconjunto de teste.

Ao final das  $k$  iterações calcula-se a acurácia final do modelo, obtendo assim uma medida mais confiável sobre a capacidade do modelo de representar o processo gerador dos dados.

### 2.5.3 Método *Leave-one-out*

O método *leave-one-out* é um caso específico do *k-fold*, com  $k$  igual ao número total de dados  $N$ . Nesta abordagem são realizados  $N$  cálculos de erro, um para cada dado.

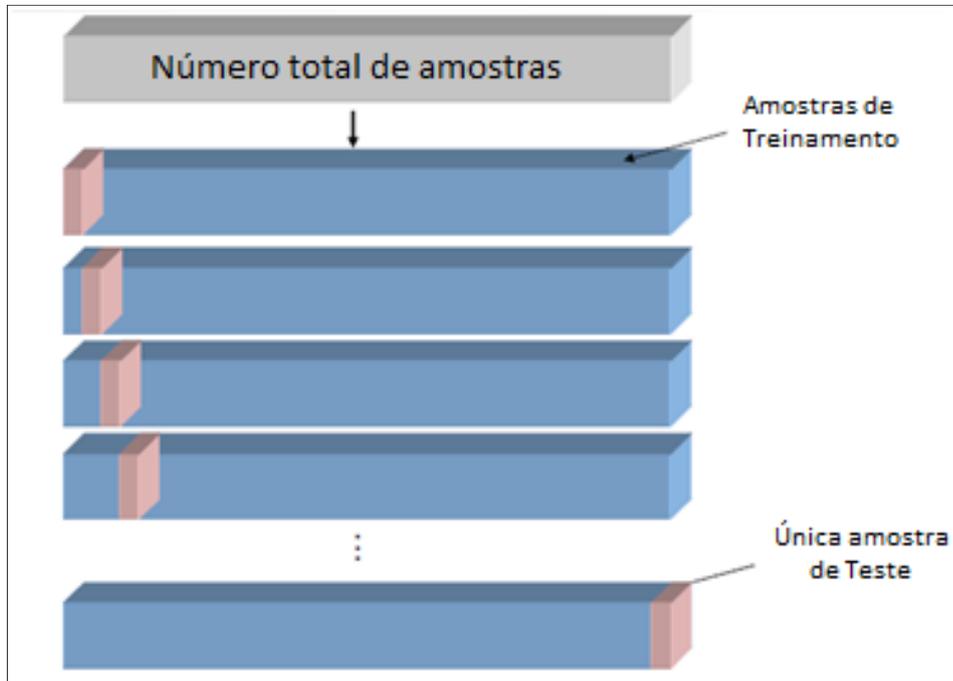
Apesar de apresentar uma investigação completa sobre a variação do modelo em relação aos dados utilizados, este método possui um alto custo computacional, sendo indicado para situações onde poucos dados estão disponíveis.

### 2.5.4 Método *Leave-p-label-out*

*Leave-p-label-out* é um método de validação cruzada que contém as amostras de acordo com um rótulo fornecido por terceiros. Cada conjunto de treinamento é assim constituído por todas as amostras, exceto as relacionadas a um rótulo específico. Nos casos de experiências múltiplas, o método pode ser usado para criar uma validação cruzada com base nas diferentes experiências, criando um conjunto de treinamento usando as amostras de todos os experimentos exceto um. Para esta pesquisa, todas as descontinuidades encontradas em uma imagem são rotuladas com um único índice ou todas as descontinuidades encontradas nas imagens obtidas por um sistema de aquisição são rotuladas com um único índice.

Em conformidade com o ilustrado na Figura 23, na validação cruzada *leave-p-label-out* o tamanho da amostra  $n$  refere-se ao número de imagens e não aos vetores de características, cada amostra pode ter valores diferentes de vetores de características. Para um conjunto de imagens de tamanho  $n$  uma hipótese é treinada utilizando  $n-1$  amostras, a hipótese

é então testada na única amostra remanescente  $p$ . Este processo é repetido  $n$  vezes, cada vez treinando uma hipótese e deixando de considerar uma única amostra. O resultado final é a soma dos resultados em cada teste dividido por  $n$ .



**Figura 23 – Validação cruzada *leave-p-label-out*.**

## 2.6 MEDIDAS DE DESEMPENHO DE CLASSIFICADORES

O desempenho de um classificador pode ser avaliado através de vários métodos. A eficiência de uma classificação pode ser avaliada pelo número de amostras da classe corretamente reconhecidas (verdadeiros positivos), pelo número de amostras que foram corretamente atribuídas como não pertencentes à classe (verdadeiros negativos), amostras que foram incorretamente atribuídas à classe (falsos positivos) e amostras que foram incorretamente classificadas como não pertencentes à classe (falsos negativos). Estas quatro medidas constituem uma matriz de confusão mostrada na Figura 24, para o caso de uma classificação binária (SOKOLOVA; LAPALME, 2009).

	Classe verdadeira (real)		
Classe prevista (saída do classificador)	Verdadeiro Positivo TP	Falso Positivo FP	Precisão
	Falso Negativo FN	Verdadeiro Negativo TN	
	Sensibilidade		Acurácia

Figura 24 – Modelo de matriz de confusão de duas classes.  
Fonte: Adaptado de Prati et al. (2008).

Segundo Fawcett (2006) e Powers (2011) através da matriz de confusão obtêm-se alguns resultados estatísticos, como acurácia, sensibilidade e precisão. Estes resultados são representados na matriz conforme mostra a Figura 24 e calculados em função dos valores de verdadeiros e falsos positivos e negativos, sendo:

- Acurácia: é a razão entre o número total de amostras que são classificadas corretamente e o número total de amostras, definida pela equação (40).

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (40)$$

- Precisão: razão entre o número de verdadeiros positivos e o total de amostras classificadas como positivas, definida pela equação (41).

$$Precisão = \frac{TP}{TP + FP} \quad (41)$$

- Sensibilidade (Cobertura): razão entre o número de verdadeiros positivos e o número de amostras atribuídas a uma determinada classe, definida pela equação (42).

$$Sensibilidade = \frac{TP}{TP + FN} \quad (42)$$

- *F-score*: Precisão e sensibilidade são frequentemente combinados em uma única estatística chamada de *F-score* ou *F-measure*, que é a média ponderada de

precisão e sensibilidade, definida na equação (43). A medida *F-score* é um indicativo de desempenho global do classificador.

$$Fscore = \frac{2 \times (Precisão \times Sensibilidade)}{(Precisão + Sensibilidade)} \quad (43)$$

## 2.7 CONSIDERAÇÕES FINAIS

Este capítulo destacou as técnicas de exposição radiográfica utilizadas em juntas soldadas de tubulações, descrevendo suas características, limitações e os tipos de discontinuidades mais comuns encontradas em juntas soldadas. Neste capítulo também foram apresentados conceitos sobre processamento de imagens, redes neurais MLP e ELM e o classificador SVM, utilizados no desenvolvimento do trabalho. No classificador com rede neural ELM somente o número de neurônios na camada escondida e/ou o fator de regularização *C* precisam ser especificados. No classificador SVM existem poucos parâmetros livres para ajustar e, além disso, a arquitetura não precisa ser encontrada por experimentação. Destaca-se, entretanto, que, apesar da vasta e detalhada literatura existente sobre aspectos e teorias sobre classificadores a finalidade da fundamentação apresentada é de fornecer subsídios para a compreensão da metodologia proposta.

A utilização de tais técnicas visa à detecção e classificação automática das discontinuidades, atendendo o objetivo do presente trabalho, que é propor novas técnicas para realizar a segmentação e classificação automática de discontinuidades em imagens radiográficas de juntas soldadas em tubulações.

No próximo capítulo é apresentado o estado da arte relacionado às pesquisas sobre detecção e classificação de defeitos em imagens radiográficas.

### 3 ESTADO DA ARTE

Segundo Mery (2011), as metodologias empregadas na detecção e classificação de defeitos de soldagem em imagens radiográficas seguem normalmente um esquema clássico:

- Aquisição de imagem: obtenção e armazenamento de uma imagem digital.
- Pré-processamento da imagem: redução de ruídos e aprimoramento do contraste.
- Segmentação ou limiarização: Segmentação de discontinuidades (potenciais defeitos de soldagem).
- Rotulagem: identificação das regiões segmentadas.
- Classificação: interpretação das características extraídas a partir de um conhecimento prévio a fim de identificar defeitos ou falsos positivos.

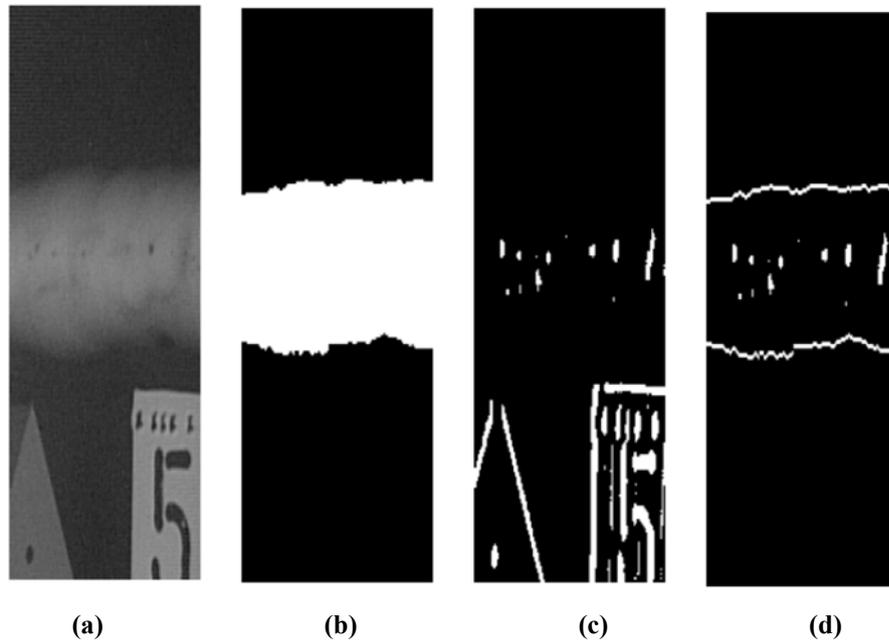
Este capítulo foi dividido em pesquisas que abordam detecção de defeitos de soldagem em imagens radiográficas obtidas pelas técnicas de exposição PSVS e PDVD. As pesquisas também estão divididas neste capítulo em três linhas diferentes de detecção de defeitos em imagens radiográficas de juntas soldadas. Inicialmente são apresentadas pesquisas onde a imagem é analisada através de janelas que “convoluem” sobre toda a imagem, depois através da análise do perfil transversal de nível de cinza do cordão de solda, e na sequência, através da segmentação de regiões com defeitos potenciais, com extração de características dos defeitos para posterior classificação.

#### 3.1 DETECÇÃO E CLASSIFICAÇÃO DE DEFEITOS EM IMAGENS PSVS

Lawson e Parker (1994) utilizaram um método baseado em redes neurais para a análise dos defeitos. Em uma primeira etapa é aplicada uma rede neural para a segmentação do cordão de solda na imagem total com o objetivo de restringir o espaço de busca. Em uma segunda etapa, outra rede é utilizada para segmentar o defeito dentro do cordão de solda. Em ambas as etapas foram utilizadas redes neurais *Perceptron* de múltiplas camadas (MLP) com treinamento baseado na retropropagação do erro.

Na detecção do defeito, a rede foi treinada com janelas de dimensões  $m \times m$  ( $m$  variando de 15 a 9 pixels) obtidas a partir das imagens radiográficas com defeitos, classificando cada pixel como defeito e não defeito. A análise do resultado foi visual. Um exemplo apresentado por Lawson e Parker (1994) está ilustrado na Figura 25. Na Figura 25(b)

é apresentada a detecção do cordão de solda, e na Figura 25(c e d) a detecção dos defeitos. Os autores não apresentaram uma análise quantitativa dos resultados.



**Figura 25 – Exemplo de resultado do método de Lawson e Parker. (a) Imagem original. (b) Extração do cordão de solda. (c) Detecção de defeitos. (d) Combinação de (b) e (c).**

**Fonte: Lawson e Parker (1994).**

Mery (2011) apresenta uma metodologia sem segmentação utilizando janelas deslizantes. A classificação é feita por SVMs (*Support Vector Machine*) que determinam se a janela possui ou não defeito e, em caso positivo, o contorno da janela é marcado na imagem. Segundo Mery (2011), esta metodologia apresenta um desempenho de 94% de acurácia na classificação de janelas com defeito e sem defeito. A Figura 26 ilustra o efeito visual da aplicação do método proposto por Mery (2011). O método foi implementado e testado em radiografias fornecidas pela BAM (*Federal Institute for Materials Research and Testing, Berlin*).

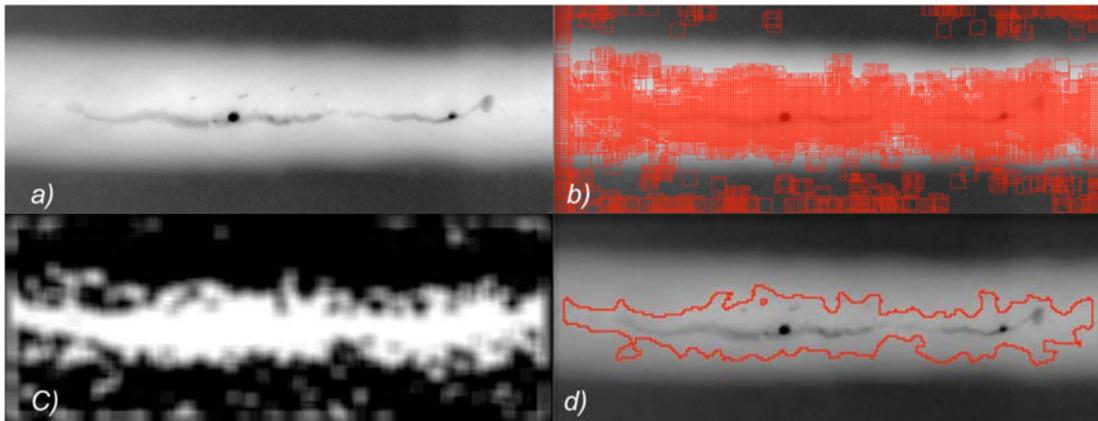


Figura 26 – Exemplo de resultado do método de Mery. (a) Imagem original. (b) Janelas classificadas como defeitos. (c) Imagem em escala de cinza proporcional ao número de subjanelas detectadas. (d) Detecção final obtida pela limiarização de (c).

Fonte: Mery (2011).

Em outra linha de pesquisa para o desenvolvimento de um sistema automatizado de análise de radiografias de juntas soldadas, a detecção dos defeitos é realizada via perfil de nível de cinza transversal ao cordão de solda. Neste caso, recorre-se normalmente à extração manual do cordão antes da detecção. A Figura 27 a seguir mostra dois exemplos típicos de perfis transversais ao cordão de solda do trabalho de Padua et al. (2003), um com a presença de defeito, Figura 27(a), e outro sem defeito, Figura 27(b).

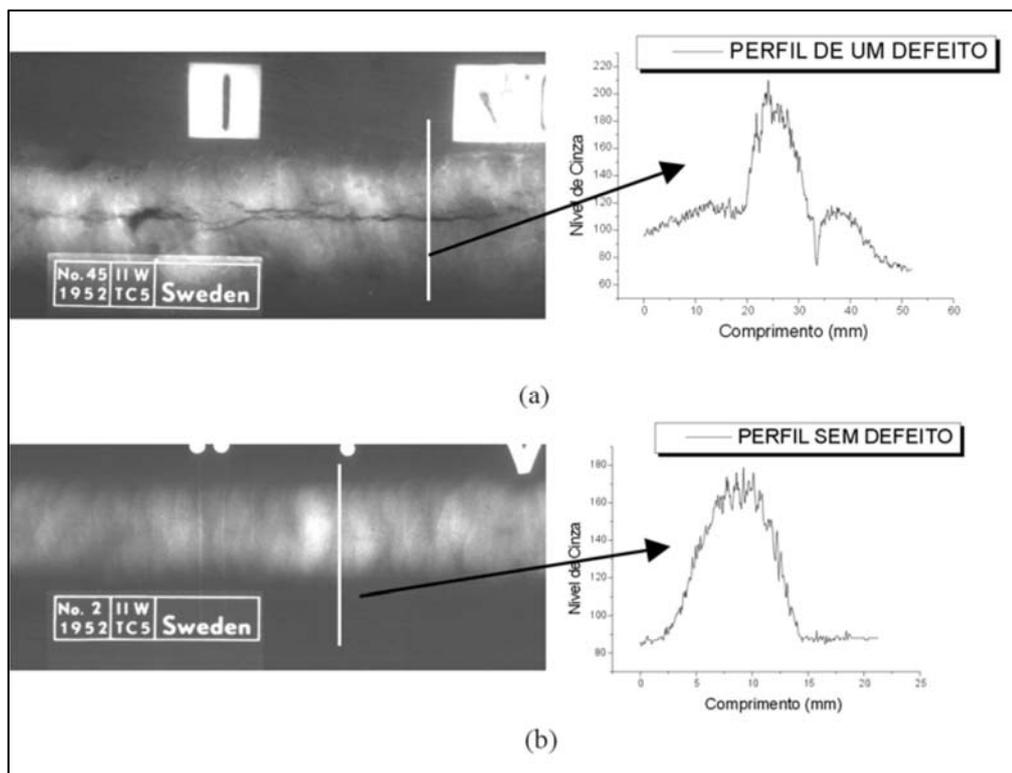


Figura 27 – Perfil transversal ao cordão-de-solda. (a) Para a situação de presença de defeito no cordão. (b) Para a situação de ausência de defeito.

Fonte: Padua et al. (2003).

Em Liao e Ni (1998), a detecção de defeitos de solda foi fundamentada na busca por anomalias de picos através da análise do perfil transversal de nível de cinza sobre o cordão de solda, com formato de uma gaussiana e extraído pela técnica de Liao e Ni (1996). Tal técnica consistiu na aplicação de quatro etapas: pré-processamento, normalização do perfil analisado, detecção de anomalia no perfil e pós-processamento. Foram utilizadas 24 imagens radiográficas de soldas de filmes digitalizados com o total de 75 defeitos. A sensibilidade do método foi de 93,30% e precisão de 95,91%.

Padua (2004) apresenta uma metodologia semi-automatizada, utilizando perfis do cordão de solda obtidos manualmente. Nesta metodologia os filmes radiográficos utilizados são padrões cedidos pelo IIW (*International Institute of Welding*) e BAM. Estes padrões são radiografias de juntas soldadas em aço carbono, cujos defeitos de soldagem são certificados por estes centros de pesquisa. Estes perfis, depois de processados, são utilizados como entrada em classificadores usando redes neurais artificiais. Os resultados apresentados por Padua (2004) mostram que as redes neurais proporcionam uma precisão de até 98% na classificação dos defeitos, quando as discontinuidades encontradas são divididas somente em duas classes, defeito e não defeito.

Os métodos apresentados anteriormente abordam a detecção de defeitos através de janelas deslizantes ou perfil transversal de nível de cinza. Na sequência, diversos métodos com abordagem através da segmentação de regiões com defeitos potenciais, extração de características e classificação dos defeitos são apresentados.

A utilização de características dos defeitos é uma das técnicas mais empregadas para detecção e classificação de defeitos de soldagem (MERY; BERTI, 2003). Neste caso, a escolha adequada das características na identificação 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 textura, tais como: localização, forma, comprimento, contraste (nível de cinza), razão de aspecto, entre outras (SILVA, 2003).

Um dos trabalhos neste campo de pesquisa, no que se refere à discriminação das classes de defeitos através do emprego de características de forma para imagens PSVS, foi desenvolvido por Aoki e Suga (1999), que tratam a classificação dos defeitos segundo os critérios que são descritos a seguir.

Primeiramente, um defeito pode ser classificado pela forma geométrica como 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 e Suga (1999), 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 com mais detalhes por serem referências ao método proposto no Capítulo 4.

C1: Posição. Localização do defeito no cordão-de-solda ( $C1=h/H$ ), onde  $h$  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 ( $C2= Fh/Fv$ ).

C3: Razão entre a maior medida de comprimento obtida no defeito e a área do defeito ( $C3=M/A$ ).

C4: Razão entre a menor medida de comprimento obtida no defeito e a área do defeito ( $C4=N/A$ ).

C5: Complexidade. Esta característica mede o nível de complexidade do defeito pelo seu perímetro ( $C5=L^2/A$ ).  $L$  é o perímetro do defeito.

C6: Coeficiente de forma. Também mede a complexidade do defeito por outra fórmula ( $C6=\pi d^2/4A$ ), sendo  $d$  o diâmetro maior do defeito e  $A$  é a área do defeito.

C7: Diâmetro Heywood. É o diâmetro de um círculo de área similar à área do defeito ( $C7=\sqrt{4A/\pi}$ ).

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 classificação dos defeitos, Aoki e Suga (1999) utilizaram redes neurais MLP com algoritmo de treinamento *backpropagation*. Para verificar a efetividade de cada característica na discriminação das classes de defeitos estudadas, foi avaliado o desempenho da rede retirando uma característica de cada vez, tendo chegado à conclusão de que o melhor desempenho era para a situação em que todas as características foram usadas. Em 27 defeitos analisados, 25 foram corretamente classificados, dando um índice de 92,6% de acerto.

