

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

FERNANDO MOREIRA SUYAMA

**DETECÇÃO DE DEFEITOS EM JUNTAS SOLDADAS DE
TUBULAÇÕES DE PETRÓLEO EM RADIOGRAFIAS
COMPUTADORIZADAS PAREDE DUPLA VISTA DUPLA (PDVD) POR
REDES NEURAIS**

DISSERTAÇÃO

CURITIBA

2015

FERNANDO MOREIRA SUYAMA

**DETECÇÃO DE DEFEITOS EM JUNTAS SOLDADAS DE
TUBULAÇÕES DE PETRÓLEO EM RADIOGRAFIAS
COMPUTADORIZADAS PAREDE DUPLA VISTA DUPLA (PDVD) POR
REDES NEURAIS**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Mestre em Ciências” – Área de Concentração: Engenharia de Computação.

Orientadora: Profa. Dra. Tania Mezzadri Centeno.

CURITIBA

2015

Dados Internacionais de Catalogação na Publicação

- S967d Suyama, Fernando Moreira
2015 Detecção de defeitos em juntas soldadas de tubulações de petróleo em radiografias computadorizadas parede dupla vista dupla (PDVD) por redes neurais / Fernando Moreira Suyama.-- 2015.
127 f.: il.; 30 cm
- Texto em português, com resumo em inglês.
Dissertação (Mestrado) - Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Curitiba, 2015.
Bibliografia: f. 120-127.
1. Processamento de imagens - Técnicas digitais. 2. Juntas soldadas - Inspeção. 3. Defeitos - Detecção. 4. Petróleo - Tubulações. 5. Redes neurais (Computação). 6. Testes não-destrutivos. 7. Métodos de simulação. 8. Engenharia elétrica - Dissertações. I. Centeno, Tania Mezzadri, orient. II. Universidade Tecnológica Federal do Paraná - Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. III. Título.

CDD 22 -- 621.3

Título da Dissertação Nº. _____

Detecção de Defeitos em Juntas Soldadas de Tubulações de Petróleo em Radiografias Computadorizadas Parede Dupla Vista Dupla (PDVD) por Redes Neurais.

por

Fernando Moreira Suyama

Orientadora: Profa. Dra. Tania Mezzadri Centeno

Esta dissertação foi apresentada como requisito parcial à obtenção do grau de MESTRE EM CIÊNCIAS – Área de Concentração: **Engenharia de Computação** do Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial – CPGEI – da Universidade Tecnológica Federal do Paraná – UTFPR, às **16:00h** do dia **25 de junho de 2015**. O trabalho foi aprovado pela Banca Examinadora, composta pelos professores doutores:

Profa. Dra. Tania Mezzadri Centeno
(Presidente – UTFPR)

Prof. Dr. Edson José Rodrigues Justino
(PUCPR)

Prof. Dr. Ricardo Dutra da Silva
(UTFPR)

Visto da coordenação:

Prof. Dr. Emilio Carlos Gomes Wille
(Coordenador do CPGEI)

AGRADECIMENTOS

A Deus, o grande engenheiro do universo, que possibilitou a minha existência.

Aos meus pais, Ademilda Pereira Moreira Suyama e Irineu Mineo Suyama, que sempre me apoiaram incondicionalmente nos meus projetos de vida e que são os responsáveis por meu desenvolvimento enquanto pessoa humana.

Aos meus irmãos, Rodolfo Moreira Suyama e Rafael Moreira Suyama, parentes e amigos que me incentivaram e apoiaram neste caminho de crescimento intelectual.

À minha amada Amanda Ramos Silva pelo carinho, amor, dedicação e apoio sempre presentes na realização dos meus projetos de vida.

À minha orientadora Prof.^a Dra. Tania Mezzadri Centeno pela dedicação em orientar.

À Prof.^a Dra. Myriam Regattieri Delgado, ao Andriy G. Krefer, ao Alex R. Faria e a toda equipe de pesquisa do Laboratório de Imagens e Visão Computacional (LIVIC) do programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial (CPGEI) da Universidade Tecnológica Federal do Paraná (UTFPR) que juntamente com a minha orientadora possibilitaram publicações científicas e discussões produtivas durante o período do mestrado.

À Me. Eng. Carla Alves Marinho que, representando o Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello (CENPES) da empresa Petróleo Brasileiro S.A. (PETROBRAS), forneceu as imagens radiográficas de juntas soldadas de tubulações de petróleo e os laudos utilizados pela equipe de pesquisa do LIVIC da UTFPR.

Ao programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial (CPGEI) da Universidade Tecnológica Federal do Paraná e seus professores pela estrutura. E à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro.

“42”

Grande Pensador Profundo
O Guia do Mochileiro das Galáxias - Douglas Adams

RESUMO

SUYAMA, Fernando Moreira. DETECÇÃO DE DEFEITOS EM JUNTAS SOLDADAS DE TUBULAÇÕES DE PETRÓLEO EM RADIOGRAFIAS COMPUTADORIZADAS PAREDE DUPLA VISTA DUPLA (PDVD) POR REDES NEURAIS. 127 f. Dissertação - Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Federal Tecnológica do Paraná. Curitiba, 2015.

A detecção de defeitos de soldagem em imagens radiográficas visa garantir a segurança das estruturas em análise com o objetivo de evitar perdas financeiras e prevenir danos ambientais. Atualmente, a inspeção de juntas soldadas é uma atividade essencialmente humana e, portanto, está sujeita a erros relacionados à acuidade visual, à experiência, à fadiga e às distrações do inspetor, afetando a repetitividade e reprodutibilidade deste processo. Nesse sentido, este trabalho apresenta um método para auxiliar na detecção de defeitos em juntas soldadas de tubulações de petróleo, utilizando radiografias computadorizadas adquiridas pela técnica de exposição Parede Dupla Vista Dupla (PDVD). O método desenvolvido compreendeu a aplicação do realce das imagens tratadas, a segmentação de descontinuidades e a redução do espaço de busca pela eliminação da região central da junta soldada PDVD. Dessa maneira, os referidos procedimentos contribuíram para que as descontinuidades segmentadas que correspondiam a regiões de defeito em potencial fossem classificadas por Redes Neurais Artificiais (RNA) *Multilayer Perceptron* (MLP), realizando a detecção de defeitos de soldagem.

Palavras-chave: Testes Não-Destrutivos. Testes Radiográficos. Redes Neurais Artificiais. Detecção de Defeitos de Solda. Junta de Soldadas. Parede Dupla Vista Dupla.

ABSTRACT

SUYAMA, Fernando Moreira. DETECTION OF WELD DEFECTS IN WELDED JOINTS OF PETROLEUM PIPELINES IN DOUBLE WALL DOUBLE IMAGE (DWDI) COMPUTED RADIOGRAPHY WITH NEURAL NETWORKS. 127 f. Dissertação - Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Federal Tecnológica do Paraná. Curitiba, 2015.

Detection of weld defects in radiographic images aims to ensure the safety of analyzed structures in order to avoiding financial losses and prevent against environmental damage. Nowadays, the inspection of welded joints is essentially a human activity and, therefore, it is subject to errors related to the inspector visual acuity, experience, fatigue and distractions, affecting the repeatability and reproducibility of this process. In this sense, this work presents a method to assist the detection of weld defects in welded joints of petroleum pipelines in computed radiography acquired by Double Wall Double Image (DWDI) technique. The developed method involved the application of contrast enhancement of treated images, segmentation of discontinuities and, the search space reduction by eliminating the central region of the DWDI weld. Thus, these procedures contributed to that segmented discontinuities which correspond to potential weld defects regions were classified by Multilayer Perceptron Neural Networks, performing the detection of weld defects.

Keywords: Non-destructive tests. Radiographic tests. Artificial Neural Networks. Detection of Weld Defects. Welded Joints. Double Wall Double Image.

LISTA DE FIGURAS

Figura 1 - Princípios básicos de radiografia.	21
Figura 2 - Image Plate (IP)	23
Figura 3 - Digitalização de radiografia computadorizada.	23
Figura 4 - Exposição PSVS com fonte interna e um detector externo.....	24
Figura 5 - Exposição PSVS panorâmica com fonte interna e detectores externos. ..	25
Figura 6 - Exposição PSVS com fonte exterior e detector interno.....	25
Figura 7 - Exemplo de radiografia PSVS panorâmica.....	25
Figura 8 - Exposição PDVS com fonte alinhada à junta soldada.	26
Figura 9 - Exposição PDVS com fonte não alinhada à junta soldada.	26
Figura 10 - Exemplo de radiografia PDVS com fonte não alinhada.	27
Figura 11 - Exposição radiográfica PDVD não sobreposta.	28
Figura 12 - Exposição radiográfica PDVD sobreposta.	28
Figura 13 - Exemplo de radiografia PDVD não sobreposta.....	29
Figura 14 - Tipos de porosidades.....	30
Figura 15 - Cordão de solda com porosidade (PO).....	30
Figura 16 - Cordão de solda com falta de penetração (FP).	31
Figura 17 - Cordão de solda com falta de fusão (FF).....	31
Figura 18 - Cordão de solda com mordedura (MO) de raiz (ou interna).....	32
Figura 19 - Cordão de solda com mordedura (MO) na margem (ou externa).	32
Figura 20 - Cordão de solda com trincas (TR).	33
Figura 21 - Cordão de solda com inclusão de escória (IE).....	34
Figura 22 - Cordão de solda com inclusão de tungstênio (IT).....	34
Figura 23 - Exemplo de imagem digital monocromática.....	36
Figura 24 - Histogramas.....	37
Figura 25 - Expansão de histograma.	38
Figura 26 - Inversão de cor..	39
Figura 27 - Limiarização de imagem.	40
Figura 28 - Exemplos de elementos estruturantes (EEs) no formato matricial	44
Figura 29 - Exemplo de erosão.	45
Figura 30 - Exemplo de dilatação.....	46
Figura 31 - Abertura e fechamento morfológicos.	47
Figura 32 - Ilustração de erosão geodésica.	51
Figura 33 - Ilustração de dilatação geodésica.....	51
Figura 34 - Abertura por reconstrução.	53
Figura 35 - Preenchimento de buracos..	54
Figura 36 - Limpeza de bordas.....	54
Figura 37 - Sete momentos invariantes.....	59
Figura 38 - Modelo de um neurônio artificial de McCulloch e Pitts (1943).	60
Figura 39 - Tipos de regiões de decisão em redes <i>feedforward</i>	62
Figura 40 - Exemplo de uma MLP com duas camadas ocultas.....	63

Figura 41 - Modelo de um neurônio de uma MLP.	64
Figura 42 - Gráfico da função de ativação degrau (ou limiar).	65
Figura 43 - Gráfico da função de ativação linear.	65
Figura 44 - Gráfico da função de ativação sigmóide logística.	66
Figura 45 - Gráfico da função de ativação tangente hiperbólica.	66
Figura 46 - Resultado do método de Gayer et al. (1990)..	76
Figura 47 - Resultado do método de Lawson e Parker (1994).	77
Figura 48 - Perfis de exemplo de Liao et al. (1999).	78
Figura 49 - Resultado do método de Liao et al. (1999)..	79
Figura 50 - Mapeamento e arquitetura da rede de Nacereddine et al. (2000).	79
Figura 51 - Resultado do método de Nacereddine et al. (2000).	80
Figura 52 - Resultado do método de Lashkia (2001)..	81
Figura 53 - Resultado do método de Carrasco e Mery (2004).	82
Figura 54 - Resultado do método de Sun et al. (2005).	84
Figura 55 - Resultado do método de Wang et al. (2008).	85
Figura 56 - Resultado do método de Vilar et al. (2009).	86
Figura 57 - Resultado do método de Valavanis e Kosmopoulos (2010).	87
Figura 58 - Resultado do método de Yazid et al. (2011).	88
Figura 59 - Resultado do método de Liling e Yangjie (2011).	89
Figura 60 - Resultado do método de Kroetz (2012).	90
Figura 61 - Processo geral das técnicas de detecção de defeitos de soldagem.	92
Figura 62 - Exemplos de radiografias computadorizadas.	95
Figura 63 - Exemplos de recortes de cordão de solda PDVD utilizados.	96
Figura 64 - Procedimento de realce.	98
Figura 65 - Procedimento de segmentação de descontinuidades.	100
Figura 66 - Procedimento de geração da máscara da região central.	102
Figura 67 - Procedimento de redução de descontinuidades.	103
Figura 68 - Configuração da rede MLP.	107
Figura 69 - Separabilidade do espaço de busca.	111
Figura 70 - Exemplo de detecção de defeitos pelo método proposto.	114

LISTA DE TABELAS

Tabela 1 - Cálculo dos sete momentos invariantes das imagens da Figura 37.....	59
Tabela 2 - Trabalhos com resultados quantitativos para a detecção de defeitos.	93
Tabela 3 - Atributos extraídos e avaliados de cada região de defeito em potencial.	106
Tabela 4 - Desempenho médio para os conjuntos de validação de configuração das RNAs.	112
Tabela 5 - Resultados de detecção de defeitos nas imagens de teste.	113
Tabela 6 - Artigos publicados em anais de congressos nacionais	119
Tabela 7 - Artigo publicado em periódico internacional	119

LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

ABNT	Associação Brasileira de Normas Técnicas
A/D	Analógico/Digital
AG	Algoritmos Genéticos
Adaline	<i>Adaptive Linear Neurons</i>
ASM	<i>American Society for Metals</i>
ASME	<i>American Society of Mechanical Engineers</i>
AWS	<i>American Welding Society</i>
BAM	<i>Federal Institute for Materials Research and Testing</i>
BP	<i>Backpropagation</i>
bpp	bits por pixel
BS	<i>British Standard</i>
BSI	<i>British Standards Institution</i>
BSM	<i>Background Subtraction Method</i>
CB	Comitê Brasileiro de Soldagem da ABNT
CD	Com Defeito
CENPES	Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello – PETROBRAS
CG	<i>Conjugate Gradient</i>
CPGEI	Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial – UTFPR
ED	Ensaio Destrutivo
EE	Elemento Estruturante
EN	<i>English</i>
END	Ensaio Não-Destrutivo
FF	Falta de Fusão
FFT	<i>Fast Fourier Transform</i>
FP	Falta de Penetração
IE	Inclusão de Escória
IIW	<i>International Institute of Welding</i>
IP	<i>Image Plate</i>
IQI	Indicador de Qualidade de Imagem
IT	Inclusão de Tungstênio
KNN	<i>K-Nearest Neighbors</i>
LIVIC	Laboratório de Imagens e Visão Computacional - CPGEI - UTFPR
LM	<i>Levenberg-Marquardt</i>
MLP	<i>Multilayer Perceptron</i>
MO	Mordedura
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	<i>picture element</i>
PO	Porosidade
PSO	<i>Particle Swarm Optimization</i>
PSVS	Parede Simples Vista Simples
RNA	Rede Neural Artificial
ROI	<i>Region Of Interest</i>
S.A.	Sociedade Anônima
SCG	<i>Scaled Conjugated Gradient</i>
SD	Sem Defeito
SSDA	<i>Sequential Similarity Detection Algorithm</i>
TIFF	<i>Tagged Image File Format</i>
TR	Trinca
UTFPR	Universidade Tecnológica Federal do Paraná

SUMÁRIO

1 INTRODUÇÃO	16
1.1 JUSTIFICATIVA	17
1.2 OBJETIVOS	19
1.2.1 Objetivos gerais.....	19
1.2.2 Objetivos específicos.....	19
1.3 ESTRUTURA DO TRABALHO.....	20
2 FUNDAMENTAÇÃO TEÓRICA.....	21
2.1 INTRODUÇÃO	21
2.2 PROCESSO RADIOGRÁFICO	21
2.2.1 Formas de aquisição de imagens radiográficas	21
2.2.1.1 Radiografia convencional	22
2.2.1.2 Radiografia direta	22
2.2.1.3 Radiografia computadorizada.....	22
2.2.2 Técnicas de exposição radiográfica	24
2.2.2.1 Parede Simples Vista Simples (PSVS).....	24
2.2.2.1 Parede Dupla Vista Simples (PDVS).....	26
2.2.2.2 Parede Dupla Vista Dupla (PDVD).....	27
2.2.3 Principais tipos de defeitos de soldagem	29
2.2.3.1 Porosidade (PO).....	29
2.2.3.2 Falta de Penetração (FP)	30
2.2.3.3 Falta de Fusão (FF).....	31
2.2.3.4 Mordedura (MO).....	32
2.2.3.5 Trinca (TR)	33
2.2.3.6 Inclusão de Escória (IE)	33
2.2.3.7 Inclusão de Tungstênio (IT).....	34
2.3 PROCESSAMENTO DIGITAL DE IMAGENS	35
2.3.1 Imagem digital	35
2.3.1 Histograma	36
2.3.1.1 Expansão de histograma.....	38
2.3.2 Negativo, complemento ou inversão de cor	39

2.3.3 Limiarização global.....	40
2.3.4 Filtros espaciais de suavização	41
2.3.4.1 Filtro da média.....	41
2.3.4.2 Filtro da mediana.....	42
2.3.5 Filtros espaciais de aguçamento	42
2.3.5.1 Máscara de nitidez e filtragem <i>High-boost</i>	43
2.3.6 Processamento morfológico de imagens binárias	43
2.3.6.1 Erosão e dilatação.....	45
2.3.6.2 Abertura e fechamento	46
2.3.7 Morfologia matemática em níveis de cinza.....	47
2.3.7.1 Erosão e dilatação.....	48
2.3.7.2 Abertura e fechamento	48
2.3.7.3 Transformadas <i>Top-Hat</i> e <i>Bottom-Hat</i>	49
2.3.8 Reconstrução morfológica.....	49
2.3.8.1 Erosão e dilatação geodésica	49
2.3.8.2 Reconstrução morfológica por dilatação e por erosão	51
2.3.9 Etiquetagem	54
2.3.10 Momentos invariantes de Hu.....	56
2.4 REDES NEURAS ARTIFICIAIS (RNA).....	59
2.4.1 Arquitetura das RNAs.....	61
2.4.2 Separabilidade do espaço de busca em redes <i>feedforward</i>	62
2.4.3 <i>Perceptron</i> de múltiplas camadas (MLP).....	62
2.4.4 Funções de ativação	64
2.4.5 Tipos de aprendizado	67
2.4.6 Avaliação de desempenho	67
2.4.7 Treinamento de redes MLP	68
2.4.7.1 Gradiente Conjugado Escalonado (SCG).....	69
2.4.8 Normalização de entradas.....	71
2.4.9 Separação de conjuntos.....	72
2.4.10 Generalização	72
2.5 MÉTRICAS DE AVALIAÇÃO DE RESULTADOS	73
2.6 CONSIDERAÇÕES FINAIS	74
3 ESTADO DA ARTE	75

3.1 INTRODUÇÃO	75
3.2 DETECÇÃO DE DEFEITOS COM VISTA SIMPLES (PSVS).....	75
3.2.1 Gayer et al. (1990)	75
3.2.2 Lawson e Parker (1994)	76
3.2.3 Liao e Li (1998) e Liao et al. (1999).....	77
3.2.4 Nacereddine et al. (2000)	79
3.2.5 Lashkia (2001).....	80
3.2.6 Mery e Berti (2003).....	81
3.2.7 Carrasco e Mery (2004).....	82
3.2.8 Padua (2004).....	83
3.2.9 Sun et al. (2005)	83
3.2.10 Wang et al. (2008)	84
3.2.11 Vilar et al. (2009)	85
3.2.12 Valavanis e Kosmopoulos (2010)	86
3.2.13 Yazid et al. (2011)	87
3.2.14 Liling e Yangjie (2011).....	88
3.3 DETECÇÃO DE DEFEITOS COM VISTA DUPLA (PDVD).....	89
3.3.1 Kroetz (2012).....	89
3.3.2 Fylyk e Centeno (2012)	90
3.4 CONCLUSÕES	91
4 MATERIAIS E MÉTODOS.....	95
4.1 INTRODUÇÃO	95
4.2 MATERIAIS	95
4.3 MÉTODOS	96
4.3.1 Detecção de descontinuidades	97
4.3.1.1 Realce	97
4.3.1.2 Segmentação de descontinuidades	98
4.3.1.3 Geração da máscara da região central	100
4.3.1.4 Redução do espaço de busca	103
4.3.2 Classificação	104
4.3.2.1 Coleta e tratamento de dados	104
4.3.2.2 Configuração da rede neural artificial.....	107
4.3.2.3 Separação de conjuntos.....	108

4.3.2.4 Treinamento e teste.....	108
4.4 CONSIDERAÇÕES FINAIS	109
5 RESULTADOS E DISCUSSÃO.....	110
5.1 INTRODUÇÃO	110
5.2 ETAPA DE DETECÇÃO DE DESCONTINUIDADES	110
5.3 ETAPA DE CLASSIFICAÇÃO	110
5.4 CONCLUSÕES	115
6 CONCLUSÕES E PERSPECTIVAS PARA TRABALHOS FUTUROS.....	116
REFERÊNCIAS.....	120

1 INTRODUÇÃO

A inspeção radiográfica de juntas soldadas é empregada em diferentes áreas, tais como: nuclear, naval, química, aeronáutica, bem como, na área de petróleo e gás (SILVA et al., 2001) no sentido de assegurar a qualidade, a segurança e a confiabilidade das estruturas analisadas (WANG; LIAO, 2002). Este tipo de inspeção industrial é considerado como um Ensaio Não Destrutivo (END) e permite a análise de cada material e componente sem interferir ou alterar as suas funcionalidades (ASNT, 2014). Além disso, a inspeção radiográfica apresenta como principal vantagem em relação às demais técnicas de END, a característica única de proporcionar uma “fotografia” interna do material ou componente em análise, permitindo obter um registro permanente da inspeção volumétrica do material (SILVA, 2003).

Por essas características, a inspeção radiográfica é amplamente empregada em instalações petroquímicas para a análise de juntas soldadas de tubulações. Tal técnica de inspeção, quando realizada de forma periódica e em ambiente real de operação (JAGANNATHAN et al., 2000), atua na prevenção de possíveis problemas a que essas instalações estão sujeitas, por exemplo: vazamentos, paradas não programadas, perdas de produção, incêndios e inclusive acidentes com sérios danos ambientais (FELISBERTO, 2007). Diante dessas considerações, é notável a importância dessa atividade tanto do ponto de vista econômico quanto ambiental e, até mesmo, social em consequência de tais problemas.

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, bem como, na sua própria experiência. No Brasil, por exemplo, a especificação dos critérios para a qualificação e certificação de inspetores de soldagem é feita através da norma vigente NBR 14842 (2003) definida pelo Comitê Brasileiro de Soldagem (ABNT/CB-42) da Associação Brasileira de Normas Técnicas (ABNT), descrevendo as atribuições e responsabilidades dos inspetores laudistas. Uma das atribuições dos inspetores de soldagem é a análise e

emissão de laudos a partir de imagens radiográficas de juntas soldadas que consiste na indicação de defeitos, sobre a região analisada.

Em vista disso, estudos sobre a confiabilidade da rotina de interpretação humana em END através de filmes radiográficos foram desenvolvidos por Fücsök et al. (2000; 2002), baseando-se em um grupo de inspetores laudistas com experiência entre 6 meses e 35 anos. Esses estudos reportaram uma taxa média de acerto na indicação de defeitos de 68% e nem mesmo o inspetor mais experiente foi capaz de acertar 100%. Um dos fatores que podem ser apontados para justificar esses resultados é que a inspeção de soldagem é uma atividade essencialmente humana sujeita a erros relacionados à acuidade visual, à experiência, à fadiga e às distrações do inspetor, afetando a repetitividade e reprodutibilidade deste processo (PADUA, 2004; RAJAGOPALAN et al., 2004; KROETZ, 2012).

1.1 JUSTIFICATIVA

Diante dessa realidade, diversas pesquisas para a automatização e apoio à tomada de decisão têm sido desenvolvidas pela comunidade científica na área de detecção/classificação de defeitos de soldagem em imagens radiográficas (e.g., LIAO; LI, 1998; LIAO et al., 1999; LASHKIA, 2001; WANG et al., 2008; PADUA, 2004; SUN et al., 2005; WANG et al., 2008; VILAR et al., 2009; VALAVANIS; KOSMOPOULOS, 2010; LILING; YANGJIE, 2011).

Apesar dessa área apresentar trabalhos com progresso significativo, a generalização dos métodos desenvolvidos é afetada, principalmente, pela diferença de características dos bancos de imagens tratados em cada estudo. Essas diferenças podem ser causadas por fatores como: material em análise, forma de aquisição/exposição da imagem radiográfica, ambiente de captura e processo de obtenção da imagem radiográfica em formato digital (DAVIS, 1998; JUNIOR; MARQUES, 2006; NASCIMENTO, 2012). Em consequência desses fatores a qualidade da imagem radiográfica formada é afetada e pode apresentar diferentes níveis de variação de luminosidade, ruído e contraste (HALMSHAW; KOWOL, 2001).

Este trabalho de pesquisa faz parte do conjunto de esforços empreendidos pela equipe de pesquisa do Laboratório de Imagens e Visão Computacional (LIVIC) do programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial (CPGEI) da Universidade Tecnológica Federal do Paraná (UTFPR). A equipe do LIVIC atua juntamente com o Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello (CENPES) da empresa Petróleo Brasileiro S.A. (PETROBRAS) para o desenvolvimento de um sistema de apoio ao procedimento de inspeção radiográfica de juntas soldadas de tubulações (e.g., FELISBERTO, 2007; KROETZ, 2012; FYLYK; CENTENO, 2012; SUYAMA et al., 2013; 2015; MARINHO et al., 2014).

Do ponto de vista científico, este trabalho de pesquisa é fundamental, pois trata de uma situação pouco explorada pela literatura que é a detecção de descontinuidades de solda em imagens radiográficas de tubulações de petróleo com diâmetro igual ou inferior a 89 mm (e.g., KROETZ, 2012; FYLYK; CENTENO, 2012). Neste caso, a técnica de exposição rotineiramente empregada é do tipo Parede Dupla Vista Dupla (PDVD). A técnica de exposição radiográfica PDVD proporciona o tratamento simultâneo das duas vistas da junta soldada. Enquanto que a grande maioria dos trabalhos presentes na literatura utiliza imagens radiográficas obtidas pela técnica de exposição do tipo Parede Simples Vista Simples (PSVS) na qual apenas uma vista da soldagem necessita ser processada.

É importante ressaltar que, além dessa diferença estrutural da região da soldagem sobre a imagem radiográfica, há grandes diferenças de características entre as imagens tratadas na literatura e neste trabalho. As imagens empregadas na literatura são, normalmente, bem uniformes e próprias do ambiente acadêmico, enquanto que as imagens tratadas neste trabalho são obtidas a partir de condições reais de operação, especialmente no campo. Ademais, o método aqui desenvolvido poderá ser incorporado em futuras versões do sistema de auxílio à inspeção radiográfica desenvolvido pela equipe do LIVIC e apresentado em sua última versão estável por Marinho et al. (2014).

1.2 OBJETIVOS

1.2.1 Objetivos gerais

O presente trabalho tem por objetivo geral desenvolver um método para auxiliar na detecção de defeitos em juntas soldadas de tubulações de petróleo em imagens radiográficas com técnica de exposição do tipo PDVD não sobreposta. Pretende-se contribuir com as pesquisas realizadas para o desenvolvimento de técnicas auxiliares para a automatização e o apoio à tomada de decisão no procedimento de inspeção radiográfica, visando à aplicabilidade prática do método aqui desenvolvido.

1.2.2 Objetivos específicos

- Realçar as imagens radiográficas dos cordões de solda que são originalmente borradas, tornando os defeitos de soldagem evidentes.
- Segmentar as descontinuidades que representam regiões de defeitos de soldagem em potencial para classificá-las como regiões com defeito (CD) e sem defeito (SD) de soldagem.
- Excluir descontinuidades completamente inscritas na região central da junta soldada PDVD não sobreposta e nos limites da imagem, permitindo a redução do espaço de busca para o processo de classificação.
- Extrair atributos de exemplos das classes de regiões com defeito (CD) e sem defeito (SD) de soldagem.
- Treinar e testar redes Neurais Artificiais (RNA) *Perceptron* de múltiplas camadas (*Multilayer Perceptron*) (MLP), para classificar as duas classes de descontinuidades segmentadas e, por reconhecimento de padrões, detectar defeitos de soldagem.

1.3 ESTRUTURA DO TRABALHO

- A fundamentação teórica (capítulo 2) apresenta os conhecimentos relativos aos conceitos e técnicas de processo radiográfico, processamento digital de imagens, redes neurais e métricas de avaliação de resultados que são necessários para a compreensão dos métodos empregados no desenvolvimento do trabalho.
- O estado da arte (capítulo 3) expõe trabalhos relacionados ao tema destacando metodologias existentes que tratam da detecção de defeitos de soldagem em imagens radiográficas de juntas soldadas.
- Os materiais e métodos (capítulo 4) descrevem o contexto e as técnicas aplicadas e desenvolvidas para a detecção de defeitos.
- O capítulo referente aos resultados e discussões (capítulo 5) apresenta as análises dos resultados e considerações do método proposto e desenvolvido.
- Finalmente as conclusões e perspectivas para trabalhos futuros (capítulo 6) apresentam as considerações gerais do trabalho exposto, do método desenvolvido e dos resultados obtidos. Além disso, propõem abordagens para trabalhos futuros e referenciam as publicações científicas produzidas durante o desenvolvimento desta dissertação.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 INTRODUÇÃO

Este capítulo apresenta a fundamentação teórica dos conceitos empregados nesta dissertação com foco em quatro áreas principais: processo radiográfico (seção 2.2), processamento digital de imagens (seção 2.3), redes neurais artificiais (seção 2.4) e métricas de avaliação de resultados (seção 2.5).