Silva (2003) utilizou, para a classificação de defeitos, sete características geométricas de defeitos (posição, razão de aspecto, espessura sobre a área, arredondamento, ângulo entre o eixo maior do defeito e a vertical, razão entre a área do defeito e a área do menor retângulo

que envolve o defeito e razão entre a largura e a altura do menor retângulo que envolve o defeito) e classificadores com redes neurais MLP. Obteve uma acurácia de 74% para a classificação separando o conjunto de 646 amostras (IIW e BAM) em seis classes de defeitos. Silva (2003) constatou que a classe inclusão de escória (IE) é a classe que teve maiores índices de confusão com as outras classes, principalmente com a classe porosidade (PO).

Shafeek et al (2004a, 2004b) desenvolveram o *software* AutoWDA para realizar a detecção de defeitos. As imagens são convertidas para oito bits, e sobre estas imagens são aplicadas transformações da intensidade, filtros de redução de ruído e limiarização manual. Após a limiarização é aplicado um algoritmo para identificação dos contornos das regiões e a rotulagem com o objetivo de determinar características (área, perímetro, largura, altura e retângulo mínimo) das regiões detectadas. Em seguida é aplicado o algoritmo por árvores de decisão, primeiramente para verificar as formas dos defeitos (circulares, retangulares (alongados) ou irregulares). A árvore de decisão atua sobre o aceite dos defeitos identificados. As dimensões dos defeitos são comparadas aos padrões internacionais para fazer o aceite mencionado (SHAFEEK et al, 2004a, 2004b). Os autores utilizaram cinco imagens de radiografias PSVS com somente um tipo de defeito em cada uma para validação, não apresentando resultados quantitativos.

Valavanis e Kosmopoulos (2010) descrevem em seu artigo que as descontinuidades são detectadas e separadas em sete classes, incluindo os não defeitos. Para limiarização é utilizada a limiarização local de Sauvola. Excluem-se do processamento adicional os segmentos detectados fora do cordão de solda e aqueles com uma área com mais de 50 pixels ou com menos de 3500 pixels. Como classificadores são utilizadas as técnicas *Support Vector Machines* (SVM) e Redes Neurais Artificiais (RNA). O método apresenta como resultados, tanto para as RNAs como para o classificador SVM, em torno de 85 % de acurácia.

No método descrito por Zapata, Vilar e Ruiz (2011), a imagem passa por algoritmos de redução de ruído, ampliação do contraste, limiarização e rotulagem. Em seguida, são extraídas características geométricas das descontinuidades detectadas. Numa terceira fase, é realizada uma comparação entre uma rede neural artificial MLP e um sistema Neuro-Fuzzy (ANFIS) para classificação de defeitos de solda. A acurácia apresentada por Zapata, Vilar e Ruiz (2011) é de 78,9% para a rede MLP e de 82,6% para o sistema ANFIS.

A abordagem apresentada no trabalho de Yahia et al.(2011) tem como princípio a utilização de redes neurais artificiais na detecção de bordas, e consiste em identificar as descontinuidades da imagem e eliminar o cordão de solda, com o restante sendo considerado como defeito. O método inclui a preparação da base de dados da rede neural, onde foram

utilizadas 48 estruturas básicas de contornos de tamanho 3x3. Antes de submeter a imagem à rede neural MLP, é realizado um pré-tratamento sobre a imagem, no qual são eliminados ruídos que podem comprometer a identificação de bordas, e depois é realizada a segmentação. Yahia et al. (2011) comparou visualmente as imagens obtidas pelo método proposto com as imagens utilizando algoritmos de detecção de bordas como Sobel e Canny. Nesta comparação Yahia et al. (2011) afirmou que seu método é mais eficiente que os métodos de Sobel e Canny. O próprio autor não faz uma avaliação quantitativa do seu método, somente uma avaliação qualitativa das imagens. O defeito é detectado, mas a indicação do tipo de defeito não é automatizada.

Na abordagem apresentada por Sikora et al. (2012), a imagem é limiarizada e as regiões de interesse são classificadas de acordo com uma lista de 60 características geométricas e de textura. As regiões selecionadas passam por uma rede neural *Multi-Layer Perceptron* (MLP) que faz a classificação definitiva para as classes porosidade, inclusão de escória e não defeitos. Os autores comparam a abordagem ao método *k-nearest neighbors* (*knn*) (KUNCHEVA, 2004) e concluem que a rede neural oferece um resultado superior.

As Tabelas 3 e 4 apresentam um resumo das abordagens anteriores e de outras abordagens descritas em um artigo de revisão apresentado por Halim, Ibrahim e Manurung (2012).

**Tabela 3 - Visão geral sobre o desenvolvimento dos sistemas automático de detecção de defeitos de soldagem.**

<b>Autores</b>	<b>Tipos de Defeitos</b>	<b>Objetivos</b>	<b>Resultados (Acurácia)</b>
Lawson e Parker (1994)	2	Classificação automática de defeitos e não defeito usando MLP	Visual
Aoki e Suga (1999)	6	Classificação automática de defeitos usando MLP	92,6%
Silva (2003)	6	Classificação semi-automática de defeitos usando MLP	74%
Wang e Liao (2002)	6	Classificação automática de 06 tipos de defeitos e não defeito usando fuzzy k-NN e MLP	k-NN 91,57% e MLP 92,39%
Carvalho et al. (2003)	4	Avaliação da relevância de 8 características e classificação de quatro tipos de defeitos	50% redução de dados e 100% classificação
Shafeek et al. (2004a, 2004b)	11	Classificação automática de 10 tipos de defeitos e não defeito usando árvores de decisão	Visual
Padua (2004)	7	Classificação semi-automática de 06 tipos de defeitos e não defeito usando RNA ART sobre perfis transversais das soldas	98% para duas classes 100% p/mordedura, inclusão de escória e porosidade 97% trincas 88% falta de fusão
Yin et al. (2008)	8	Classificação automática de 08 tipos de defeitos e não defeito usando RNA	93,9 % de classificação
Rale, Gharpure e Ravindran (2009)	4	Apresentação do desempenho (MLP) e (RFP) para a detecção de defeitos	RFB é melhor do que MLP, mas MLP é mais rápida que RFB
Valavanis e Kosmopoulos (2010)	7	Classificação automática de 07 tipos de defeitos e não defeito usando SVM e RNA	85%
Wang, Wong e Tan (2010)	7	Desenvolvimento de um sistema baseado em SVM para melhorar o processo de um sistema de detecção	96,98%

de soldas automatizado			
Shao et al. (2011)	2	Detecção automática dos defeitos e não defeitos usando SVM	99,4%
Mery (2011)	2	Detecção automática dos defeitos e não defeitos usando janelas deslizantes e SVM	94%
Yahia et al. (2011)	2	Detecção automática dos defeitos e não defeitos usando RNA na identificação de contornos	Visual
Zapata, Vital e Ruiz (2012)	5	Classificação automática de 04 tipos de defeitos e não defeito usando MLP e ANFIS	78,9% para RNA 82,6% para ANFIS
Sikora et al. (2012)	5	Classificação automática de 04 tipos de defeitos e não defeito usando RNA	71%

**Tabela 4 - Visão geral de técnicas de detecção de defeitos e tipos de características.**

Autores	Processamento da imagem		Classificação	Características
	Aprimoramento da imagem	Segmentação		
Lawson e Parker (1994)	5x5 filtro passa baixa	----	MLP	Textura do Pixel (Janela)
Aoki e Suga (1999)	Filtro de mediana	----	MLP	Geométrica e Textura
Silva (2003)	Filtro de mediana	Visual	MLP	Geométrica
Zapata, Vital e Ruiz (2012)	Filtro 7x7 Wiener, 3x3 filtro passa baixa Gaussiano	Limiarização de Otsu	MLP e Neuro-Fuzzy ANFIS	Eixo maior, Área, Orientação, Excentricidade, Diâmetro equivalente, Solidez, Centroide, Eixo menor, Número de Euler, extensão e posição da imagem no gráfico.
Mery (2011)	Janelas deslizantes	---	SVM	Textura do Pixel (Janela)
Yahia et al. (2011)	filtro passa baixa Gaussiano	Limiarização de Otsu	MLP	Estruturas de contorno
Padua (2004)	Filtro Savitzky-Golay 8x8	Desvio padrão e mediana do perfil	RNA ART	Perfis transversais
Valavanis e Kosmopoulos (2010)	Não mencionado	Limiarização por Sauvola,	SVM, RNA, K-NN	Mínima área do retângulo, momento angular, momento da diferença inversa, Posição, Retângulo, Variância e diferença de variância
Sikora et al. (2012)	Filtros no domínio da frequência, operadores morfológicos de dilatação e erosão, equalização de histograma	Limiarização por Sauvola,	MLP	Geométricas e de textura
Shafeek et al. (2004a, 2004b)	Alongamento do histograma, equalização do histograma, filtro mediano, especificação histograma	Limiarização, Chain Code	Árvores de decisão	Largura, comprimento, perímetro, área, área min. retângulo, comprimento total e comprimento de solda.
Shao et al. (2011)	Mediana 3x3, filtro de média 3x3, subtração de fundo.	Limiarização adaptativo	SVM	Desvio padrão, intensidade média e Área.
Wang, Wong e Tan (2010)	Thresholding wavelet Adaptivo Equalização de histograma Adaptivo	Limiarização multi-nível	SVM	Compacidade, largura, comprimento, alongamento, área, orientação, relação área-largura, entropia, contraste, segundo momento angular
Rale, Gharpure e Ravindran (2009)	Intensidade do perfil, filtro mediana	Limiarização	MLP, SVM	7 geométricas

Yin et al. (2008)	Não mencionado	Não mencionado	MLP	Compacidade, eixo principal, alongamento, perímetro, área, orientação, relação área - largura, área convexa, excentricidade, diâmetro equivalente, solidez, menor eixo, anisometria, taxa circinal, retangularidade e relação perímetro área
Carvalho et al. (2003)	Filtro de mediana e passa alta	Não mencionada	ANN	Intensidade média, orientação, relação de aspecto, retângulo, retangularidade, relação de raio maior e menor, a taxa de circinal e fractal
Wang e Liao (2002)	Filtro de mediana e equalização de histograma	Subtração de fundo e limiarização	Fuzzy k-NN e MLP	Distância do centro, raio médio, desvio padrão, circularidade, compacidade, o eixo principal, largura, comprimento, alongamento, diâmetro, intensidade média e desvio padrão da intensidade

### 3.2 DETECÇÃO E CLASSIFICAÇÃO DE DEFEITOS EM IMAGENS PDVD

Kroetz (2012) desenvolveu um método semiautomático para a detecção e realce de defeitos em cordões de solda em imagens radiográficas obtidas pela técnica PDVD. O método realiza a detecção automática da região do cordão de solda e detecta descontinuidades (possíveis defeitos) na região através da operação morfológica *bottom-hat*. Para a redução de falsos positivos é aplicada uma limiarização com ajuste manual do limiar. Segundo Kroetz (2012), os resultados foram considerados inadequados a uma inspeção automática, porém, servem como uma ferramenta de auxílio à inspeção.

Fylyk e Centeno (2012) utilizaram o método desenvolvido por Kroetz (2012) para detecção do cordão de solda em imagens radiográficas obtidas pela técnica PDVD. Para destacar e marcar regiões de defeitos em cordões de solda é utilizado um *ensemble* com 10 redes neurais. Um conjunto de 100 redes foi treinado através de amostras de defeitos e não defeitos extraídos manualmente de janelas de 41x41 pixels, e utilizadas as 10 redes com melhor desempenho. A seleção de padrões para treinamento de redes neurais *Multi-Layer Perceptron* é manual. O sistema apresenta como resultado do *ensemble* uma sensibilidade de 100%, porém, a precisão foi de apenas 37,5%, resultando em um *F-score* de 54,5%.

O método desenvolvido por Suyama (2015) é aplicado em recortes de imagens PDVD contendo o cordão de solda a ser analisado. O ajuste do tamanho do recorte foi realizado manualmente, com o objetivo de diminuir o espaço de busca, tornando o método de

classificação semiautomático. Sobre o recorte da imagem é realizada uma operação de realce, visando destacar a região que contém os defeitos a serem detectados. Uma redução do espaço de busca é realizada pela eliminação da região central da junta soldada. Na região reduzida, o método busca segmentar descontinuidades (potenciais defeitos) que posteriormente são classificados por um *ensemble* com até 10 Redes Neurais *Multi-layer Perceptron* (MLP) em defeitos e não defeitos. Apenas quatro características (área, perímetro, entropia e primeiro momento invariante de Hu) foram utilizadas como entrada das redes MLP. Em seu trabalho, Suyama (2015) apresenta como resultado uma detecção de 96,53% dos defeitos e precisão 77,67%, resultando em um *F-score* de 86,06%. Este resultado foi obtido por Suyama (2015) com a combinação de duas redes neurais. O valor do *F-score* diminuiu com um número maior de redes neurais no *ensemble*.

### 3.3 CONSIDERAÇÕES FINAIS

A maior parte da literatura se concentra na detecção de defeitos em imagens radiográficas de cordões de solda obtidas pela técnica PSVS (LAWSON; PARKER, 1994; LIAO; LI, 1998; SILVA, 2003; MERY, 2011; ZAPATA; VILAR; RUIZ, 2011; YAHIA et al., 2011; VALAVANIS; KOSMOPOULOS, 2010; SIKORA et al., 2012). Há poucos trabalhos que abordam a técnica PDVD (KROETZ, 2012; FYLYK; CENTENO, 2012; SUYAMA, 2015).

Analisando as principais publicações na pesquisa de detecção de defeitos em imagens radiográficas de tubulações, 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 podem ser visto nos resumos dos trabalhos citados.

De uma forma geral, os trabalhos buscaram detectar e analisar descontinuidades encontradas sobre as regiões de interesse (ROIs). Os métodos se concentram em três linhas diferentes de detecção de defeitos em imagens radiográficas de juntas soldadas: através de janelas que “convoluem” sobre toda a imagem, de perfil transversal de nível de cinza do cordão de solda e de segmentação de regiões, com extração de características dos defeitos. Os métodos propostos na literatura geralmente seguem os seguintes caminhos para a detecção de defeitos de soldagem: a delimitação da ROI; o pré-processamento para redução de ruídos e o

realce; a segmentação de perfis, janelas ou regiões e o pós-processamento para eliminação de ruídos e a extração de características e classificação das descontinuidades.

Em termos de classificação dos defeitos, a maioria dos trabalhos está direcionada para o reconhecimento de características típicas de cada defeito usando redes neurais. Grande parte dos trabalhos (ZAPATA; VILAR; RUIZ, 2012; VALAVANIS; KOSMOPOULOS, 2010; SIKORA et al., 2012; SHAFEEK et al., 2004a, 2004b; SHAO et al., 2011; WANG; WONG; TAN, 2010; RALE; GHARPURE; RAVINDRAN, 2009; YIN et al., 2008; CARVALHO et al., 2003; WANG; LIAO, 2002; SUYAMA, 2015) utiliza algumas considerações de forma e de textura dos defeitos para escolher as características mais relevantes na classificação dos defeitos usuais de soldagem.

Seguindo uma linha utilizada por grande parte dos pesquisadores, que usam o recurso de extração de características de regiões segmentadas com potenciais defeitos para posterior classificação, no próximo capítulo é apresentado o método proposto para segmentação, extração das características e classificação de descontinuidades em imagens radiográficas de soldas em tubulações, para imagens obtidas pela técnica de exposição radiográfica PDVD.

## 4 MATERIAIS E MÉTODOS

Este capítulo, além de apresentar o conjunto de imagens radiográficas disponibilizadas para a realização do estudo desta tese, explica o método proposto para a detecção e classificação automática de defeitos em imagens radiográficas de soldas em tubulações.

São apresentados os métodos e técnicas para a identificação da região do cordão de solda, detecção e identificação das descontinuidades, e extração das características para o treinamento das redes neurais *Perceptron* de múltiplas camadas (*Multilayer Perceptron*) (MLP), Máquinas de Aprendizado Extremo (*Extreme Learning Machines*) (ELMs) e o classificador estatístico (*Support Vector Machines*) (SVM). Também são apresentadas três propostas para o critério de decisão do *ensemble* de redes neurais ELM utilizados na classificação das descontinuidades.

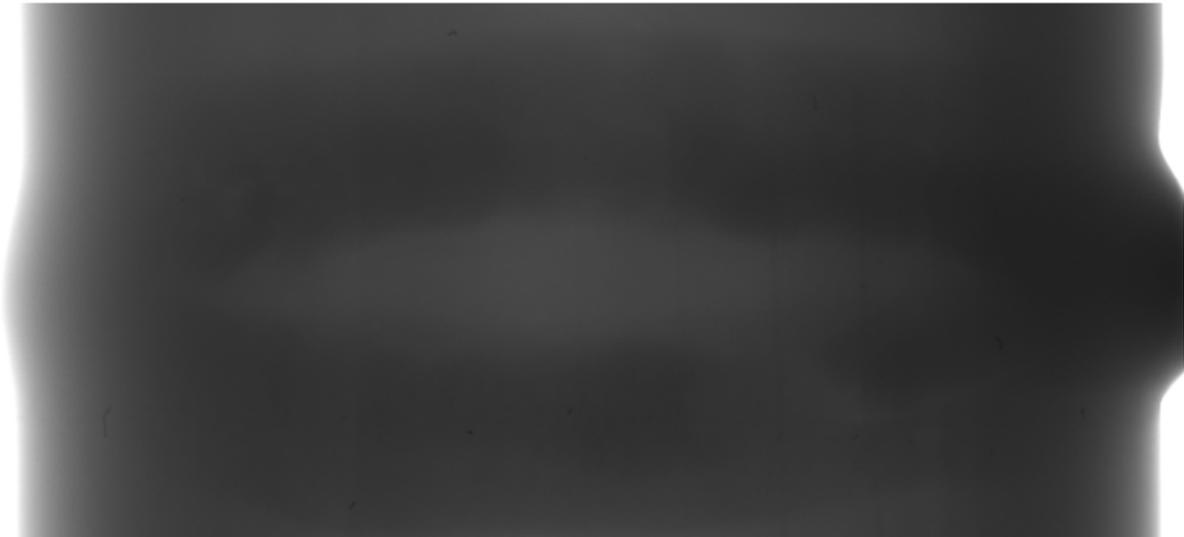
### 4.1 MATERIAIS

Numa primeira fase da pesquisa foram usados cordões de solda recortados de oito imagens radiográficas computadorizadas de juntas soldadas obtidas pelo sistema de radiografia computadorizada Dürr. As imagens empregadas foram obtidas a partir de condições reais de operação, sendo afetadas por parâmetros diferentes de captura e digitalização, tais como quantidade de radiação e tempo de exposição, o que ocasionou diferentes níveis de luminosidade, ruído e contraste. A Figura 29(a) apresenta um dos recortes do cordão de solda utilizado no treinamento dos classificadores MLP, ELM e SVM. Estas imagens foram fornecidas pela PETROBRAS e obtidas através da técnica parede dupla vista dupla (PDVD). Em uma segunda fase da pesquisa, foram acrescentadas mais nove imagens obtidas pelo sistema de radiografia computadorizada GE, totalizando um conjunto com 17 imagens.

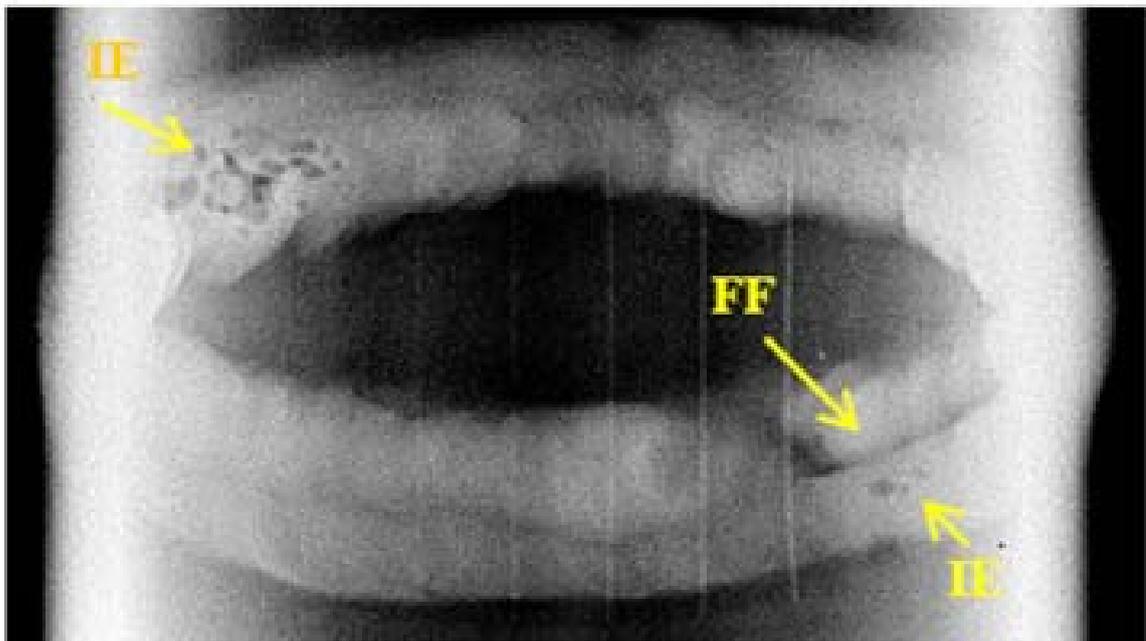
As imagens foram fornecidas na forma de negativos em arquivos no formato *Tagged Image File Format* (TIFF) com 65536 tons de cinza (16 bpp) e dimensões (largura x altura) variadas por se tratarem de recortes (dimensão mínima de 1000x412 pixels e dimensão máxima de 1989x793 pixels).