2.2 PROCESSO RADIOGRÁFICO

2.2.1 Formas de aquisição de imagens radiográficas

Os exames radiográficos utilizam dois tipos de radiação eletromagnética: raios-x e raios- γ . O objetivo desses exames é a utilização da radiação para atravessar o corpo de prova (material a ser analisado) e permitir a projeção dos defeitos em um detector (ou filme). A aquisição de imagens radiográficas é composta por seis elementos básicos: a fonte de radiação (raios-x ou raios- γ), o feixe da radiação, o corpo de prova (material a ser analisado), o defeito (ou descontinuidade) do corpo de prova, a imagem latente do defeito (projetada sobre o detector) e o detector (ou filme) (DAVIS, 1998). A Figura 1 ilustra essa estrutura básica de aquisição de imagem radiográfica.

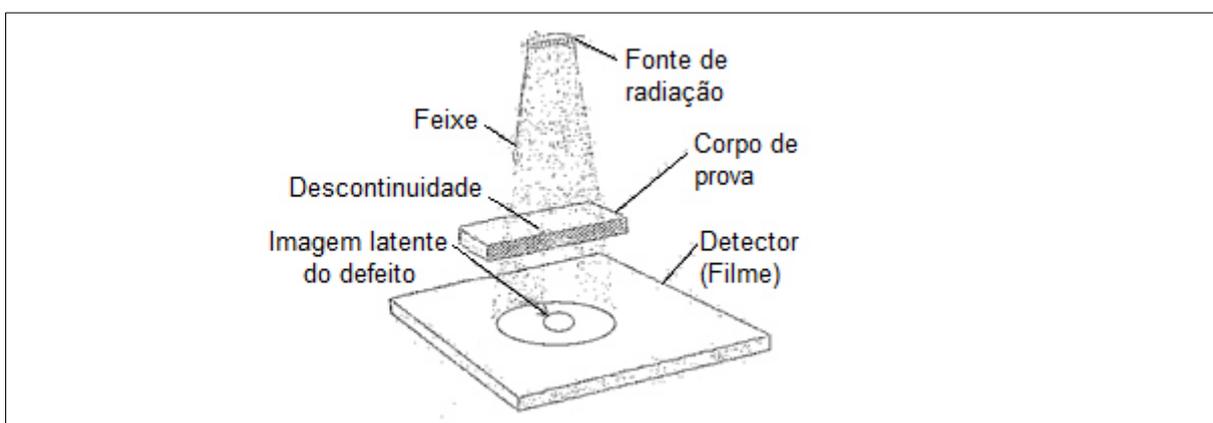


Figura 1 - Princípios básicos de radiografia.

Fonte: Adaptado de Davis (1998).

Há três formas de aquisição de imagens radiográficas (NASCIMENTO, 2012): convencional, direta e computadorizada.

2.2.1.1 Radiografia convencional

A radiografia convencional é realizada através da estrutura básica de aquisição de imagens radiográficas. Suas características principais são a necessidade de processamento do filme radiográfico (detector) para que a imagem latente do material a ser analisado (corpo de prova) se torne evidente e o filme radiográfico possa ser revelado. Apesar de ser analógica, a análise de defeitos pode ser feita pelo computador através da digitalização dos filmes radiográficos por escâner.

2.2.1.2 Radiografia direta

A radiografia direta segue a mesma disposição física básica de um sistema radiográfico. Entretanto, sua principal característica reside no detector que é capaz de capturar a imagem radiográfica diretamente na forma digital. O detector empregado nesta técnica é comumente designado como *Flat Panel*, também conhecido como Matriz de Detector Digital (MDD), e é composto por milhões de detectores individuais. Esses detectores individuais possuem conversão A/D (analógica/digital) relativa à quantidade de radiação recebida e a sua resolução em bits para a conversão do sinal na escala de cinza (NASCIMENTO, 2012).

2.2.1.3 Radiografia computadorizada

Um sistema de radiografia computadorizada possui os mesmos princípios básicos com relação à disposição física dos componentes necessários para a aquisição radiográfica. Porém há três componentes fortemente acoplados neste sistema: o detector, a digitalização e o sistema de processamento da imagem digitalizada (*software* de apoio) (BSI BS EN 14784, 2005). Os detectores utilizados na radiografia computadorizada são denominados *Image Plates* (IP) (Figura 2) e são

compostos por uma camada protetora (0,008 a 0,03 mm), uma camada de fósforo (0,08 a 0,03 mm), um suporte de poliéster (0,18 mm) e um reforço de controle da curvatura (OLIVEIRA et al., 2007). A digitalização de um IP é ilustrada na Figura 3.

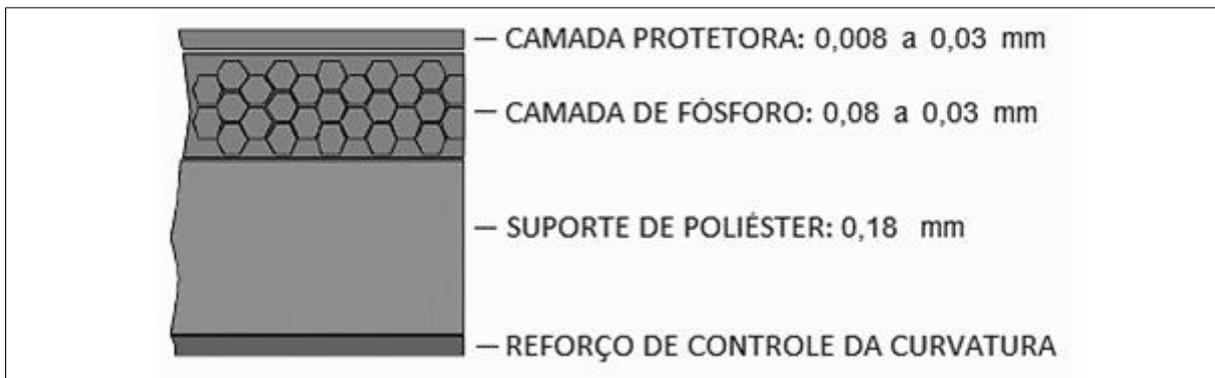


Figura 2 - Image Plate (IP).

Fonte: Adaptado de Oliveira et al. (2007, p. 4).

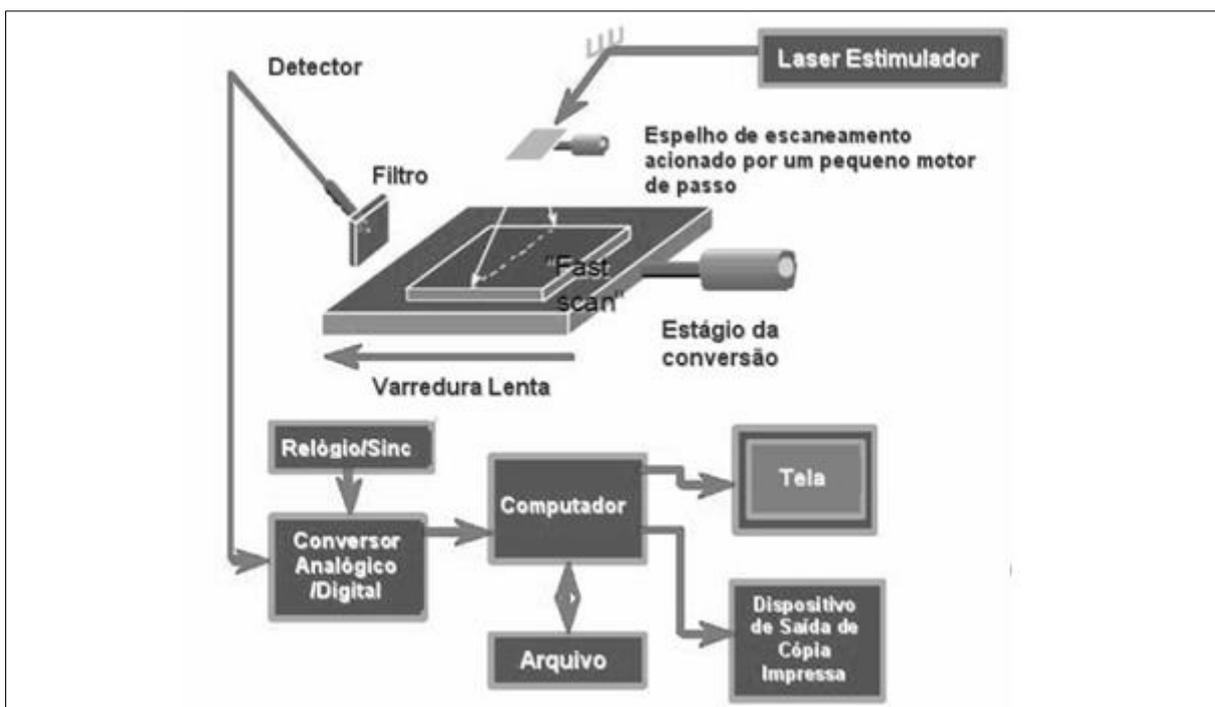


Figura 3 - Digitalização de radiografia computadorizada.

Fonte: Oliveira et al. (2007, p. 4)

2.2.2 Técnicas de exposição radiográfica

As técnicas de exposição radiográfica para a inspeção END de imagens radiográficas de juntas soldadas de tubulações são separadas em três tipos: Parede Simples Vista Simples (PSVS), Parede Dupla Vista Simples (PDVS) e Parede Dupla Vista Dupla (PDVD).

2.2.2.1 Parede Simples Vista Simples (PSVS)

A técnica de exposição radiográfica PSVS forma a imagem radiográfica de apenas uma parede (vista simples) do material inspecionado (corpo de prova). Nesta técnica, há duas configurações possíveis em tubulações: fonte interna com detector(es) externo(s) à tubulação (Figura 4, Figura 5), e fonte externa com o detector interno à tubulação (Figura 6) (JUNIOR; MARQUES, 2006). Nas imagens radiográficas PSVS para as duas configurações possíveis (fonte interna com detector externo e fonte externa com detector interno) a imagem da junta soldada fica com formato retilíneo. A Figura 7 apresenta um exemplo de radiografia PSVS panorâmica.

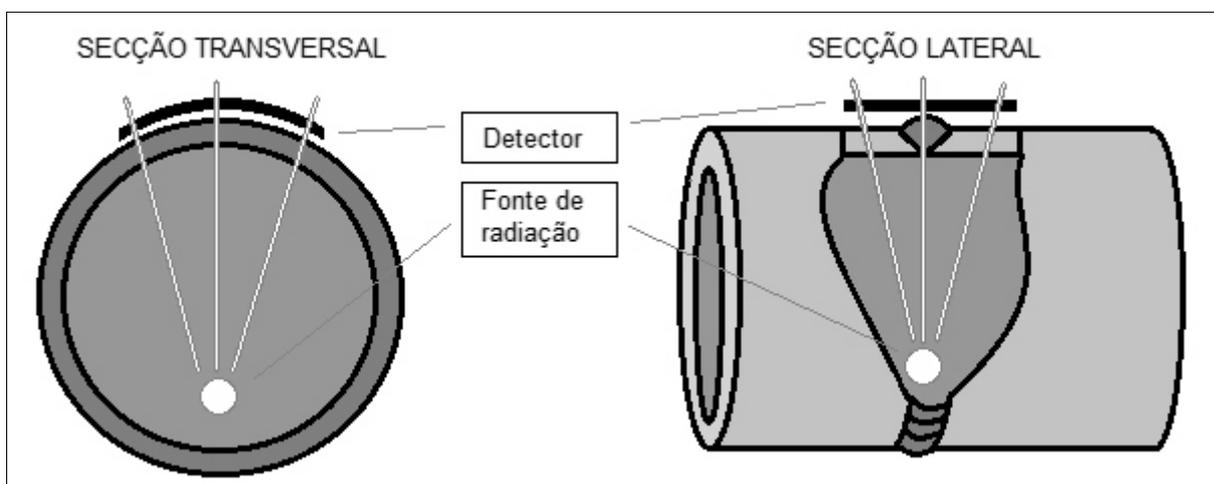


Figura 4 - Exposição PSVS com fonte interna e um detector externo.

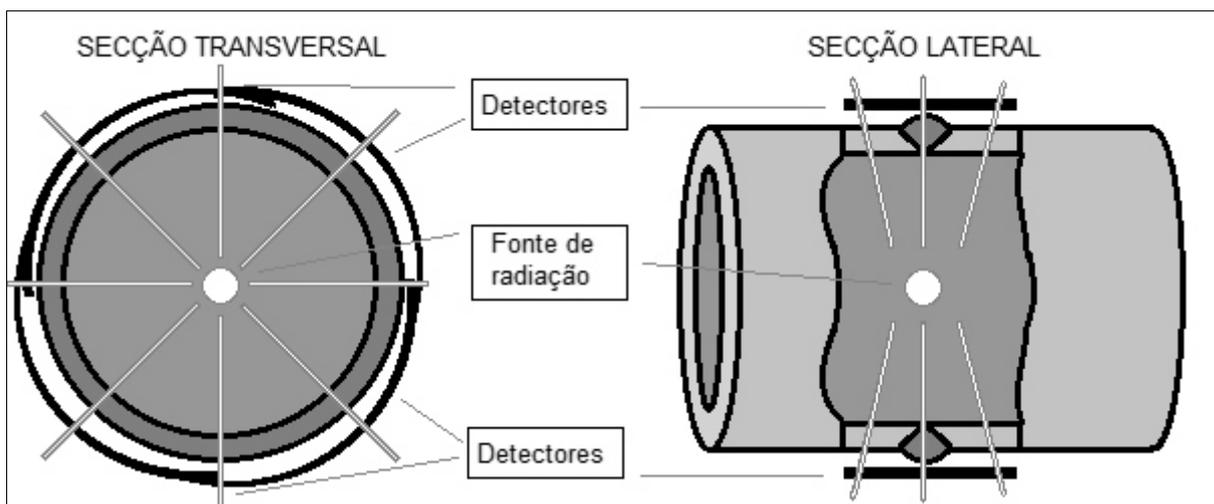


Figura 5 - Exposição PSVS panorâmica com fonte interna e detectores externos.

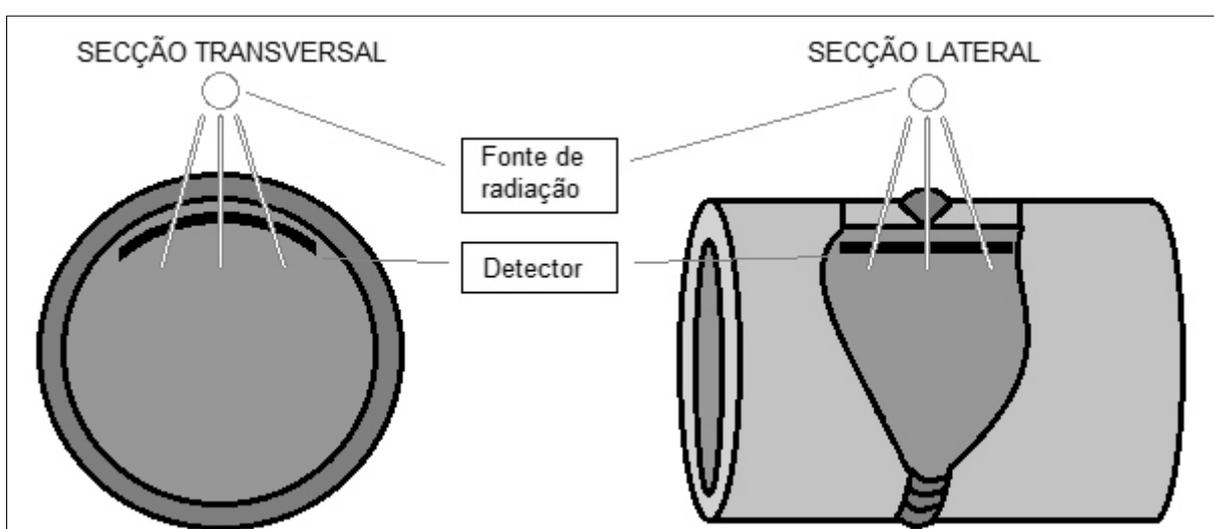


Figura 6 - Exposição PSVS com fonte exterior e detector interno.

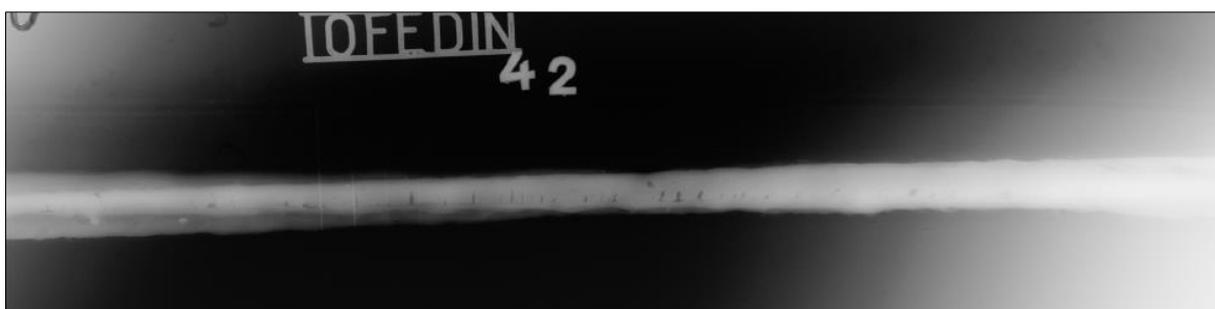


Figura 7 - Exemplo de radiografia PSVS panorâmica. Junta soldada retilínea com presença de indicadores de qualidade de imagem (IQIs¹) na porção superior da imagem.

Fonte: Kroetz (2012, p. 35).

¹ Indicadores de Qualidade da Imagem (IQIs) são componentes posicionados sobre o corpo de prova nos ensaios radiográficos, contendo, geralmente letras e linhas. Os IQIs permitem que a qualidade da imagem obtida seja avaliada por inspetores de soldagem com relação a três fatores: nitidez, contraste e ruído (HALMSHAW; KOWOL, 2001).

2.2.2.1 Parede Dupla Vista Simples (PDVS)

A técnica de exposição radiográfica PDVS ocorre quando a fonte de radiação e o detector são posicionados em lados opostos, ambos exteriores e adjacentes à parede da tubulação (JUNIOR; MARQUES, 2006). Essa forma de exposição radiográfica PDVS pode ser adotada de duas formas: na primeira a fonte é alinhada com a junta soldada (Figura 8) com projeção retilínea da solda, na segunda a fonte não é alinhada com a junta soldada (Figura 9) com projeção levemente curvada da solda. A Figura 10 ilustra um exemplo de radiografia PDVS com fonte não alinhada, apresentando indicadores de qualidade de imagem (IQIs) próximos à solda.

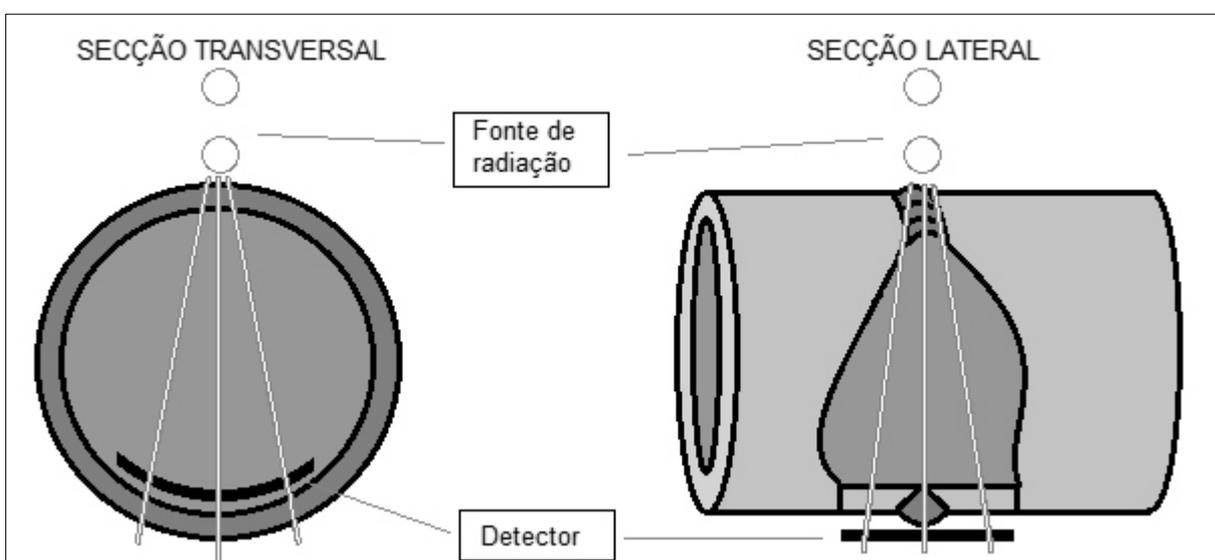


Figura 8 - Exposição PDVS com fonte alinhada à junta soldada.

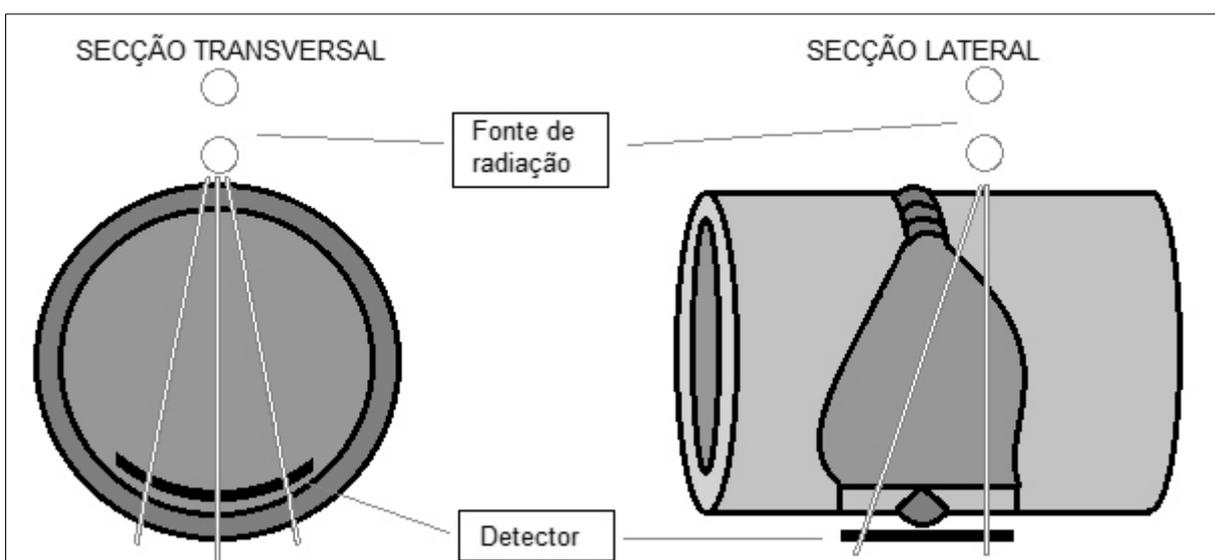


Figura 9 - Exposição PDVS com fonte não alinhada à junta soldada.

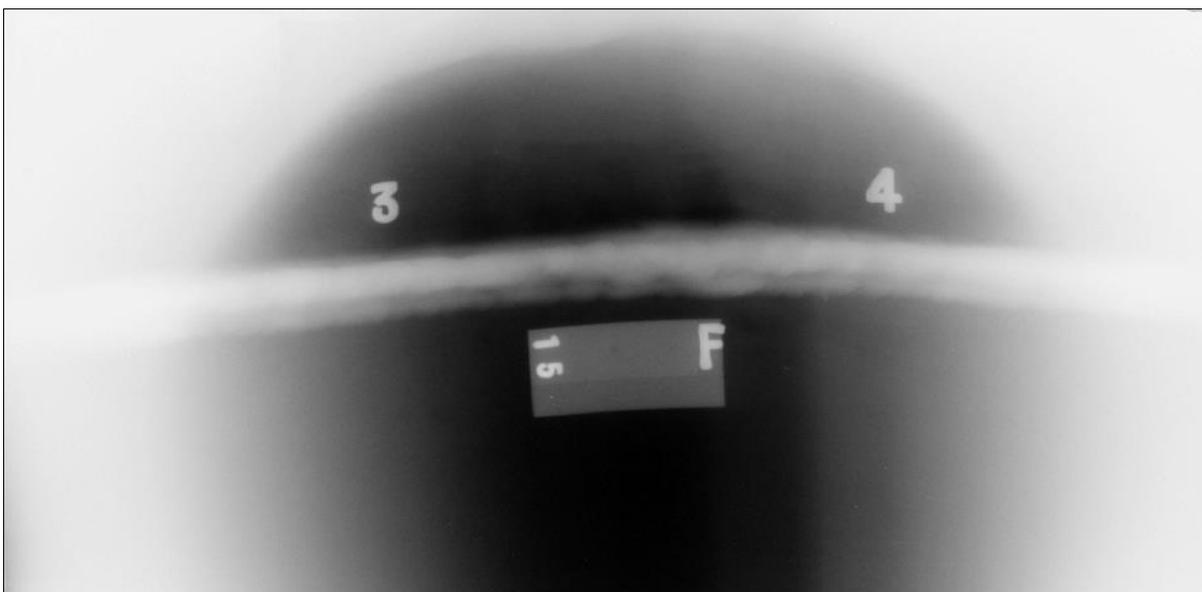


Figura 10 - Exemplo de radiografia PDVS com fonte não alinhada. Junta soldada levemente curva com presença de indicadores de qualidade de imagem (IQIs) próximos à solda.

Fonte: Kroetz (2012, p. 37).

2.2.2.2 Parede Dupla Vista Dupla (PDVD)

A forma de exposição radiográfica PDVD permite a captura de duas paredes do corpo de prova, formando a imagem radiográfica de uma parede externa e uma parede interna do corpo de prova. De acordo com o código ASME (*American Society of Mechanical Engineers*) V - *Nondestructive Examination* (2010), essa forma de exposição é aplicada para materiais com diâmetro igual ou inferior a 89 mm. Há duas formas de exposição radiográfica PDVD: a fonte não é alinhada em relação à junta soldada (não sobreposta - Figura 11) e a forma em que a fonte é alinhada em relação à junta soldada (sobreposta - Figura 12).

A radiografia PDVD não sobreposta difere da radiografia PDVD sobreposta por proporcionar uma visão interna e uma externa da solda de forma simultânea, formando uma projeção elíptica da região da solda. A primeira é preferível por não causar a sobreposição das regiões da solda e, por conseguinte, facilitar a análise para a detecção de defeitos. A Figura 13 apresenta exemplo de radiografia PDVD não sobreposta.

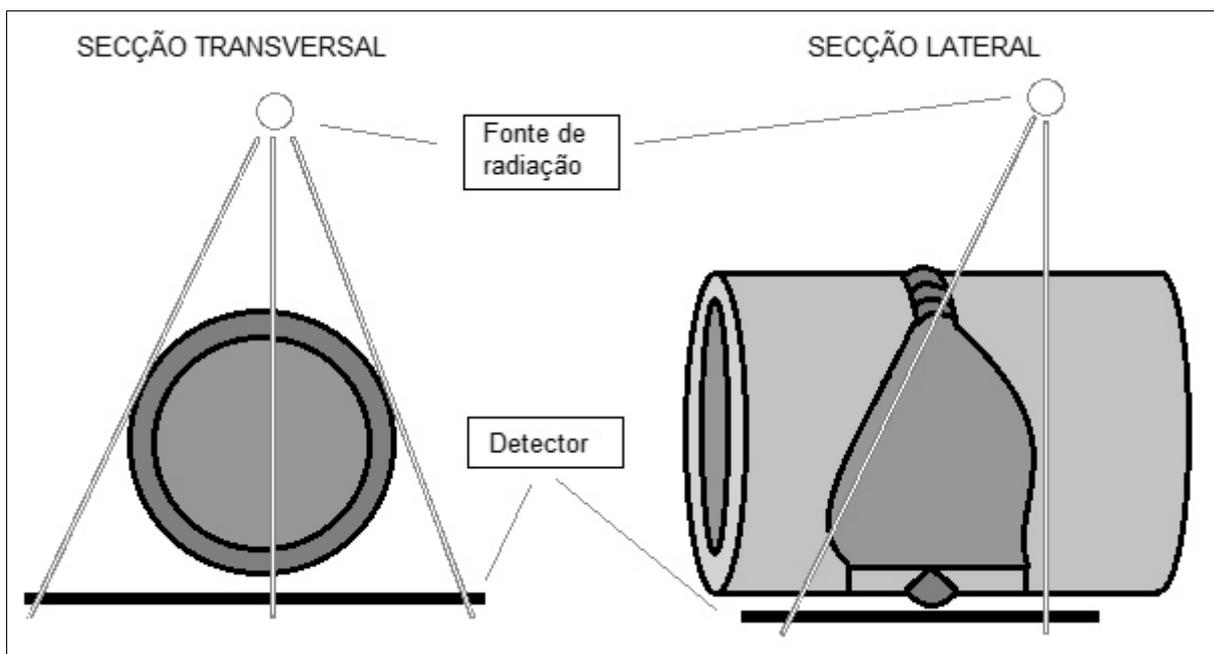


Figura 11 - Exposição radiográfica PDVD não sobreposta.