As imagens utilizadas apresentam quatro dos seis tipos de defeitos em juntas soldadas descritos no Capítulo 2. Os defeitos encontrados nestas imagens são: porosidade (PO), inclusão de escória (IE), falta de fusão (FF) e trincas (TR). Todas as imagens foram

laudadas por especialistas. A Figura 28(b) mostra o laudo da imagem da Figura 28(a). Nesta imagem observa-se a presença dos defeitos inclusão de escória e falta de fusão.



(a)



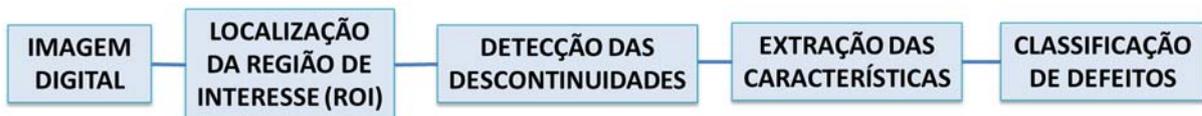
(b)

**Figura 28 - Imagens do cordão de solda. (a) Recorte da imagem original. (b) Laudo realizado pelo especialista sobre a mesma imagem.**

O software Matlab® foi utilizado para o desenvolvimento do algoritmo para detecção e classificação de defeitos de soldas.

## 4.2 MÉTODO

O algoritmo proposto consiste em quatro etapas principais: localização da região de interesse (*region of interest* - ROI), detecção de descontinuidades (potenciais defeitos), extração das características das descontinuidades detectadas e classificação das descontinuidades (defeitos). A Figura 29 mostra os principais passos do algoritmo para detecção e classificação automática de defeitos de soldagem.



**Figura 29 - Passos do algoritmo de detecção e classificação de defeitos.**

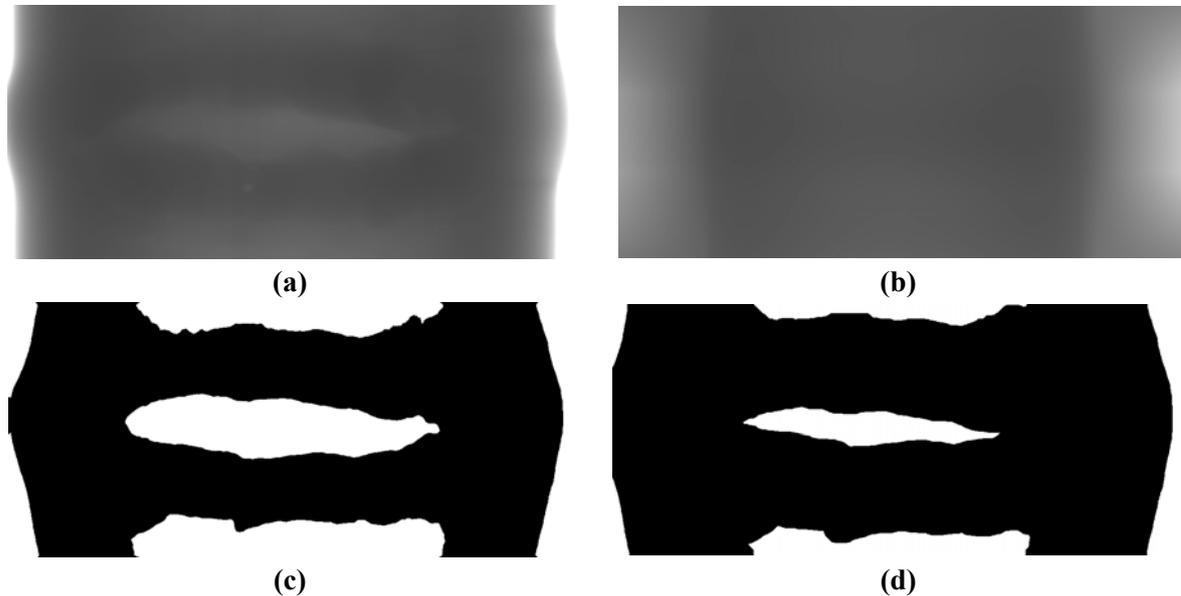
### 4.2.1 Localização da Região do Cordão de Solda (ROI)

A segmentação da região de cordão da soldagem é executada no recorte da imagem original (Figura 30(a)), e destina-se a limitar a região de pesquisa para o próximo passo (detecção de descontinuidades). Descontinuidades encontradas fora da região de interesse não são consideradas no treinamento da rede neural e na detecção e classificação de defeitos, pois estão fora do cordão de solda.

A segmentação do cordão de solda é realizada através de técnicas de processamento de imagens. Inicialmente é aplicado um filtro de mediana 9x9 sobre a imagem original com o objetivo de diminuir o nível de ruídos indesejados. Na sequência é aplicado um filtro de média 300x300 na imagem filtrada visando um “borramento” da imagem, conforme mostra a Figura 30(b). Uma constante de valor 200 é somada à imagem resultante, que é subtraída da imagem filtrada pelo filtro de mediana, resultando em uma máscara de nitidez entre as duas imagens. Os valores foram definidos empiricamente e adotados para todas as imagens, buscando uma maior cobertura dos defeitos de soldagem. Sobre a máscara obtida é aplicada a limiarização descrita na Seção 2.2.6.2, com a utilização de limiar igual a 0 (zero). As regiões escuras com área inferior a 10.000 pixels são excluídas, restando somente a imagem do cordão de solda. O resultado da limiarização pode ser observado na Figura 30(c). Todos os valores foram definidos empiricamente com o objetivo de reduzir o espaço de busca e não excluir descontinuidades pertencentes à região do cordão de solda.

Para que as descontinuidades existentes na margem do cordão de solda não sejam descartadas, a imagem resultante é morfologicamente erodida com um elemento estruturante

disco de raio 23, obtido empiricamente. O resultado da aplicação da erosão pode ser observado na Figura 30(d). Somente as descontinuidades encontradas na região escura desta figura são consideradas na etapa de classificação.



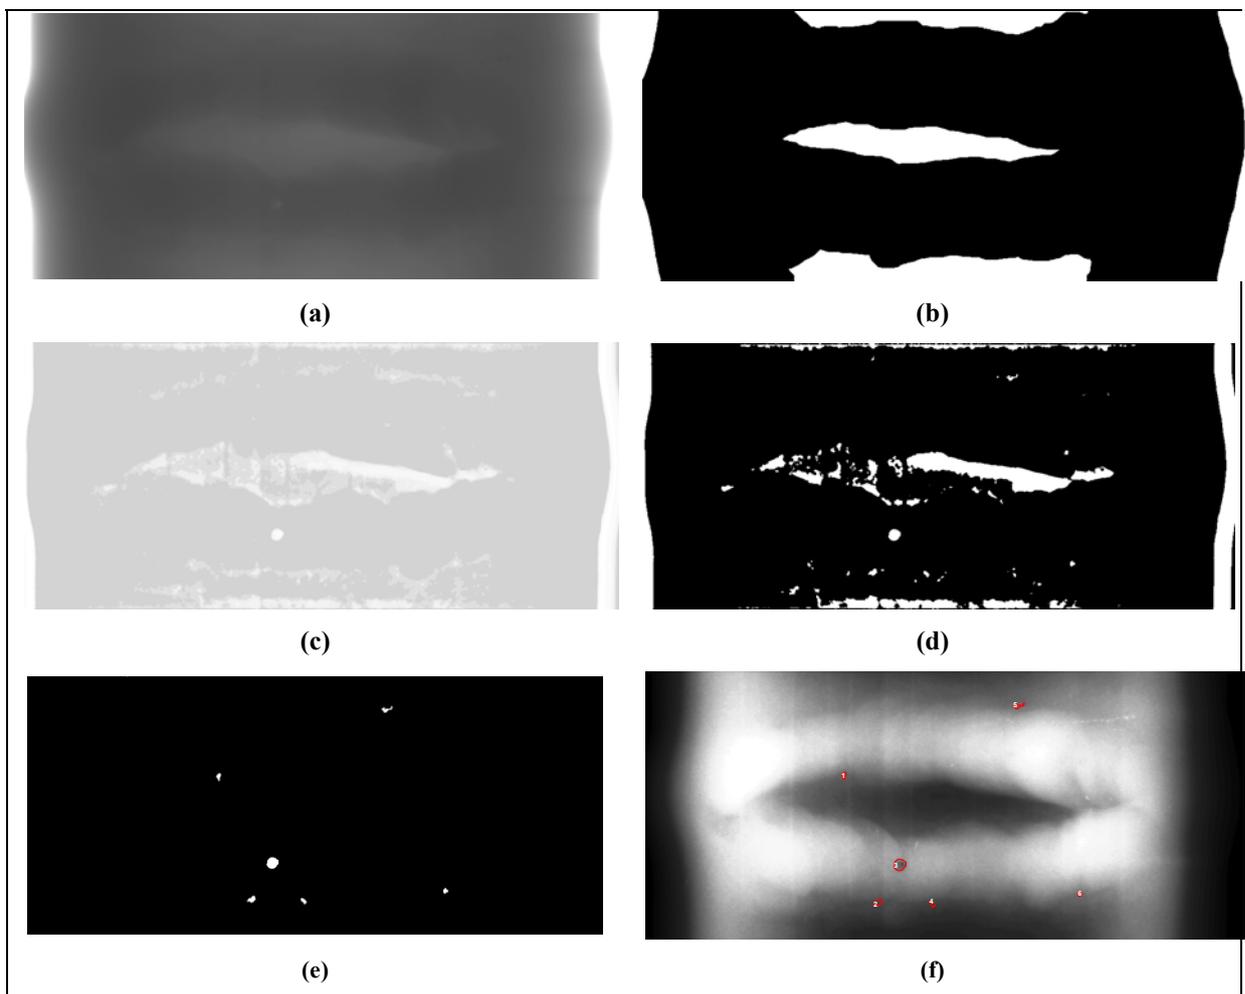
**Figura 30 – Segmentação do cordão de solda. (a) Recorte da imagem original. (b) Imagem filtrada pelo filtro da média 300x300. (c) Imagem limiarizada. (d) Imagem erodida.**

#### 4.2.2 Detecção de Descontinuidades e Extração das Características

Esta etapa realiza a detecção de descontinuidades existentes na ROI, que foi segmentada na etapa anterior, e extrai as características das descontinuidades detectadas a serem posteriormente utilizadas como entrada dos classificadores de padrões avaliados nesta pesquisa.

Sobre o recorte da imagem original mostrada na Figura 31(a) é aplicado o filtro adaptativo de Wiener 5x5. Esta técnica, utilizada por Zapata, Vilar e Ruiz (2011), busca a redução do nível de ruído das imagens, preservando as bordas e outras descontinuidades de alta frequência. Sobre esta imagem é aplicada a operação *top-hat*, com elemento estruturante disco de raio 10. Segundo Solomon e Breckon (2013) a imagem resultante da operação morfológica *top-hat* somada com a imagem filtrada pelo filtro de Wiener realça os detalhes brilhantes salientando as descontinuidades. Estas operações não apresentam alterações visíveis para as imagens utilizadas. O resultado pode ser visualizado somente após a limiarização.

De maneira semelhante à técnica utilizada na identificação da região do cordão de solda, descrita na Seção 4.2.1, é aplicado o filtro da média 55x55 sobre a imagem resultante, valor definido para este grupo de imagens. Esta imagem é somada a uma constante de valor 40 e subtraída da imagem filtrada pela operação *top-hat*, resultando em uma máscara de nitidez. Para melhorar o brilho e contraste, sobre esta máscara é aplicada a equalização de histograma, cujo resultado é mostrado na Figura 31(c). Em seguida é aplicada a limiarização de Otsu, resultando na imagem apresentada na Figura 31(d). O resultado é somado com a imagem limiarizada da região de interesse que representa o cordão de solda (Figura 31(b)), descrita na seção anterior.



**Figura 31 – Imagens das etapas principais na identificação de defeitos candidatos. (a) Original. (b) Região de interesse. (c) Máscara de nitidez equalizada. (d) Imagem segmentada pela técnica de Otsu. (e) Segmentação final das discontinuidades. (f) Identificação dos defeitos candidatos na imagem equalizada.**

Após a execução das operações descritas, todos os objetos com área maior que 40 pixels e menor que 6000 pixels são considerados defeitos candidatos. Além disso, todos os defeitos localizados dentro de uma faixa de 10% nas extremidades direita e esquerda da

imagem e 7% nas extremidades superior e inferior são descartados, conforme a região destacada da Figura 32. As descontinuidades encontradas nesta faixa não são consideradas como defeitos potenciais, porque não estão nos laudos. Os resultados após a execução desta etapa e da etapa anterior podem ser vistos na Figura 31(e). Todos os valores utilizados foram definidos empiricamente através de comparações entre as imagens segmentadas e as imagens laudadas.

Os defeitos candidatos da Figura 31(e) (objetos brancos da imagem) são identificados por um algoritmo de rotulagem (GONZALEZ; WOODS; EDDINS, 2004), e suas bordas são detectadas através de contornos pelo gradiente morfológico. A Figura 31(f) apresenta as descontinuidades detectadas (possíveis defeitos).

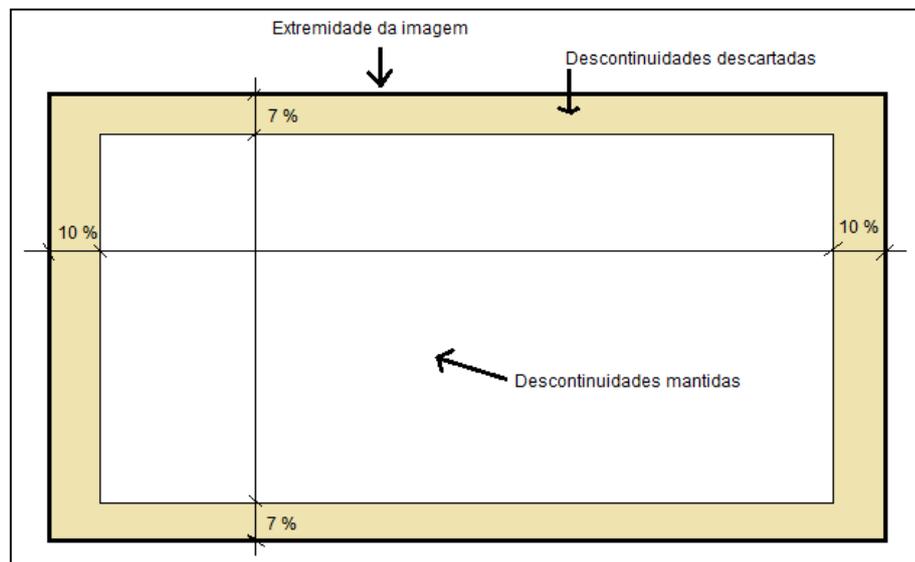


Figura 32 – Área de exclusão de defeitos candidatos da extremidade da imagem.

O algoritmo proposto extrai o seguinte conjunto de atributos (características geométricas de forma) para cada descontinuidade identificada (SILVA, 2003; VALAVANIS; KOSMOPOULOS, 2010):

1. Área = Área da descontinuidade (defeito) detectada, ou seja, número total de *pixels* dentro da descontinuidade, incluindo seu contorno ( $A$ ).
2. Extensão = Razão entre a área do defeito e a área do menor retângulo que envolve o defeito ( $E_x=A/A_R$ ).
3. Razão 1 = Razão entre o menor eixo do retângulo que envolve o defeito e a área do defeito ( $R_1=d/A$ ).

4. Razão 2 = Razão entre o maior eixo do retângulo que envolve o defeito e a área do defeito ( $R_2 = D/A$ ).
5. Razão 3 = Razão entre o maior eixo do retângulo que envolve o defeito e o menor eixo do retângulo que envolve o defeito ( $R_3 = D/d$ ).
6. Arredondamento = Razão  $p^2/4\pi A$ , onde  $p$  é o perímetro do contorno do defeito e  $A$  é a área do defeito.
7. Excentricidade = Razão entre a distância entre os focos da elipse que envolve o defeito e o comprimento do seu eixo principal ( $E_c = c/a$ ).
8. Solidez = Razão entre a área do defeito e a área poligonal convexa do defeito ( $S = A/A_c$ ).

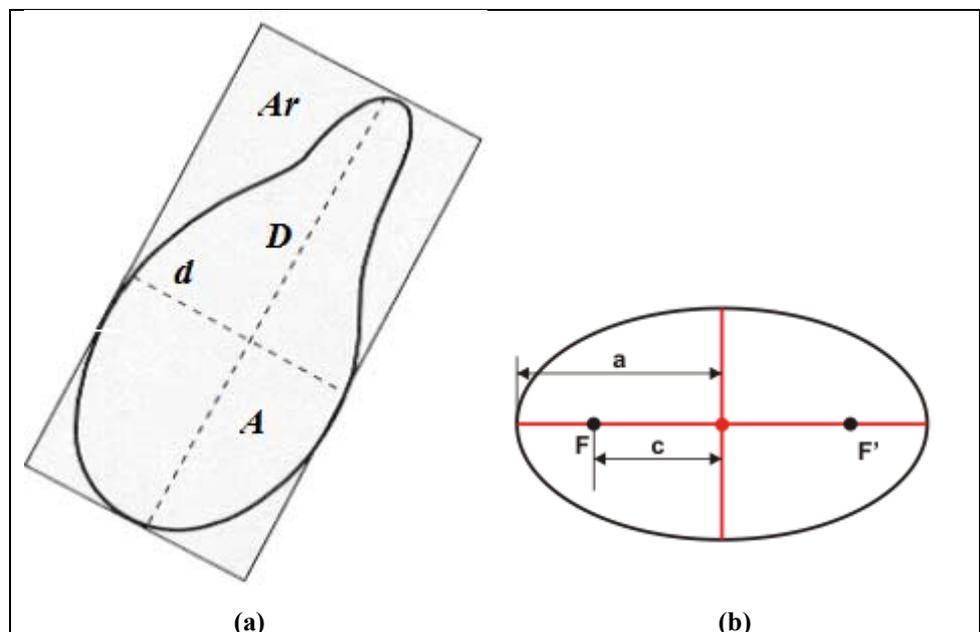


Figura 33 – Exemplo de forma da descontinuidade com indicação dos parâmetros utilizados na extração das características geométricas. (a) Características 1 a 6. (b) Característica 7.

Além do conjunto de atributos (características geométricas de forma) descritos acima, o algoritmo também gera para cada descontinuidade identificada as seguintes características de textura:

1. Diferença = Diferença entre o menor e o maior nível de cinza do defeito.
2. Contraste = Razão entre a variação do nível de cinza no defeito e a variação do nível de cinza presente no recorte da imagem.
3. Desvio padrão = medida de dispersão em relação à média de níveis de cinza do defeito.

4. Entropia = número quantificador da aleatoriedade dos níveis de cinza do defeito. Quanto maior for este número, mais irregular, atípica ou despadronizada será a imagem analisada.
5. Assimetria = assimetria em relação ao centro dos valores de níveis de cinza do defeito.

Estas características compõem um banco de padrões contendo um conjunto com  $N$  vetores. Cada vetor contém as 8 características geométricas de um defeito e 5 características de textura. Estas características são utilizadas parcialmente ou na sua totalidade como entrada nos classificadores MLP, ELM e SVM.

#### 4.2.3 Normalização das Características (*Features*) de Entrada

A normalização de entradas da rede neural tem a função de adaptar os dados de entrada à faixa dinâmica das funções de ativação, aperfeiçoando a convergência da rede ao evitar a saturação das saídas das funções de ativação. Essa operação pode ser usada, por exemplo, para normalizar os dados de entrada da rede no intervalo  $[-1; 1]$  caso a função de ativação empregada na camada oculta da rede neural seja do tipo tangente hiperbólica ou entre  $[0; 1]$  caso a função de ativação seja sigmoide.

Uma das formas de normalização é definida na equação (44), onde a matriz ou vetor de entrada  $\mathbf{x}$  possui apenas valores reais finitos e os elementos de cada linha são distintos,  $\mathbf{y}$  é a matriz ou vetor de entrada normalizada (i.e., no novo intervalo),  $x_{max}$  é o valor máximo de  $\mathbf{x}$ ,  $x_{min}$  é o valor mínimo de  $\mathbf{x}$ ,  $y_{max}$  é o valor de máximo do novo intervalo e  $y_{min}$  é o valor mínimo do novo intervalo.

$$\mathbf{y} = \frac{(y_{max}-y_{min})(\mathbf{x}-x_{min})}{(x_{max}-x_{min})} + y_{min} \quad (44)$$

#### 4.2.4 Treinamento da Rede Neural MLP

Para o treinamento da rede neural MLP utiliza-se um conjunto de  $N$  vetores de entrada ( $\mathbf{x}$ ) representando padrões de descontinuidades com classificação conhecida. Cada vetor contém as 8 características geométricas de um defeito e 5 características de textura e uma das classes de defeitos ou não defeitos.

Para cada inicialização da rede neural estes  $N$  vetores (amostras) são distribuídos aleatoriamente entre treinamento, validação e teste, em uma proporção de 60/20/20% para esta divisão, quando usado validação cruzada *hold-out* definida na Seção 2.5.1. Os vetores de treinamento são usados para o ajuste de pesos da rede pelo algoritmo de treinamento. Os vetores de validação são empregados para testar o desempenho da rede durante o aprendizado, servindo também como critério de parada do algoritmo de treinamento. Os vetores de teste são utilizados para verificar o desempenho da rede para amostras desconhecidas. Com o objetivo de obter uma estimativa de erro mais precisa são realizadas múltiplas execuções de *hol-dout (Random Subsampling)* e calculado a média dos indicadores obtidos.

Para definição de um protocolo de treinamento padrão e posterior comparação dos classificadores é usado o método de validação cruzada *leave-p-label-out* definida na Seção 2.5.4, onde o tamanho da amostra  $n$  refere-se ao número de imagens e não aos vetores de características, cada amostra pode ter valores diferentes de vetores de características. Para o conjunto de imagens utilizado o número total de amostras  $n$  pode ser igual a oito no cenário intra-sensor Dürr, nove no cenário intra-sensor GE, 17 no cenário multi-sensor Dürr + GE ou dois no cenário inter-sensor Dürr com GE ou GE com Dürr. Onde a amostra remanescente  $p$  tem seus vetores identificados através de um rótulo e representa a imagem ou as imagens que serão usadas como teste na validação cruzada.

A Figura 34 mostra um esquema da rede neural proposta para o treinamento do classificador. Trata-se de uma rede MLP *feed-forward* de duas camadas. Esta rede tem 8 ou 13 entradas, dependendo do número de características empregadas no treinamento,  $L$  neurônios na camada oculta e cinco neurônios na camada de saída, um para cada classe (porosidade, inclusão de escória, falta de fusão, trinca e não-defeito). Para o classificador binário (defeito e não-defeito) a arquitetura da rede é alterada para 2 neurônios na camada de saída.

A rede é treinada pelo algoritmo *backpropagation* em gradiente conjugado escalonado. O treinamento é realizado por época e a rede neural encerra o treinamento quando o erro quadrático médio de validação não evolui durante um número de iterações pré-definidas.

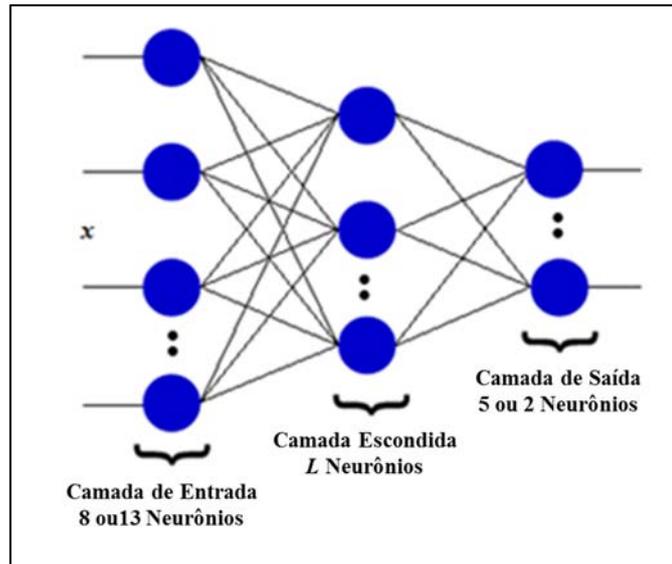


Figura 34 - Rede neural MLP com  $L$  neurônios na camada oculta.

#### 4.2.5 Treinamento da Rede Neural ELM

Para o treinamento da rede neural ELM utiliza-se o conjunto de  $N$  vetores de entrada representando padrões de discontinuidades com classificação conhecida. A pesquisa foi adaptada para classificadores binários, classificando as discontinuidades em defeito e não defeito. O banco de padrões utilizado no treinamento da ELM contém  $N$  vetores com 8 características geométricas e 5 de textura e as classes de saída defeito e não defeito.

Para cada inicialização da rede neural estes  $N$  vetores são distribuídos aleatoriamente entre treinamento e teste, em uma proporção de 70/30% para esta divisão, quando usado validação cruzada *hold-out* definida na Seção 2.5.1. Com o objetivo de obter uma estimativa de erro mais precisa são realizadas múltiplas execuções de *hol-dout* (*Random Subsampling*) e calculado a média dos indicadores obtidos.

Para definição de um protocolo de treinamento padrão e posterior comparação dos classificadores é usado o método de validação cruzada *leave-p-label-out* definida na Seção 2.5.4, onde o tamanho da amostra  $n$  refere-se ao número de imagens e não aos vetores de características, cada amostra pode ter valores diferentes de vetores de características. Para o conjunto de imagens utilizado o número total de amostras  $n$  pode ser igual a oito no cenário intra-sensor Dürr, nove no cenário intra-sensor GE, 17 no cenário multi-sensor Dürr + GE ou dois no cenário inter-sensor Dürr com GE ou GE com Dürr. Onde a amostra remanescente  $p$  tem seus vetores identificados através de um rótulo e representa a imagem ou as imagens que serão usadas como teste na validação cruzada.

A Figura 35 mostra a rede utilizada. Trata-se de uma rede *Extreme Learning Machine* (ELM) que pode ser empregada com ou sem a utilização do fator de regularização  $C$ . Esta rede tem oito ou treze entradas, dependendo do número de características empregadas no treinamento,  $L$  neurônios na camada oculta e dois neurônios na camada de saída, um para a classe defeito e um para a classe não defeito.

A escolha dos  $L$  neurônios na camada oculta e do fator de regularização  $C$  é determinada após um número de inicializações do algoritmo de treinamento para cada valor de  $L$  e  $C$ , e tem o objetivo de obter a média para cada um dos indicadores no treinamento e teste da rede neural. Os indicadores são os descritos na Seção 2.6, ou seja, acurácia, precisão, sensibilidade e *F-score*.

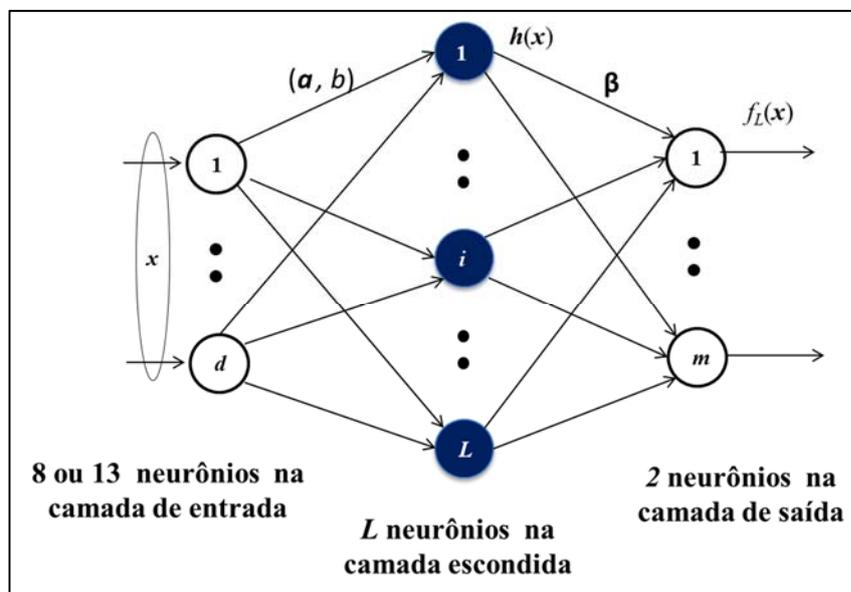


Figura 35 - Rede neural ELM proposta com 8 ou 13 entradas,  $L$  neurônios na camada oculta e 2 neurônios na camada de saída.

Fonte: Adaptado de Huang et al. (2015).

O resultado de saída de cada neurônio é um valor contínuo limitado entre os valores  $[-1$  e  $1]$ . Para o treinamento, valores maiores ou iguais a zero indicam que a saída estimada é verdadeira para o respectivo neurônio, e valores menores que zero indicam que a saída é falsa.

#### 4.2.6 Definição do *Ensemble* de ELMs

Com o objetivo de melhorar os indicadores de desempenho do método proposto,  $n$  ELMs treinadas são agrupadas em paralelo formando um *ensemble* de ELMs, conforme

ilustrado na Figura 36. O número de componentes de redes e as características de diversidade destas redes são definidos através de experimentos.

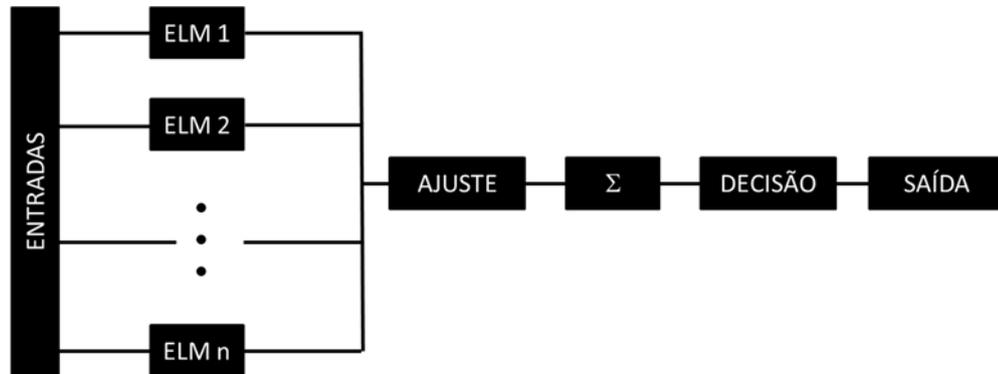


Figura 36 - *Ensemble* de redes neurais ELMs.

Observa-se na Figura 36 que os dados de entrada (descontinuidades a serem classificadas) são submetidos a  $n$  redes neurais ELM. Cada rede apresenta um resultado de saída variando de -1 a 1, conforme explicado na Seção 4.2.5. Estes resultados passam por um ajuste antes de serem somados. Após a soma, o *ensemble* toma a decisão final se a descontinuidade é defeito ou não. Os resultados obtidos pelos *ensembles* são comparados com os resultados obtidos pelo melhor classificador ELM treinado individualmente.

Podem-se usar variadas formas de ajuste e combinação dos dados de saída de cada ELM. Neste trabalho são propostas e avaliadas três destas formas: discretizado em duas faixas, discretizado em três faixas com peso diferenciado na faixa intermediária e soma contínua das saídas das redes (sem ajuste). Estas formas serão discutidas nas subseções a seguir.

#### 4.2.6.1 *Ensemble* de ELMs discretizado em duas faixas

Neste processo de decisão do *ensemble* de ELMs, as saídas de cada rede neural são discretizadas no ponto central. Para valores menores que 0 (zero) é atribuído o valor 0 (zero) à rede, e para valores de saída maior ou igual a zero é atribuído o valor 1. As saídas das  $n$  redes são somadas e define-se o valor da somatória para a tomada de decisão, convencionado como limiar de decisão ( $\delta$ ). Este método proposto é semelhante ao método voto majoritário apresentado na Seção 2.3.4.2, mas difere dele por incluir um limiar de decisão variável para a saída do *ensemble* de ELMs, e não somente o voto majoritário. O limiar de decisão  $\delta$  é

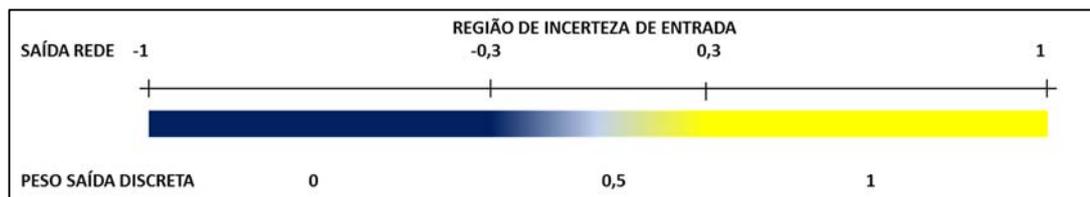
definido através de experimentos com o objetivo de encontrar os melhores resultados para os indicadores selecionados, onde:

$$\text{DECISÃO} \begin{cases} \text{Saída} \geq \delta: \text{ defeito} \\ \text{Saída} < \delta: \text{ não defeito} \end{cases}$$

#### 4.2.6.2 Ensemble de ELMs discretizado em três faixas

A diferença deste método para o método proposto na seção anterior, é que, neste processo de decisão de saída do *ensemble* de ELMs, as saídas de cada rede neural não são discretizadas no ponto central. Atribui-se um grau de incerteza nesta região, criando-se uma terceira faixa de decisão ou discretização, definida como região de incerteza de entrada do *ensemble*, atribuindo-se neste caso um peso diferente para as saídas das redes.

A Figura 37 mostra os possíveis resultados de saída de uma rede neural ELM antes e depois da discretização. Para este exemplo foi definido um grau de incerteza entre -0,3 e 0,3 para a entrada do *ensemble*, e atribuído peso 0,5 para esta faixa. Para esta forma de decisão tanto os valores desta faixa de incerteza, bem como o seu respectivo peso, são novas variáveis incluídas na decisão e que podem ser alteradas.



**Figura 37 - Discretização da saída da ELM em três faixas.**

Neste exemplo, para valores menores ou iguais a -0,3 é atribuído o valor 0 (zero) à saída da rede, para valores de saída maiores ou iguais a 0,3 é atribuído o valor 1, e para valores entre -0,3 e 0,3 atribui-se o valor 0,5. A saída das  $n$  redes são somadas e define-se o valor da somatória para a tomada de decisão, onde:

$$\text{DECISÃO} \begin{cases} \text{Saída} \geq \delta: \text{ defeito} \\ \text{Saída} < \delta: \text{ não defeito} \end{cases}$$

#### 4.2.6.3 Ensemble de ELMs contínuo

Neste processo de decisão do *ensemble* de ELMs as saídas das redes neurais não são discretizadas. Utiliza-se neste *ensemble* o valor corrente da saída de cada rede e somam-se seus valores para a tomada de decisão. A decisão pode ser tomada a partir da definição de um limiar  $\delta$  entre os valores da somatória, bem como pode-se definir uma região de incerteza de saída do *ensemble* na classificação das descontinuidades, neste caso há dois limiares de decisão,  $\delta_1$  e  $\delta_2$ . Este método proposto é semelhante ao método média simples, apresentado na Seção 2.3.4.2, e difere dele por somar as saídas e não fazer a média de cada componente. Neste método também é incluído um limiar de decisão variável para a saída do *ensemble* de ELMs.

A Figura 38 mostra os possíveis resultados de saída de um *ensemble* com 12 redes neurais ELMs. A decisão pode ser tomada a partir de um único limiar, por exemplo, limiar igual a zero ( $\delta = 0$ ). Para este processo de decisão pode-se incluir uma região de incerteza de saída do *ensemble*, no exemplo da Figura 38  $\delta_1 = -3$  e  $\delta_2 = 3$ . As descontinuidades pertencentes a esta região podem ser identificadas na imagem radiográfica de saída como região de incerteza, e a decisão fica a critério do inspetor laudista.



Figura 38 - Saída do *ensemble* contínuo para 12 ELMs.

$$\text{DECISÃO} \begin{cases} \text{Saída} \leq \delta_1: \text{ não defeito} \\ \delta_1 \leq \text{Saída} \leq \delta_2: \text{ incerteza} \\ \text{Saída} > \delta_2: \text{ defeito} \end{cases}$$

#### 4.2.7 Treinamento da SVM

Para o treinamento do classificador SVM utiliza-se o conjunto de  $N$  vetores de entrada representando padrões de descontinuidades com classificação conhecida. Cada vetor contém um conjunto de 13 características geométricas e de textura e as classes defeito e não-defeito.

Para definição de um protocolo de treinamento padrão e posterior comparação dos classificadores é usado o método de validação cruzada *leave-p-label-out* definida na Seção

2.5.4, onde o tamanho da amostra  $n$  refere-se ao número de imagens e não aos vetores de características, cada amostra pode ter valores diferentes de vetores de características. Para o conjunto de imagens utilizado o número total de amostras  $n$  pode ser igual a oito no cenário intra-sensor Dürr, nove no cenário intra-sensor GE, 17 no cenário multi-sensor Dürr + GE ou dois no cenário inter-sensor Dürr com GE ou GE com Dürr. Onde a amostra remanescente  $p$  tem seus vetores identificados através de um rótulo e representa a imagem ou as imagens que serão usadas como teste na validação cruzada.

O método utilizado para encontrar o hiperplano de separação ótimo implementa a *soft-margin* para o classificador SVM, com o uso do parâmetro de custo  $C$  para os erros.

A função *kernel* usada para mudar do espaço original para um espaço característico de dimensão mais elevada no hiperplano é a função Gaussiana de base radial (RBF), onde  $\sigma$  é interpretado como variância da RBF.

Portanto, para o treinamento da SVM, os parâmetros  $C$  e  $\sigma$  podem ser definidos visando obter o mínimo erro, ou o máximo acerto para o conjunto de dados de teste.

#### 4.2.8 Comparação entre classificadores MLP, ELM e SVM

Os classificadores MLP, ELM e SVM são comparados pelos indicadores definidos na Seção 2.6 através dos cenários intra-sensor, inter-sensor e multi-sensor. Para o classificador ELM também são realizados testes para identificar qual o método de regularização que retorna os melhores indicadores.

### 4.3 CONSIDERAÇÕES FINAIS

Com a utilização dos métodos propostos, apresentados neste capítulo, podem-se ressaltar alguns aspectos:

- A localização da ROI no recorte da imagem diminui o número de descontinuidades a serem classificadas, o que em conjunto com a utilização de redes neurais ELMs podem diminuir o tempo de solução na segmentação de descontinuidades e classificação de defeitos em uma imagem radiográfica digital.
- As características extraídas dos defeitos são as mesmas utilizadas por alguns autores citados no texto e escolhidas para as imagens PDVD. Outras

características também podem ser utilizadas e testadas utilizando o mesmo método proposto.

- A definição de uma região de incerteza de saída no critério de decisão do *ensemble* de ELMs permite o seguinte encaminhamento: apresentar na imagem as descontinuidades onde o algoritmo proposto tem um grau elevado de confiança no resultado e deixar a decisão das demais descontinuidades para o inspetor laudista.

Tal metodologia foi testada para todas as imagens radiográficas disponíveis, através de uma série de testes que são apresentados e discutidos no próximo capítulo.

## 5 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados os resultados, bem como as considerações sobre a implementação do método proposto. A Seção 5.1 compreende uma série de testes que tem por objetivo a geração de um banco de padrões para o treinamento dos classificadores. As Seções 5.2, 5.3, 5.4 e 5.5 visam avaliar o desempenho do classificador com base em redes neurais MLP e ELM, e o classificador estatístico SVM, bem como definir o critério e o limiar de decisão do *ensemble* de ELMs que apresenta o melhor resultado na classificação das descontinuidades. A Seção 5.6 apresenta um banco de padrões ampliado, com um conjunto maior de imagens, o que possibilita ter um banco de padrões específico para teste. O banco de padrões ampliado foi testado no *ensemble* de ELMs no cenário multisensor e na comparação entre os classificadores MLP, ELM e SVM nos cenários inter, intra e multi-sensor.

### 5.1 EXTRAÇÃO DO BANCO DE PADRÕES PARA TREINAMENTO DOS CLASSIFICADORES

O método proposto para localização da ROI segmentou todos os cordões de solda das imagens utilizadas na pesquisa, sem perder nenhum defeito laudado pelo especialista. A Figura 39 ilustra o resultado da aplicação desta etapa do algoritmo para um dos recortes. Apenas descontinuidades completamente inscritas na região identificada em preto são consideradas para extração das características usadas nos vetores (padrões) de treinamento, bem como na classificação das descontinuidades em novas imagens.