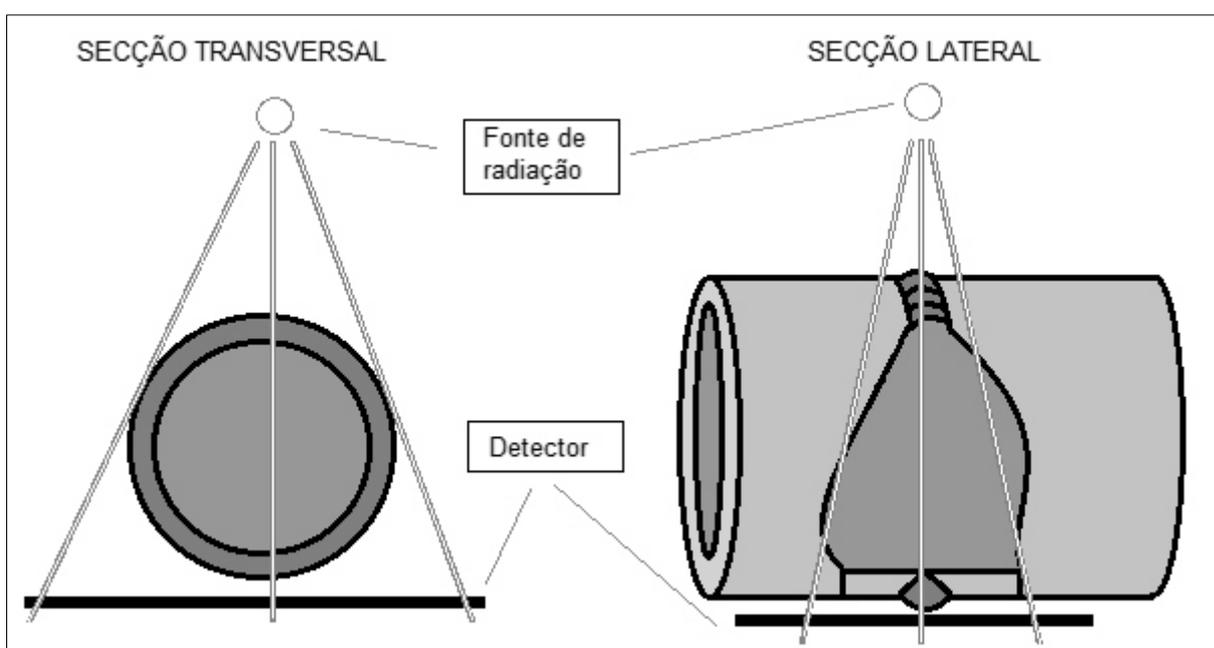


Figura 12 - Exposição radiográfica PDVD sobreposta.

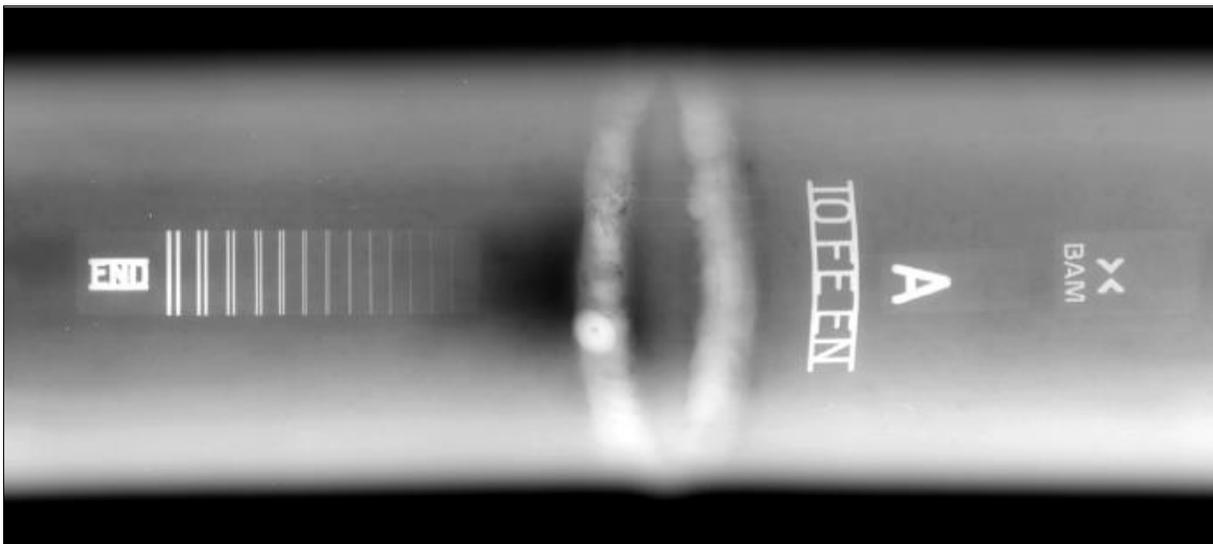


Figura 13 - Exemplo de radiografia PDVD não sobreposta. Junta soldada com formato elipsoidal com indicadores de qualidade de imagem (IQIs) sobre o corpo de prova.

Fonte: Kroetz (2012, p. 39).

2.2.3 Principais tipos de defeitos de soldagem

De acordo com a *American Welding Society* (AWS) (2001), os principais tipos de discontinuidades, consideradas como defeitos, encontradas em radiografias de juntas soldadas podem ser classificados como: Porosidade (PO), Falta de Penetração (FP), Falta de Fusão (FF) ou Solubilização, Mordedura (MO) (interna e externa), Trinca (TR), Inclusão de Escória (IE) e Inclusão de Tungstênio (IT).

2.2.3.1 Porosidade (PO)

A Porosidade (PO) é caracterizada por manchas de baixa densidade (escuras) geralmente arredondadas ou vermiculares (alongadas) e, por vezes, isolada ao longo da linha central da zona de fusão da solda. A Figura 14 ilustra o esquema da secção transversal (em cima) de uma junta soldada e da vista superior (em baixo) de um cordão de solda com quatro disposições distintas comumente classificadas como PO: uniformemente distribuída, agrupada, alinhada, ou vermicular (FELISBERTO, 2007).

A PO é causada pelo aprisionamento do gás durante a fase de solidificação da solda pela presença de impurezas ou correntes de ar (MARQUES, 1991). A

Figura 15 ilustra um exemplo de PO agrupada com a secção transversal (canto superior esquerdo) de uma junta soldada e a vista superior (canto inferior esquerdo) de um cordão de solda e imagem radiográfica da solda (canto direito).

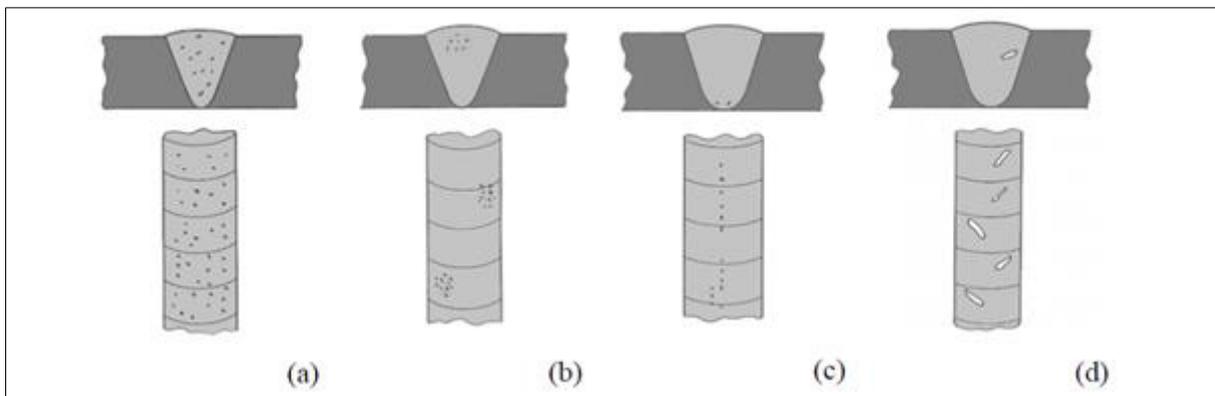


Figura 14 - Tipos de porosidades. (a) PO distribuída, (b) agrupada, (c) alinhada e (d) vermicular. Fonte: Felisberto (2007).

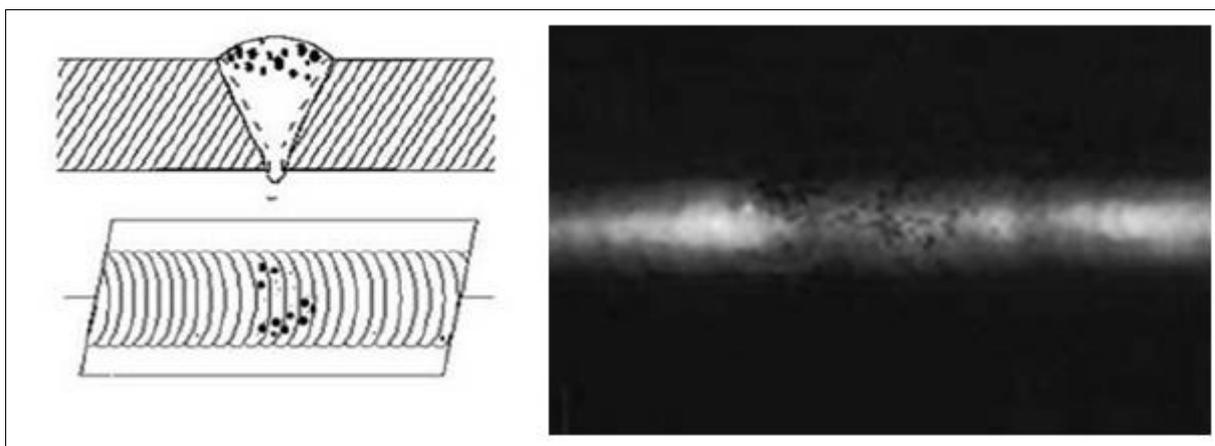


Figura 15 - Cordão de solda com porosidade (PO).

Fonte: QUITES (2009).

2.2.3.2 Falta de Penetração (FP)

A Falta de Penetração (FP) se refere às falhas ocorridas no preenchimento da raiz da junta (MARQUES, 1991) e corresponde a áreas escuras alongadas com largura igual à largura da raiz da junta (QUITES, 2009). A FP é caracterizada pela falta de aderência de parte do cordão de solda na lateral do chanfro ou entre cordões. A Figura 16 ilustra um exemplo de FP com a secção transversal (canto

superior esquerdo) de uma junta soldada e a vista superior (canto inferior esquerdo) de um cordão de solda e imagem radiográfica da solda (canto direito).

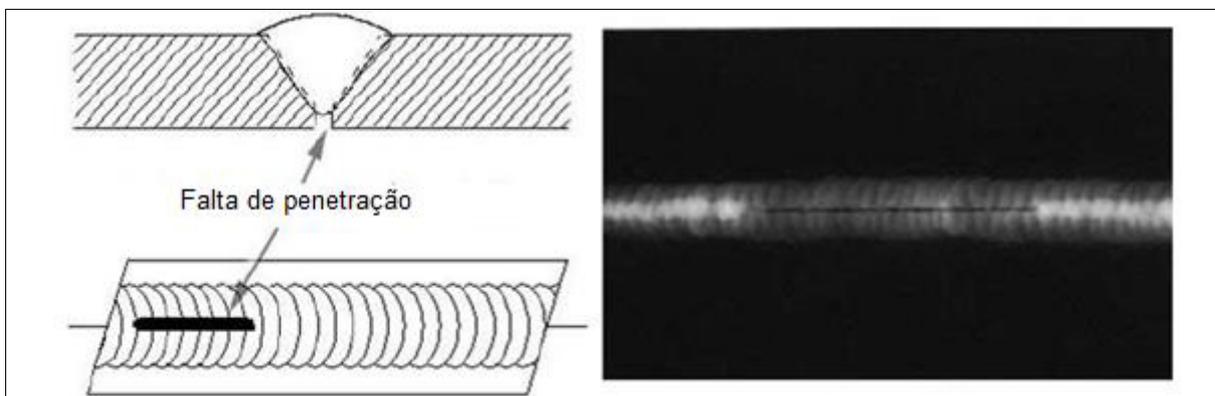


Figura 16 - Cordão de solda com falta de penetração (FP).

Fonte: Adaptado de Quites (2009).

2.2.3.3 Falta de Fusão (FF)

Os defeitos do tipo Falta de Fusão (FF) são manchas de baixa densidade (escuras) orientadas no sentido da face da junta (QUITES, 2009) e como a falta de penetração também é causada pela falta de aderência. A Figura 17 ilustra um exemplo de FF com a secção transversal (canto superior esquerdo) de uma junta soldada e a vista superior (canto inferior esquerdo) de um cordão de solda e imagem radiográfica da solda (canto direito).

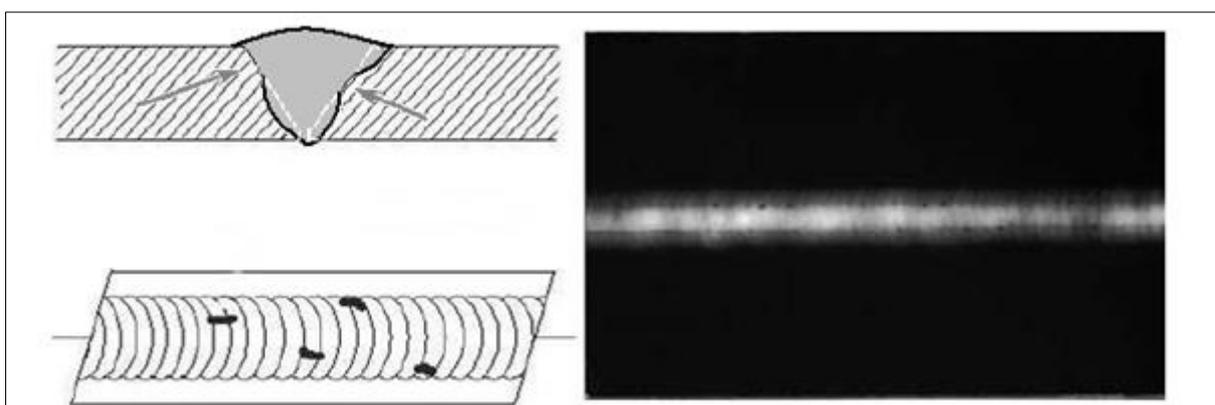


Figura 17 - Cordão de solda com falta de fusão (FF).

Fonte: Quites (2009).

2.2.3.4 Mordedura (MO)

As mordeduras (MO) são linhas estreitas, alongadas, escuras e irregulares; separando-se em dois tipos: de raiz (ou interna) e de margem (ou externa) (QUITES, 2009). A MO interna é uma linha escura estreita e irregular ou dupla seguindo a face da raiz da junta, enquanto que a MO externa é uma linha escura, estreita, alongada e irregular posicionada ao longo da margem da solda. A mordedura é causada pelo preenchimento incorreto das laterais da junta. A Figura 18 e a Figura 19 ilustram, respectivamente, exemplos de MO interna e externa com a secção transversal (canto superior esquerdo) de uma junta soldada e a vista superior (canto inferior esquerdo) de um cordão de solda e imagem radiográfica da solda (canto direito).

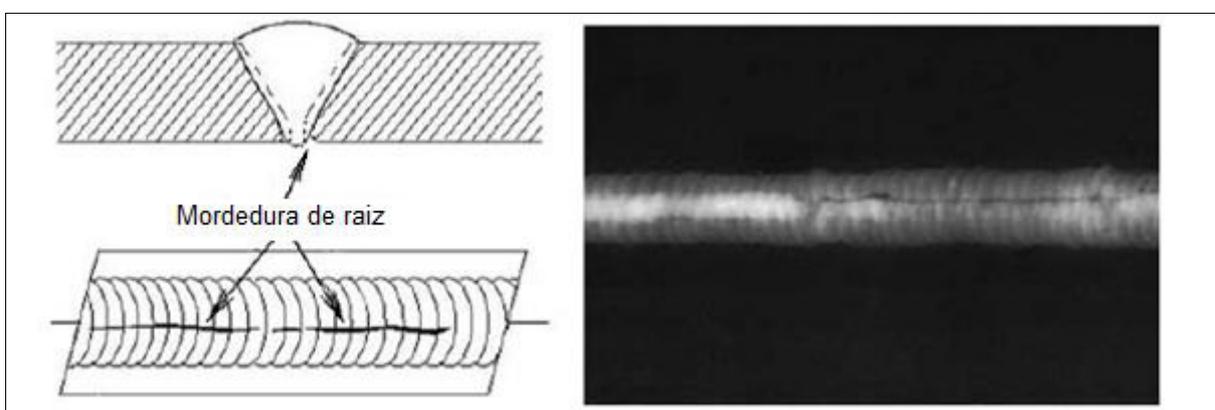


Figura 18 - Cordão de solda com mordedura (MO) de raiz (ou interna).

Fonte: Adaptado de Qites (2009).

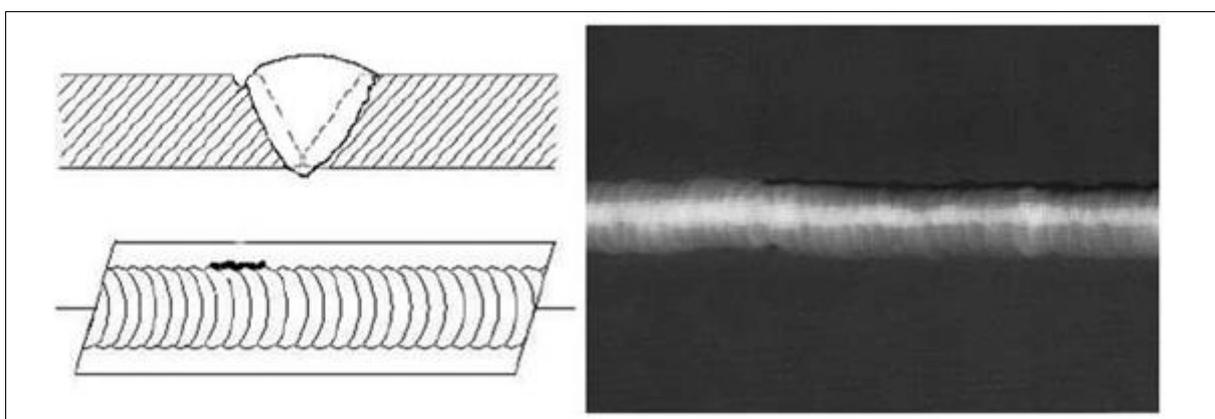


Figura 19 - Cordão de solda com mordedura (MO) na margem da solda (ou externa).

Fonte: Qites (2009).

2.2.3.5 Trinca (TR)

As trincas são consideradas em geral, os defeitos mais graves em uma junta soldada por serem fortes concentradores de tensão e podem se formar durante, logo após a soldagem. As trincas (TR) são linhas tênues e irregulares, as TRs se tornam evidentes na radiografia apenas quando apresentam orientação praticamente paralela em relação aos feixes de raios-x (QUITES, 2009). A Figura 20 ilustra um exemplo de TR com a secção transversal (canto superior esquerdo) de uma junta soldada e a vista superior (canto inferior esquerdo) de um cordão de solda e imagem radiográfica da solda (canto direito).

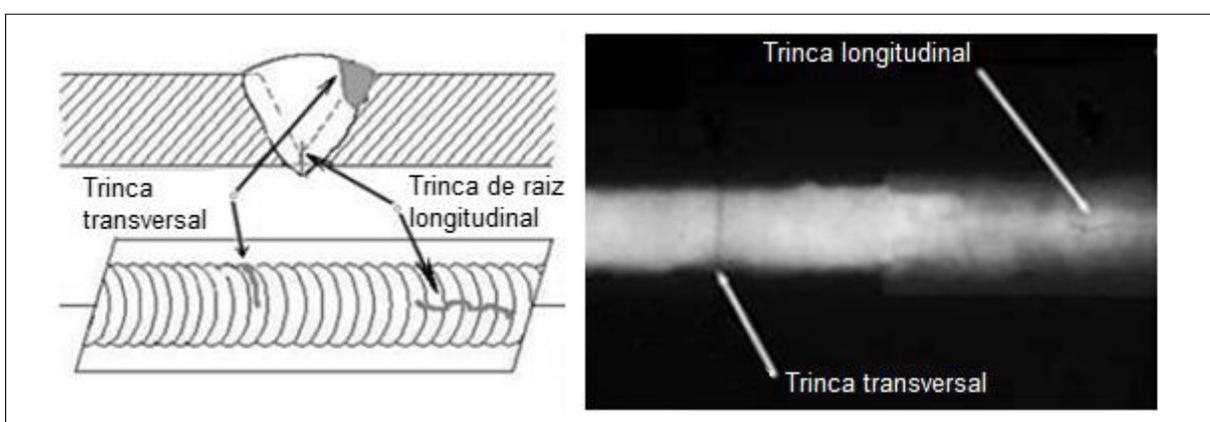


Figura 20 - Cordão de solda com trincas (TR).

Fonte: Adaptado de Qites (2009).

2.2.3.6 Inclusão de Escória (IE)

As inclusões de escória (IE) são manchas de baixa densidade (escuras) assimétricas (QUITES, 2009) e são geradas pela presença de partículas no metal solidificado. A Figura 21 ilustra um exemplo de IE com a secção transversal (canto superior esquerdo) de uma junta soldada e a vista superior (canto inferior esquerdo) de um cordão de solda e imagem radiográfica da solda (canto direito).

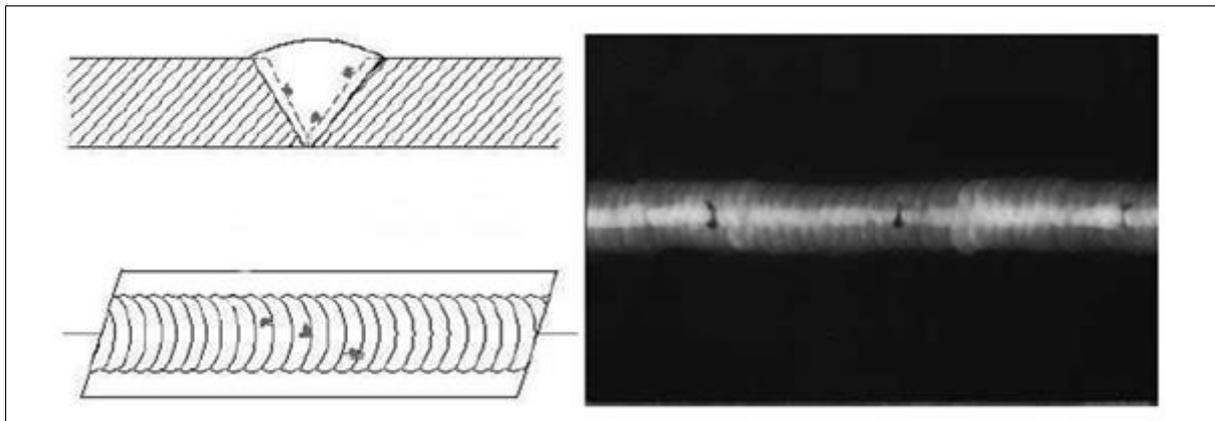


Figura 21 - Cordão de solda com inclusão de escória (IE).

Fonte: Quites (2009).

2.2.3.7 Inclusão de Tungstênio (IT)

As inclusões de tungstênio (IT) são regiões de alta densidade (claras) em relação ao alumínio ou o aço. As ITs ocorrem se o eletrodo tocar a poça metálica, contaminando a solda (QUITES, 2009). A Figura 22 ilustra um exemplo de IT com a seção transversal (canto superior esquerdo) de uma junta soldada e a vista superior (canto inferior esquerdo) de um cordão de solda e imagem radiográfica da solda (canto direito).

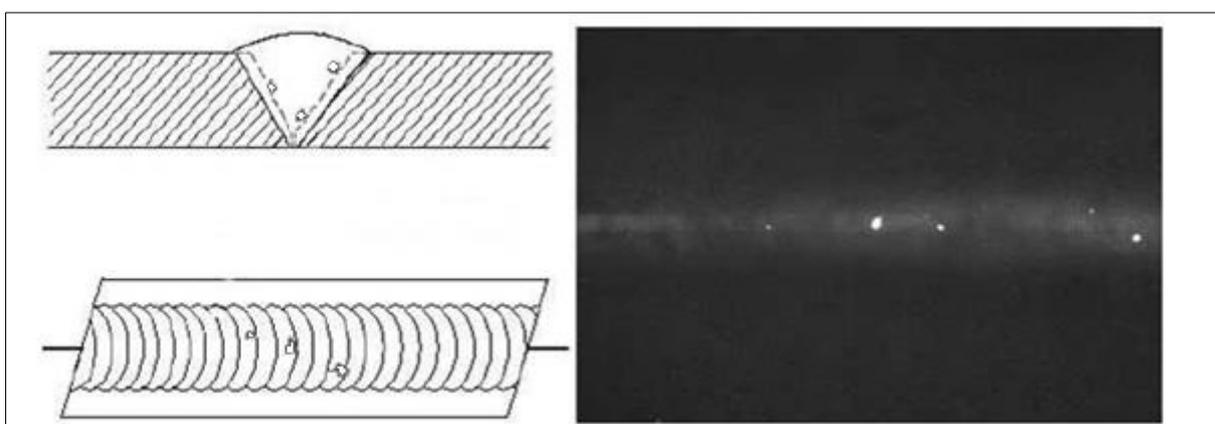


Figura 22 - Cordão de solda com inclusão de tungstênio (IT).

Fonte: Adaptado de Quites (2009).

2.3 PROCESSAMENTO DIGITAL DE IMAGENS

2.3.1 Imagem digital

Uma imagem digital pode ser descrita por uma função $f(x, y)$ em que x e y são coordenadas espaciais (plano) (GONZALEZ; WOODS, 2010) e é composta por pixels (*picture element*). Cada pixel representa uma intensidade de cor. A equação (1) mostra a estrutura de uma forma de representação matricial de uma imagem digital $f(x, y)$ de forma discreta e finita através de uma matriz $M \times N$, em que cada posição da matriz representa um pixel que compõe imagem digital.

$$f(x, y) = \begin{bmatrix} f(0,0) & \cdots & f(0, N - 1) \\ \vdots & \ddots & \vdots \\ f(M - 1, 0) & \cdots & f(M - 1, N - 1) \end{bmatrix} \quad (1)$$

Na qual:

M - quantidade de linhas da imagem $f(x, y)$

N - quantidade de colunas da imagem $f(x, y)$

x - coordenada espacial da imagem $f(x, y)$ referente à altura

y - coordenada espacial da imagem $f(x, y)$ referente ao comprimento.

O processo de formação de uma imagem digital ocorre através das etapas amostragem e quantização (GONZALEZ; WOODS, 2010) que consistem na digitalização dos valores de intensidade e amplitude, respectivamente, das coordenadas de uma imagem contínua (GONZALEZ; WOODS, 2010). A captura de uma imagem contínua para a formação de uma imagem digital é realizada, normalmente, por sensores de varredura em linha (e.g., escâneres) e por matriz de sensores (e.g., câmeras). De acordo com Gonzalez e Woods (2010), a qualidade de uma imagem digital é claramente determinada, em grande parte, pelo número de amostras e de níveis discretos de intensidades utilizados nas etapas de amostragem e quantização.

A taxa de conversão desses níveis discretos depende da resolução em bits do mecanismo de captura. Por exemplo, se o mecanismo for de 16 bpp (bits por pixel), então a imagem digital poderá possuir até 2^{16} (65536) valores discretos de níveis de cinza [0, 65535]. Assim, cada um destes pixels assume um valor inteiro no intervalo de 0 e $2^{bpp} - 1$. A Figura 23 ilustra o exemplo de uma imagem digital monocromática com o par de eixos (x, y) .



Figura 23 - Exemplo de imagem digital monocromática.

2.3.1 Histograma

O histograma de uma imagem digital permite uma análise qualitativa da imagem com relação ao brilho e ao contraste. Considerando uma imagem digital com k níveis de intensidade que um pixel pode assumir no intervalo $[0, 2^{bpp} - 1]$ então seu histograma $h(r_k)$ é definido por uma função discreta apresentada na equação (2) (GONZALEZ; WOODS, 2010).

$$h(r_k) = n_k \quad (2)$$

Na qual:

r_k - k -ésimo valor de intensidade

n_k - número de pixels da imagem com intensidade r_k .