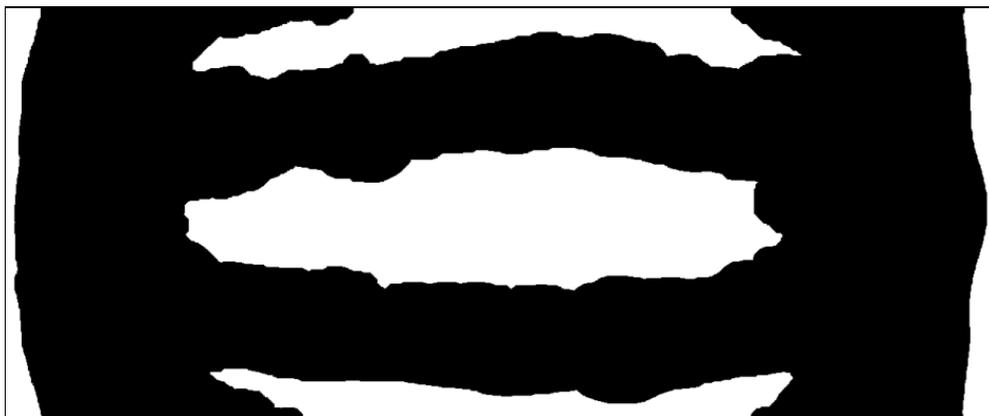
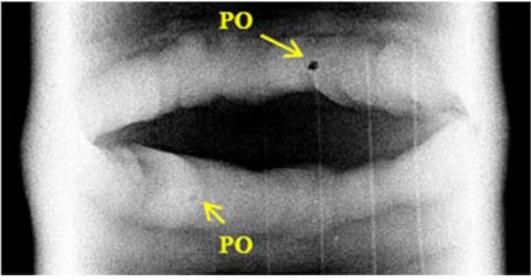
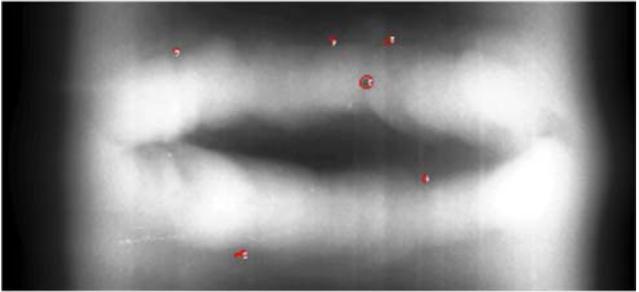
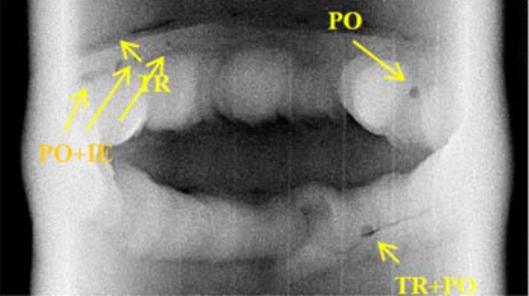
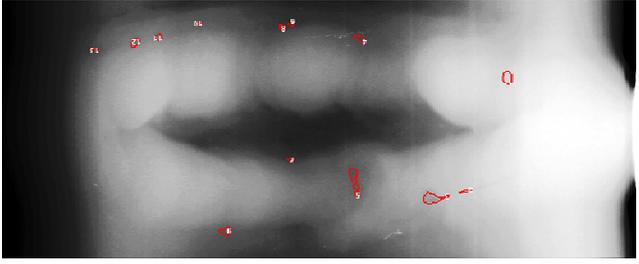
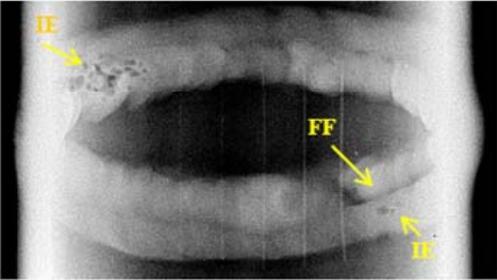
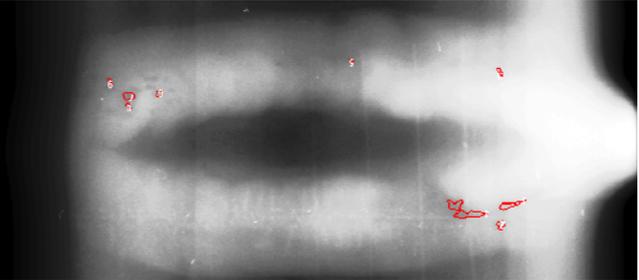


Figura 39 – Localização da região do cordão de solda (ROI).

A etapa de detecção de descontinuidades localizou na ROI das imagens os defeitos laudados e também descontinuidades não destacadas nos laudos, que foram tratadas como não defeitos para o treinamento dos classificadores.

A Figura 40 apresenta o resultado visual de saída para cada uma das oito imagens usadas na primeira fase da pesquisa, na qual as descontinuidades encontradas (potenciais defeitos) estão realçadas. A primeira coluna da figura apresenta as imagens contendo o laudo fornecido pelo especialista e a segunda coluna, as imagens geradas pelo algoritmo após a etapa de detecção das descontinuidades.

Laudos fornecidos das imagens	Imagens obtidas com algoritmo proposto
<b>06 descontinuidades encontradas</b>	
	
<b>13 descontinuidades encontradas</b>	
	
<b>09 descontinuidades encontradas</b>	
	
<b>37 descontinuidades encontradas</b>	

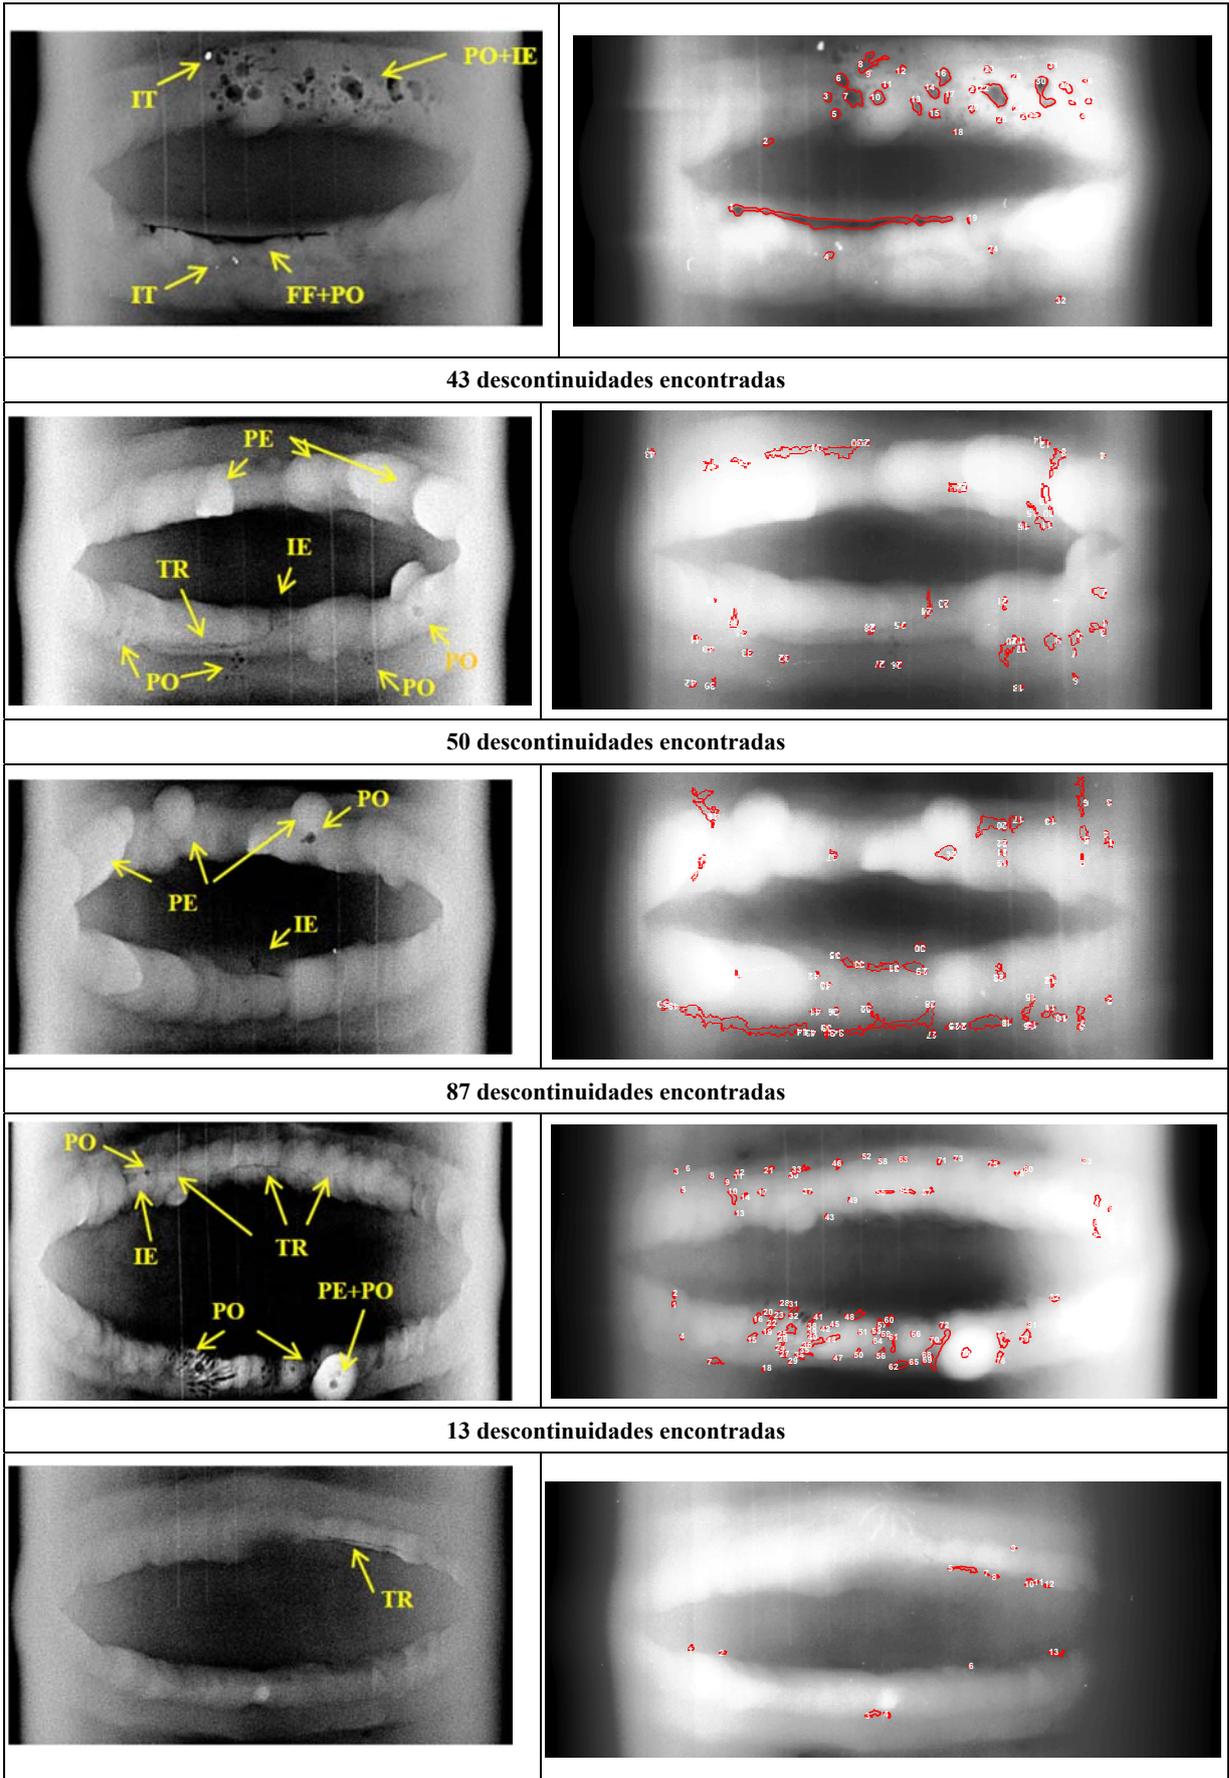


Figura 40 - Extração de características para treinamento dos classificadores.

Para cada descontinuidade identificada pelo algoritmo de rotulagem é gerado um vetor com suas respectivas características. O banco de padrões utilizado no treinamento dos classificadores na primeira fase da pesquisa é a combinação dos resultados dos vetores das oito imagens Dürr. Para evitar vícios no processo de amostragem, nenhuma descontinuidade foi desprezada, resultando em um banco de padrões desbalanceado com 258 vetores, contendo 08 características geométricas, 05 características de textura (descritas na Seção 4.2.2) e com 05 classes de saída para cada vetor. O banco de padrões resultante com a separação de vetores (amostras) entre as classes está apresentado na Tabela 5.

**Tabela 5 – Banco de padrões com identificação do número de amostras de cada classe**

CLASSES DE DEFEITOS	AMOSTRAS
Porosidade (PO)	77
Inclusão de escória (IE)	23
Falta de fusão (FF)	04
Trinca (TR)	08
Não defeito (ND)	146
TOTAL	258

## 5.2 TREINAMENTO COM REDES NEURAIAS MLP

O banco de padrões descrito na Tabela 5 é utilizado como entrada no treinamento do classificador com redes neurais MLPs. Para o treinamento da rede neural MLP multiclasse, foram utilizadas somente as características geométricas de forma, resultando em um banco de padrões com 258 amostras e 8 características geométricas.

A partir de uma arquitetura de rede com uma camada oculta e dez neurônios nesta camada, dez treinamentos foram realizados com diferentes pesos de inicialização. O resultado para este conjunto de treinamento apresentou uma acurácia média para os dados de teste de 69,87% e desvio padrão de 7,07%, para uma arquitetura de rede com dez neurônios na camada oculta. O melhor resultado dos dez treinamentos é apresentado na matriz de confusão da Figura 41. De acordo com a matriz de confusão, a acurácia na classificação dos dados de teste foi igual a 79,5%. Os resultados revelaram uma classificação inadequada para as classes "falta de fusão", "trinca" e "inclusão de escória". O melhor desempenho de *F-score* calculado pela equação (43) foi obtido para a classe "porosidade" com valor de 81,48%, seguido pela classe "não defeito" com valor de 85,10%. O baixo desempenho do classificador deveu-se principalmente ao desequilíbrio do conjunto de treinamento. Devido aos resultados

apresentados, o classificador multiclasse foi descartado e a pesquisa foi direcionada para classificador binário, com as classes defeito e não defeito.

		Treinamento						Teste						
Classe de Saída da Rede	PO	40	1	11	2	6	56,7%	PO	11	0	1	0	2	78,6%
	FF	0	1	0	0	0	100%	FF	0	0	0	0	1	0,0%
	IE	0	0	0	0	0	NaN%	IE	0	0	0	0	0	NaN%
	TR	0	0	0	1	1	50,0%	TR	0	0	0	0	0	NaN%
	ND	14	1	8	3	91	77,8%	ND	2	1	1	0	20	83,3%
			74,1%	33,3%	0,0%	16,7%	92,9%	73,9%		84,6%	0,0%	0,0%	NaN%	87,0%
		PO	FF	IE	TR	ND	Classe Real do Defeito							

**Figura 41 - Matriz de confusão de treinamento e teste da rede neural com 10 neurônios na camada oculta na classificação de 05 tipos de defeitos (NaN = valor numérico não válido).**

Tendo em vista os resultados anteriores, em outra perspectiva, foi realizado o treinamento da MLP utilizando apenas duas classes: defeito e não defeito. Todos os padrões de defeitos listados no experimento anterior foram agrupados na mesma classe "defeito". Com este arranjo obteve-se um conjunto de dados de treinamento equilibrado, contendo 112 vetores representando a classe "defeito" e 146 vetores representando a classe "não defeito".

Para determinar o número apropriado de neurônios na camada escondida, um conjunto de 20 treinamentos foi realizado para cada arquitetura da MLP contendo diferentes números de neurônios na camada escondida, com 8 neurônios na camada de entrada (somente características geométricas). O número de neurônios variou de 5 a 100 com um incremento regular de 5. A Figura 42 apresenta a média do *F-score* dos dados de teste para cada conjunto de 20 treinamentos. Com base nos resultados destes ensaios, o número "ótimo" de neurônios escolhido para a camada escondida foi de 40, uma vez que adicionar mais neurônios nesta camada não aumentou o *F-score* médio.

Para a arquitetura de rede escolhida como "ótima", ou seja, com 40 neurônios na camada escondida, os resultados apresentaram um *F-score* médio para os dados de teste de 73,79% e desvio padrão de 6,27% para o conjunto de 20 treinamentos. O melhor resultado destes 20 treinamentos realizados é apresentado na matriz de confusão na Figura 43. Para este

treinamento, a acurácia para os dados de teste foi de 88,6% e com *F-score* de 87,5% para a classe defeito.

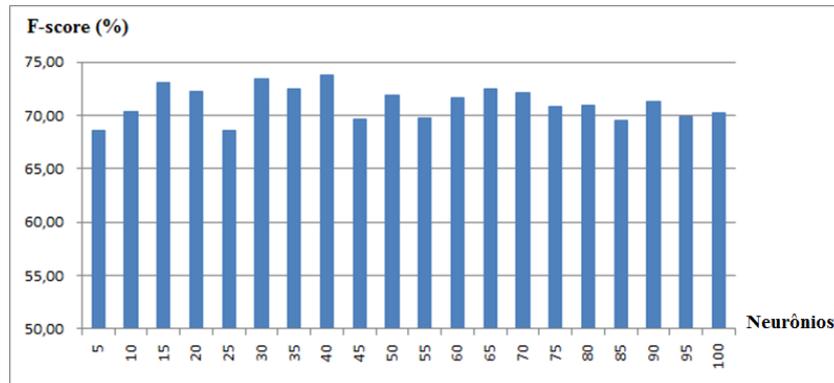


Figura 42 - Média do *F-score* dos dados de teste variando o número de neurônios na camada escondida.

		Treinamento			Teste			
Classe de Saída da Rede	DF	44	7	86,3%	DF	21	2	91,3%
	ND	20	83	80,6%	ND	4	25	86,2%
		68,8%	92,2%	82,5%		84,0%	92,6%	88,6%
		DF	ND			DF	ND	
		Classe Real do Defeito			Classe Real do Defeito			

Figura 43- Matriz de confusão de um treinamento da rede neural com 40 neurônios na camada oculta para as classes defeito e não defeito.

Mantendo a arquitetura de rede com 40 neurônios na camada escondida e utilizando o banco de padrões completo, com 8 características geométricas e 5 de textura, 20 treinamentos foram novamente realizados, apresentando um *F-score* médio para os dados de teste de 72,3% e desvio padrão de 7,67%. Este resultado indica que a inclusão de características de textura no treinamento da MLP para um número de pequeno de exemplos de treinamento não resultou em aumento do ganho médio do indicador *F-score*.

Para exemplificar o critério da parada descrito na Seção 2.3.3.1, a Figura 44 mostra o momento de parada do treinamento da rede neural MLP utilizada na simulação da Figura 43.

A parada ocorreu após 34 ciclos de treinamento, no momento em que o erro de validação não diminuiu por seis épocas consecutivas. O melhor resultado foi observado com 28 épocas.

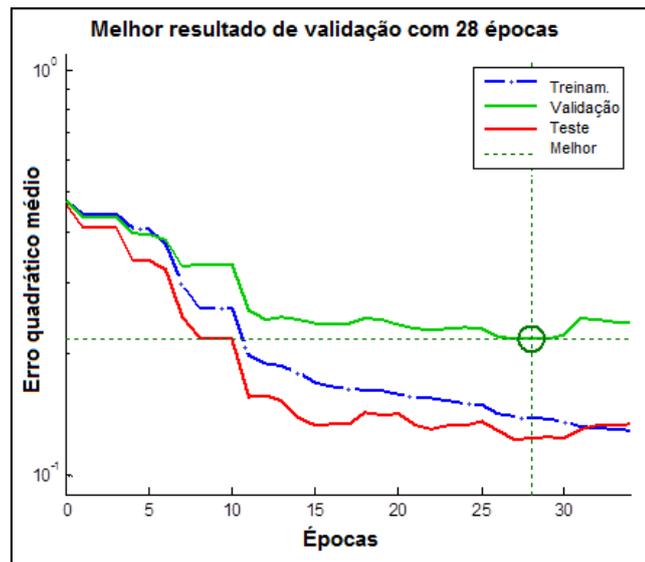


Figura 44 - Critério de parada utilizado na rede neural MLP

O resultado da aplicação do algoritmo automatizado do classificador MLP para duas classes (defeito e não defeito) pode ser visualizado na Figura 45. Nesta etapa, a rede neural treinada cujos indicadores estão descritos na Figura 43 foi inserida na última etapa do algoritmo e as imagens foram novamente processadas, identificando automaticamente as classes por cores: em amarelo as discontinuidades classificadas como defeitos, e em vermelho as discontinuidades classificadas como não defeitos. Com o objetivo de comparar a identificação manual realizada por especialistas com a utilização do algoritmo automatizado, a imagem do laudo foi inserida no canto inferior esquerdo da imagem processada pelo algoritmo. Para esta imagem somente uma discontinuidade não foi classificada corretamente. O defeito Inclusão de Tungstênio (IT) que aparece no laudo da Figura 45 não é abordado nesta pesquisa, já que suas características são bastante diferentes das características dos defeitos investigados na abordagem proposta.

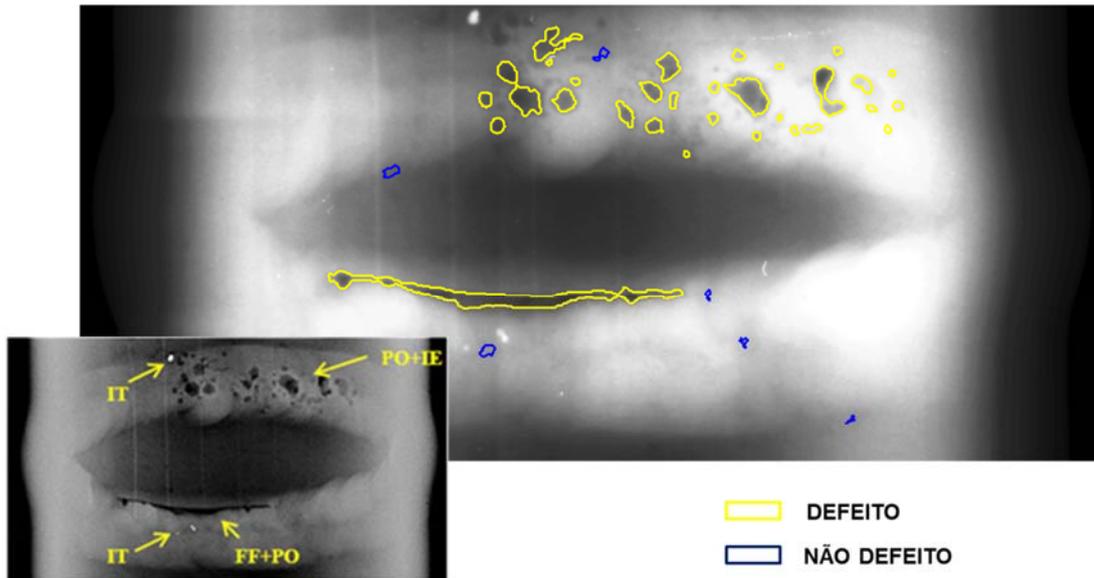


Figura 45- Imagem após a classificação das discontinuidades: superior - automatizada com utilização do algoritmo; inferior esquerda - manual fornecida pelo especialista.