O histograma costuma ser normalizado por uma estimativa de probabilidade de ocorrência do nível de intensidade r_k de uma imagem e é obtido pela divisão de cada um dos componentes pela quantidade total de pixels que compõe a imagem (GONZALEZ; WOODS, 2010). A equação (3) descreve o cálculo de um histograma normalizado $p(r_k)$ para uma imagem com k níveis de intensidade que um pixel pode assumir no intervalo $[0, 2^{bpp} - 1]$. A Figura 24 ilustra quatro tipos básicos de imagem escura, clara, de baixo contraste e de alto contraste e respectivos histogramas.

$$p(r_k) = \frac{r_k}{MN} \quad (3)$$

Na qual:

r_k - k -ésimo valor de intensidade

MN - quantidade de pixels que compõe a imagem com dimensões $M \times N$.

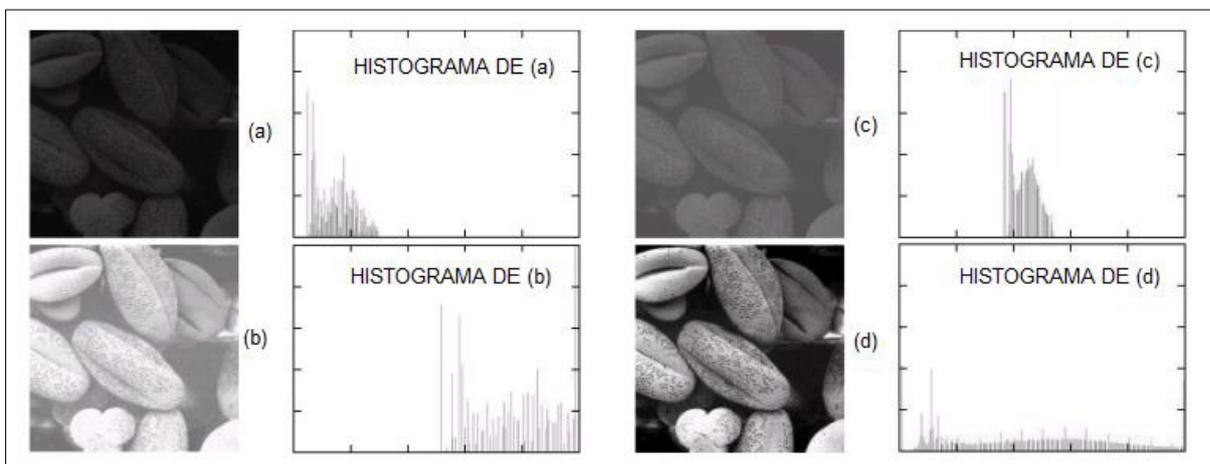


Figura 24 - Histogramas. (a) Imagem clara (b) escura (c) com baixo contraste e (d) alto contraste e respectivos histogramas.

Fonte: Adaptado de Gonzalez e Woods (2010, p. 79).

A seção 2.3.1.1 apresenta uma técnica de aprimoramento de contraste de imagem por expansão de histograma.

2.3.1.1 Expansão de histograma

A expansão do histograma é uma técnica empregada para aprimorar o contraste de uma imagem pela redistribuição dos níveis de cinza de forma que estes ocupem toda a faixa de cinza disponível (GONZALEZ; WOODS, 2010). Por exemplo, se uma imagem é monocromática com 16 bpp, então o histograma é ajustado entre 0 a 65535 (2^{16}). O processo é descrito pela equação (4) e ilustrado na Figura 25.

$$g(x, y) = (2^{bpp} - 1) \frac{f(x, y) - \min}{\max - \min} \quad (4)$$

Na qual:

$g(x, y)$ - imagem resultante do processo de expansão de histograma

$f(x, y)$ - imagem original

\min - menor valor de pixel da imagem original $f(x, y)$

\max - maior valor de pixel da imagem original $f(x, y)$

bpp - quantidade de bits por pixel.

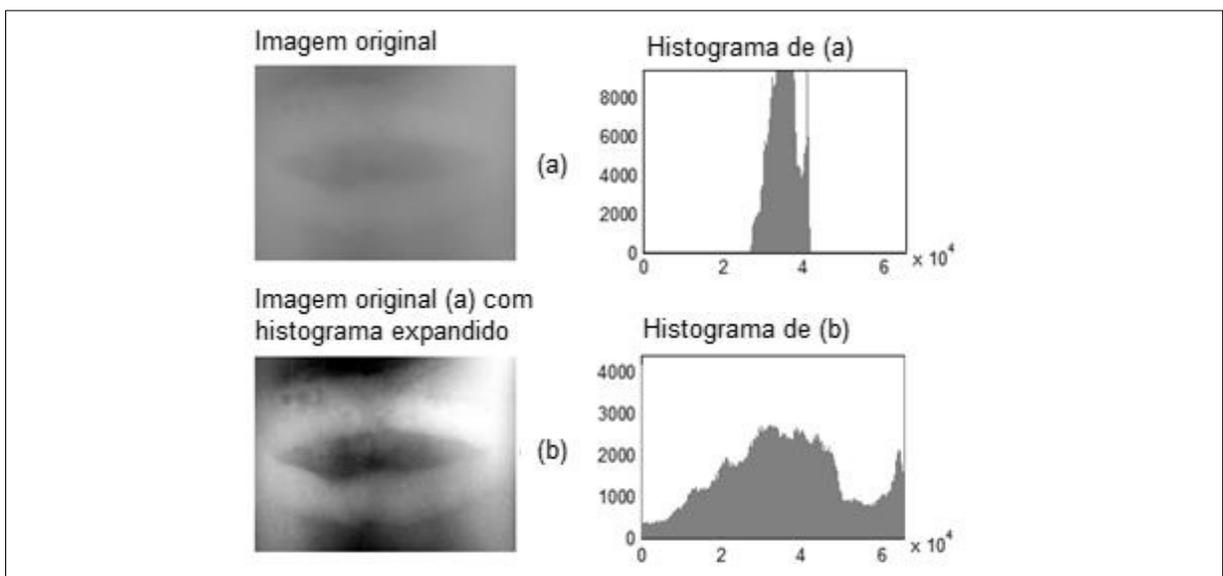


Figura 25 - Expansão de histograma. (a) Imagem original (b) histograma expandido de (a).

2.3.2 Negativo, complemento ou inversão de cor

O processamento do negativo, do complemento ou da inversão de cor de uma imagem monocromática $f(x, y)$ produz o equivalente a um negativo fotográfico. Gonzalez e Woods (2010) denotam essa operação em uma imagem I , por exemplo, como I^c . O negativo de uma imagem consiste em computar o complemento de cada valor de pixel da imagem original $f(x, y)$ em relação sua à quantidade bits por pixel (bpp) com o intuito de gerar a imagem com cor invertida $g(x, y)$. Essa operação é descrita na equação (5).

$$g(x, y) = -f(x, y) + 2^{bpp} - 1 \quad (5)$$

Na qual:

$f(x, y)$ - imagem original a ser invertida

bpp - quantidade de bits por pixel da imagem original $f(x, y)$.

A Figura 26 ilustra um exemplo de inversão com a imagem $f(x, y)$ de 16 bpp (intervalo de níveis de cinza de $[0, 65535]$) e sua imagem invertida $g(x, y)$.

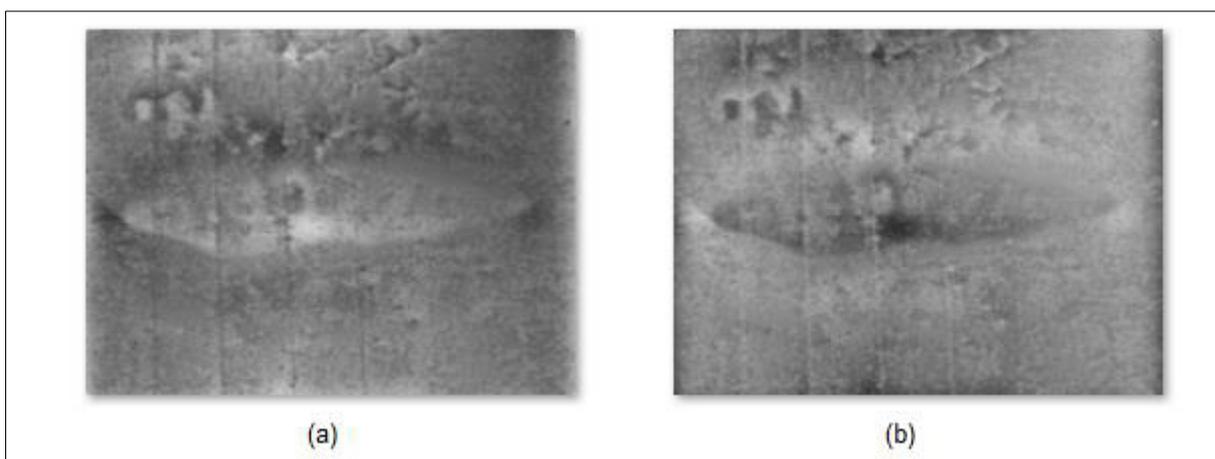


Figura 26 - Inversão de cor. (a) Imagem original (b) inversão da imagem (a).

2.3.3 Limiarização global

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 do método podem ser de diferentes níveis de cinza, mas geralmente são binárias ($\text{bpp} = 1$). Considerando uma saída binária, uma imagem limiarizada $b(x, y)$ é gerada a partir de uma imagem monocromática $f(x, y)$, baseando-se em um limiar (T). Assim, pixels com valores maiores ou iguais ao limiar T recebem o valor 0 e valores abaixo de T recebem o valor 1, conforme descrita na equação (6).

$$g(x, y) = \begin{cases} 0, & f(x, y) \geq T \\ 1, & f(x, y) < T \end{cases} \quad (6)$$

Na qual:

$f(x, y)$ - imagem original a ser limiarizada

T - limiar definido no intervalo $[0, 2^{\text{bpp}} - 1]$ em relação à imagem $f(x, y)$.

A Figura 34 ilustra um exemplo de limiarização com dois níveis de cinza (i.e., binarização) da imagem monocromática $f(x, y)$ que gera a imagem limiarizada $g(x, y)$ em (b). Neste exemplo, a imagem monocromática $f(x, y)$ é de 16 bpp (intervalo de níveis de cinza de $[0, 65535]$) e o valor de limiar (T) adotado de 30000. A região de fundo fica em preto e a região de interesse segmentada fica em branco na imagem limiarizada $g(x, y)$.

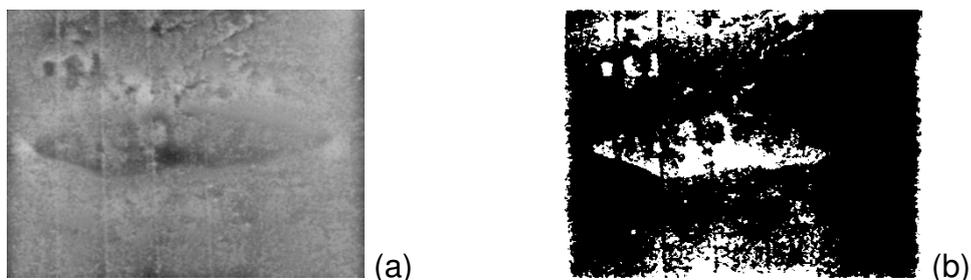


Figura 27 - Limiarização de imagem. (a) Imagem original (b) Imagem (a) limiarizada com limiar $T=30000$.

2.3.4 Filtros espaciais de suavização

O termo filtro é empregado do processamento no domínio da frequência que se refere a aceitar (passar) ou rejeitar certos componentes de frequência (GONZALEZ; WOODS, 2010). Filtros espaciais atuam diretamente na matriz de pixels de uma imagem $f(x, y)$, gerando a imagem $g(x, y)$. O componente mais importante utilizado na filtragem linear espacial é o filtro espacial $w(x, y)$ conhecido também como: máscara, *kernel*, *template* e janela.

De acordo com Gonzalez e Woods (2010), a filtragem espacial é definida pela equação (7), onde o tamanho da imagem $f(x, y)$ é $M \times N$ e o tamanho do filtro espacial $w(x, y)$ é $m \times n$; com $m = 2a + 1$ e $n = 2b + 1$, sendo a e b números inteiros positivos, de modo a gerar, normalmente, valores ímpares para m e n . Os valores de x e y variam de forma que a cada pixel em que a máscara (*kernel*, *template* ou janela) $w(x, y)$ percorre todos os pixels na imagem $f(x, y)$. Os filtros da média e mediana são especificados, respectivamente, nas seções 2.2.4.1 e 2.2.4.2.

$$g(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x + s, y + t) \quad (7)$$

2.3.4.1 Filtro da média

O filtro da média, também denominado de filtro passa-baixa é utilizado para borramento e redução de ruído (GONZALEZ; WOODS, 2010). A filtragem da média emprega um filtro de média ponderada $w(x, y)$ com dimensões $m \times n$ e é aplicada a uma imagem $f(x, y)$ de ordem $M \times N$, gerando a imagem $g(x, y)$ também de ordem $M \times N$ suavizada. A filtragem da média é definida na equação (8) baseando-se na equação (7), onde $m = 2a + 1$ e $n = 2b + 1$, sendo a e b números inteiros positivos, de modo a gerar, normalmente, valores ímpares para m e n . As matrizes (9) e (10) exemplificam duas máscaras (*kernels*, *templates* ou janelas) 3×3 (de média) para a suavização. O quociente da fração que multiplica a matriz que

compõe o filtro da média ponderada $w(x, y)$ é igual à soma dos coeficientes da matriz (GONZALEZ; WOODS, 2010).

$$g(x, y) = \frac{\sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x + s, y + t)}{\sum_{s=-a}^a \sum_{t=-b}^b w(s, t)} \quad (8)$$

$$\frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (9)$$

$$\frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \quad (10)$$

2.3.4.2 Filtro da mediana

O filtro da mediana é um filtro de estatística de ordem (não linear) cuja resposta se baseia na ordenação (classificação) dos pixels contidos na área da imagem coberta pela máscara (*kernel*, *template* ou janela), substituindo o valor do pixel central pelo valor determinado pelo resultado da classificação (GONZALEZ; WOODS, 2010). Os filtros da mediana são muito utilizados para a redução de ruídos, com borramento consideravelmente menor do que filtros lineares (e.g., filtro da média) de tamanho similar (GONZALEZ; WOODS, 2010).

2.3.5 Filtros espaciais de aguçamento

De acordo com Gonzalez e Woods (2010), o principal objetivo do aguçamento é salientar transições de intensidade para o aumento da nitidez de uma imagem. Os filtros espaciais de aguçamento por máscara de nitidez e filtro de alto-esforço são especificados na seção 2.3.5.1.

2.3.5.1 Máscara de nitidez e filtragem *High-boost*

A máscara de nitidez (*unsharpening mask*) tem como objetivo aumentar a nitidez das imagens (aguçamento) através da subtração de uma versão não nítida (suavizada) de uma imagem pela imagem original (GONZALEZ; WOODS, 2010). Esse procedimento consiste nos seguintes passos:

1. Suavizar a imagem original $f(x, y)$ através de um filtro da média, por exemplo, resultando na imagem suavizada $f_s(x, y)$.
2. Subtrair a imagem original $f(x, y)$ pela imagem suavizada $f_s(x, y)$, resultando na máscara $g_{máscara}(x, y)$, equação (11);
3. Adicionar a máscara $g_{máscara}(x, y)$ ponderada por um peso k à imagem original $f(x, y)$, gerando a imagem nítida $g(x, y)$ (GONZALEZ; WOODS, 2010). Tal passo é definido na equação (12), onde o valor do peso k deve ser maior ou igual à zero ($k \geq 0$).
 - a. Se $0 \leq k \leq 1$, então o procedimento é denominado máscara de nitidez.
 - b. Se $k > 1$, então o processo é denominado filtragem *High-boost*.

$$g_{máscara}(x, y) = f(x, y) - f_s(x, y) \quad (11)$$

$$g(x, y) = f(x, y) + k * g_{máscara}(x, y) \quad (12)$$

2.3.6 Processamento morfológico de imagens binárias

O processamento morfológico de imagens opera sobre as formas de objetos contidos nas imagens. De acordo com Gonzalez e Woods (2010), os conjuntos de morfologia matemática representam os objetos encontrados em uma imagem, e.g., o conjunto de todos os pixels brancos contidos em uma imagem binária (i.e., imagem em que os pixels só podem assumir valores 0 ou 1) é considerado uma descrição morfológica completa da imagem. Os conjuntos de todos os pixels das imagens binárias são descritos em um espaço com duas dimensões de números inteiros

positivos Z^2 e imagens digitais em níveis de cinza podem ser representadas como conjuntos cujos componentes estão em Z^3 (GONZALEZ; WOODS, 2010).

Há dois conceitos fundamentais de morfologia: reflexão e translação. A reflexão de um conjunto B é indicada por B_r e definida na equação (13). Se B é o conjunto de pontos bidimensionais (pixels) que representa um objeto em uma imagem, então B_r é a troca dos pontos (x, y) de B que foram substituídos por $(-x, -y)$ (GONZALEZ; WOODS, 2010). A translação de um conjunto B no ponto $z = (z_1, z_2)$ é indicada por $(B)_z$ e definida na equação (14). Se B é o conjunto de pontos bidimensionais que representam um objeto em uma imagem, então $(B)_z$ é a troca dos pontos (x, y) de B por $(x + z_1, y + z_2)$ (GONZALEZ; WOODS, 2010).

$$B_r = \{w | w = -b, \text{ para } b \in B\} \quad (13)$$

$$(B)_z = \{c | c = b + z, \text{ para } b \in B\} \quad (14)$$

A reflexão e a translação são amplamente empregadas para formular operações de morfologia matemática baseadas nos elementos estruturantes (EEs) que são pequenos conjuntos ou subimagens usadas para examinar uma imagem buscando propriedades de interesse (GONZALEZ; WOODS, 2010). Os EEs são representados com arranjos matriciais retangulares ao se trabalhar com imagens digitais, a Figura 28 apresenta alguns tipos de EE, onde cada pixel em cinza representa um componente do EE e o ponto simboliza a origem.

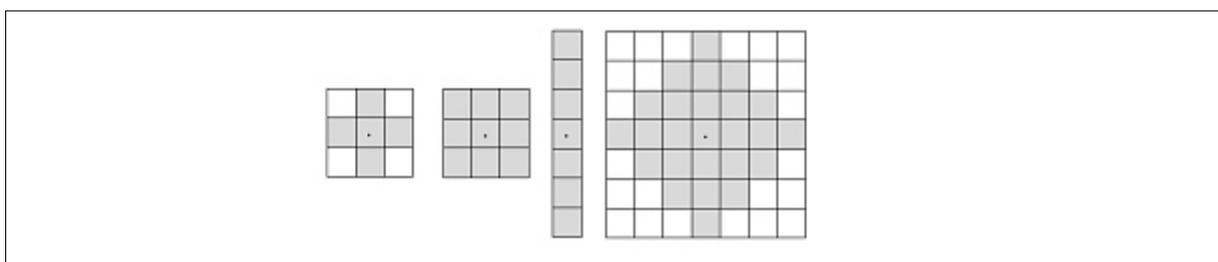


Figura 28 - Exemplos de elementos estruturantes (EEs) no formato matricial.

Fonte: Adaptado de Gonzalez e Woods (2010, p. 416).

2.3.6.1 Erosão e dilatação

A erosão opera sobre os objetos encontrados em uma imagem através de um elemento estruturante com o objetivo de reduzir o tamanho de objetos se o elemento estruturante tiver o mesmo nível de cinza dos objetos. A erosão pode ser definida pela equação (15), onde A e B são conjuntos de Z^2 e $A \ominus B$ (a notação $A \ominus B$ representa a erosão de A pelo elemento estruturante B) é o conjunto de todos os pontos z de forma que B , transladado por z , está contido em A ; (A^c é complemento de A) (GONZALEZ; WOODS, 2010). A Figura 29 ilustra um exemplo de erosão de A de tamanho $d \times d$ pelo elemento estruturante B de tamanho $d/4 \times d/4$, gerando $A \ominus B$ com dimensão $3d/4 \times 3d/4$ pela redução de $d/8$ no contorno de A .

$$A \ominus B = \{z | (B)_z \subseteq A\} = \{z | (B)_z \cap A^c = \emptyset\} \quad (15)$$

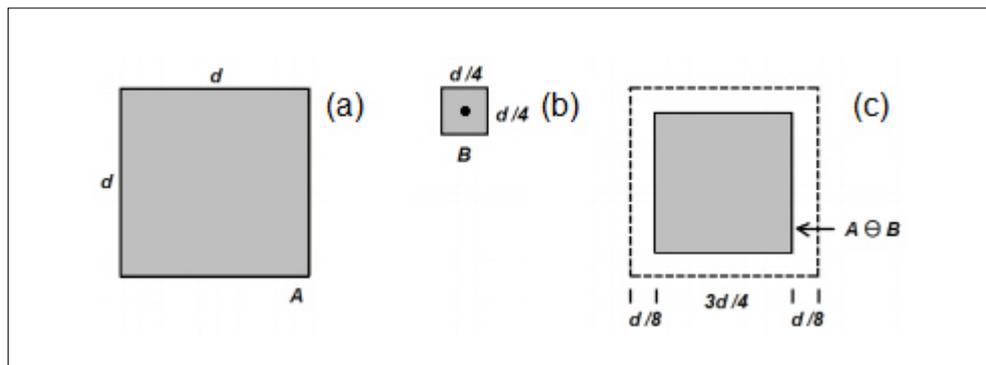


Figura 29 - Exemplo de erosão.

Fonte: Adaptado de Gonzalez e Woods (2010, p. 418).

A dilatação é aplicada sobre os objetos encontrados em uma imagem através de um elemento estruturante, aumentando o tamanho desses objetos se o elemento estruturante tiver o mesmo nível de cinza dos objetos. A dilatação pode ser definida pela equação (16), onde A e B são conjuntos de Z^2 e $A \oplus B$ (a notação $A \oplus B$ representa a dilatação de A pelo elemento estruturante B) é o conjunto de todos os deslocamentos, z , de forma que B_r (B refletido em torno da sua origem) e A se sobreponham pelo menos por um elemento; (A^c é complemento de A) (GONZALEZ; WOODS, 2010). A Figura 29 ilustra um exemplo de dilatação de A de tamanho $d \times d$

pelos elementos estruturantes B de tamanho $d/4 \times d/4$, gerando $A \oplus B$ com dimensão $10d/8 \times 10d/8$ pelo aumento de $d/8$ no contorno de A .

$$A \oplus B = \{z | (B_r)_z \cap A \neq \emptyset\} = \{z | [(B_r)_z \cap A] \subseteq A\} \quad (16)$$

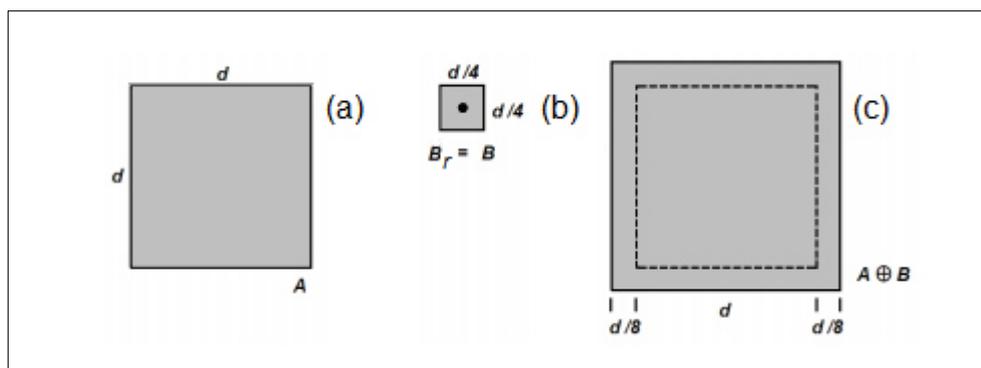


Figura 30 - Exemplo de dilatação.

Fonte: Adaptado de Gonzalez e Woods (2010, p. 419).

2.3.6.2 Abertura e fechamento

Segundo Gonzalez e Woods (2010), a abertura geralmente suaviza o contorno de um objeto, rompe istmos e elimina as saliências finais. O fechamento, por sua vez, atua também na suavização de objetos, geralmente, funde descontinuidades estreitas e alonga os golfos finos, elimina pequenos buracos e preenche as lacunas em um contorno. As operações de erosão e dilatação são componentes primitivos das operações de abertura e fechamento apresentadas, respectivamente, nas equações (17) e (18). A abertura de A por B consiste na erosão de A por B , seguida de uma dilatação do resultado por B . O fechamento de A por B consiste na dilatação de A por B , seguida de uma erosão do resultado por B . A Figura 32 ilustra a aplicação de abertura e fechamento na imagem original, processo de erosão, abertura, dilatação e fechamento.

$$A \circ B = (A \ominus B) \oplus B \quad (17)$$

$$A \bullet B = (A \oplus B) \ominus B \quad (18)$$

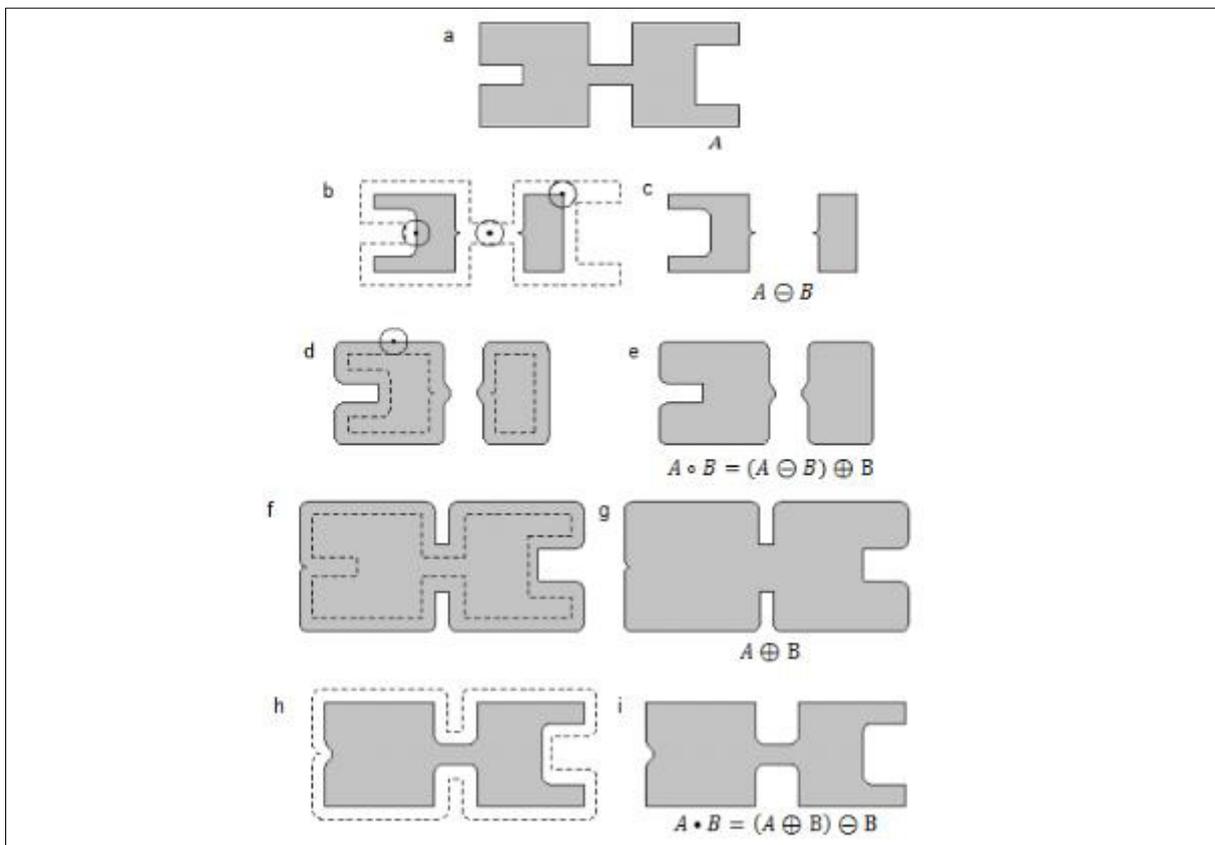


Figura 31 - Abertura e fechamento morfológicos. O elemento estruturante (EE) é o pequeno círculo em várias posições.

Fonte: Adaptado de Gonzalez e Woods (2010, p. 421).

2.3.7 Morfologia matemática em níveis de cinza

Nesta seção, são descritos os métodos de erosão, dilatação, abertura morfológica, fechamento morfológico, bem como, filtros *Top-Hat* e *Bottom-Hat*, atuando sobre imagens em níveis de cinza. As imagens em escala de cinza tratadas são tratadas como funções digitais na forma $f(x, y)$ e o elemento estruturante como $b(x, y)$. De acordo com Gonzalez e Woods (2010), se Z denota o conjunto dos inteiros reais, então as coordenadas (x, y) são inteiros do produto cartesiano Z^2 e f e b são funções que atribuem um valor de intensidade para cada par distinto de coordenadas (x, y) e se os níveis de intensidade também forem inteiros, então Z deve ser substituído por R (conjunto dos números reais).

2.3.7.1 Erosão e dilatação

A erosão de f por b em qualquer posição de f é obtida pelo mínimo da imagem na região coincidente com b quando b está em (x, y) como apresentado na equação (19) e a dilatação de f por b em qualquer posição de f é obtida pelo máximo da imagem na região coincidente com b quando b está em (x, y) como apresentado na equação (20) (GONZALEZ; WOODS, 2010).

$$[f \ominus b](x, y) = \min_{(s,t) \in b} \{f(x + s, y + t)\} \quad (19)$$

$$[f \oplus b](x, y) = \max_{(s,t) \in b} \{f(x + s, y + t)\} \quad (20)$$

2.3.7.2 Abertura e fechamento

As operações de abertura e fechamento morfológico em níveis de cinza seguem a mesma definição de seus equivalentes binários, considerando a image f e o elemento estruturante b (GONZALEZ; WOODS, 2010). A abertura consiste na erosão de f por b seguida da dilatação deste resultado por b . O fechamento consiste na dilatação de f por b seguida da erosão deste resultado por b . As equações (21) e (22) definem, respectivamente, as operações de abertura e fechamento para níveis de cinza.

$$f \circ b = (f \ominus b) \oplus b \quad (21)$$

$$f \bullet b = (f \oplus b) \ominus b \quad (22)$$

2.3.7.3 Transformadas *Top-Hat* e *Bottom-Hat*

As transformadas *Top-Hat* e *Bottom-Hat* são a combinação dos métodos de abertura e fechamento com subtração de imagens usadas para a extração de objetos da imagem em regiões de luminosidade não uniforme (GONZALEZ; WOODS, 2010). A transformada *Top-Hat* em níveis de cinza sobre a imagem f com o elemento estruturante b é definida na equação (23). A transformada *Bottom-Hat* em níveis de cinza sobre a imagem f com o elemento estruturante b é definida na equação (24).

$$T_{hat}(f, b) = f - (f \circ b) \quad (23)$$

$$B_{hat}(f, b) = (f \bullet b) - f \quad (24)$$

2.3.8 Reconstrução morfológica

A reconstrução morfológica é uma operação que envolve duas imagens e um elemento estruturante. Uma imagem é o marcador (F) que contém as posições de pixels para a transformação, a outra imagem é a máscara (G) que delimita a transformação e o elemento estruturante (B) é usado para definir a conectividade, por exemplo, por um arranjo matricial 3x3 de 1s com origem no centro (GONZALEZ; WOODS, 2010).

2.3.8.1 Erosão e dilatação geodésica

Os conceitos de erosão e dilatação geodésica são empregados nos métodos de reconstrução morfológica (GONZALEZ; WOODS, 2010). Considerando que $F \subseteq G$. A erosão geodésica de tamanho 1 do marcador (F) em relação à máscara (G) é definida na equação (25), onde \cup indica a operação lógica OU. Enquanto que a erosão geodésica de tamanho n de F em relação a G é definida na equação (26), onde $E_G^{(0)}(F) = F$. A operação de união de conjuntos na equação (25) realizada a

cada passo iterativamente, garantindo que a erosão geodésica de uma imagem continue a ser maior ou igual a sua imagem de máscara (GONZALEZ; WOODS, 2010). A Figura 32 ilustra o exemplo da aplicação de uma erosão geodésica.

$$E_G^{(1)}(F) = (F \ominus B) \cup B \quad (25)$$

$$E_G^{(n)}(F) = E_G^{(1)}[E_G^{(n-1)}(F)] \quad (26)$$

A dilatação geodésica de tamanho 1 do marcador (F) em relação à máscara (G) é definida na equação (27), onde \cap indica a operação lógica E. Enquanto que a dilatação geodésica de tamanho n de F em relação a G é definida na equação (28), onde $D_G^{(0)}(F) = F$. O operador de intersecção garante que a máscara G limitará o crescimento (dilatação) do marcador F (GONZALEZ; WOODS, 2010). A Figura 33 ilustra a aplicação de uma dilatação geodésica.

$$D_G^{(1)}(F) = (F \oplus B) \cap G \quad (27)$$

$$D_G^{(n)}(F) = D_G^{(1)}[D_G^{(n-1)}(F)] \quad (28)$$

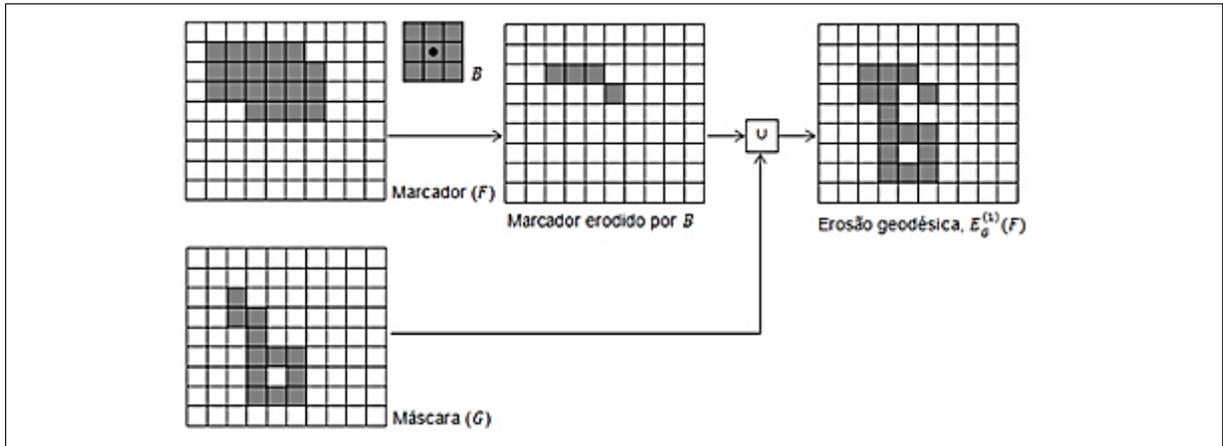


Figura 32 - Ilustração de erosão geodésica.

Fonte: Adaptado de Gonzalez e Woods (2010, p. 434).

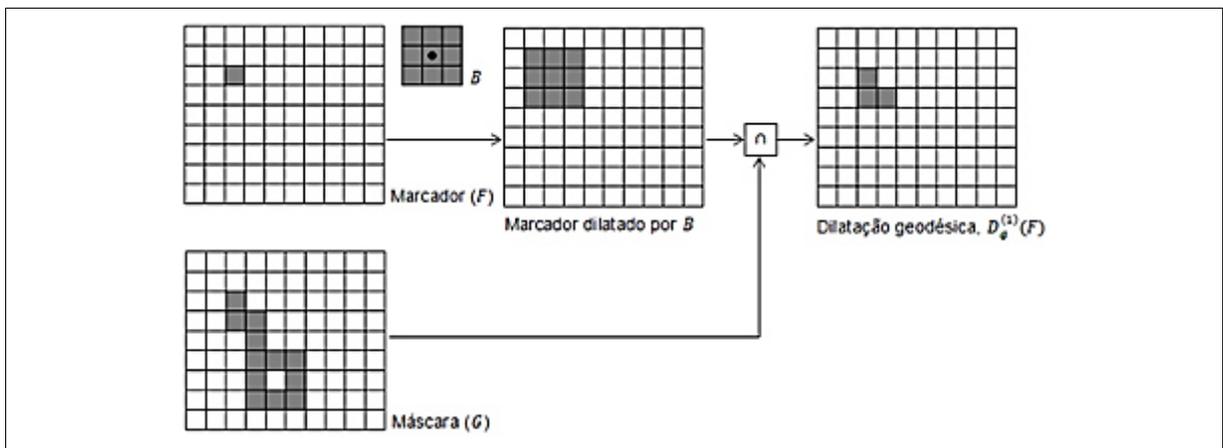


Figura 33 - Ilustração de dilatação geodésica.

Fonte: Adaptado de Gonzalez e Woods (2010, p. 433).

2.3.8.2 Reconstrução morfológica por dilatação e por erosão

A reconstrução morfológica por dilatação de uma imagem de máscara G a partir da imagem do marcador F , denominado $R_G^D(F)$, é definida como a dilatação geodésica de F em relação à G , iteragida até que a estabilidade seja alcançada como definido na equação (29) com k tal que $D_G^{(k)}(F) = D_G^{(k+1)}(F)$. Da mesma forma, a reconstrução morfológica por erosão de uma imagem de máscara G de uma imagem com marcador F , chamada de $R_G^E(F)$, é definida como a erosão geodésica de F em relação a G , iteragida até atingir a estabilidade como definida na equação (30) com k tal que $E_G^{(k)}(F) = E_G^{(k+1)}(F)$ (GONZALEZ; WOODS, 2010).

$$R_G^D(F) = D_G^{(k)}(F) \quad (29)$$

$$R_G^E(F) = E_G^{(k)}(F) \quad (30)$$

Na reconstrução morfológica por dilatação e por erosão podem ser citadas algumas aplicações práticas: abertura por reconstrução, preenchimento de buracos e limpeza de bordas (GONZALEZ; WOODS, 2010).

A abertura por reconstrução (Figura 34) permite a restauração da forma exata dos objetos após a aplicação de uma erosão, diferentemente de um processo de abertura morfológica que modifica a forma dos objetos restantes. Tal operação é definida para um tamanho n de uma imagem F como a reconstrução por dilatação de F a partir da erosão do tamanho n de F , apresentada na equação (31), sendo que $(F \ominus nB)$ indica n erosões de F por B (GONZALEZ; WOODS, 2010). Esta operação é definida da mesma forma tanto para imagens binárias, quanto para imagens em nível de cinza.

$$O_R^{(n)}(F) = R_F^D[F \ominus nB] \quad (31)$$

O preenchimento de buracos é definido considerando uma imagem binária $I(x, y)$ e uma imagem marcador F formada com 0 em todos os pixels, exceto nos pixels localizados nas bordas da imagem, onde F vale $1 - I$, como definido na equação (32) (GONZALEZ; WOODS, 2010). Assim, H é uma imagem binária igual a I , conforme definida na equação (33), com a diferença de possuir todos os buracos preenchidos, onde c denota o negativo (ou complemento) da imagem (GONZALEZ; WOODS, 2010). A Figura 35 ilustra a aplicação do procedimento de preenchimento de buracos.

$$F(x,y) = \begin{cases} 1 - I(x,y), & \text{se } (x,y) \text{ estiver sobre a borda } I \\ 0, & \text{caso contrário} \end{cases} \quad (32)$$

$$H = [R_{I^c}^D(F)]^C \quad (33)$$

A limpeza de bordas é uma operação que visa remover objetos conectados as bordas da imagem. A imagem original é utilizada como máscara e a imagem definida na equação (34) como marcador para a extração de objetos presentes na borda da imagem $R_I^D(F)$ para obter uma imagem X sem objetos tocando a borda definida na equação (35) (GONZALEZ; WOODS, 2010). A Figura 36 ilustra a aplicação do procedimento de limpeza de bordas.

$$F(x,y) = \begin{cases} I(x,y), & \text{se } (x,y) \text{ estiver sobre a borda } I \\ 0, & \text{caso contrário} \end{cases} \quad (34)$$

$$X = I - R_I^D(F) \quad (35)$$

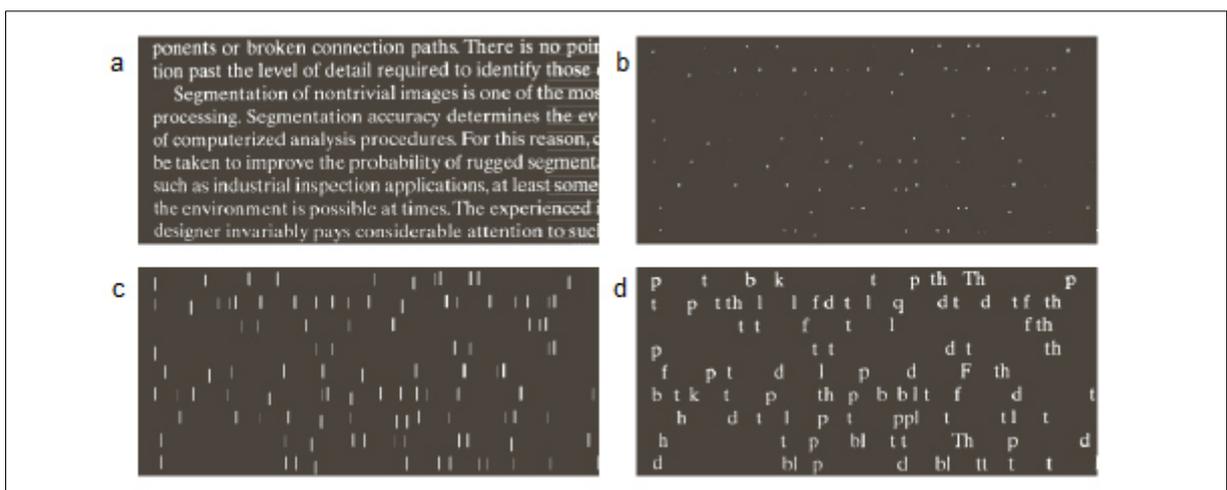


Figura 34 - Abertura por reconstrução. (a) Imagem de texto de tamanho 918x2018 pixels. Altura média aproximada dos caracteres é de 50 pixels. (b) Erosão de (a) por um EE 51x1 pixels. (c) Abertura de (a) com o mesmo EE. (d) resultado de abertura por reconstrução.

Fonte: Adaptado de Gonzalez e Woods (2010, p. 435).

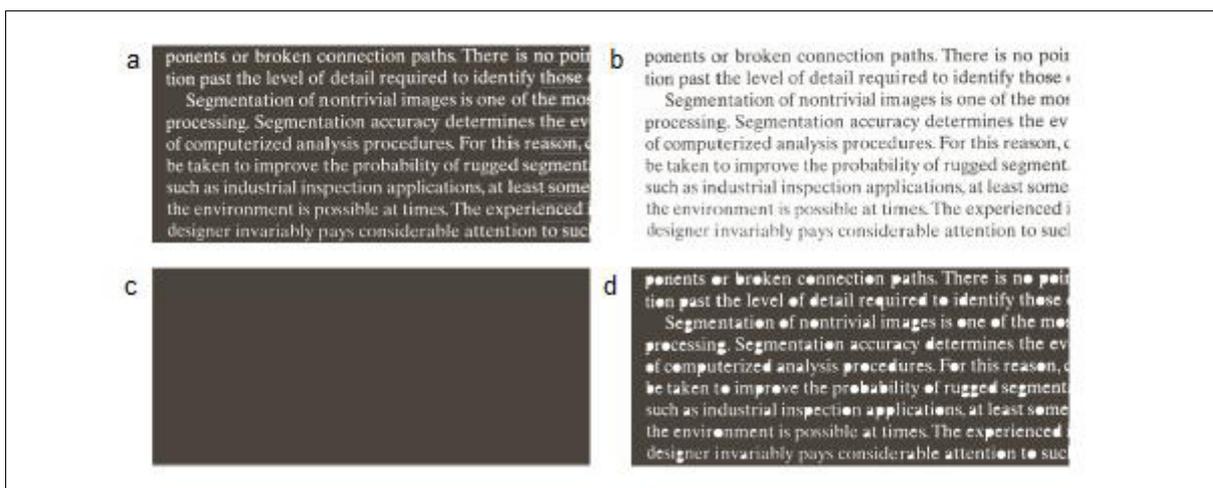


Figura 35 - Preenchimento de buracos. (a) Imagem de texto de tamanho 918x2018 pixels. (b) Complemento de (a) para o uso como uma imagem de máscara. (c) Imagem do marcador. (d) Resultado do preenchimento de buracos.

Fonte: Adaptado de Gonzalez e Woods (2010, p. 436).

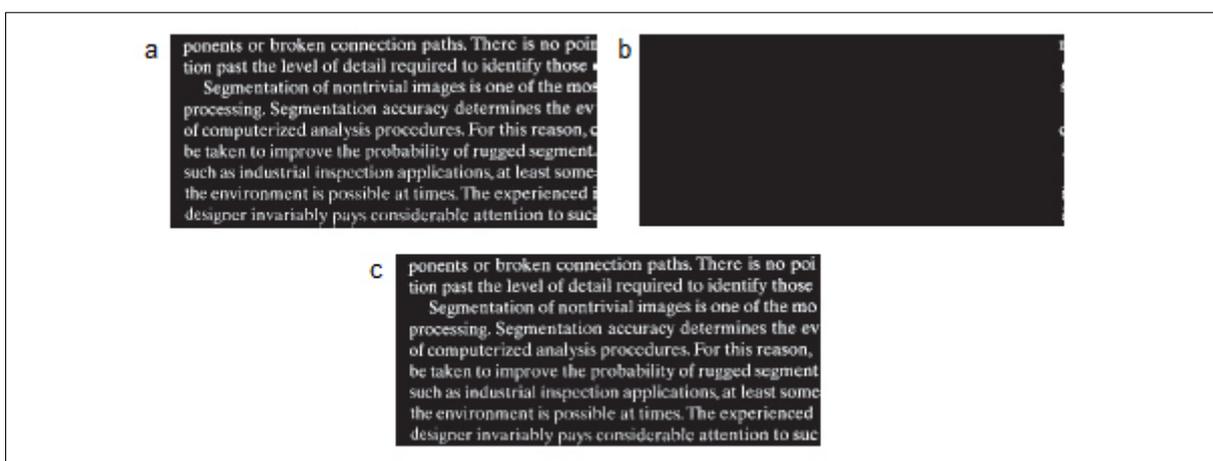


Figura 36 - Limpeza de bordas. (a) Imagem de texto de tamanho 918x2018 pixels. (b) Imagem do marcador. (c) Imagem sem objetos tocando a borda.

Fonte: Adaptado de Gonzalez e Woods (2010, p. 435-437).

2.3.9 Etiquetagem

Imagens em tons de cinza podem ser limiarizadas, resultando em imagens binárias nas quais os pixels conectados podem ser etiquetados para separar as regiões de interesse do fundo da imagem. A etiquetagem resulta em uma imagem simbólica na qual cada região possui uma etiqueta (SHAPIRO, 1996).

Um conceito importante para a etiquetagem é a conectividade que permite verificar se um pixel faz parte de um componente conexo em relação aos pixels da vizinhança. As análises de conectividade mais comuns são a quatro (C_4) e a oito (C_8) apresentadas, respectivamente, nas matrizes (36) e (37). Os pixels de vizinhança com o pixel central em análise c possuem valor 1 e 0. Se o valor do pixel da vizinhança com o pixel em análise c for 1, então c é conexo com o pixel vizinho, caso contrário c não é conexo.

$$C_4 = \begin{bmatrix} 0 & 1 & 0 \\ 1 & c & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad (36)$$

$$C_8 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & c & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (37)$$

A etiquetagem clássica emprega duas etapas (SHAPIRO, 1996). A primeira etapa movimenta a máscara de conectividade (C) do canto superior esquerdo até o canto inferior direito da imagem binária $b(x, y)$, etiquetando cada posição de pixel com valor 1 em $b(x, y)$ na imagem simbólica $g(x, y)$. Se o pixel em análise c possuir conectividade com vizinhos já etiquetados c recebe uma etiqueta dos vizinhos, caso esses vizinhos tenham etiquetas diferentes, essas etiquetas são armazenadas em uma tabela de equivalência de etiquetas. Se o pixel em análise c não ativar conectividade com nenhum pixel da vizinhança ou com pixels ainda não etiquetados, então c recebe uma etiqueta única nova. A segunda etapa faz a substituição das etiquetas com base na tabela de equivalência de etiquetas, assim, cada região conexa da imagem fica com uma etiqueta única apenas ao final do processamento.

A matriz (38) ilustra uma possível composição de uma imagem binária $b(x, y)$ de ordem 6×6 . Na matriz (39), a imagem simbólica $g(x, y)_{C_4}$ representa o resultado de etiquetagem de $b(x, y)$ com C_4 , obtendo três regiões etiquetadas. Na matriz (40),

a imagem simbólica $g(x,y)_{C_8}$ representa o resultado de etiquetagem de $b(x,y)$ com C_8 , obtendo duas regiões etiquetadas.

$$b(x,y) = \begin{bmatrix} 0 & 0 & 0 & 1 & 1 & 1 \\ 0 & 1 & 1 & 0 & 1 & 0 \\ 0 & 1 & 1 & 0 & 1 & 0 \\ 0 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 \end{bmatrix} \quad (38)$$

$$g(x,y)_{C_4} = \begin{bmatrix} 0 & 0 & 0 & 1 & 1 & 1 \\ 0 & 2 & 2 & 0 & 1 & 0 \\ 0 & 2 & 2 & 0 & 1 & 0 \\ 0 & 2 & 2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 3 & 3 \end{bmatrix} \quad (39)$$

$$g(x,y)_{C_8} = \begin{bmatrix} 0 & 0 & 0 & 1 & 1 & 1 \\ 0 & 1 & 1 & 0 & 1 & 0 \\ 0 & 1 & 1 & 0 & 1 & 0 \\ 0 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 2 & 2 \end{bmatrix} \quad (40)$$

2.3.10 Momentos invariantes de Hu

Os momentos invariantes de Hu (1962) são sete atributos de uma imagem descritos de forma matemática que permanecem praticamente inalterados quando sofrem rotação, translação e variação de escala, constituindo-se atributos interessantes na identificação de objetos segmentados sobre imagens. É necessário definir os conceitos de momentos regulares, centrais e normalizados para prosseguir com a definição dos sete momentos invariantes de Hu (1962). Na equação (41), m_{pq} é o momento de ordem $(p + q)$ da função de intensidade $f(x,y)$ em que nx e ny representam respectivamente altura e largura da imagem digital (GONZALEZ; WOODS, 2010).

$$m_{pq} = \sum_1^{nx} \sum_1^{ny} x^p y^q f(x, y) \quad (41)$$

Os momentos regulares são interessantes na identificação de diferentes formas, e.g., momentos regulares de ordem 0 e 1 são usados para o cálculo do baricentro (i.e., centro de massa do objeto) a equação (42) descreve o valor do ponto na abcissa e a equação (43) descreve o valor do ponto no eixo.

$$x_c = \frac{m_{10}}{m_{00}} \quad (42)$$

$$y_c = \frac{m_{01}}{m_{00}} \quad (43)$$

Os momentos centrais (u_{pq}) são calculados através das informações obtidas dos baricentros e definidos pela equação (44). Os momentos centrais normalizados (n_{pq}) definidos pela equação (45). Os sete momentos invariantes à escala, rotação e translação de Hu (1962) ($\phi_1, \phi_2, \phi_3, \phi_4, \phi_5, \phi_6$ e ϕ_7) são definidos, respectivamente, pelas equações (46), (47), (48), (49), (50), (51) e (52) (GONZALEZ; WOODS, 2010).

$$u_{pq} = \sum_1^{nx} \sum_1^{ny} (x - x_c)^p (y - y_c)^q f(x, y) \quad (44)$$

$$n_{pq} = \frac{u_{pq}}{m_{00}^{\frac{(p+q)}{2}+1}} \quad (45)$$

$$\phi_1 = n_{20} + n_{02} \quad (46)$$

$$\phi_2 = (n_{20} - n_{02})^2 + 4n_{11}^2 \quad (47)$$

$$\phi_3 = (n_{30} - 3n_{12})^2 + (3n_{21} - n_{03})^2 \quad (48)$$

$$\phi_4 = (n_{30} - n_{12})^2 - (n_{21} - n_{03})^2 \quad (49)$$

$$\begin{aligned} \phi_5 = & (n_{30} - 3n_{12})(n_{30} + n_{12})[(n_{30} + n_{12})^2 - 3(n_{21} + n_{03})^2] \\ & + (3n_{21} - n_{03})(n_{21} + n_{03})[3(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2] \end{aligned} \quad (50)$$

$$\phi_6 = (n_{20} - n_{02})[(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2] + 4n_{11}(n_{30} + n_{12})(n_{21} + n_{03}) \quad (51)$$

$$\begin{aligned} \phi_7 = & (3n_{21} - n_{03})(n_{30} + n_{12})[(n_{30} + n_{12})^2 - 3(n_{21} + n_{03})^2] \\ & + (n_{30} - 3n_{12})(n_{21} + n_{03})[3(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2] \end{aligned} \quad (52)$$

A Figura 37 ilustra uma imagem original, transladada, redimensionada em 0,5, espelhada, rotacionada em 45° e rotacionada em 90°. Os resultados dos cálculos dos sete momentos invariantes (ϕ_1 , ϕ_2 , ϕ_3 , ϕ_4 , ϕ_5 , ϕ_6 e ϕ_7) das imagens apresentadas na Figura 37 são apresentados na Tabela 1, permitindo observar que os valores dos momentos permanecem praticamente inalterados.

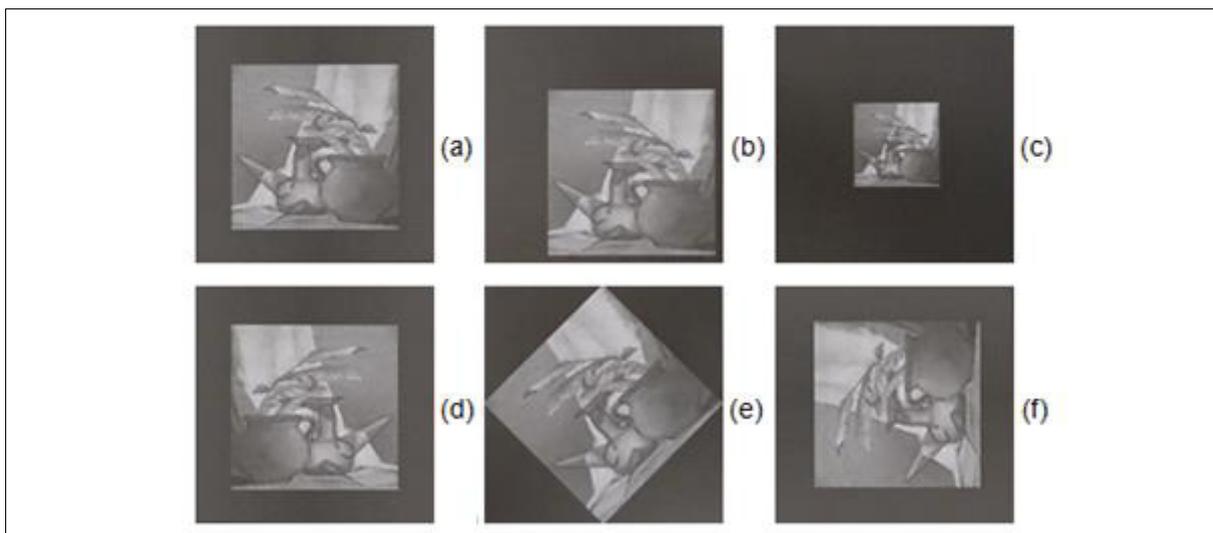


Figura 37 - Sete momentos invariantes. (a) Imagem original (b) transladada (c) redimensionada por 0,5 (d) espelhada (e) rotacionada em 45° (f) rotacionada em 90°.

Fonte: Adaptado de Gonzalez e Woods (2010, p. 554).

Tabela 1 - Cálculo dos sete momentos invariantes das imagens da Figura 37.

Momento invariante	Imagem original	Transladada	Redimensio- nada por 0.5	Espelhada	Rotacionada em 45°	Rotacionada em 90°
ϕ_1	2,8662	2,8664	2,8662	2,8662	2,8661	2,8662
ϕ_2	7,1265	7,1265	7,1257	7,1265	7,1266	7,1265
ϕ_3	10,4109	10,4109	10,4047	10,4109	10,4115	10,4109
ϕ_4	10,3742	10,3742	10,3719	10,3742	10,3742	10,3742
ϕ_5	21,3674	21,3674	21,3924	21,3674	21,3663	21,3674
ϕ_6	13,9417	13,9417	13,9383	13,9417	13,9417	13,9417
ϕ_7	-20,7809	-20,7809	-20,7724	-20,7809	-20,7813	-20,7809

Fonte: Gonzalez e Woods (2010, p. 555).

2.4 REDES NEURAIS ARTIFICIAIS (RNA)

Rede Neural Artificial (RNA) é um método biologicamente inspirado, pois objetiva mimetizar o processo de comunicação e processamento entre neurônios biológicos, que teve início com o modelo de neurônio artificial publicado no trabalho

de McCulloch e Pitts (1943). RNAs são aplicadas em problemas de aproximação de funções, previsão de séries temporais, classificações e reconhecimento de padrões, tais como: reconhecimento de voz, diagnóstico médico e reconhecimento Óptico de Caracteres (Optical Character Recognition - OCR).

A inspiração biológica para o processo de assimilação do aprendizado vem da forma de conexão entre neurônios biológicos que é feita por regiões denominadas sinapses. As sinapses influenciam com intensidades diferentes na ativação (sinapse excitatória) e na desativação (sinapse inibitória) dos neurônios. De forma análoga, uma RNA é composta por neurônios artificiais interligados e um peso (sináptico) é designado a cada conexão de entrada, influenciando na intensidade de ativação do neurônio artificial. Assim, a capacidade adaptativa do aprendizado de uma RNA se dá através da variação dos pesos da rede (HEBB, 1949).