### 5.3 TREINAMENTO COM REDES NEURAIS ELM

Com o objetivo de definir o número de neurônios na camada escondida, bem como o método de regularização e o fator de regularização  $C$  que retornam os melhores indicadores para o treinamento da rede neural ELM, foi implementado o treinamento apresentado na Seção 2.3.2.1. Nesta fase da pesquisa foi aproveitado o mesmo banco de padrões usado no treinamento da rede MLP, ou seja, com o banco de padrões parcial da Tabela 5, utilizando somente as 8 características geométricas como entrada. Para este treinamento a ELM proposta no Capítulo 4 com 13 entradas foi alterada para oito neurônios na camada de entrada.

A Tabela 6 apresenta os resultados para o treinamento de ELMs sem regularização, e as Tabelas 7 e 8 o treinamento das ELMs com regularização, utilizando as equações (27) e (28) respectivamente, aqui denominado método 1 e método 2. A regularização permite aumentar o número de neurônios da camada escondida, diminuindo o efeito do sobreajuste ocasionado por este aumento. Com isso o resultado tende a um melhor desempenho na generalização. Se o número de vetores (padrões) de treinamento  $N$  é maior que o número de neurônios ocultos  $L$  ( $N > L$ ) recomenda-se o método 1, e se o número de vetores (padrões) de treinamento  $N$  é menor que o número de neurônios ocultos  $L$ ,  $N < L$  recomenda-se o método 2.

Os resultados apresentados em cada coluna das tabelas representam a média e o melhor de 50 treinamentos realizados em cada configuração de rede, com a divisão do banco de padrões na proporção de 70% para treinamento e 30% para teste.

**Tabela 6 - Treinamento ELM não regularizada e com características geométricas.**

<b>ELM NÃO REGULARIZADA</b>							
Número de neurônios	500	250	100	75	50	25	5
Média acurácia treinamento (%)	100	100	92,1	89,5	85,5	82,4	73,2
Média acurácia teste (%)	54,6	54,3	62,5	70,6	74,7	75,4	71,2
Melhor acurácia teste (%)	61,5	70,5	79,5	80,8	85,9	82,05	84,6

**Tabela 7 - Treinamento ELM regularizada método 1 e com características geométricas.**

<b>ELM REGULARIZADA - MÉTODO 1</b>							
Número de neurônios	1000	1000	500	500	500	50	50
Fator $C$	2000	1000	2000	1000	500	2000	1000
Média acurácia treinamento (%)	89,1	87,8	88	87,2	86,2	84,1	83,1
Média acurácia teste (%)	74,8	75,7	74,5	76	75,2	75,9	76
Melhor acurácia teste (%)	85,9	87,2	87,2	84,6	84,5	88,5	82,1

**Tabela 8 - Treinamento ELM regularizada método 2 e com características geométricas.**

<b>ELM REGULARIZADA - MÉTODO 2</b>							
Número de neurônios	1000	1000	500	500	500	50	50
Fator $C$	2000	1000	2000	1000	500	2000	1000
Média acurácia treinamento (%)	88	87,8	87,6	87	85,9	84,7	83,5
Média acurácia teste (%)	74,1	75,2	76,2	75,3	75,6	75,1	76,1
Melhor acurácia teste (%)	84,6	83,3	84,6	83,3	85,9	83,3	84,6

O melhor resultado médio de teste foi encontrado com a utilização do método 2, com 500 neurônios na camada escondida e com fator de regularização  $C=2000$ . Com esta configuração o treinamento foi repetido mais 200 vezes obtendo uma acurácia média para os dados de treinamento de 87,7% e uma acurácia média de 75,1% para os dados de teste.

Um novo treinamento foi criado, agora com a utilização das 13 características, incluindo as características de textura, tendo como base o resultado do método 2, por este ter apresentado melhores resultados do que o anterior.

Os resultados apresentados em cada coluna da Tabela 9 representam a média de 50 treinamentos realizados em cada configuração de rede, com a divisão do banco de padrões na proporção de 70% para treinamento e 30% para teste.

**Tabela 9 - Treinamento ELM regularizada método 2 e com características geométricas e de textura.**

ELM REGULARIZADA - MÉTODO 2							
Número de neurônios	1000	500	400	<b>400</b>	300	300	50
Fator $C$	2000	2000	2000	<b>100</b>	2000	100	2000
Média acurácia treinamento (%)	96,7	95	94,5	<b>89,8</b>	93,2	89,7	86,5
Média acurácia teste (%)	68,1	70	70,2	<b>76,5</b>	72,5	75,9	75,2
Melhor acurácia teste (%)	75,6	80,8	79,5	<b>84,6</b>	83,3	83,3	83,3

Os resultados indicam que aumentando o número de características de entrada, a rede apresenta uma leve melhora nos indicadores. Os melhores resultados para os indicadores são evidenciados com 400 neurônios na camada escondida e com fator de regularização  $C=100$ . Com essa configuração os treinamentos foram também repetidos 200 vezes, obtendo uma acurácia média no treinamento de 89,8% e uma acurácia média de 76,4% (desvio padrão de 4,23%) para os dados de teste, e um  $F$ -score médio de 71,64% (desvio padrão de 5,45%) para os dados de teste. Houve um ganho de 1,73% no teste em comparação com os resultados da acurácia utilizando somente características geométricas.

### 5.3.1 Definição do *ensemble* de ELMs

Com o objetivo de melhorar os indicadores de desempenho do método proposto, 12 ELMs são treinadas e agrupadas em paralelo formando um *ensemble* de ELMs. A definição destas 12 redes foi fundamentada na diversidade dos componentes do *ensemble* e na seleção dos mais qualificados. Entre as doze redes, são escolhidas as 5 que apresentam o maior  $F$ -score, as 5 com a maior sensibilidade e as 2 com a maior acurácia. Para cada seleção realizam-se 200 treinamentos e escolhem-se as redes que apresentam o melhor indicador escolhido para garantir a diversidade ( $F$ -score, sensibilidade e acurácia). A Tabela 10 apresenta as 12 redes selecionadas para o *ensemble* com os seus respectivos indicadores de teste.

Tabela 10 - Resultado individual dos dados de teste das ELMs para comporem o *ensemble*.

ELM – IMAGENS COM CARACTERÍSTICAS DE FORMA E TEXTURA												
	F-score – máximo					Sensibilidade – máximo					Acurácia máximo	
	1	2	3	4	5	6	7	8	9	10	11	12
ELM												
F-score (%)	85,71	85,29	88,57	85,71	85,71	84,93	80,00	80,56	80,00	75,95	83,64	85,71
Acurácia (%)	84,62	87,18	89,74	87,18	85,90	85,90	82,05	82,05	84,62	75,64	88,46	88,46
Precisão (%)	92,31	93,55	93,94	90,91	91,67	77,50	68,29	70,73	75,00	66,67	74,19	87,10
Sensibilidade (%)	80,00	78,38	83,78	81,08	80,49	93,94	96,55	93,55	85,71	88,24	95,93	84,38
Média (%)	85,66	86,1	89,00	86,22	85,95	85,56	81,72	81,72	81,33	76,62	85,55	86,41

Os resultados descritos na Tabela 10 são obtidos em treinamentos onde a seleção dos vetores para treinamento e teste é obtido de forma aleatória, 70% e 30% respectivamente, para cada ELM selecionada a repartição dos vetores de teste é diferente.

Para comprovar o ganho na utilização do *ensemble* de ELM com um mesmo parâmetro de comparação, 100% do banco de padrões foi utilizado como entrada de cada rede neural selecionada. Os resultados obtidos estão apresentados na Tabela 11.

Tabela 11 - Resultado individual das ELMs com aplicação da rede treinada e utilização de 100% do banco de padrões

ELM – IMAGENS COM CARACTERÍSTICAS DE FORMA E TEXTURA												
Teste com a rede treinada – 100% banco de padrões												
	F-score – máximo					Sensibilidade – máximo					Acurácia – máximo	
	1	2	3	4	5	6	7	8	9	10	11	12
ELM												
F-score (%)	85,31	85,45	85,58	85,58	84,11	85,33	85,09	84,58	83,78	84,21	86,09	<b>86,36</b>
Acurácia (%)	87,98	87,98	87,98	87,98	86,82	87,21	86,82	86,43	86,05	86,05	87,60	<b>88,37</b>
Precisão (%)	90,91	90,10	89,32	89,32	88,24	84,96	83,62	83,48	84,55	82,76	83,90	<b>87,96</b>
Sensibilidade (%)	80,36	81,25	82,14	82,14	80,36	85,71	86,61	85,71	83,04	85,71	88,39	<b>84,82</b>
Média (%)	86,14	86,19	86,25	86,25	84,88	85,80	85,53	85,05	84,35	84,68	86,49	<b>86,87</b>

A ELM<sub>12</sub> apresenta o melhor *F-score* para o conjunto de redes neurais selecionadas para o *ensemble*, por esse motivo, os valores da ELM<sub>12</sub> serão considerados como referência para verificar o ganho na utilização do *ensemble*. Com o *ensemble* selecionado, as três formas de ajuste dos dados de saída de cada ELM são testadas.

### 5.3.1.1 *Ensemble* de ELMs discretizado em duas faixas

Como são 12 ELMs, o limiar de decisão de saída pode ser um valor entre 0 e 12, sendo o valor 0 (zero) quando todas as redes concordam que não é defeito e 12 quando todas concordam que é defeito.

A Figura 46 mostra graficamente e em forma de tabela os resultados dos indicadores para este *ensemble* variando o limiar de decisão entre 0 a 12. Os melhores resultados são observados quando o limiar de decisão  $\delta$  para a saída do *ensemble* está entre 6 e 9, com *F-score* entre 87% e 87,16%, porém, para um limiar de decisão igual a 6 os resultados mostram um equilíbrio maior entre precisão e sensibilidade. Comparando este resultado com a ELM<sub>12</sub> mostrada na Tabela 11 observa-se um ganho de 0,7% no *F-score*.

Outra informação importante retirada desta figura é que o *ensemble* alcança 100% de precisão se considerar que todas as redes concordam com a classificação, embora isso leve a uma sensibilidade menor (69,64%). No outro extremo da tabela o *ensemble* alcança 90,18 % de sensibilidade, quando pelo menos uma das redes tem como saída a indicação defeito, mas neste caso a precisão cai para 72,14%.

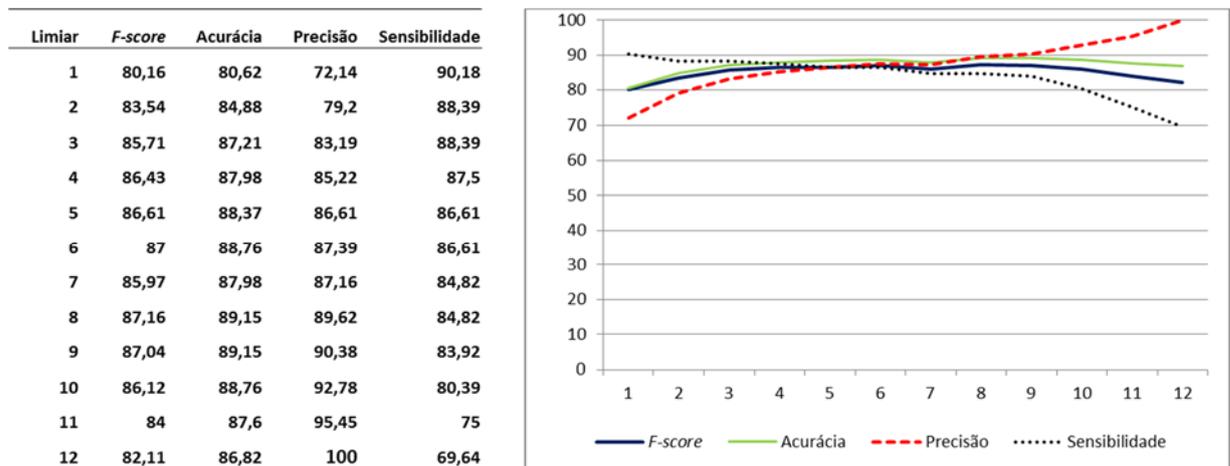


Figura 46 - Resultados dos indicadores para *ensemble* discretizado em duas faixas.

### 5.3.1.2 *Ensemble* de ELMs discretizado em três faixas

Neste método, uma terceira faixa denominada de região de incerteza de entrada do *ensemble* foi criada. O tamanho desta região e o ajuste do peso a ser atribuído à saída de cada rede que compõe o *ensemble* devem ser definidos.

Para esta definição, o tamanho da região e o peso de saída de cada ELM são alterados e testados com o objetivo de atingir 100% de sensibilidade e/ou 100% de precisão nas extremidades dos limiares de decisão e mantendo-se o *F-score* o mais elevado possível.

A Figura 47 mostra graficamente e em forma de tabela os resultados do *ensemble* em função da somatória das saídas das redes, com utilização de uma região de incerteza de entrada do ensemble para os limiares de decisão entre 0 e 12. O peso de saída de cada ELM na região de incerteza que retornou os melhores resultados foi de 0,5 para o tamanho da faixa entre -0,45 e 0,3. Para esta forma de decisão do *ensemble* não se observa um ganho no indicador *F-score* quando comparado com a ELM<sub>12</sub>, porém, a saída do *ensemble* apresenta 100% de precisão e 100% de sensibilidade nas extremidades da tabela de limiares de decisão.

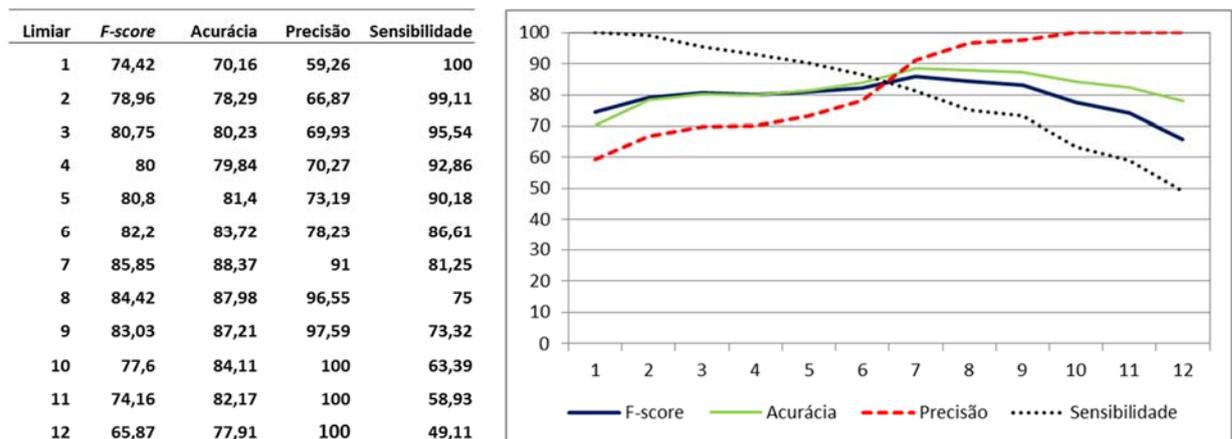


Figura 47- Resultados dos indicadores para *ensemble* discretizado em três faixas.

### 5.3.1.3 *Ensemble* de ELMs contínuo

A Figura 48 mostra graficamente e em forma de tabela os resultados dos indicadores do *ensemble* com decisão em função da somatória contínua das saídas das redes. Para esta forma de decisão observa-se um ganho no indicador *F-score* de 0,7% em relação à ELM que apresentou o melhor resultado individualmente, no caso, a ELM<sub>12</sub>. Este resultado foi obtido para o limiar de decisão no ponto central (zero). Observa-se também que para esta forma de decisão obtém-se com facilidade 100% de precisão e 100% de sensibilidade nas extremidades da escala de decisão. Em uma escala de -12 até 12 o gráfico desta figura apresenta uma região de incerteza de saída do *ensemble* com limiares de decisão entre -7 até 4.

Limiar	F-score	Acurácia	Precisão	Sensibilidade
-12	65,31	53,88	48,48	100
-11	66,87	56,98	50,22	100
-10	69,35	61,63	53,08	100
-9	71,57	65,5	55,72	100
-8	73,2	68,22	57,73	100
-7	77,51	74,81	63,28	100
-6	79,56	78,29	67,28	97,32
-5	79,85	79,46	69,54	93,75
-4	80,95	81,4	72,86	91,07
-3	82,16	83,33	76,74	88,39
-2	83,4	84,88	79,67	87,5
-1	85,84	87,6	85,09	86,61
0	87	88,76	87,39	86,61
1	85,58	87,98	89,32	82,18
2	87,13	89,92	97,78	78,57
3	83,67	87,6	97,62	73,21
4	78,26	84,5	100	64,29
5	75,56	82,96	100	60,71
6	73,45	81,78	100	58,04
7	66,67	78,29	100	50
8	62,58	76,36	100	45,54
9	56,41	73,64	100	39,29
10	50,67	71,32	100	33,93
11	42,25	68,22	100	26,79
12	29,01	63,95	100	16,96

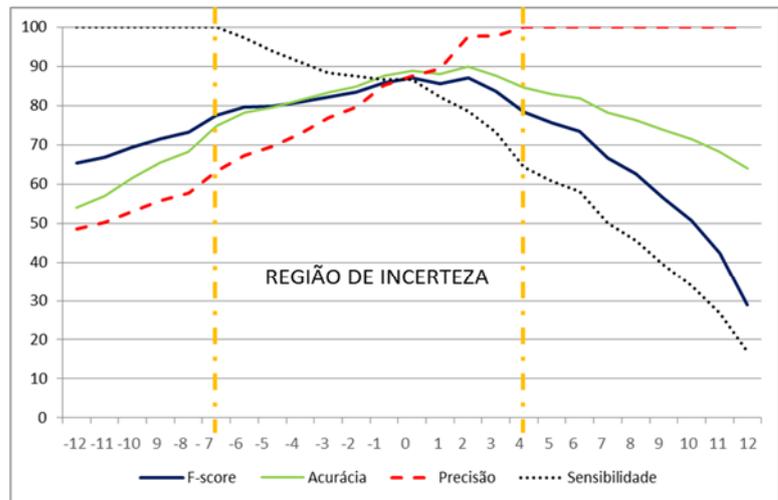


Figura 48 - Resultados dos indicadores para *ensemble* contínuo.

#### 5.3.1.4 Análise e aplicação de *Ensemble* de ELMs

Entre as três formas de decisão, o *ensemble* contínuo foi o que apresentou os melhores resultados, na comparação com a ELM que retornou o melhor resultado individualmente. O *ensemble* contínuo apresentou o mesmo ganho de *F-score* de 0,7% apresentado pelo *ensemble* discretizado em duas faixas, porém, chegou a 100% de sensibilidade e 100% de precisão para limiares de saída do *ensemble* mais próximos à região central da escala de limiares de decisão, diminuindo a região com discontinuidades classificadas como incerteza.

Uma aplicação deste *ensemble* contínuo com utilização da região de incerteza de saída do *ensemble* pode ser observada na Figura 49. Para este exemplo, um recorte do cordão de solda foi submetido à entrada do algoritmo automatizado proposto utilizando o *ensemble* contínuo já treinado e parametrizado. A saída resultante é a imagem de entrada com as discontinuidades classificadas.

As discontinuidades na imagem de saída são classificadas por cores: em azul estão as discontinuidades classificadas como não defeito, em amarelo as discontinuidades classificadas como defeito e em vermelho estão destacadas as discontinuidades da região de incerteza. Para fins de comparação, foi anexada uma imagem menor, localizada no lado direito, referente ao laudo feito pelo especialista.

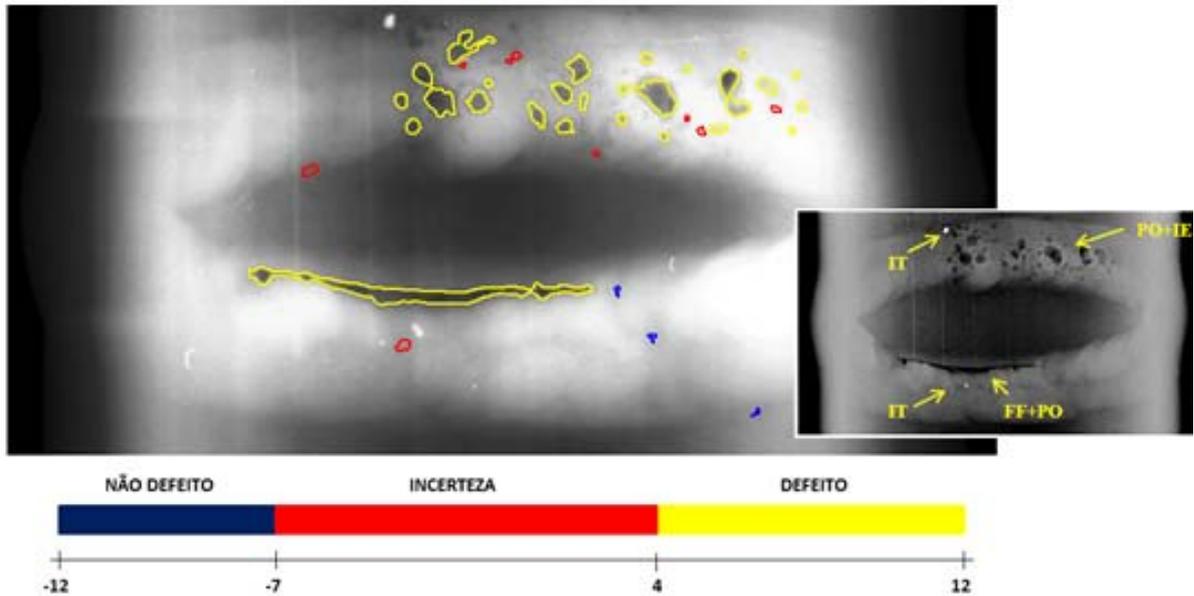


Figura 49 - *Ensemble* contínuo com grau de incerteza de saída aplicado a imagem.