O modelo de neurônio artificial (nodo) de McCulloch e Pitts (1943) (Figura 38) é formado por m conexões de entrada dotadas de sinais de entrada ($x = [x_1, x_2, \dots, x_m]^T$) e pesos sinápticos ($W = [W_1, W_2, \dots, W_m]^T$); função de processamento das conexões de entrada $v = \sum_{k=1}^m W_k x_k$ e da função de ativação $\varphi(v)$ do tipo degrau (limiar T) que gera uma saída binária y . Se $v \geq T$, então $y = 1$ (nodo excitado). Se $v < T$, então $y = 0$ (nodo inibido).

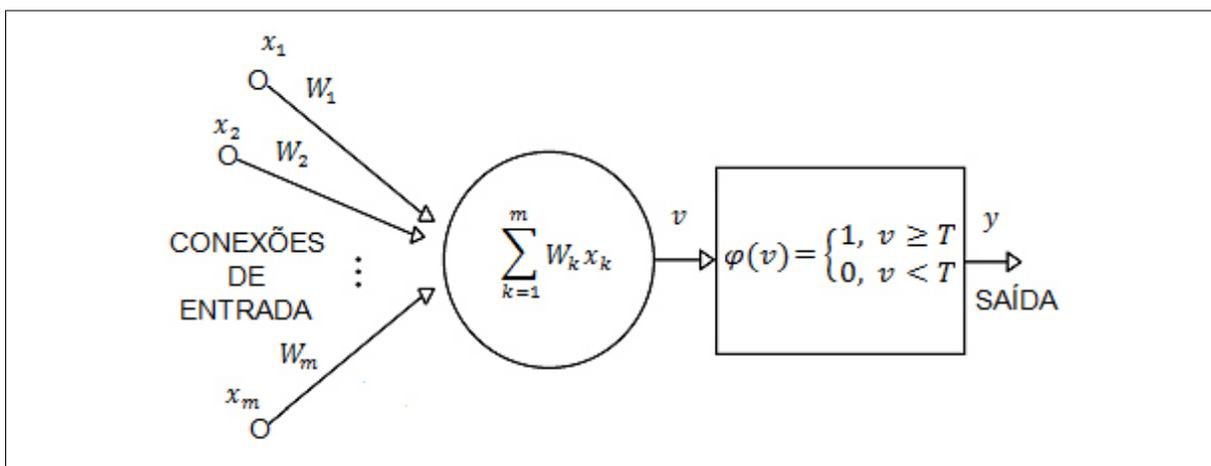


Figura 38 - Modelo de um neurônio artificial de McCulloch e Pitts (1943).

Rosenblatt (1958) propôs o modelo de RNA *Perceptron*, descreveu a tipologia e a estrutura das ligações das RNAs, além de demonstrar que tais redes poderiam ser treinadas para classificar certos tipos de padrões. Widrow e Hoff (1960) apresentaram o modelo *Adaline* (*Adaptive Linear Neurons*) que possui como

diferença relevante em relação aos modelos anteriores o ajuste dos pesos de entrada feito pelo erro calculado da diferença entre a saída da função de entrada e a saída esperada, introduzindo a regra delta.

Contudo, os trabalhos de Minsky e Papert (1969; 1972) demonstraram que as RNAs *Perceptron* estavam restritas a conjuntos linearmente separáveis (i.e., só poderiam tratar de problemas com conjuntos de treinamento separados por um hiperplano simples), o aprendizado não garantia convergência para as RNAs com mais de uma camada. O panorama das redes *Perceptron* de múltiplas camadas (*Multilayer Perceptron*) (MLP), mudou consideravelmente pela introdução do método de treinamento denominado regra generalizada delta para o aprendizado por retropropagação *Backpropagation* (BP), com o trabalho apresentado por Rumelhart et. al (1986). A regra delta generalizada se mostrou eficiente para as redes MLPs, caracterizando as MLPs como um dos principais modelos de RNAs utilizados na atualidade.

2.4.1 Arquitetura das RNAs

A arquitetura das RNAs descreve o tipo de conexão entre os nodos, o número de camadas da rede e o número de nodos em cada camada, definindo a topologia da rede. Os principais tipos de conexão entre os nodos são a conexão direta (*feedforward*) e cíclica (*feedback*). Na conexão direta, as saídas dos nodos da camada atual só podem alimentar os nodos da camada seguinte. Enquanto que na conexão cíclica, as saídas dos nodos da camada atual podem alimentar os nodos da própria camada, da camada seguinte e das camadas anteriores. Algumas das principais classes de RNA que podem ser destacadas são *Perceptron*, *Adaline* e MLP.

A quantidade de camadas e de neurônios em cada camada da rede varia de acordo com a quantidade de saídas e entradas, afetando o grau de refinamento da região de decisão (ou a separabilidade) do espaço de busca do problema tratado e, por conseguinte, o desempenho da rede.

2.4.2 Separabilidade do espaço de busca em redes *feedforward*

A Figura 39 ilustra o impacto da escolha do número de camadas em redes *feedforward* para a separabilidade do espaço de busca. É possível notar que os problemas exemplificados da solução do OU-exclusivo e das classes com regiões interligadas não são linearmente separáveis, portanto, um hiperplano simples não é suficiente para delimitar corretamente o espaço de busca. O primeiro problema possui superfície de decisão corretamente delineada a partir de uma estrutura de rede com duas camadas e o segundo problema a partir de três camadas. Portanto, quanto maior é o número de camadas da rede, maior é o grau de refinamento das formas de superfície de decisão do espaço de busca.

Estrutura da rede	Tipo de região de decisão	Solução ao problema OU-Exclusivo	Classes com regiões interligadas	Formas mais comuns de superfície de decisão
Camada única	Hiperplano simples			
Duas camadas	Regiões convexas abertas ou fechadas			
Três camadas	Arbitrário (a complexidade está limitada pelo número de nós)			

Figura 39 - Tipos de regiões de decisão em redes *feedforward*.

Fonte: Adaptado de Lippmann, 1987 (apud GONZALEZ; WOODS, 2010, p. 592).

2.4.3 *Perceptron* de múltiplas camadas (MLP)

As redes neurais artificiais (RNAs) *Perceptron* de múltiplas camadas (*Multilayer Perceptron*) (MLP) possuem q camadas ocultas (intermediárias) entre as camadas de entrada e saída, onde o valor $q \geq 1$. Neste tipo de rede, o fluxo da informação se move em uma única direção, passando pelos nós de entrada, nós da camada oculta e nós de saída da rede (i.e., não há conexões cíclicas entre os

neurônios). A Figura 40 exemplifica uma rede MLP com duas camadas ocultas ($q = 2$). O ajuste da quantidade de camadas ocultas e de nodos em cada uma delas é uma tarefa, geralmente empírica, que afeta o desempenho das MLPs.

De acordo com Haykin (2008), os nodos nas camadas ocultas desempenham um papel crítico em uma rede MLP, atuando como detectores de características, pois, durante o processo de aprendizado, os nodos da camada oculta aprendem gradualmente as características que caracterizam os dados de treinamento. Dessa forma, criam um espaço de características pela transformação não linear dos dados de entrada da rede em que as características podem ser mais facilmente separáveis do que no espaço de busca das entradas originais da rede, característica que o distingue do *Perceptron* de Rosenblatt (1958).

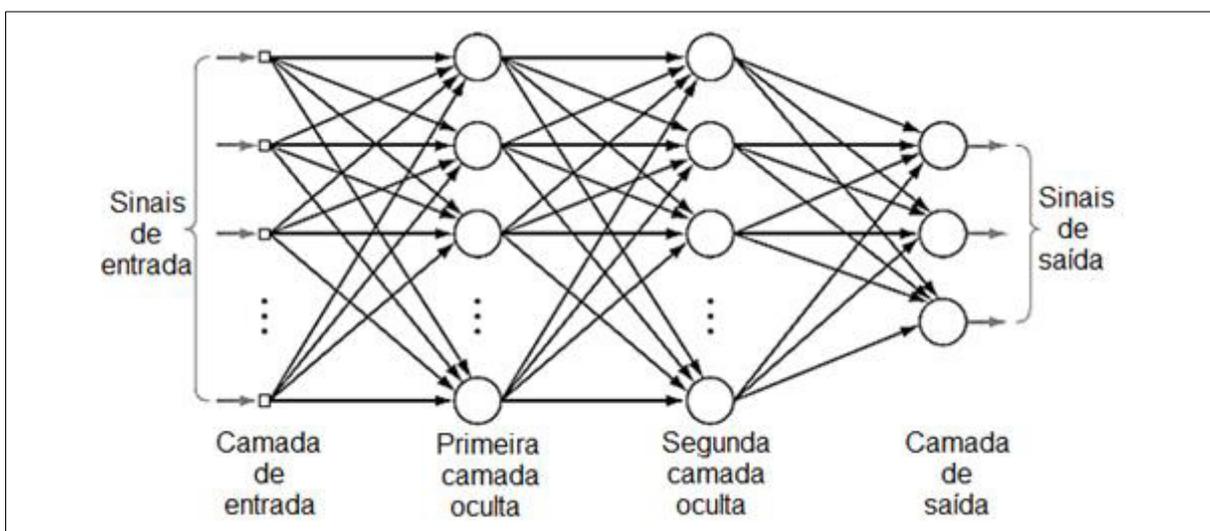


Figura 40 - Exemplo de uma MLP com duas camadas ocultas.

Fonte: Adaptado de Haykin (2008, p. 124).

O neurônio (nodo) de uma MLP, denotado por j , é formado por m conexões de entrada dotadas de sinais de entrada x_i ($x_i = [x_{i_1}, x_{i_2}, \dots, x_{i_m}]^T$) e pesos sinápticos $W_{i,j}$ ($W_{i,j} = [W_{i,j_1}, W_{i,j_2}, \dots, W_{i,j_m}]^T$); função de processamento das conexões de entrada $v_j = \sum_{k=1}^m W_{i,j_k} x_{i_k} + b_j$ com a inclusão do valor denominado *bias* b_j e variados tipos funções de ativação $\varphi(v_j)$ (definidas na seção 2.4.4). O valor *bias* b_j é um parâmetro externo do neurônio j que tem o efeito de aumentar ou diminuir os valores de entrada da rede para a função de ativação (HAYKIN, 2008).

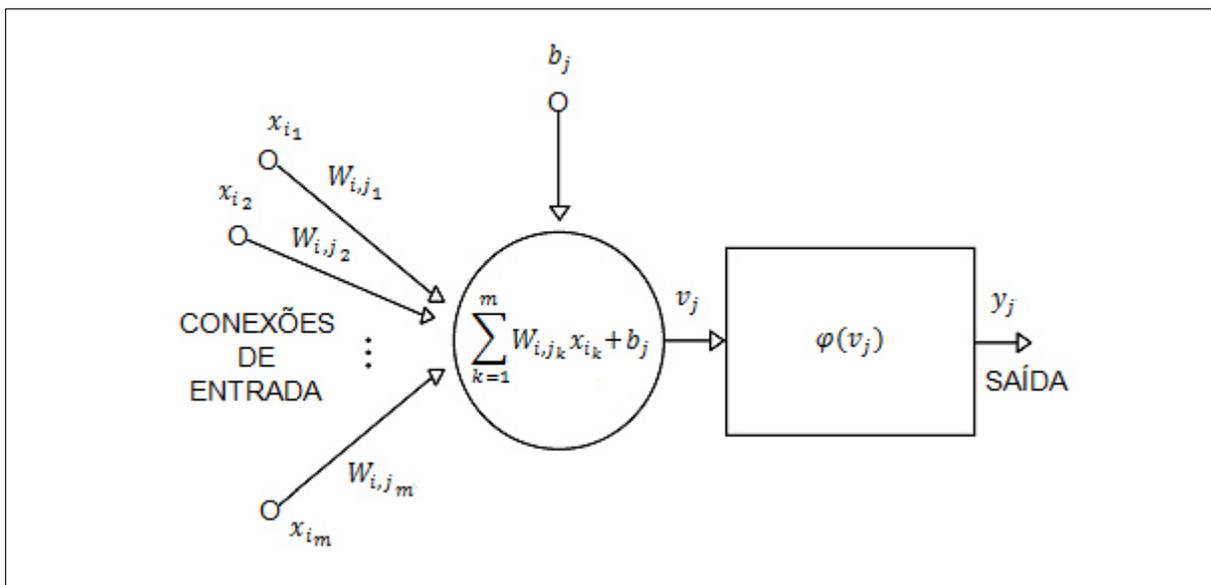


Figura 41 - Modelo de um neurônio de uma MLP.

Fonte: Adaptado de Haykin (2008).

2.4.4 Funções de ativação

As funções de ativação são componentes fundamentais dos neurônios artificiais, sendo que a escolha delas é livre pelo projetista da RNA e apresenta grande influência no desempenho das RNAs. As formas mais comuns de funções de ativação $\varphi(v_j)$ de uma RNAs são degrau (ou limiar), linear, sigmóide logística e tangente hiperbólica (HAYKIN, 2008).

A função de ativação degrau, definida na equação (53), apresenta uma saída binária (0 ou 1), onde parâmetro β determina o ponto de transição (limiar) do neurônio. A Figura 42 ilustra o formato da saída desta função de ativação a partir de um limiar $\beta = 0$.

$$\varphi(v_j)_{degrau} = y_j = \begin{cases} 1, & v_j \geq \beta \\ 0, & v_j < \beta \end{cases} \quad (53)$$

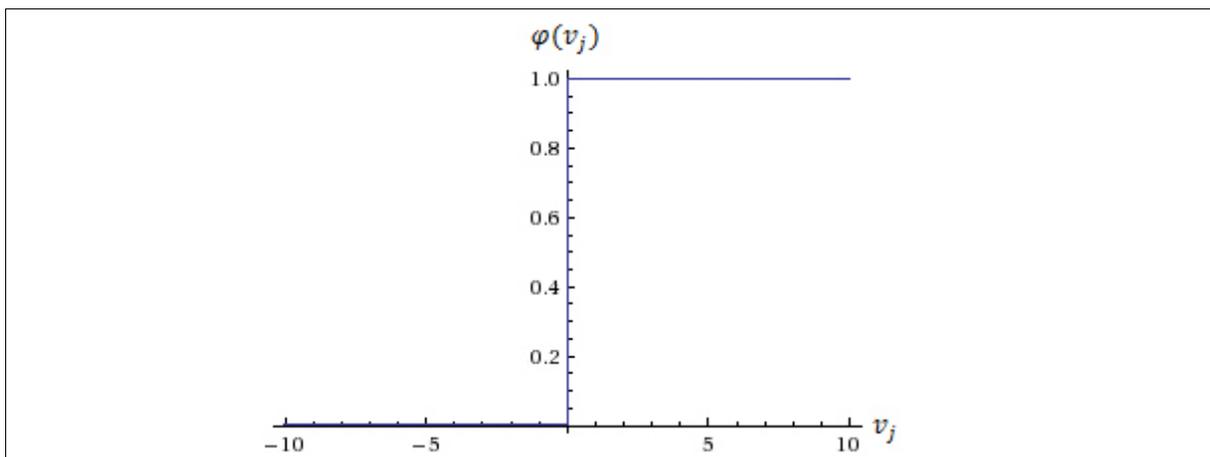


Figura 42 - Gráfico da função de ativação degrau (ou limiar).

A função de ativação linear, definida na equação (54) e ilustrada na Figura 43, é utilizada, por exemplo, no modelo Adaline (WIDROW; HOFF, 1960).

$$\varphi(v_j)_{linear} = y_j = v_j \quad (54)$$

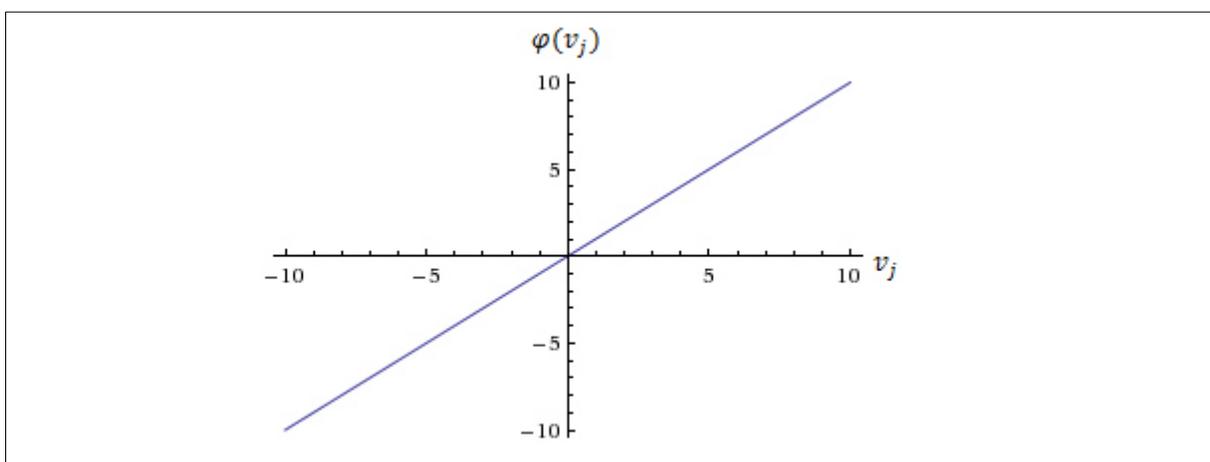


Figura 43 - Gráfico da função de ativação linear.

As funções do tipo sigmóide logística e tangente hiperbólica são utilizadas, por exemplo, por redes neurais treinadas com algoritmos baseados em gradiente descendente que exigem que as funções de ativação sejam deriváveis (HAYKIN, 2008). A função de ativação sigmóide logística, definida na equação (55), apresenta uma saída no intervalo $[0; 1]$ (Figura 44), onde a é um parâmetro positivo ajustável ($a > 0$), normalmente $a = 1$.

$$\varphi(v_j)_{\text{sigmóide logística}} = y_j = \frac{1}{1 + e^{-a \cdot v_j}} \quad (55)$$

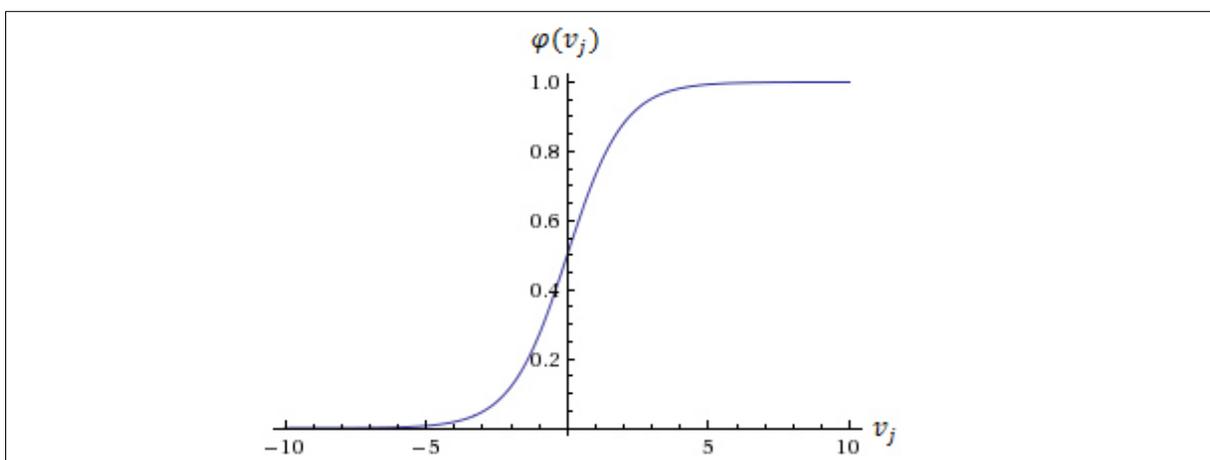


Figura 44 - Gráfico da função de ativação sigmóide logística.

A função de ativação tangente hiperbólica, definida na equação (56), possui uma saída no intervalo $[-1; 1]$ (Figura 45).

$$\varphi(v_j)_{\text{tangente hiperbólica}} = y_j = \frac{1 - e^{-v_j}}{1 + e^{-v_j}} = \frac{2}{1 + e^{-2v_j}} - 1 \quad (56)$$

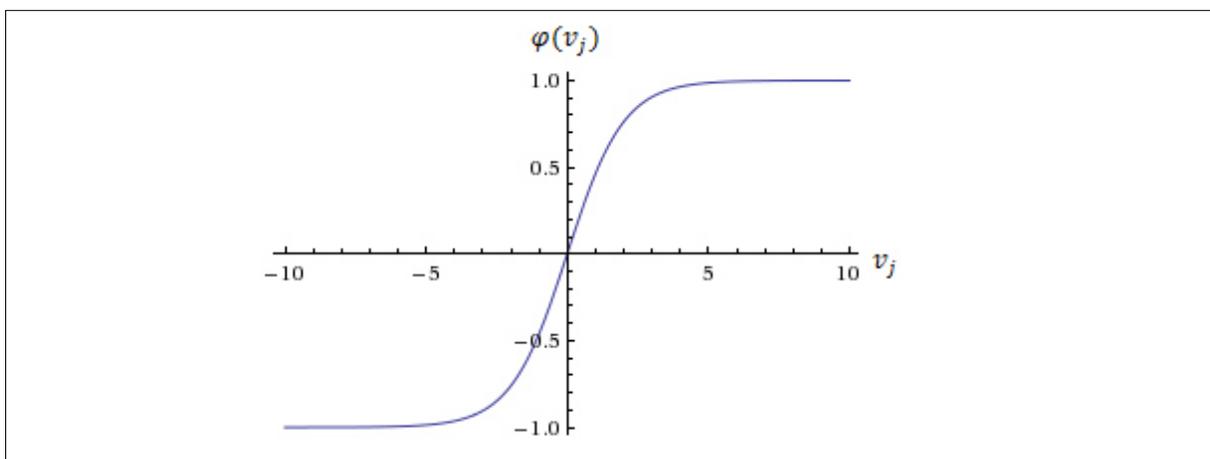


Figura 45 - Gráfico da função de ativação tangente hiperbólica.

2.4.5 Tipos de aprendizado

O aprendizado (ou treinamento) pode ser dividido em duas formas análogas ao aprendizado humano: sem professor e com professor (HAYKIN, 2008). O aprendizado sem professor (não supervisionado) possui apenas as entradas (x) sem as saídas esperadas alvo (t) com o objetivo de explorar características para a obtenção de grupos com características similares, técnica denominada agrupamento (*clustering*). Enquanto que o aprendizado com professor (supervisionado) recebe o mapeamento dos dados de entrada-saída ($x-t$) corretamente definido, baseando-se em exemplos. O aprendizado supervisionado pode ser dinâmico (a topologia da rede é modificada durante o treinamento) ou estático (apenas os pesos da rede sofrem alteração). Na sequência, são apresentados conceitos relativos, especificamente, ao treinamento supervisionado estático em redes MLP.

2.4.6 Avaliação de desempenho

Uma das formas mais comuns para a verificação do desempenho de classificação de treinamento é o erro quadrático médio (*Mean Squared Error*) (MSE), apresentado na equação (57), onde y é saída obtida pela rede, t é saída esperada alvo e N é quantidade dos dados de entrada da rede. O MSE deve ser minimizado para que o resultado de classificação seja aperfeiçoado. Dessa forma, quanto mais próximo de zero for o valor do MSE, melhor será o resultado de classificação.

$$MSE = \frac{\sum_{k=1}^N (y_k - t_k)^2}{N} \quad (57)$$

2.4.7 Treinamento de redes MLP

O algoritmo precursor para o treinamento supervisionado para redes MLP é o *Backpropagation* (BP), também conhecido como Gradiente Descendente (*Steepest Descent*), (RUMELHART et al., 1986). O algoritmo BP realiza duas etapas a cada época (i.e., ciclo de processamento) do treinamento: a propagação (*feedforward*) e a retropropagação dos erros. A propagação ocorre quando os sinais de entrada se propagam até a saída da rede. A retropropagação dos erros acontece no sentido inverso (da saída até a entrada da rede), atualizando os pesos da rede. As épocas são executadas até que um critério de parada seja obtido.

Contudo, o BP possui um alto custo computacional e depende de parâmetros críticos definidos pelo usuário como taxa de aprendizado e momento, afetando a convergência do treinamento da rede que pode ser extremamente lenta ou não ocorrer. Apesar de esforços no sentido do aperfeiçoamento do BP clássico, tal algoritmo não é considerado o algoritmo de treinamento mais robusto. Portanto, uma melhor alternativa em relação ao BP são os algoritmos de Gradiente Conjugado (*Conjugate Gradient*) (CG) que são mais rápidos e robustos (TOWSEY, 1995).

Os métodos de Gradiente Conjugado (*Conjugate Gradient*) (CG), baseados na teoria das direções conjugadas, pertencem à classe dos métodos de otimização de segunda ordem (HAYKIN, 2008). O CG original usa o gradiente para obter uma direção de busca pela execução de uma busca em linha para determinar a distância ideal para se mover na direção atual. Essa busca evita a necessidade de se calcular a matriz Hessiana da derivada segunda, mas depende do cálculo de erro em vários pontos ao longo da linha, tornando o método custoso computacionalmente (DE PINA; 2010).

Em vista disso, o algoritmo, introduzido por Møller (1993), conhecido como Gradiente Conjugado Escalonado (*Scaled Conjugate Gradient*) (SCG) que é uma variação do CG evita essa busca unidimensional (em linha) em cada iteração, reduzindo o esforço computacional. Além disso, o SCG não depende do ajuste de parâmetros críticos definidos pelo usuário. A definição do SCG é apresentada na seção (2.4.7.1).

2.4.7.1 Gradiente Conjugado Escalonado (SCG)

De acordo com Silva (1998), a busca em linha é evitada pelo SCG (MØLLER, 1993) em relação aos demais métodos de CG através de uma abordagem por Levenberg-Marquardt (LM) (LEVENBERG, 1944; MARQUARDT, 1963) cujo objetivo é realizar um escalonamento do passo de ajuste α .

Se o problema tratado não é quadrático, então a matriz Q de dimensões $P \times P$ deve ser aproximada pela matriz hessiana calculada no ponto θ_j , como definida na equação (58), onde d_j é a direção de busca e $\nabla J(\theta_j) = \alpha_0^* d_0 + \alpha_1^* d_1 + \dots + \alpha_{p-1}^* d_{p-1}$.

$$\alpha_j^* = -\frac{d_j^T \nabla J(\theta_j)}{d_j^T \nabla J(\theta_j) d_j} \quad (58)$$

A ideia de Møller (1993) foi estimar o termo denominado $s_j = \nabla^2 J(\theta_j)$ do CG por uma aproximação da forma descrita na equação (59).

$$s_j = \nabla^2 J(\theta_j) \approx \frac{\nabla J(\theta_j - \sigma_j d_j) - \nabla J(\theta_j)}{\sigma_j}, \quad 0 < \sigma_j \ll 1 \quad (59)$$

A aproximação tende, no limite, ao valor de $\nabla^2 J(\theta_j)$. Combinando esta estratégia com a abordagem de CG e LM, obtém-se um algoritmo diretamente aplicável ao treinamento de redes MLP (SILVA, 1998). Considerando a equação (60).

$$s_j = \frac{\nabla J(\theta_j - \sigma_j d_j) - \nabla J(\theta_j)}{\sigma_j} + \lambda_j d_j \quad (60)$$

Seja δ_i o denominador da equação (58), então, utilizando a expressão (59), a equação (61) é obtida. O ajuste do parâmetro λ_j a cada iteração e a análise do sinal de δ_j permitem a verificação se a hessiana é definida-positiva ou não.

$$\delta_j = d_j^T s_j \quad (61)$$

Silva (1998) destaca que a aproximação quadrática $J_{quad}(\theta)$, utilizada pelo algoritmo, nem sempre representa uma boa aproximação para $J(\theta)$, uma vez que λ_j escala a matriz hessiana de maneira artificial. Um mecanismo para aumentar e diminuir λ_j é necessário para fornecer uma boa aproximação, mesmo quando a matriz for definida-positiva. Na equação (62), termo Δ_j representa uma medida da qualidade da aproximação $J_{quad}(\theta)$ em relação a $J(\theta_j - \sigma_j d_j)$, assim, quanto mais próximo de 1 estiver Δ_j , melhor será a aproximação, onde $\mu_j = -d_j^T \nabla J(\theta_j)$.

$$\Delta_j = \frac{J(\theta_j) - J(\theta_j + \alpha_j d_j)}{J(\theta_j) - J_{quad}(\alpha_j d_j)} = \frac{2\delta_j [J(\theta_j) - J(\theta_j + \alpha_j d_j)]'}{\mu_j^2} \quad (62)$$

O algoritmo do SCG é descrito de forma sintetizada a seguir (SILVA, 1998):

1. Escolha um vetor de parâmetros inicial θ_0 e escalares $0 < \sigma \ll 1$ e $\lambda_0 = 0$;
2. Faça: $p_0 = r_0 = -\nabla J(\theta_j)$; $j = 0$; sucesso = 1;
3. Se sucesso = 1, calcule a informação de 2ª ordem: $\sigma_j = \sigma / \|d_j\|$; efetue a operação definida na equação (60); $\delta_j = p_j^T s_j$;
4. Se o valor de $\delta_j < 0$, então faça a matriz hessiana definida-positiva: $\lambda_j^N = 2[\lambda_j - \delta_j / \|d_j\|]$; $\delta_j = \delta_j + (\lambda_j^N - \lambda_j) \|d_j\|^2$; $\lambda_j = \lambda_j^N$;
5. Calcule a taxa de ajuste: $\mu_j = -p_j^T r_j$; $\alpha_i = \mu_j / \delta_j$;

6. Calcule o parâmetro de comparação Δ_j pela operação descrita na equação (62);
7. Se o valor de $\Delta_j \geq 0$ (o erro pode ser reduzido), então atualize o vetor de pesos: $\theta_{j+1} = \theta_j + \alpha_j d_j$; $r_{j+1} = -\nabla J(\theta_{j+1})$;
8. Se $(j \bmod P) = 0$, então reinicialize o algoritmo: $p_{j+1} = r_{j+1}$;
 Senão, defina uma nova direção conjugada: $\beta_j = \frac{\|r_{j+1}\|^2 - r_{j+1}^T r_j}{\mu_j}$;

$$p_{j+1} = r_{j+1} + \beta_j p_j$$
;
9. Se $\lambda_j \geq 0,75$, então faça $\lambda_j = 0,5\lambda_j$.
10. Se $\lambda_j \leq 0,25$, então faça $\lambda_j = 4\lambda_j$.
 Senão, uma redução no erro não é possível: sucesso = 0;
11. Se $r_{j+1} > \varepsilon$, onde $\varepsilon \rightarrow 0$, então faça: $j = j + 1$; retorne ao passo 3.
 Senão, o procedimento de ajuste chegou ao fim e θ_{j+1} é o ponto de mínimo.

Recomenda-se a leitura de Møller (1993) para maiores detalhes do SCG.

2.4.8 Normalização de entradas

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 MLP seja do tipo tangente hiperbólica.

Uma das formas de normalização é definida na equação (63), onde x (matriz ou vetor de entrada) possui apenas valores reais finitos e os elementos de cada linha são distintos, y é a matriz ou vetor de entrada normalizada (i.e., no novo intervalo), x_{max} é o valor máximo de x , x_{min} é o valor mínimo de x , y_{max} é o valor de máximo do novo intervalo e y_{min} é o valor mínimo do novo intervalo.

$$y = \frac{(y_{max}-y_{min})(x-x_{min})}{(x_{max}-x_{min})} + y_{min} \quad (63)$$

2.4.9 Separação de conjuntos

A cada rotina de treinamento supervisionado, é comum separar os dados de entrada-saída ($x-t$) da rede em três conjuntos:

- **Treinamento:** usado para o ajuste de pesos da rede pelo algoritmo de treinamento.
- **Validação:** empregado para testar o desempenho de classificação da rede durante o aprendizado, servindo como critério de parada do algoritmo de treinamento na busca da generalização da rede.
- **Teste:** aplicado para o teste cego da rede, ou seja, para confirmar o poder preditivo real da rede.

A proporção dos dados entre os conjuntos é definida pelo projetista da rede e a distribuição dos dados em cada conjunto de dados é feita, geralmente, de forma aleatória e proporcional em relação às classes que definem a saída da rede, gerando configurações distintas dos pesos das redes a cada treinamento. Porém, é importante frisar que estes dados não devem ser redundantes nem contraditórios para evitar que, respectivamente, o treinamento se torne tendencioso com dados repetidos ou tenha o seu desempenho afetado por dados com saídas com classes conflitantes.

2.4.10 Generalização

O objetivo da definição adequada de um critério de parada ideal para uma rede MLP é alcançar a generalização. Uma rede possui boa generalização quando o mapeamento entrada-saída ($x-t$) é correto (ou bem próximo do correto) para os dados de teste definidos na criação ou durante o treinamento da rede, assumindo que os dados de teste e treinamento são oriundos de uma mesma população (HAYKIN, 2008).

A generalização de uma rede MLP pode ser afetada pela falta de ajuste (*underfitting*) e pelo sobreajuste (*overfitting*). A falta de ajuste ocorre, normalmente, quando há um curto período de treinamento, resultando em uma baixa capacidade de generalização da rede (se a rede fosse treinada por mais tempo, o resultado seria melhor). O sobreajuste acontece quando há um longo período de treinamento, resultando na perda da capacidade preditiva da rede. Neste caso, a rede decora (i.e., memoriza) os dados de treinamento, distanciando-se de bons resultados quando aplicada aos dados de teste (HAYKIN, 2008).

2.5 MÉTRICAS DE AVALIAÇÃO DE RESULTADOS

De acordo com Powers (2007), alguns dos métodos mais comuns de avaliação de resultados de experiências com aprendizado de máquina são as métricas conhecidas como: cobertura (ou sensibilidade), precisão (ou confiança) e *f-score*. A cobertura (C), definida na equação (64), informa a proporção entre a quantidade de verdadeiros positivos (v_{pos}) e a soma dos verdadeiros positivos (v_{pos}) com os falsos negativos (f_{neg}). A precisão (P), definida na equação (65), apresenta a proporção entre os verdadeiros positivos (v_{pos}) e a soma dos verdadeiros positivos (v_{pos}) com os falsos positivos (f_{pos}). O *f-score* (f_{score}) é a média harmônica entre a precisão e a cobertura definida na equação (66).

$$C = \frac{v_{pos}}{v_{pos} + f_{neg}} \quad (64)$$

$$P = \frac{v_{pos}}{v_{pos} + f_{pos}} \quad (65)$$

$$f_{score} = 2 \frac{(P \cdot C)}{(P + C)} \quad (66)$$

2.6 CONSIDERAÇÕES FINAIS

Os fundamentos descritos neste capítulo compreendem os temas explorados neste trabalho com relação ao processo radiográfico, processamento digital de imagens, redes neurais artificiais e métricas de avaliação de resultados. O estado da arte sobre detecção de defeitos de soldagem em imagens radiográficas é apresentado no próximo capítulo.

3 ESTADO DA ARTE

3.1 INTRODUÇÃO

É importante enfatizar que apesar dos resultados das técnicas de exposição PSVS não serem comparáveis pela diferença estrutural da região de interesse (ROI) na imagem radiográfica com a técnica de exposição PDVD explorada nesta dissertação, estudos com técnica de exposição PSVS são apresentados neste capítulo para expor os esforços da comunidade científica acerca do tema: detecção de defeitos de soldagem em imagens radiográficas.

Em vista disso, o estado da arte foi dividido com base nas técnicas de exposição radiográfica tratadas pelos trabalhos que abordam detecção de defeitos de soldagem com exposição: vista simples (PSVS) (seção 3.2) e vista dupla (PDVD) (seção 3.3). As conclusões sobre o estado da arte são apresentadas na seção 3.4.

3.2 DETECÇÃO DE DEFEITOS COM VISTA SIMPLES (PSVS)

3.2.1 Gayer et al. (1990)

O método de Gayer et al. (1990) foi aplicado com duas etapas: busca por defeitos em potencial e identificação/localização de verdadeiros positivos. A primeira etapa consistiu na aplicação de uma transformada rápida de Fourier (*Fast Fourier Transform*) (FFT) sobre janelas 32x32 da imagem original. Caso o somatório de regiões de alta frequência atingisse um determinado limiar, a janela era marcada como defeito em potencial.

Para a segunda etapa foram definidos dois algoritmos. No primeiro algoritmo, *Sequential Similarity Detection Algorithm* (SSDA) (BARNEA; SILVERMAN, 1972), as janelas marcadas eram comparadas com padrões de defeitos. Se o casamento de padrões atingisse um determinado limiar, então a janela analisada era marcada como defeito. O segundo algoritmo, *Background Subtraction Method* (BSM), subtraiu

a imagem original por uma imagem de fundo estimada através de uma suavização realizada por uma função *spline* interpolada (DIERCKX, 1993).

A Figura 46 mostra que os métodos por SSDA e BSM foram capazes de alcançar uma aproximação aceitável para os padrões de inspeção na detecção de defeitos de soldagem. Por outro lado, conforme os próprios autores ressaltaram, uma comparação quantitativa do método proposto com inspeção visual humana seria uma atitude muito ambiciosa, pois esses métodos são dependentes das dimensões dos defeitos e da qualidade do contraste da imagem.

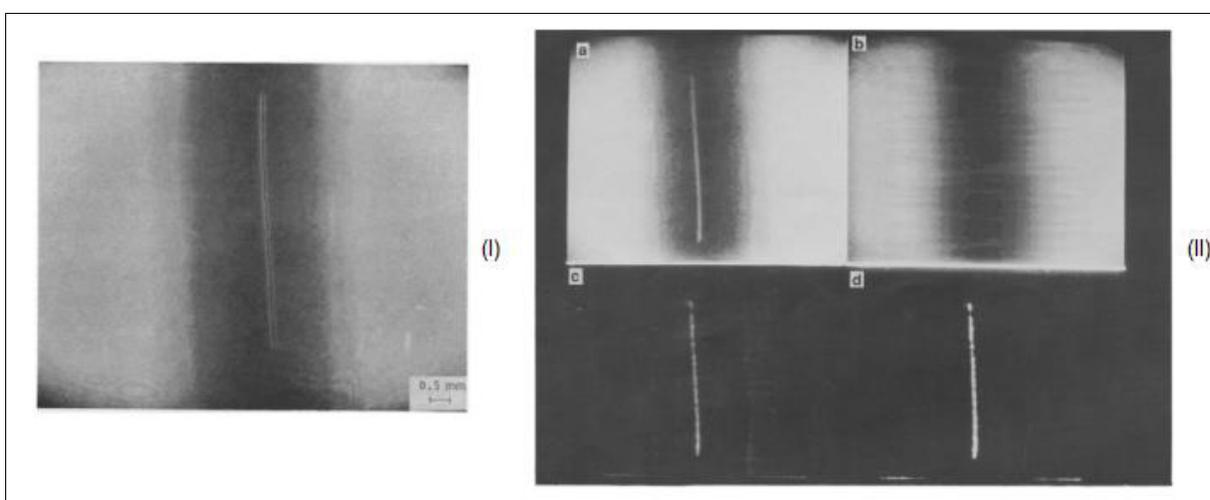


Figura 46 - Resultado do método de Gayer et al. (1990). Detecção de uma trinca por (I) SSDA e por (II) BSM. (a) imagem original, (b) fundo estimado, (c) subtração de (a) por (b), (d) limiarização de (c).

Fonte: Adaptado de Gayer et al. (1990, p. 134-136).

3.2.2 Lawson e Parker (1994)

Lawson e Parker (1994) empregaram redes neurais artificiais (RNA) do tipo *Perceptron* de múltiplas camadas (MLP) para detectar defeitos de solda. A abordagem foi realizada em duas etapas: segmentação do cordão de solda e detecção de defeitos de soldagem. Na primeira etapa as imagens foram pré-processadas pela aplicação de filtros passa-baixa para a remoção de ruído. Para a localização do cordão de solda a RNA foi treinada com uma imagem modelo obtida a partir da imagem de uma imagem real da junta soldada, discriminando cada pixel

da imagem de entrada como soldagem e não soldagem. 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 defeito, classificando cada pixel como defeito e não defeito.

A Figura 47 ilustra a saída binária do método que apresenta uma detecção visualmente bem sucedida de detecção de defeitos de soldagem com exclusão de regiões externas à junta soldada, eliminando os indicadores de qualidade de imagem (IQIs) posicionados próximos ao cordão de solda. Resultados quantitativos de detecção de defeitos de soldagem não foram apresentados.

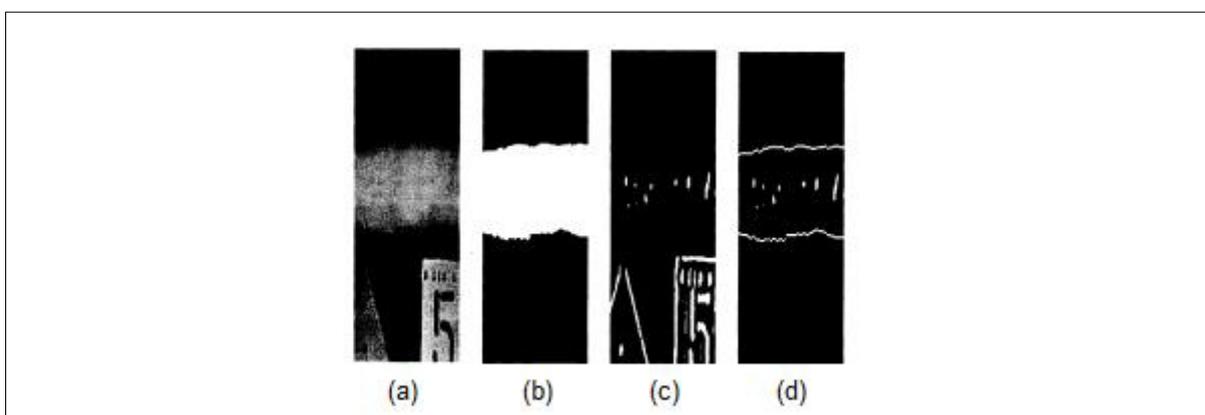


Figura 47 - Resultado do método de Lawson e Parker (1994). (a) Imagem original, (b) extração do cordão de solda, (c) detecção de defeitos, (d) combinação de (b) e (c).

Fonte: Lawson e Parker (1994, p. 254).

3.2.3 Liao e Li (1998) e Liao et al. (1999)

Em Liao e Li (1998), a detecção de defeitos de solda foi baseada na busca por anomalias de picos através da análise do perfil com formato de uma gaussiana sobre o cordão de solda 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 cobertura do método foi de 93,30% com 4,19% de falsos positivos (precisão de 95,91%) devido aos perfis com falta de fusão, excesso de ruídos e perfis de solda com características não gaussianas, resultando em um *f-score* de 94,55%.

Liao et al. (1999) também empregaram um método baseado na análise de anomalias de perfil, mas com a inclusão de sistemas para classificação por agrupamento: *fuzzy k nearest neighbors* (KNN) e *fuzzy c-means*. Neste estudo, 25 atributos foram extraídos de cada linha (ou perfil) do cordão de solda. Ao todo, 10501 linhas foram testadas, sendo 1517 linhas de defeitos, extraídas de 18 cordões de solda de radiografias convencionais. A Figura 48 apresenta a forma normalizada entre um perfil sem defeito (SD) e um perfil com defeito (CD). O classificador KNN obteve o melhor resultado com 93,99% de cobertura, 18,68% de falsos positivos (81,32% de precisão) e um *f-score* de 87,20%.

A Figura 49 ilustra dois exemplos de defeitos detectados: uma Inclusão de Tungstênio (IT) e uma Trinca (TR). Apesar do bom desempenho de detecção de perfis com defeitos de soldagem em Liao e Li (1998) e Liao et al. (1999), estes trabalhos consideraram que o perfil de solda sempre possui característica gaussiana. Porém, essa característica gaussiana da junta soldada não é uma propriedade extensível para todas as imagens radiográficas de cordões de solda.

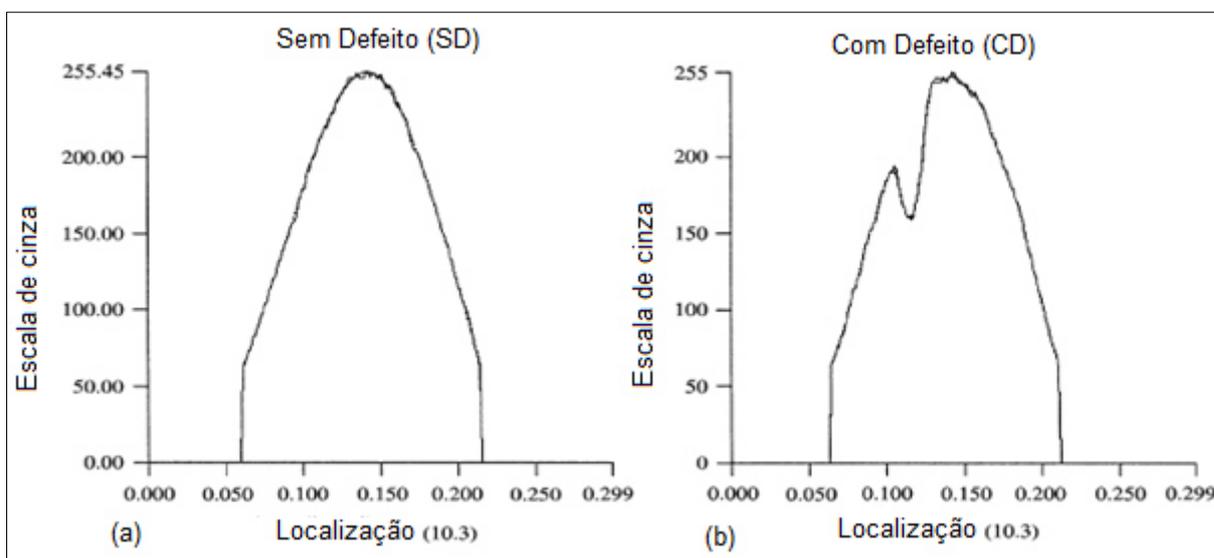


Figura 48 - Perfis de exemplo de Liao et al. (1999). (a) Perfil com defeito, (b) perfil sem defeito.

Fonte: Adaptado de Liao et al. (1999, p. 147).

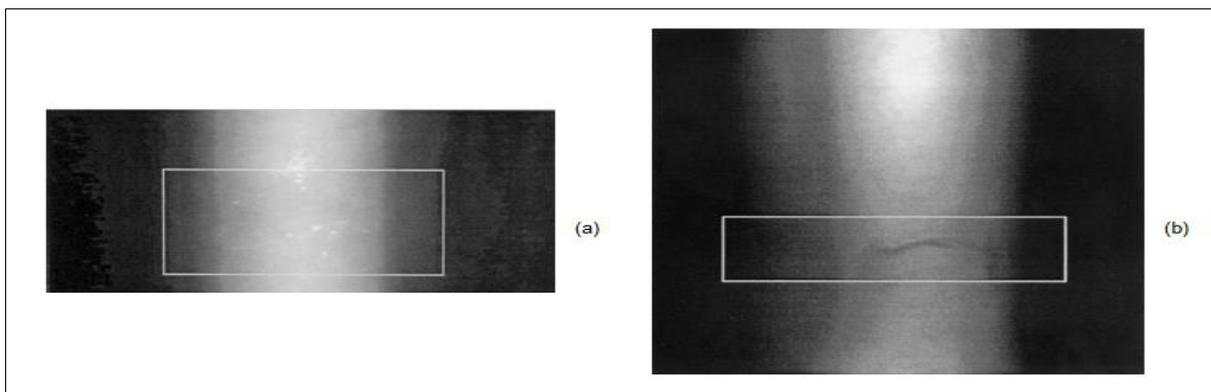


Figura 49 - Resultado do método de Liao et al. (1999). (a) Inclusão de tungstênio (IT), (b) trinca (TR).

Fonte: Adaptado de Liao et al. (1999, p. 155-156).

3.2.4 Nacereddine et al. (2000)

Nacereddine et al. (2000) apresentaram um método baseado em redes MLP para detectar regiões de bordas e, por conseguinte, defeitos de soldagem em imagens radiográficas. O método consistiu em uma detecção baseada em janelas 3x3, substituindo o pixel central correspondente da janela analisada por uma saída binária. A Figura 50 ilustra a arquitetura da rede com nove neurônios na camada de entrada que corresponderam aos valores de pixels das janelas analisadas, 10 neurônios na única camada oculta e um neurônio na saída que definiu a saída binária do método.

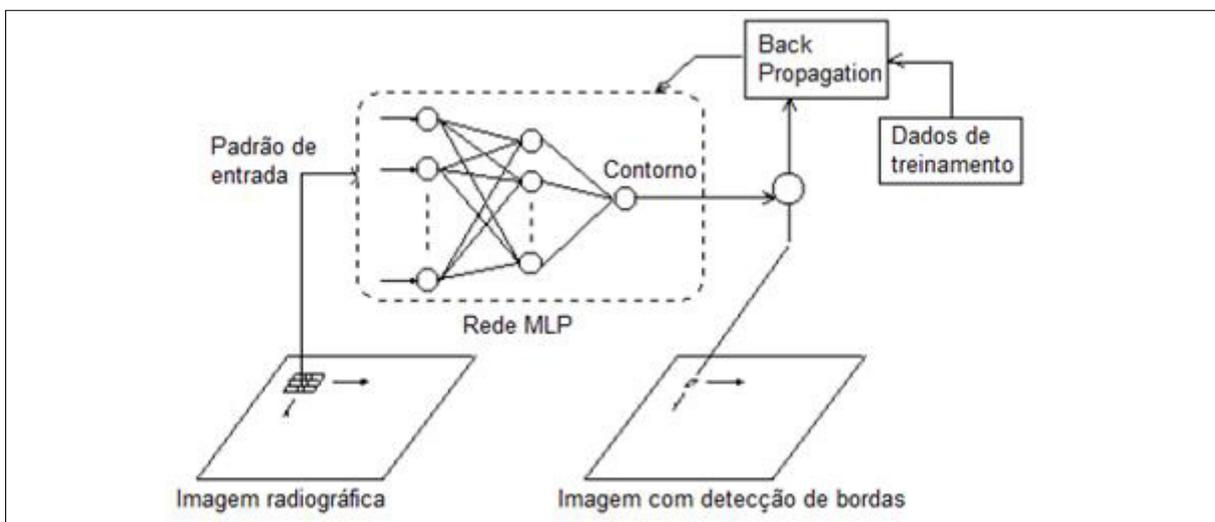


Figura 50 - Mapeamento dos pixels e arquitetura da rede de Nacereddine et al. (2000).

Fonte: Adaptado de Nacereddine et al. (2000).

Os autores não apresentaram a quantidade de imagens utilizadas, mas informaram sobre alguns dos tipos de defeitos de soldagem presentes nas imagens, tais como: porosidade (PO), trinca (TR), falta de fusão (FF), inclusão de tungstênio (IT), inclusão de escória (IE) e falta de penetração (FP). O melhor resultado de detecção de defeitos de soldagem foi com uma cobertura de 96%. E, apesar do número de falsos positivos não ser fornecido, a detecção excessiva de falsos positivos é visível em uma das imagens de saída fornecidas em seu trabalho como ilustrado na Figura 51, essa alta ocorrência de falsos positivos é oriunda da presença de ruídos provenientes de zonas de transição de luminosidade na imagem radiográfica.

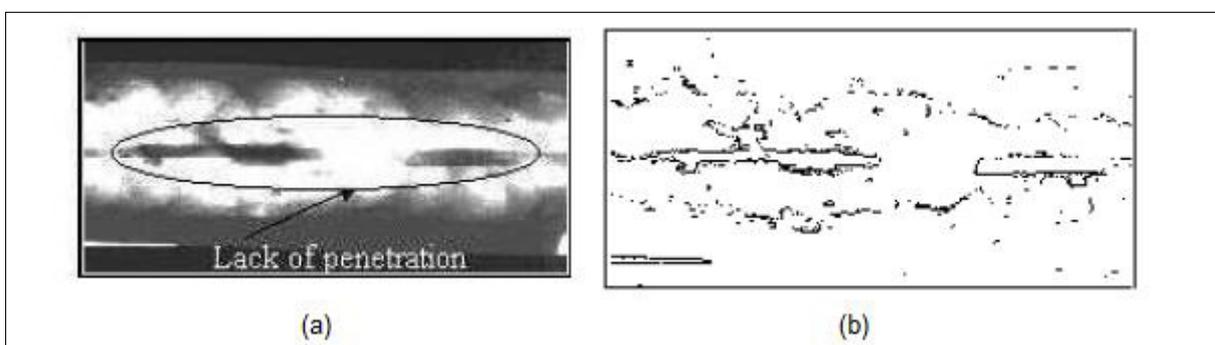


Figura 51 - Resultado do método de Nacereddine et al. (2000). (a) Imagem original com defeito de soldagem do tipo falta de penetração (FP), (b) segmentação de regiões de defeito em potencial.

Fonte: Adaptado de Nacereddine et al. (2000).

3.2.5 Lashkia (2001)

O trabalho de Lashkia (2001) empregou mais de 100 imagens de partes cordão de solda de aço de radiografias digitalizadas por câmera, realizando o treinamento *neuro-fuzzy* do sistema com 16 imagens de baixo contraste com o objetivo de detectar defeitos de soldagem nas imagens restantes. O método aplicou lógica *fuzzy* com busca vertical/horizontal pelo recorte do cordão de solda e métodos de morfologia matemática sobre as regiões, apresentando como saída uma imagem binária com regiões de defeitos de soldagem em preto conforme ilustrado na Figura 52.

A cobertura do método foi de 97,79%, falhando na detecção de defeitos próximos à borda do cordão de solda. Houve detecção de falsos positivos em 35

imagens devido à presença de ruídos, mas a quantidade de falsos positivos não foi informada. A principal dificuldade de tal técnica é que, para o defeito ser realçado perfeitamente, a imagem tratada deve ser uma janela com parte da junta soldada delimitada praticamente ao defeito de soldagem.



Figura 52 - Resultado do método de Lashkia (2001). (a) Imagem de teste melhorada com trinca (TR), (b) resultado do processamento da imagem (a).

Fonte: Adaptado de Lashkia (2001, p. 268).

3.2.6 Mery e Berti (2003)

Mery e Berti (2003) basearam-se na análise de textura de regiões extraídas para a detecção de defeitos de solda em imagens radiográficas. A técnica desenvolvida foi aplicada em apenas uma imagem radiográfica “BAM5” cedida pelo BAM (*Federal Institute for Materials Research and Testing, Berlin*) com 3512x366 pixels. Ao todo, foram extraídas 1419 regiões a serem classificadas como com defeito (CD) ou sem defeito (SD) pelo método de detecção de bordas filtro LoG (*Laplacian-of-Gauss*) (MERY; FILBERT, 2002). Sendo que apenas 13,95% (198/1419) dessas regiões representaram defeitos de soldagem.

Foram selecionados 28 atributos de textura de matriz de coocorrência com três distâncias e 64 atributos de textura de filtros bidimensionais de Gabor, totalizando 148 ($28 \times 3 + 64$) atributos. Os desempenhos de três classificadores (Polinomial, *Mahalanobis* e Vizinhança mais próxima) foram testados e o melhor resultado obtido foi do classificador Polinomial com cobertura de 90,91%, precisão de 64,52% e *f-score* de 74,47%. Todavia, este método é limitado com relação à capacidade de generalização para outras imagens, pois todo o método foi desenvolvido e aplicado para apenas uma imagem radiográfica.

3.2.7 Carrasco e Mery (2004)

Carrasco e Mery (2004) usaram dez imagens disponibilizadas pelo BAM (*Federal Institute for Materials Research and Testing, Berlin*) para segmentar os defeitos de solda como ilustrado na Figura 53. O método adotado empregou seis etapas: filtro da mediana (para eliminar ruídos), filtro *Bottom-Hat* (para aumentar a intensidade de regiões de defeitos), limiarização (para gerar uma máscara binária de regiões segmentadas), extração de regiões da imagem filtrada (baseada na imagem limiarizada), modificação dos mínimos locais das regiões (BEUCHER, 1991) para evitar uma sobresegmentação e garantir que esta seja precisa; e a transformação *Watershed* (BEUCHER; LANTUÉJOU, 1979) para indicar dentro de cada região segmentada qual parte deveria ser evidenciada no processo de detecção.

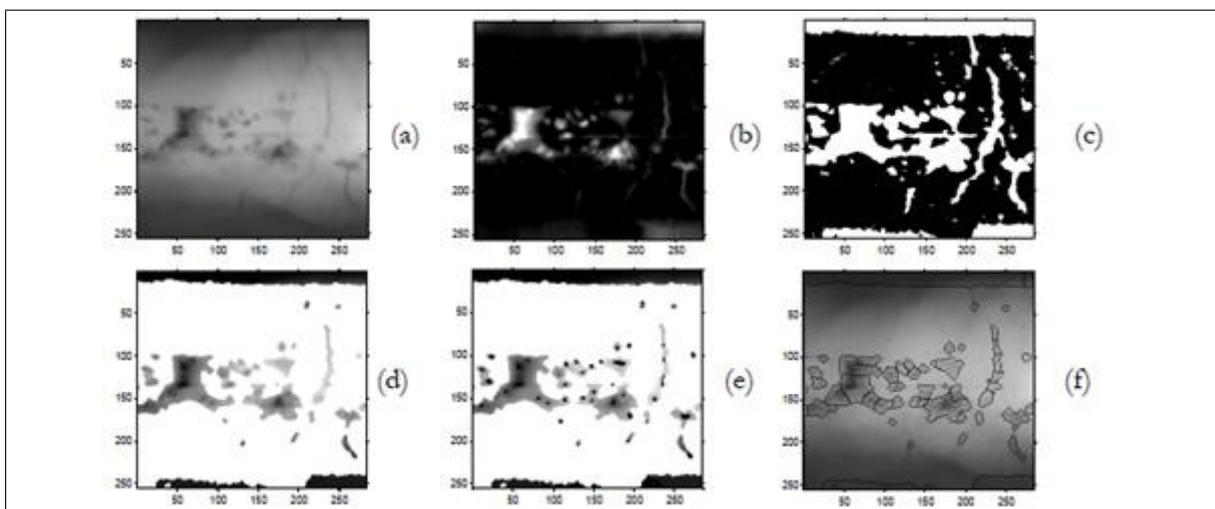


Figura 53 - Resultado do método de Carrasco e Mery (2004). (a) Imagem após a aplicação do filtro da mediana, (b) aplicação filtro *top-hat*, (c) limiarização, (d) extração de regiões da imagem filtrada, (e) modificação dos mínimos locais das regiões, (f) aplicação da transformação *Watershed*.