#### 5.4 TREINAMENTO REDE NEURAL ELM COM BANCO DE PADRÕES AMPLIADO

Em uma segunda fase da pesquisa, ao conjunto de imagens Dürr foram acrescentadas mais nove imagens obtidas pelo sistema de radiografia computadorizada GE, totalizando um conjunto com 17 imagens. Deste novo conjunto, 11 imagens foram utilizadas no treinamento e validação e 6 na medida de desempenho do classificador e do *ensemble* com rede neural ELM. O treinamento foi realizado somente no cenário multi-sensor com o método de validação cruzada *hold-out*. O banco de padrões resultante é composto de 236 vetores (amostras) para treinamento e 192 vetores para teste do classificador e é apresentado na Tabela 12.

Tabela 12 – Banco de padrões ampliado com 17 imagens para treinamento e teste

CLASSES DE DEFEITOS	AMOSTRAS TREINAMENTO (11 imagens)	AMOSTRAS TESTE (6 imagens)
Defeito (DF)	98	101
Não defeito (ND)	138	91
<b>TOTAL</b>	<b>236</b>	<b>192</b>

Os resultados dos indicadores para a rede neural ELM obtidos na primeira fase da pesquisa indicam que a regularização pelo método 2 com 400 neurônios na camada escondida e com fator de regularização  $C=100$  foi o que retornou os melhores resultados de indicadores

para os banco de padrões. Com essa configuração de rede, e utilizando o banco de padrões ampliado extraídos de 11 imagens, os treinamentos foram repetidos 200 vezes e obteve-se uma acurácia média no treinamento de 89,92% (89,8% na primeira fase da pesquisa). Para o banco de padrões de teste extraídos de 6 imagens foi obtida uma acurácia média de 70,01% (76,4% na primeira fase da pesquisa) com desvio padrão de 5,5%, e um *F-score* médio de 61,1% (71,64% na primeira fase da pesquisa) com desvio padrão de 8,02%. Para fins de comparação com a primeira fase da pesquisa, nenhum parâmetro de filtragem, realce e de segmentação das imagens foi alterado.

Os resultados obtidos na segunda fase da pesquisa são inferiores aos obtidos na primeira fase. Na primeira fase, os padrões de teste foram escolhidos aleatoriamente para cada treinamento e na segunda fase os padrões de teste provenientes do conjunto ampliado (6 imagens) só foram utilizados na fase de testes.

Também nesta etapa da pesquisa, 15 ELMs foram treinadas e agrupadas em paralelo, formando um *ensemble* de ELMs. A definição destas 15 redes foi fundamentada na diversidade dos componentes do *ensemble* e na seleção dos mais qualificados. Entre as 15 redes, são escolhidas as 5 que apresentam o maior *F-score*, as 5 com a maior sensibilidade e as 5 com a maior acurácia. Para cada seleção realizam-se 200 treinamentos e escolhem-se as que apresentam o melhor indicador escolhido para garantir a diversidade. A Tabela 13 apresenta as 15 redes selecionadas para o *ensemble* com os seus respectivos indicadores de teste.

**Tabela 13 - Resultado individual dos dados de validação das ELMs para comporem o *ensemble* para o banco de padrões ampliado (11 imagens).**

ELM – IMAGENS COM CARACTERÍSTICAS DE FORMA E TEXTURA															
	<i>F-score</i> – máximo					Sensibilidade – máximo					Acurácia - máximo				
ELM	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
<i>F-score</i> (%)	78,05	77,78	82,35	76,92	84,85	75,56	80,00	75,68	74,42	76,60	78,26	78,05	78,95	80,95	75,00
Acurácia (%)	83,93	85,71	83,93	83,93	91,07	80,36	87,50	83,93	80,36	80,36	82,14	83,93	85,71	85,71	82,14
Precisão (%)	84,21	73,68	95,45	93,75	82,35	68,00	77,78	66,67	64,00	69,23	78,26	84,21	75,00	85,00	88,24
Sensibilidade (%)	72,73	82,35	72,41	65,22	87,50	85,00	82,35	87,50	88,89	85,71	78,26	72,73	83,33	77,27	65,22

Estas quinze ELMs também foram testadas individualmente com o banco de padrões de teste, extraído das 6 imagens do conjunto ampliado. Os resultados mostrados na Tabela 14 indicam que a ELM<sub>7</sub> retorna o melhor indicador *F-score* (84,76%). Portanto o desempenho alcançado pela ELM<sub>7</sub> foi utilizado para fins de comparação com o desempenho do *ensemble* de ELMs.

**Tabela 14 - Resultado individual das ELMs com aplicação da rede treinada para o conjunto de imagens de teste (6 imagens) do banco de padrões ampliado.**

ELM – IMAGENS COM CARACTERÍSTICAS DE FORMA E TEXTURA															
BANCO DE PADRÕES AMPLIADO E COM AS 06 IMAGENS NÃO UTILIZADAS NO TREINAMENTO															
	<i>F-score</i> – máximo					Sensibilidade – máximo					Acurácia - máximo				
ELM	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
<i>F-score</i> (%)	82,08	84,31	82,00	82,35	80,56	80,00	84,76	80,18	81,11	81,73	78,57	79,61	80,61	82,13	79,07
Acurácia (%)	80,21	83,33	81,25	81,25	79,17	78,13	83,33	77,60	78,65	80,21	78,13	78,13	80,21	80,73	76,56
Precisão (%)	78,38	83,50	82,33	81,55	79,05	77,06	81,65	75,00	75,86	79,46	81,05	78,10	83,16	80,19	74,56
Sensibilidade (%)	86,14	85,15	81,19	83,17	82,18	83,17	88,12	80,18	81,11	84,16	76,24	81,19	78,22	84,16	84,16

Na primeira fase da pesquisa concluiu-se que o *ensemble* contínuo foi o que apresentou os melhores resultados, por essa razão, nesta fase somente o *ensemble* contínuo e com limiar de decisão  $\delta=0$  foi testado. O banco de padrões de teste foi testado com algumas das inúmeras combinações possíveis de quantidade e diversidade das componentes de ELMs. A tabela 15 mostra 8 destas possíveis combinações, os números 5+0+0 da primeira coluna representam respectivamente: 5 ELMs que fazem parte deste *ensemble* cujo indicador de escolha foi o *F-score* máximo, 0 ELMs cujo indicador de escolha foi a sensibilidade máxima e 0 ELMs cujo indicador de escolha foi a acurácia máxima. Observa-se que o melhor resultado de *F-score* (85,17%) foi obtido com a combinação 0+5+5, que representa 10 ELMs, sendo, 0 ELMs cujo indicador de escolha foi o *F-score* máximo, 5 ELMs cujo indicador de escolha foi a sensibilidade máxima e 5 ELMs cujo indicador de escolha foi a acurácia máxima. A combinação 5+5+2, mostrada na última coluna da tabela 15 é a mesma utilizada na primeira fase da pesquisa.

**Tabela 15 – Definição do número de componentes de ELMs para o *ensemble*.**

ELM – IMAGENS COM CARACTERÍSTICAS DE FORMA E TEXTURA								
BANCO DE PADRÕES AMPLIADO E COM AS 06 IMAGENS NÃO UTILIZADAS NO TREINAMENTO								
	Proporção de ELMs com quantidade de ( <i>F-score</i> + Sensibilidade + Acurácia) máximo							
Quantidade de ELMs	5+0+0	0+5+0	0+0+5	5+5+0	<b>0+5+5</b>	5+0+5	5+5+5	5+5+2
<i>F-score</i> (%)	84,31	83,57	81,55	83,90	<b>85,17</b>	84,31	83,65	84,06
Acurácia (%)	83,33	81,77	80,21	82,81	<b>83,85</b>	83,33	82,29	82,81
Precisão (%)	83,50	79,46	80,00	82,69	<b>82,41</b>	83,50	81,31	82,08
Sensibilidade (%)	85,15	88,12	83,17	85,15	<b>88,12</b>	85,15	86,14	86,14

A Figura 50 mostra graficamente e em forma de tabela os resultados dos indicadores do *ensemble* com decisão em função da somatória contínua das saídas das redes. Para esta

forma de decisão observa-se um ganho no indicador  $F$ -score de 0,5% em relação à ELM que apresentou o melhor resultado individualmente, no caso, a ELM<sub>7</sub>. Este resultado foi obtido para o limiar de decisão no ponto central (zero). Observa-se também que para esta forma de decisão obtém-se com 98,21% de precisão e 100% de sensibilidade nas extremidades. Em uma escala de -10 até 10 o gráfico desta figura apresenta uma região de incerteza de saída do *ensemble* entre -6 até 7.

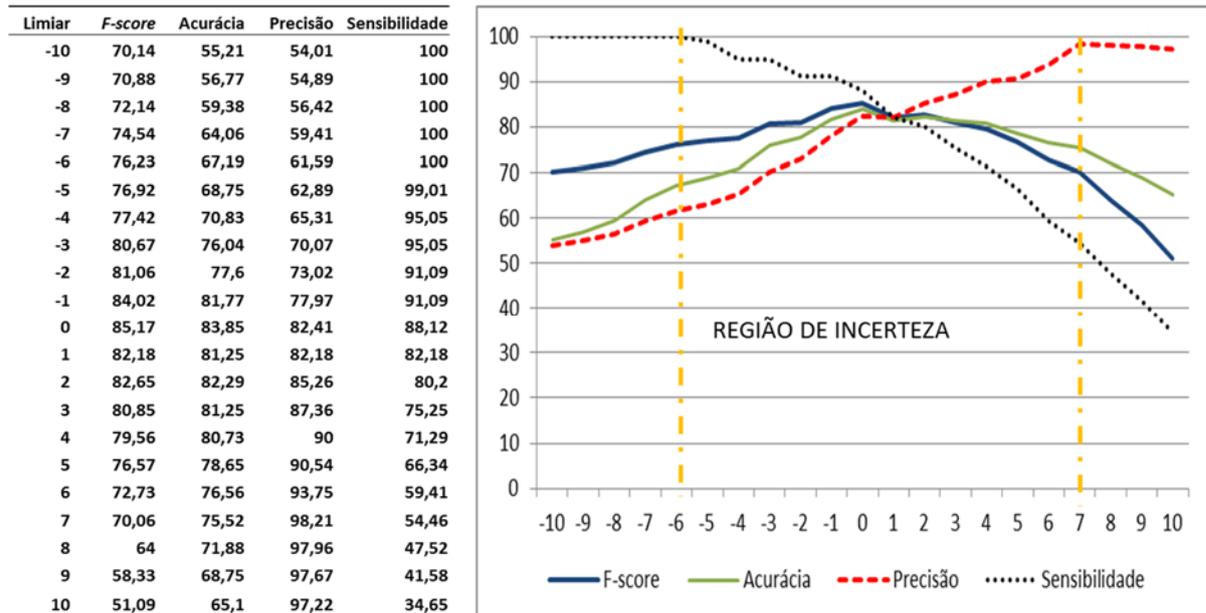


Figura 50 - Resultados dos indicadores para *ensemble* de ELMs contínuo e banco de padrões de teste ampliado (6 imagens).

## 5.5 TREINAMENTO DO CLASSIFICADOR SVM

Para definir os parâmetros  $C$  e  $\sigma$  que retornam os melhores indicadores de desempenho no treinamento do classificador estatístico SVM, foi implementado o treinamento apresentado na Seção 2.4, sendo o classificador SVM testado com as 8 características geométricas e as 5 características de textura como entrada.

O valor ótimo  $C$  e  $\sigma$  para o classificador SVM foi definido através da aplicação do protocolo definido com treinamentos nos três cenários. O valor do  $F$ -score foi calculado para valores de  $C$  variando de 1 até 25 com incremento de um e  $\sigma$  variando de 1 a 15 com incremento de um para cada validação cruzada *leave-p-label-out*.

## 5.6 COMPARAÇÃO ENTRE CLASSIFICADORES MLP, ELM E SVM

A tabela 16 apresenta um resumo dos testes realizados por meio de protocolo padrão de treinamento/teste e com uso de classificadores MLP, ELM e SVM para os três cenários abordados: intra-sensor, inter-sensor e multi-sensor. Para o classificador ELM também foram realizados testes com ELMs sem regularização e ELMs regularizadas pelo método 1 e método 2. Todos os classificadores foram treinados com validação cruzada *leave-p-level-out*.

**Tabela 16 – Indicadores de desempenho dos classificadores MLP, ELM e SVM.**

Indicadores de Desempenho dos Classificadores					
Cenário (Treinamento x Teste)	Classificador	<i>F-score</i> (%)	Acurácia (%)	Sensibilidade (%)	Precisão(%)
Intra-sensor (Dürr x Dürr)	SVM	73,39	77,52	71,43	75,47
	MLP	70,74	75,92	67,11	75,07
	ELM reg. Mét. 2	68,20	73,01	66,67	69,82
	ELM reg. Mét. 1	67,93	72,56	66,96	68,97
	ELM não reg.	64,70	72,87	60,89	69,16
Intra-sensor (GE x GE)	SVM	70,05	74,35	73,40	66,99
	MLP	62,78	71,19	59,50	66,52
	ELM reg. Mét. 2	63,00	71,16	60,11	66,20
	ELM reg. Mét. 1	63,06	71,70	59,15	67,58
	ELM não reg.	64,70	72,87	60,89	69,16
Inter-sensor (Dürr x GE)	SVM	77,49	81,30	78,72	76,29
	MLP	74,59	79,57	73,40	75,82
	ELM reg. Mét. 2	73,91	79,13	72,34	75,56
	ELM reg. Mét. 1	74,32	79,57	72,34	76,40
	ELM não reg.	71,74	74,81	73,33	70,21
Inter-sensor (GE x Dürr)	SVM	75,95	77,91	80,36	72,00
	MLP	75,86	78,29	78,57	73,33
	ELM reg. Mét. 2	76,92	79,07	80,36	73,77
	ELM reg. Mét. 1	75,21	77,52	78,57	72,13
	ELM não reg.	74,53	79,07	79,00	70,54
Multi-sensor (Dürr + GE x Dürr + GE)	SVM	74,29	77,87	75,73	72,90
	MLP	71,79	77,52	67,73	76,38
	ELM reg. Mét. 2	70,65	76,89	65,89	76,17
	ELM reg. Mét. 1	70,39	76,91	65,03	76,73
	ELM não reg.	70,16	76,49	65,50	75,59

Para o classificador SVM os indicadores mostrados na Tabela 16 representam o resultado de uma validação cruzada para os parâmetros ótimos do fator de custo ( $C$ ) e da variância RBF ( $\sigma$ ), uma vez que repetindo o treinamento os resultados se mantêm inalterados. Para MLP e ELM os indicadores representam a média de 30 validações cruzadas para cada arquitetura de rede definida como ótima, visto que para cada validação cruzada os valores dos

pesos da camada oculta são alterados randomicamente no treinamento da rede neural ELM, bem como, o valor de inicialização dos pesos dos neurônios são alterados randomicamente em cada validação cruzada no treinamento da rede neural MLP.

Analisando os resultados dos indicadores mostrados na Tabela 16 verifica-se que o classificador SVM é melhor que os classificadores MLP e ELM em todos os cenários testados. Outra constatação é que no treinamento da ELM regularizada pelo método 2, os resultados dos indicadores são melhores que os resultados da ELM regularizada pelo método 1 ou pela ELM sem regularização.

Pode-se analisar também que aumentando o número de vetores do banco de padrões, ou seja, juntando Dürr e GE em um único banco de padrões, os resultados são melhores daqueles apresentados com testes com o banco de padrões somente Dürr ou somente GE. Mesmo com a combinação de sistemas de aquisição de imagens diferentes, observa-se que no cenário multi-sensor obtém-se uma generalização melhor que nos cenários intra-sensor. Isto permite concluir que as características extraídas a partir da segmentação realizadas pelo método proposto na tese demonstram serem robustas com relação aos equipamentos de aquisição de imagens utilizados.

## 5.7 CONSIDERAÇÕES FINAIS

O método proposto para identificação da região de interesse (ROI) detectou todos os cordões de solda, tanto para as imagens obtidas pelo sistema Dürr, bem como para as imagens obtidas pelo sistema GE.

As amostras de padrões de defeitos de soldagem obtidos das imagens PDVD apresentaram uma distribuição de classes desbalanceada, com isso, os resultados dos indicadores obtidos no treinamento da rede MLP para classificador multiclasse indicam que não é apropriada a utilização deste banco de padrões para os classificadores avaliados nesta pesquisa. Com esta conclusão, na sequência da pesquisa somente foram testados classificadores binários, com as classes defeito e não defeito.

Na primeira fase da pesquisa os testes foram realizados somente com imagens Dürr, com um banco de padrões reduzido, não permitindo testar o *ensemble de ELMs* para um conjunto de imagens inédito, que não havia sido utilizado na fase de treinamento. Com a ampliação do conjunto de imagens e inclusão de imagens GE, foi possível ter um banco de padrões independente para avaliar o *ensemble*. Este banco de padrões ampliado foi testado

com validação cruzada *hold-out* na rede neural ELM e no *ensemble* de ELMs no cenário multi-sensor, resultando num *F-score* de 85,7% para o *ensemble* contínuo.

O uso de *ensemble* contínuo de ELMs representa um ganho de 0,5% no *F-score* em comparação com o melhor resultado da rede treinada individualmente, um ganho relativamente pequeno. O uso de faixas de limiares de decisão possibilita, especialmente no *ensemble* contínuo, chegar a 100% de sensibilidade ou 100% de precisão nas extremidades do limiar de decisão. Esta opção de uso de faixas de limiares na decisão do *ensemble* permite a obtenção de imagens de saída, com as descontinuidades classificadas como defeitos, não defeitos e descontinuidades onde o método não tem certeza, chamada de região de incerteza.

Comparando os três classificadores MLP, ELM e SVM, conclui-se que o classificador SVM é melhor que os classificadores MLP e ELM em todos os cenários testados.

## 6 CONCLUSÃO

A radiografia é um método não destrutivo amplamente utilizado para os ensaios de soldas em tubulações. Um grande número de imagens radiográficas é analisado por inspetores laudistas, tornando a inspeção longa e fatigante, o que pode conduzir a uma interpretação subjetiva com o risco potencial de erros na identificação dos defeitos. Muitos esforços têm sido feitos para a concepção e construção de sistemas de inspeção automática, destinada a apoiar a interpretação de imagens radiográficas de solda e, portanto, melhorar a robustez, precisão e velocidade do processo de inspeção. Apesar do grande número de publicações de pesquisa nesta área, há poucos estudos que investigam inspeção automática de imagens radiográficas de soldas em tubulações obtidas pela técnica de exposição radiográfica parede dupla vista dupla (PDVD), especialmente utilizando imagens reais de campo.

Na pesquisa descrita nesta tese, um algoritmo para detecção automática de defeitos em juntas soldadas de tubulações de petróleo foi desenvolvido utilizando técnicas de processamento de imagens. Para classificação dos defeitos foram testados classificadores com redes neurais MLP e ELM e classificador estatístico SVM. A ideia básica é tentar imitar a forma como um inspetor humano inspeciona as imagens radiográficas: primeiramente o cordão de solda é segmentado, em seguida é realizada a detecção de descontinuidades (defeitos potenciais) na região do cordão de solda e, por fim, tais descontinuidades são classificadas como defeito ou não defeito. Um conjunto de características é extraído das descontinuidades detectadas para ser usado como entrada do classificador. Os experimentos foram realizados com imagens radiográficas PDVD obtidas em reais de situações de campo e que, geralmente, têm uma qualidade mais baixa do que as imagens usadas em outros estudos.

O método para a detecção e classificação de defeitos de soldagem em imagens radiográficas PDVD proposto neste trabalho consistiu na aplicação de quatro etapas principais: localização da região de interesse (*region of interest* - ROI), detecção de descontinuidades (potenciais defeitos), extração das características das descontinuidades detectadas e classificação das descontinuidades (defeitos).

O método proposto para identificação da região de interesse (ROI) permitiu reduzir o espaço de busca na detecção de descontinuidades nas imagens obtidas por ambos os sistemas de aquisição de imagens: Dürr e GE.

A etapa de detecção de descontinuidades localizou na ROI das imagens os defeitos laudados e também descontinuidades não destacadas nos laudos e que foram tratadas como não defeitos para o treinamento dos classificadores.

Na etapa de extração de características, para cada descontinuidade identificada pelo algoritmo de rotulagem é gerado um vetor com suas respectivas características. O banco de padrões utilizado no treinamento dos classificadores foi a combinação dos vetores resultantes para os conjuntos de imagens utilizados.

Com relação à classificação de defeitos, inicialmente, buscaram-se identificar cinco classes de descontinuidades (porosidade, inclusão de escória, falta de fusão, trinca e não-defeito) através de uma rede MLP multiclasse. Amostras destas classes foram coletadas entre as imagens disponíveis para compor a banco de padrões de treinamento da MLP. Devido ao desbalancamento ocasionado pela pequena quantidade de amostras de cada defeito, os indicadores obtidos mostraram que o desempenho da rede MLP multiclasse ficou bastante aquém do esperado.

Tendo em vista que a quantidade de amostras de cada defeito inviabilizou a obtenção de um desempenho aceitável para a rede MLP multiclasse, foi alterado o foco da pesquisa para a utilização de um classificador binário utilizando duas classes: defeito e não defeito.

Entre as três formas de decisão de saídas de *ensembles* de ELMs, o *ensemble* contínuo foi o que apresentou os melhores resultados. Na primeira fase da pesquisa, utilizaram-se somente imagens do sistema Dürr e na segunda fase aplicou-se o mesmo método sobre o conjunto de imagens ampliado (imagens Dürr e GE). Para banco de padrões composto por imagens Dürr e GE testado no cenário multi-sensor obteve-se um *F-score* de 85,7% para o *ensemble* de ELMs.

O uso de *ensembles* de ELMs representa um ganho de 0,5% no *F-score* em comparação com o melhor resultado da rede treinada individualmente, um ganho relativamente pequeno. Autores citados na revisão de literatura já citavam a possibilidade do uso de *ensemble* não apresentar um ganho nos resultados. Porém, o uso de *ensemble* contínuo permitiu chegar a 100% de sensibilidade ou 100% de precisão alterando-se o limiar de decisão adotado. Esta opção de uso de faixas de limiares na decisão do *ensemble* permite a obtenção de imagens de saída com as descontinuidades classificadas como defeitos, não defeitos e descontinuidades onde o método não tem certeza, chamada de região de e incerteza.

Com o banco de padrões de defeitos e não defeitos do conjunto de 17 imagens obtidas pelos sistemas de aquisição Dürr e GE, os indicadores de desempenho dos classificadores MLP, ELM e SVM foram comparados nos cenários intra, inter e multi-sensor.

O classificador SVM obteve um desempenho superior aos classificadores MLP e ELM em todos os cenários.

Com a utilização dos métodos propostos, o algoritmo identifica na imagem a região do cordão de solda, detecta as descontinuidades e classifica as mesmas em defeitos e não defeitos, destacando na imagem o resultado. Com o uso de faixas de limiares de decisão do *ensemble*, o método permite também, mostrar as descontinuidades que o *ensemble* não tem certeza, destacando estas como região de incerteza, deixando para o especialista a avaliação final destas descontinuidades. A imagem resultante serve de auxílio ao especialista na elaboração dos laudos.

A melhor comparação do método proposto em relação aos métodos apresentados na literatura é alcançada por Suyama (2015). De forma semelhante ao trabalho proposto nesta tese, Suyama (2015) também realizou classificação binária de defeitos em imagens PDVD e testou com *ensemble* de redes neurais MLP. Suyama (2015) obteve um *F-score* de 86,06% para um conjunto de 10 imagens não utilizadas na etapa de treinamento. Com a utilização do método proposto nesta tese, obteve-se um *F-score* de 85,7% com utilização de *ensemble* de ELM contínuo. No método proposto nesta tese o resultado é obtido automaticamente e no método de Suyama (2015) o recorte da imagem é otimizado manualmente, tornando o método semiautomático.

A continuidade dos estudos voltados à área de pesquisa desta tese visa agregar melhorias à metodologia apresentada, proporcionando como objetivo melhorar a capacidade de generalização dos classificadores de padrões de defeitos de soldagem, com o uso de imagens radiográficas PDVD. Neste contexto, algumas perspectivas de trabalhos futuros são sugeridas e podem ser exploradas, como:

- Buscar um conjunto de imagens radiográficas PDVD que contenham uma incidência equilibrada dos principais tipos de defeitos de soldagem, e com isso, testar o método proposto para os classificadores multiclasse.
- testar o uso de novas características no treinamento dos classificadores, definindo a relevância de cada uma no resultado final, com objetivo de redução de falsas detecções.
- testar outras arquiteturas de redes neurais MLP, bem como de seus algoritmos de treinamento, como: Levenberg-Marquardt, Gradiente descendente com momento. Estas arquiteturas devem apresentar resultados diferentes dos obtidos com o treinamento proposto nesta tese.

- testar algumas das variantes de ELMs, como: incremental ELM (I-ELM), online sequencial ELM (OS-ELM). Estas técnicas visam à ponderação do uso das características de entrada e do número de neurônios da camada escondida da ELM e podem levar a resultados melhores nos indicadores de desempenho do classificador.

Durante o desenvolvimento desta tese também foi possível contribuir com alguns trabalhos científicos cujas referências são apresentadas a seguir:

a) Artigos publicados

BOARETTO, Neury; CENTENO, Tania M.; MARINHO, Carla A. Classificação de Descontinuidades em Imagens Radiográficas de Juntas Soldadas de Tubulações com Redes Neurais. **Conferência Ibero-Americana de Computação Aplicada - CIACA 2014, Porto**, p. 204-208, 2014.

BOARETTO, Neury; CENTENO, Tania M. Automated detection of welding defects in pipelines from radiographic images DWDI. **NDT&E International**, 86, 7-13, 2017.

b) Artigo submetido e recomendado para aceite

BOARETTO, Neury; CENTENO, Tania M. Classifiers Evaluation of Welding Defects in Pipelines from Radiographic Images Double Wall Double Image. **IEEE Latin America Transactions**.

## REFERÊNCIAS

- ABE, Shigeo. **Support Vector Machines for Pattern Classifications**. Kobe, Japão: Springer, 2005.
- ANDREUCCI, Ricardo. **Radiologia Industrial**. 5. ed. São Paulo: ABENDE, 2003. Disponível em: <<https://www.slideshare.net/WillameNascimento/radiologia-industrial>>. Acesso em: 10/10/2013.
- AOKI, Kimiya; SUGA, Yasuo. 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.
- BALAKRISHNAN, Ramamoorthy. Innovative RT Technique to Evaluate Flaws Location and Sensitivity in Tube Butt Welds in DWDI Technique. In: **Proceedings of the National Seminar & Exhibition on Non-Destructive Evaluation**, India, 2009.
- CARVALHO, Antonio A.; SUITA, Rafael C. S. B.; SILVA, Romeu R.; REBELLO, João M. A. Evaluation of the Relevant Features of Welding Defects in Radiographic Inspection. **Materials Research**, 6(3):427-432, abril/junho 2003.
- COELHO, Guilherme P. **Geração, seleção e combinação de componentes para ensembles de redes neurais aplicadas a problemas de classificação**. Dissertação de Mestrado. Universidade Estadual de Campinas, 2006.
- COELHO, Guilherme P.; VON ZUBEN, Fernando J. The influence of the pool of candidates on the performance of selection and combination techniques in ensembles. In: **Proceedings of the IEEE international joint conference on neural networks**, Vancouver, pp 10588-10595, 2006.
- DUDA, Richard O.; HART, Peter E.; STORK, David G. **Pattern Classification**. 2. Ed. New York: Wiley-Interscience, 2000.
- EDALATI, Kaveh; ROKROK, Behrouz; KERMANI, Aboutaleb, SEIEDI, Masoud, MOVAFEGH, Amir; SHAHANDEH, Mohammad. Scattering and image contrast simulation for double wall radiography of pipes. **International journal of pressure vessels and piping**, 84(7), 441-450, 2007.
- EDALATI Kaveh; ROKROK, Behrouz, KERMANI Aboutaleb, SEIEDI, Masoud; MOVAFEGHI, Amir; RASTKHAH N. Sensitivity evaluation in double wall radiography of pipes and multilayer plates by assessment the Monte Carlo simulation. **Journal of Testing and Evaluation**, 34(6), 562, 2006.
- FAWCETT, Tom. An Introduction to ROC Analysis. **Pattern Recognition Letters**, 27 (8): 861 – 874, 2006.

FELISBERTO, Marcelo K. **Técnicas automáticas para detecção de cordões de solda e defeitos de soldagem em imagens radiográficas industriais**. Tese de Doutorado. Curitiba. UTFPR, 2007.

FÜCSÖK, Ferenc; MULLER, Christina; SCHARMACH, Martina. Reliability of Routine Radiographic Film Evaluation - An Extended ROC Study of the Human Factor. In: **Proceedings of the 8th European Conference on Non Destructive Testing**, Barcelona, p. 17-21. jun. 2002.

FUKUNAGA, Keinosuke. **Introduction to Statistical Pattern Recognition**. 2. ed. San Diego, USA: Academic Press Professional, 1990.

FYLYK, Vitor M.; CENTENO, Tania M. Detecção de defeitos em cordões de solda por redes neurais. In: **Proceedings of the XVII Seminário de Iniciação Científica e Tecnológica da UTFPR**. Curitiba, 2012.

GODOI, Walmor C.; SILVA, Romeu R.; SWINKA-Filho, Vitoldo. Pattern recognition in the automatic inspection of flaws in polymeric insulators. **Non-Destructive Testing and Condition Monitoring**, 47(10), 608-614, 2005.

GOLDSCHMIDT, Ronaldo R. **Uma introdução à Inteligência Computacional: fundamentos, ferramentas e aplicações**. Rio de Janeiro: IST-Rio, 2010.

GOLUB, Gene H.; VAN LOAN, Charles F. **Matrix Computations**. 3. ed. Baltimore: Johns Hopkins University Press, 1996.

GONZALEZ, Rafael C.; WOODS Richard E.; EDDINS Steven L, **Digital Image Processing using MATLAB**. New York: Pearson Education, 2004.

GONZALEZ, Rafael C.; WOODS, Richard E. **Processamento Digital de Imagens**. 3. ed. São Paulo: Pearson Prentice Hall, 2010.

HALIM, Suhaila A.; IBRAHIM, Arsmah; MANURUNG, Yupiter. A review on automated inspection and evaluation system of weld defect detection on radiographic image. **International Journal of Recent Scientific Research**, Vol. 3, pp.1019-1023, 2012.

HANSEN, Lars K.; SALAMON, Peter. Neural network ensembles. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 12, 993–1001, 1990.

HAYKIN, Simon. **Neural Networks: A Comprehensive Foundation**. Saddle River, NJ, USA: Prentice Hall, 1999.

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. 2. ed. Porto Alegre: Bookman, 2001.

HUANG, Gau; HUANG, Guang-Bin; SONG, Shiji; YOU, Keyou. Trends in extreme learning machines: A review. **Neural Networks**, 61, 32–48, 2015.

HUANG, Guang-Bin; ZHOU, Hongming; DING, Xiaojian; ZHANG, Rui. Extreme learning machine for regression and multiclass classification. **IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics**, 42(2), 513–529, 2012.

HUANG, Guang-Bin; CHEN, Lei. Enhanced random search based incremental extreme learning machine. **Neurocomputing**, 71(16), 3460–3468, 2008.

HUANG, Guang-Bin; CHEN, Lei; SIEW, Chee-Kheong. Universal approximation using incremental constructive feedforward networks with random hidden nodes. **IEEE Transactions on Neural Networks**, 17(4), 879–892, 2006.

HUANG, Guang-Bin; ZHU, Qin-Yu; SIEW, Chee-Kheong. Extreme learning machine: theory and applications. **Neurocomputing**, 70(1), 489–501, 2006.

HUANG, Guang-Bin; ZHU, Qin-Yu; SIEW, Chee-Kheong. Extreme learning machine: a new learning scheme of feedforward neural networks. . In: **Proceedings of the IEEE International Joint Conference on Neural Networks**, vol. 2, pp. 985–990, 2004.

KARPATHY, Andrej. **Cs231n: Convolutional neural networks for visual recognition - lecture notes**. Disponível em: <<http://cs231n.github.io/neural-networks-1/>>. Acesso em: 22/05/2016.

KEHOE, Antony; PARKER, Graham. A. Image Processing for Industrial Radiographic Inspection: Image Enhancement. **British Journal of NDT**, v. 32, n.4., pp.183-190, 1990.

KOHAVI, Ron. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: **Proceedings of the International Joint Conference on artificial intelligence**, v. 14, p. 1137–1145, 1995.

KROETZ, Marcel G. **Sistema de apoio na inspeção radiográfica computadorizada de juntas soldadas de tubulações de petróleo**. Dissertação de Mestrado. Curitiba: UTFPR, 2012.

KROETZ, Marcel G.; CENTENO, Tania M.; DELGADO, Myriam R.; FELISBERTO, Marcelo K.; LUCAS, Luis A.; DORINI Leyza B.; FYLYK Vitor, VIEIRA Allan. Genetic algorithms to automatic weld bead detection in double wall double image digital radiographs. **WCCI 2012 IEEE World Congress on Computational Intelligence**, Brisbane, 2012.

KUNCHEVA, Ludmila I. **Combining Pattern Classifiers: Methods and Algorithms**. Hoboken, New Jersey: Wiley-Interscience, 2004.

LAN, Yuan; SOH, Yeng C.; HUANG, Guang-Bin. Ensemble of online sequential extreme learning machine. **Neurocomputing**, 72(13-15):3391-3395, 2009.

LARSON, Ron; FARBER, Betsy. **Introdução à estatística**. 6 ed. São Paulo: Pearson, 2016.

LAWSON, Shaun W.; PARKER, Graham A. Intelligent segmentation of industrial radiographic images using neural networks. **Photonics for Industrial Applications. International Society for Optics and Photonics**, p. 245-255, 1994.

LIAO, T. Warren; NI, Jiawei. An Automated Radiographic NDT System for Weld Inspection: Part I – Weld Extraction. **NDT&E International**, v. 29, n.3, pp.157-162, 1996.

LIAO, T. Warren; NI, Jiawei. An Automated Radiographic NDT System for Weld Inspection: Part II – Flaw Detection. **NDT&E International**, v. 31, n. 3, pp. 183-192, 1998.

LOPES, Diego; FARIAS, Claudia; ALBUQUERQUE, Maria C.; OLIVEIRA, Teodório; SOUZA, Inain S. Visão geral sobre a inspeção em cordões de solda através de técnicas não destrutivas ultrassônicas. V **CONNEPI, Congresso Norte Nordeste de Pesquisa e Inovação**, Maceió, 2010.

MARINHO, Carla A. **Radiografia Computadorizada Aplicada na Inspeção de Soldas de Tubulações nos Limites da Técnica de Parede Dupla Vista Dupla (PDVD)**. Dissertação de Mestrado. Rio de Janeiro: UFRJ/COPPE, 2009.

MARQUES, Paulo V. **Tecnologia da Soldagem**. Belo Horizonte: O Lutador, 1991.

MARQUES FILHO, Ogê; VIEIRA NETO, Hugo. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999.

MERY, Domingo; BERTI, Miguel. Automatic Detection of Welding Defects Using Textures Features. **Non-Destructive Testing and Condition Monitoring**, v. 45, n. 10, p. 676-681, 2003.

MERY, Domingo. Automated Detection of Welding Defects. **Materials Evaluation**, p. 657-663, junho-2011.

MØLLER, Martin F. A scaled conjugate gradient algorithm for fast supervised learning. **Neural networks**, v. 6, n. 4, p. 525-533, 1993.

OTSU, Nobuyuki. A threshold selection method from grey-level histograms. **IEEE Transactions on Systems, Man and Cybernetics**, vol. 9, no. 1, pp. 62–66, 1979.

PADUA Germano X.; SILVA. Romeu R.; REBELLO, João M. A.; CALOBA, Luiz P. Extração do Cordão-de-Solda e Detecção de Defeitos em Radiografias Usando Redes Neurais. In: **3 Panamerican Conference for Nondestructive Testing (PANNDT)**, Rio de Janeiro, pp. 1-8, 2003.

PADUA, Germano X. **Detecção e Classificação de Defeitos de Soldagem em Radiografias Utilizando Perfil Transversal do Cordão de Solda**. Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, 2004.

POWERS, David M. W. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation. **Journal of Machine Learning Technologies**, 2 (1): 37–63, 2011.

PRATI, Ronaldo C.; BATISTA, Gustavo E. A. P. A.; MONARD, Maria C. Curvas ROC para avaliação de classificadores. **Revista IEEE América Latina**, v. 6, n. 2, p. 215-222, 2008.

PRATT, William K. Generalized Wiener Filtering Computation Techniques. **IEEE Transactions on computers**, c-21 (7), 1972.

QUINN Richard A.; SIGL Claire C. **Radiography in Modern Industry**, 4. ed. Rochester, New York: Eastman Kodak Company, 1980.

RALE, Amod P.; GHARPURE, Damayanti C.; RAVIDRAN, V. R. Comparison of different ANN techniques for automatic defect detection in X-Ray images. **International Conference on Emerging Trends in Electronic and Photonic Devices and Systems**, p. 193-197, 2009.

RAO, C. Radhakrishna, MITRA, Sujit K. **Generalized Inverse of Matrices and Its Applications**. New York: Wiley, 1971.

SEMOLINI, Robinson. **Support Vector Machines, Inferência Transdutiva e o Problema de Classificação**. Dissertação de Mestrado – Departamento de Engenharia de Computação e Automação Industrial – UNICAMP, Campinas, SP, 2002.

SERRE, Denis. **Matrices: Theory and Applications**. 1. ed. New York: Springer, 2002.

SHAFEEK, Hani I.; GADELMAWLA, Elamir S.; ABDEL-SHAFY, A. A.; ELEWA, Ibrahim M. Assessment of welding defects for gas pipeline radiographs using computer vision. **NDT & E International**, 37(4): 291-299, 2004a.

SHAFEEK, Hani I.; GADELMAWLA, Elamir S.; ABDEL-SHAFY, A. A.; ELEWA, Ibrahim M. Automatic inspection of gas pipeline welding defects using an expert vision system. **NDT & E International**, 37(4): 301-307, 2004b.

SHAO, Jiaxin; SHI, Han, DU, Dong; WANG, Li; CAO, Huayong. Automatic Weld Defect Detection in Real-time X-ray Images Based on Support Vector Machine. **4<sup>th</sup> International Congress on Image and Signal Processing**, 1842-1846, 2011.

SIKORA, Ryszard; CHADY, Tomasz; BANIUKIEWICZ, Piotr; LOPATO, Przemyslaw; NAPIERALA, Lech; PIETRUSEWICZ, Tomasz; PSUJ, Grzegorz. Intelligent System for Radiogram Analysis for Welds' Defects Inspection – Results of Chosen Algorithms' Work. **In Proceedings of 18th World Conference on Nondestructive Testing**, pp 1-7, 2012.

SILVA, Romeu R.; SIQUEIRA Marcio H. S.; CALÔBA Luiz P.; REBELLO João M. A. Radiographics pattern recognition of welding defects using linear classifiers. **Insight**, 43(10), 669-74, 2001.

SILVA, Romeu R. **Reconhecimento de Padrões de Defeitos de Soldagem em Radiografias Industriais**, Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, 2003.

SILVESTRE, Leonardo J. **Regularização de Extreme Learning Machines : uma abordagem com matrizes de afinidade**, Tese de Doutorado, UFMG, Belo Horizonte, 2015.

SOLOMON, Chris; BRECKON, Toby. **Fundamentos de processamento digital de imagens: uma abordagem prática com exemplos em MatLab**. Rio de Janeiro: LTC, 2013.

SOKOLOVA, Marina; LAPALME, Guy. A systematic analysis of performance measures for classification tasks. **Information Processing & Management**, v. 45, n. 4, p. 427-437, 2009.

SUYAMA, Fernando M. **Detecção de defeitos em juntas soldadas de tubulações de petróleo em radiografias computadorizadas parede dupla vista dupla (PDVD) por redes neurais**, Dissertação de Mestrado, UTFPR, Curitiba, 2015.

SUYAMA, Fernando M.; KREFER Andriy G.; FARIA Alex R.; CENTENO, Tania M. Detecting Central Region in Weld Beads of DWDI Radiographic Images Using PSO. **International Journal of Natural Computing Research**, v. 5, p. 42-56, 2015.

TRIOLA, Mario F. **Estatística aplicada**. 10. ed. Rio de Janeiro: LTC, 2008.

VALAVANIS, Ioannis; KOSMOPOULOS, Dimitrios. Multiclass defect detection and classification in weld radiographic images using geometric and texture features. **Expert Systems with Applications**, 37(12):7606–14, 2010.

VAPNIK, Vladimir N. **The nature of statistical learning theory**. 2. ed. New York, NY, USA: Springer-Verlag New York, Inc., 1995.

WAINER, Emilio; BRANDI, Sérgio D.; MELLO, Fábio D. H. **Soldagem - Processos e Metalurgia**. São Paulo: Edgard Blücher, 1992.

WANG, Gang; LIAO, T. Warren. Automatic identification of different types of welding defects in radiographic images. **Ndt & E International**, v. 35, n. 8, p. 519-528, 2002.

WANG, Xin, WONG, Brian S., TAN, ChingSeong. Recognition of Welding Defects in Radiographic by Using Support Vector Machine Classifier. **Research Journal of Applied Sciences, Engineering and Technology**, 2(3): 295-301, 2010.

YAHIA, Nouredine B.; BELHADJ, Touhami; BRAG, S.; ZGHAL Ali. Automatic detection of welding defects using radiography with a neural approach. **Procedia Engineering**, 10, 671-679, 2011.

YIN, Ying; TIAN, Gui Y.; YIN, Guofu; LUO, A.M. Defect Identification and Classification for Digital X-Ray Images. **Applied Mechanics and Materials**, 1-12, 543-547, 2008.

ZAPATA, Juan; VILAR, Rafael; RUIZ, Ramón. Performance evaluation of an automatic inspection system of weld defects in radiographic images based on neuro-classifiers. **Expert Systems with Applications**. 38, 8812-8824, 2011.