Fonte: Carrasco e Mery (2004).

A redução de falsos positivos foi feita pela exclusão de regiões que possuem 32 pixels ou menos. O método obteve como resultado uma cobertura de 89,40%, uma precisão de 7,23% e um *f-score* de 13,37%. Nas 10 imagens empregadas, 9005 regiões foram segmentadas pelo método, e apenas 728 realmente correspondiam a regiões de defeitos.

3.2.8 Padua (2004)

O trabalho de Padua (2004) utilizou imagens radiográficas de soldagem do IIW (*International Institute of Welding*) (dos anos de 1952 e 1995) e BAM (*Federal Institute for Materials Research and Testing, Berlin*). O método detectou e classificou os defeitos de soldagem simultaneamente através da análise do perfil gaussiano da solda. No experimento de melhor resultado, baseando-se em uma rede neural semi-supervisionada *Adaptive Resonance Theory* (ART) (CARPENTER; GROSSBERG, 1988), foram empregados 1638 perfis (ou sinais) representados por sete classes: 467 Sem Defeito (SD), 64 de Falta de Fusão (FF), 181 de Falta de Penetração (FP), 154 de Inclusão de Escória (IE), 95 de Mordedura (MO), 412 de Porosidade (PO) e 265 de Trinca (TR). O pré-processamento dos perfis consistiu nas seguintes etapas: extração manual da região que delimita o cordão de solda, filtragem de Savitzky-Golay (SOPHOCLES, 1995) de segunda ordem com janela 8x8, normalização da amplitude, interpolação para 276 pontos pela transformada rápida de Fourier, e normalização da posição do defeito à direita do pico da curva gaussiana.

A precisão do método foi de 100% na detecção dos perfis sem defeito (SD) e o resultado total de classificação foi de 98%. Contudo, o método assumiu, assim como os métodos de Liao e Li (1998) e Liao et al. (1999), que o perfil de solda sempre possui características gaussianas. E, de acordo com o próprio autor, tal comportamento gaussiano é obtido apenas em soldas com reforço. Além disso, foram apresentados resultados de classificação de perfis extraídos de forma manual.

3.2.9 Sun et al. (2005)

Sun et al. (2005) desenvolveram um sistema *fuzzy* de reconhecimento de padrões para a detecção de defeitos de soldagem em tubulações de aço em tempo real sobre imagens radiográficas com aquisição direta. O método foi baseado em casamento de padrões circulares para detecção de defeitos e classificação por tipos: Inclusão de Escória (IE), Porosidade (PO) e Falta de Penetração (FP). Ao todo, foram realizados testes em três situações diferentes: no laboratório com 98,5% de defeitos detectados corretamente com 2 falsos positivos e 1 falso negativo devido a ruídos sobre a imagem; com amostras de tubo na fábrica com precisão de 100%

sem falsos positivos e na fábrica com 100% de defeitos detectados (desempenho igual ao especialista humano). Um dos resultados visuais de detecção de defeitos de soldagem de detecção no terceiro teste (na fábrica) é apresentado na Figura 54.

Desta forma, o método obteve, em média nos três testes efetuados, uma cobertura de 99,67%, uma precisão de 99,34% e um *f-score* de 99,51%. No entanto, a qualidade de iluminação uniforme das imagens radiográficas com aquisição direta tratadas neste trabalho proporcionaram uma baixa taxa de ruído e alta qualidade de contraste da imagem, tornando o procedimento de detecção menos suscetível a erros provenientes de ruídos quando comparadas com imagens radiográficas obtidas a partir de aquisição convencional e computadorizada.

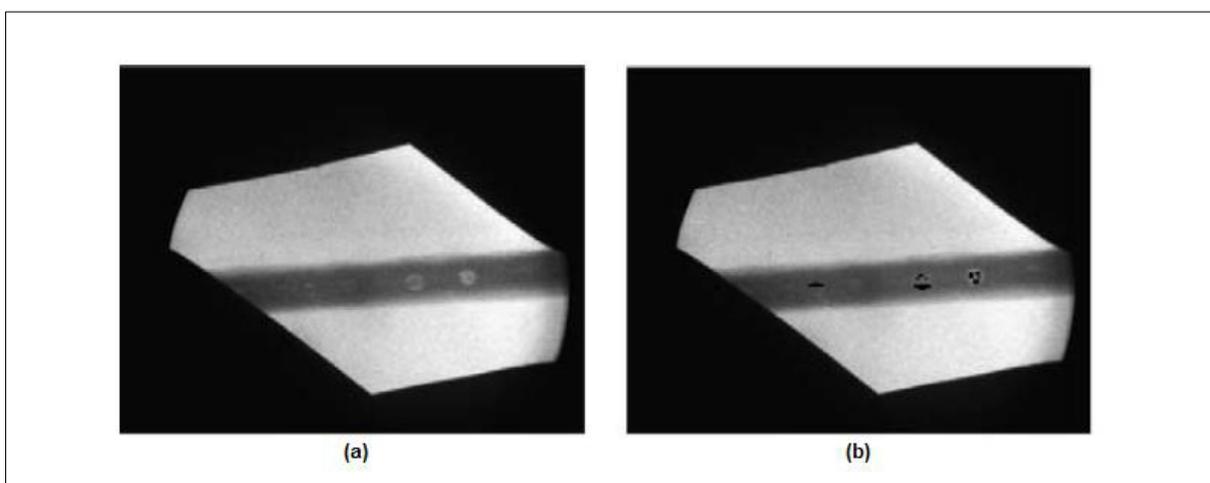


Figura 54 - Resultado do método de Sun et al. (2005). (a) Imagem original, (b) detecção de defeitos do tipo inclusão de escória (IE).

Fonte: Adaptado de Sun et al. (2005, p. 527).

3.2.10 Wang et al. (2008)

Wang et al. (2008) desenvolveram uma técnica de detecção de defeitos de soldagem com formato em linha, e.g., Trincas (TR). O método foi aplicado a imagens radiográficas obtidas por aquisição direta. A transformada de Hough (AGGARWAL, 2006) foi utilizada para eliminar pixels não pertencentes ao defeito, obtendo uma segmentação mais precisa e localizada do defeito. A classificação de características foi realizada por máquinas de vetor de suporte (*Support Vector Machines*) (SVMs). O método foi aplicado em janelas de tamanho (45x30) sobre o cordão de solda já segmentado. A entrada da SVM consistiu de múltiplas imagens binárias com

diferentes valores de limiares, para a busca de defeitos com formato linear. Foram usados 400 amostras (200 de defeitos e 200 sem defeitos) para treinar e testar a SVM.

O método foi capaz de detectar 96,15% dos defeitos com formato em linha, mas a quantidade de falsos positivos não foi informada. Exemplos de entradas e saídas do método são mostrados na Figura 55. Pelo fato das imagens radiográficas tratadas neste trabalho serem obtidas por aquisição direta, essas imagens tendem a possuir uma distribuição mais homogênea dos níveis de cinza sobre o cordão de solda, característica não apresentada por técnicas de aquisição computadorizada e convencional que exigem um procedimento de digitalização do detector.

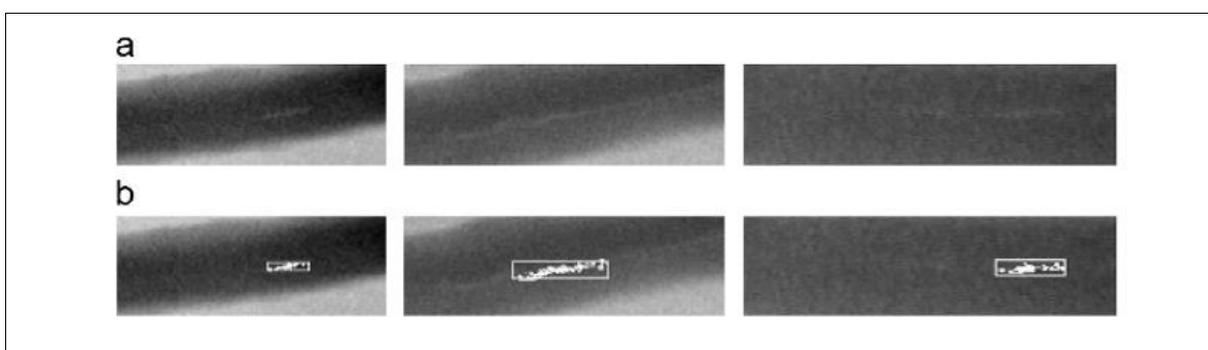


Figura 55 - Resultado do método de Wang et al. (2008). (a) Imagens originais, (b) detecções com blocos 45 x 30.

Fonte: Adaptado de Wang et al. (2008, p. 523).

3.2.11 Vilar et al. (2009)

Um método misto de detecção e classificação de defeitos de soldagem foi descrito por Vilar et al. (2009) e aplicado em 86 radiografias do IIW (*International Institute of Welding*). O pré-processamento das imagens consistiu na aplicação de um filtro de Wiener adaptativo (LIM, 1990) 7x7 e de um filtro Gaussiano (passa-baixa) 3x3 para eliminar/reduzir ruídos. Em seguida foi aplicado um mapeamento da faixa de níveis de cinza para a melhora do contraste. Tal melhora de contraste mapeou os valores de pixels entre 1% (0,01) do menor valor e 1% (0,99) do maior valor dos níveis de cinza em novos valores no intervalo [0; 1] e os valores restantes foram descartados. Após essa rotina de pré-processamento a limiarização por Otsu (1979) foi aplicada em cada recorte do cordão da soldagem para a detecção de

heterogeneidades internas (Figura 49), gerando regiões de defeitos em potencial para a classificação por rede neural MLP.

Os atributos extraídos de cada região para a classificação foram: área, centroide (coordenadas x e y), eixo maior, eixo menor, excentricidade, orientação, número de Euler, diâmetro equivalente, solidez, extensão e posição. O melhor desempenho médio de classificação foi com cobertura de 80,41% com 88,39% para regiões Sem Defeito (SD); 70,23% para Inclusão de Escória (IE); 74,27% para Porosidade (PO); 79,38% para Trinca (TR) transversal e 89,30% para TR longitudinal. Deste modo, o método foi capaz de classificar 78,30% das classes com defeito (CD) e 88,39% da classe sem defeito (SD).

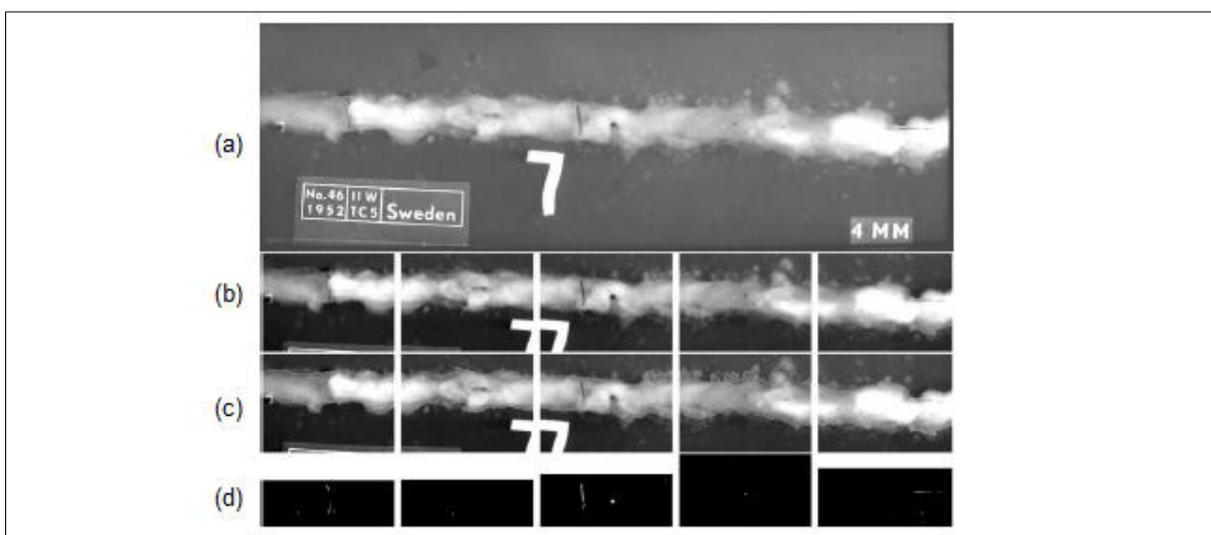


Figura 56 - Resultado do método de Vilar et al. (2009). (a) Imagem original, (b) dividida, (c) soldagem segmentada, (d) regiões de defeitos em potencial.

Fonte: Adaptado de Vilar et al. (2009, p. 471).

3.2.12 Valavanis e Kosmopoulos (2010)

Valavanis e Kosmopoulos (2010) apresentaram um método de segmentação baseado em grafos para a detecção e classificação simultânea de defeitos de soldagem em navios, utilizando 24 radiografias de 16 bits fornecidas pela *Technic Control Co.* (Polônia). O método foi aplicado em janelas definidas sobre o cordão de solda para detectar e classificar regiões obtidas através da aplicação do método de segmentação baseada em grafos (FELZENSZWALB; HUTTENLOCHER, 2004).

Essas regiões representaram classes de diferentes tipos de defeitos de soldagem e uma classe que representa região sem defeito (SD). Ao todo, 43 descritores de medidas de textura e atributos geométricos foram extraídos de cada região segmentada e foram usados como entrada para três algoritmos de aprendizado: Máquina de Vetor de Suporte (*Support Vector Machine*) (SVM); Rede Neural Artificial (RNA); e *K-Nearest Neighbors* (KNN).

Os melhores desempenhos de detecção/classificação foram obtidos por SVM e RNA com cobertura de, respectivamente, 78% e 77% para a classe sem defeito (SD); 62% e 46% para trinca (TR); 59% e 85% para falta de fusão (FF), 95% e 95% para porosidade (PO) vermicular; 93% e 89% para inclusão de escória (IE) linear, 96% e 93% para porosidade (PO); e 92% e 92% para porosidade (PO) de gás. O método foi capaz de classificar 82,14% e 82,43% das classes com defeito (CD) e 78% e 77% da classe sem defeito (SD) através de SVM e RNA respectivamente. Porém, as janelas foram posicionadas sobre os defeitos, de forma que a abordagem funcionou mais como um método de auxílio de análise pontual de detecção de defeitos de soldagem do que um método de detecção sobre a junta soldada como um todo.

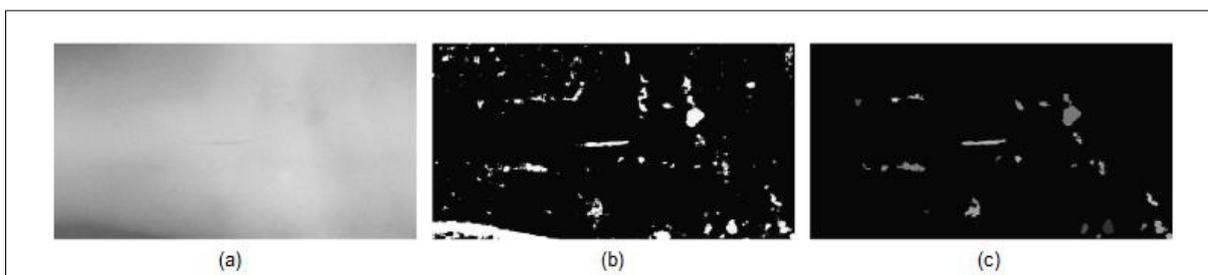


Figura 57 - Resultado do método de Valavanis e Kosmopoulos (2010). (a) Imagem original, (b) limiarizada, (c) segmentada com um TR linear no centro.

Fonte: Adaptado de Valavanis e Kosmopoulos (2010, p. 7611).

3.2.13 Yazid et al. (2011)

Em Yazid et al. (2011) a detecção de defeitos foi realizada em 60 recortes de cordões de solda. Tal método é ilustrado na Figura 58 pela imagem de teste, consistindo na classificação por agrupamento *fuzzy*, preenchimento de regiões para a delimitação da região do cordão de solda, detecção bordas e limiarização,

detecção de vales com uma limiarização, reconstrução inversa da superfície sobre a imagem original e uma nova limiarização.

Tal método de detecção de defeitos de soldagem obteve uma cobertura de 94,6%. Contudo, a abordagem proposta foi aplicada em janelas de recortes sobre a soldagem, restringindo a região da detecção de defeitos a uma porção delimitada praticamente aos defeitos de soldagem.

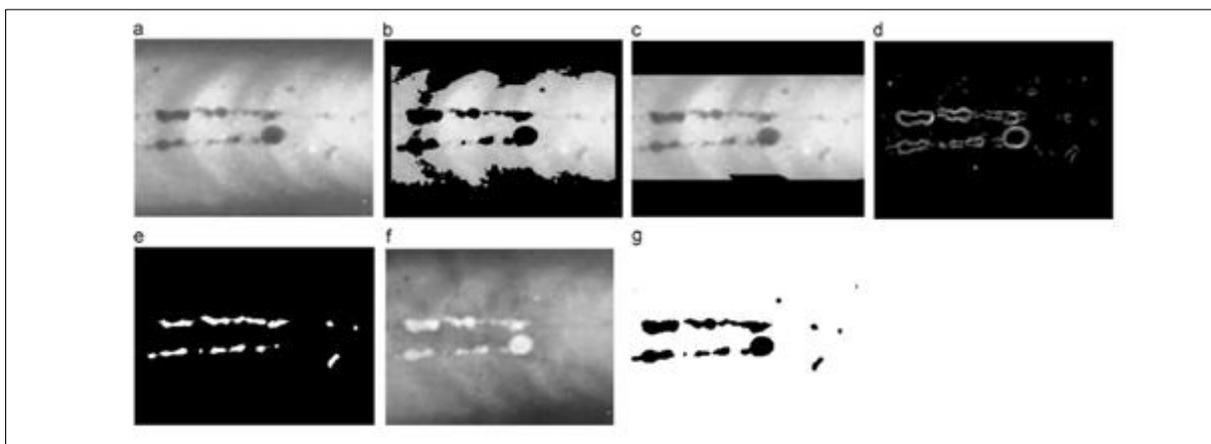


Figura 58 - Resultado do método de Yazid et al. (2011). (a) Imagem original testada, (b) imagem obtida por agrupamento *fuzzy*, (c) preenchimento de regiões, (d) detecção de bordas e limiarização, (e) detecção de vales e limiarização, (f) reconstrução inversa da superfície sobre a imagem original, (g) imagem final limiarizada.

Fonte: Adaptado de Yazid et al. (2011, p. 569).

3.2.14 Liling e Yangjie (2011)

Liling e Yangjie (2011) empregaram uma árvore de decisão para realizar a detecção dos defeitos de soldagem em 84 imagens radiográficas de recortes de cordões de solda contendo 63 defeitos. Primeiramente foi empregado o particionamento da imagem pelo algoritmo de corte mínimo (SHI; MALIK, 2000). Em seguida, foi definido o contorno de regiões, utilizando uma segmentação por difusão linear com critério de avaliação baseado em energia que consiste na avaliação individual de regiões a partir de um dado limiar para diferenciar as regiões com defeito e sem defeito.

O melhor resultado de detecção de defeitos foi com uma cobertura de 97,2%, porém, a quantidade de falsos positivos não foi informada. A Figura 59 ilustra a

aplicação do método com a imagem original, particionada e a detecção dos defeitos de soldagem. Apesar do bom desempenho do método proposto por Liling e Yangjie (2011), os próprios autores afirmaram que na prática é um grande desafio distinguir regiões com defeito (CD) e sem defeito (SD) com base apenas nos níveis de cinza ainda em decorrência de contaminações químicas e parâmetros impróprios de digitalização dos filmes radiográficos.

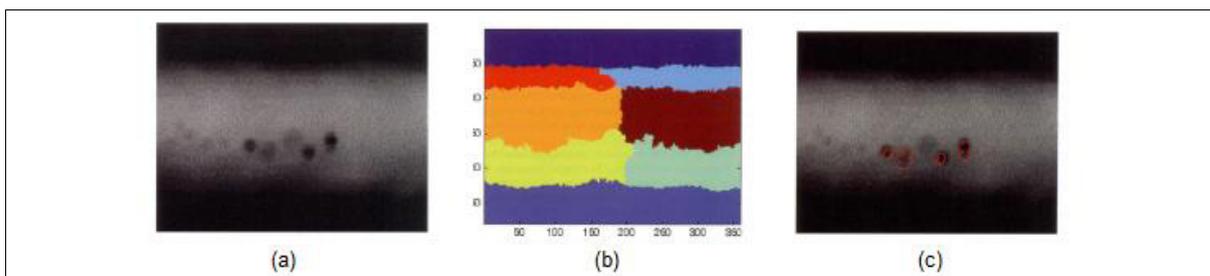


Figura 59 - Resultado do método de Liling e Yangjie (2011). (a) Imagem original, (b) resultado do particionamento por cortes mínimos, (c) resultado da detecção dos defeitos.

Fonte: Adaptado de Liling e Yangjie (2011, p. 268).

3.3 DETECÇÃO DE DEFEITOS COM VISTA DUPLA (PDVD)

3.3.1 Kroetz (2012)

Kroetz (2012) desenvolveu um sistema de apoio para a inspeção radiográfica de juntas soldadas. Este trabalho compreendeu a concepção de um método para a detecção automática dos cordões de solda em radiografias reais do tipo PDVD obtidas por diferentes sistemas de aquisição e fornecidas pela PETROBRAS. Além disso, incluiu uma abordagem baseada em técnicas de morfologia matemática para a detecção e realce de discontinuidades (possíveis defeitos) na região segmentada e o desenvolvimento de um *software* para o auxílio na inspeção radiográfica de juntas soldadas.

A segmentação do cordão de solda utilizando Algoritmos Genéticos (AG) e a Otimização por Enxame de Partículas (PSO) foi realizada com o objetivo de delimitar a região de busca por discontinuidades. Foi aplicada a operação *Bottom-Hat* para evidenciar as discontinuidades sobre a região do cordão de solda seguida por uma limiarização manual para controlar a quantidade de discontinuidades visíveis na

imagem final. A Figura 60 ilustra o exemplo de detecção de defeitos de soldagem pela aplicação de um limiar específico de 2500 para uma imagem com resolução de 16 bits. Em função das diferentes características das imagens tratadas o autor não obteve sucesso em adotar um método de limiarização padrão que obtivesse um bom desempenho para todo o conjunto de imagens. Dessa forma, foi necessário definir um limiar manualmente para cada imagem, o que não é desejável num sistema automático.

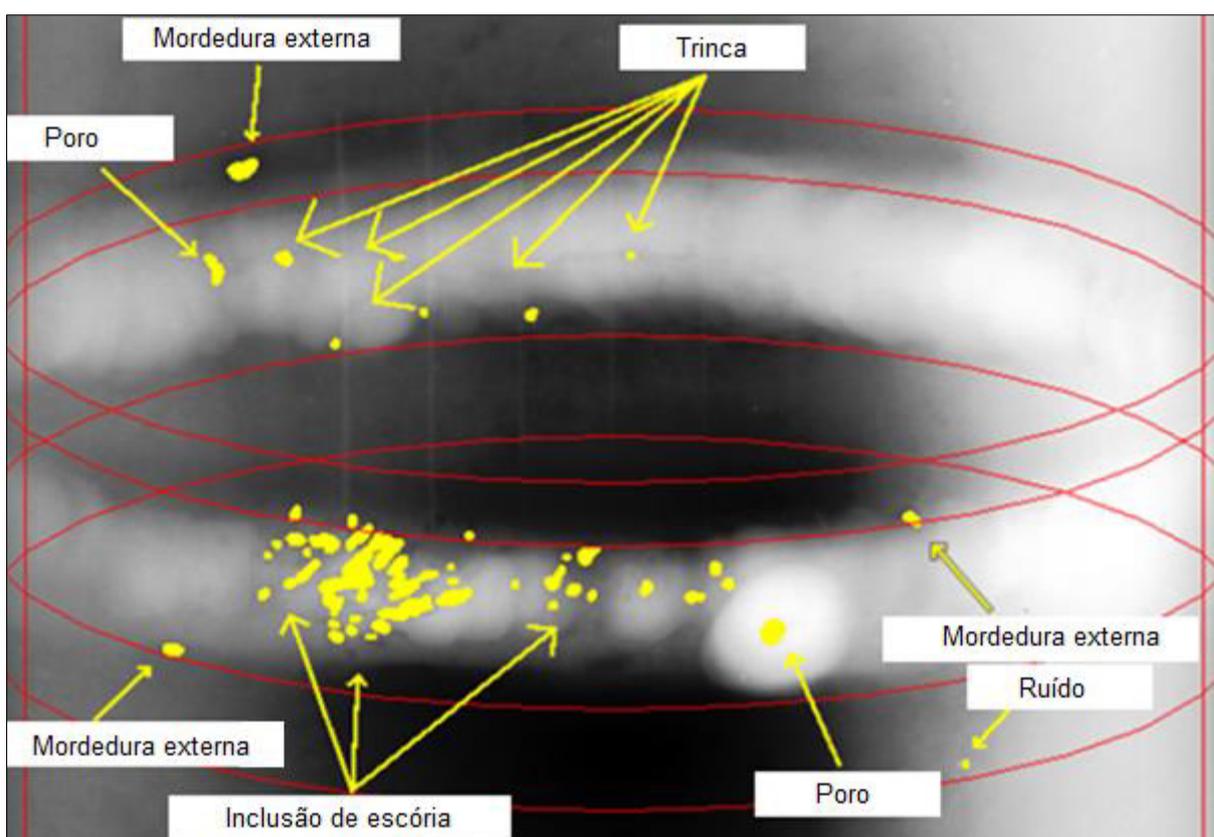


Figura 60 - Resultado do método de Kroetz (2012). Aplicação do filtro *Bottom-Hat*, limiar 2500 e defeitos identificados manualmente.

Fonte: Adaptado de Kroetz (2012, p. 99).

3.3.2 Fylyk e Centeno (2012)

Fylyk e Centeno (2012) apresentaram um método para a detecção de defeitos de soldagem em cordões de solda baseado em janelas por Redes Neurais Artificiais (RNA) de múltiplas camadas. Ao todo, foram utilizadas 22 imagens fornecidas pelo BAM (*Federal Institute for Materials Research and Testing*). A detecção do cordão de solda foi realizada pela abordagem apresentada por Kroetz (2012). As imagens

foram divididas em dois conjuntos: 11 imagens para o treinamento/validação e 11 para testes das redes. Um conjunto de 100 redes foi treinado através de amostras de defeitos e não-defeitos extraídas manualmente de janelas de 41x41 pixels das imagens do conjunto de treinamento/validação.

As 10 redes com melhores desempenhos realizaram a classificação de janelas obtidas através de amostras retiradas das imagens de teste. Contudo, apesar deste sistema ter apresentado uma cobertura de 100%, a precisão foi de apenas 37,5%, resultando em um *f-score* de 54,5%. Essa baixa precisão representou uma taxa superior de falsos positivos em relação aos verdadeiros positivos.

3.4 CONCLUSÕES

Após a análise individual das técnicas expostas nos trabalhos apresentados neste estado da arte, pode-se afirmar que há uma grande variação na qualidade das imagens tratadas. Tal variação de qualidade se dá principalmente pelas diferentes formas de exposição e aquisição radiográfica, características que afetam as imagens radiográficas em relação a três fatores: luminosidade, contraste e ruído. Essa variação da qualidade de imagem ocorre até em imagens adquiridas pelo mesmo sistema de aquisição radiográfico.

De uma forma geral, os trabalhos buscaram analisar irregularidades sobre as regiões de interesse (ROIs) com base em janelas, perfis e regiões. A Figura 58 ilustra um diagrama de blocos geral de caminhos que os métodos propostos na literatura geralmente seguem para a detecção de defeitos de soldagem, explorando: 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 atributos caso envolva um método de classificação para delimitar as regiões, janelas ou perfis de defeito sobre a ROI.

Dos trabalhos abordados neste capítulo sobre detecção de defeitos de soldagem em cordões de solda PDVD, apenas o trabalho de Fylyk e Centeno (2012) apresentou resultados quantitativos de detecção. Os trabalhos com resultados

quantitativos de detecção de defeitos de soldagem expostos no estado da arte são apresentados na Tabela 2. O método desenvolvido nesta dissertação é apresentado no próximo capítulo.

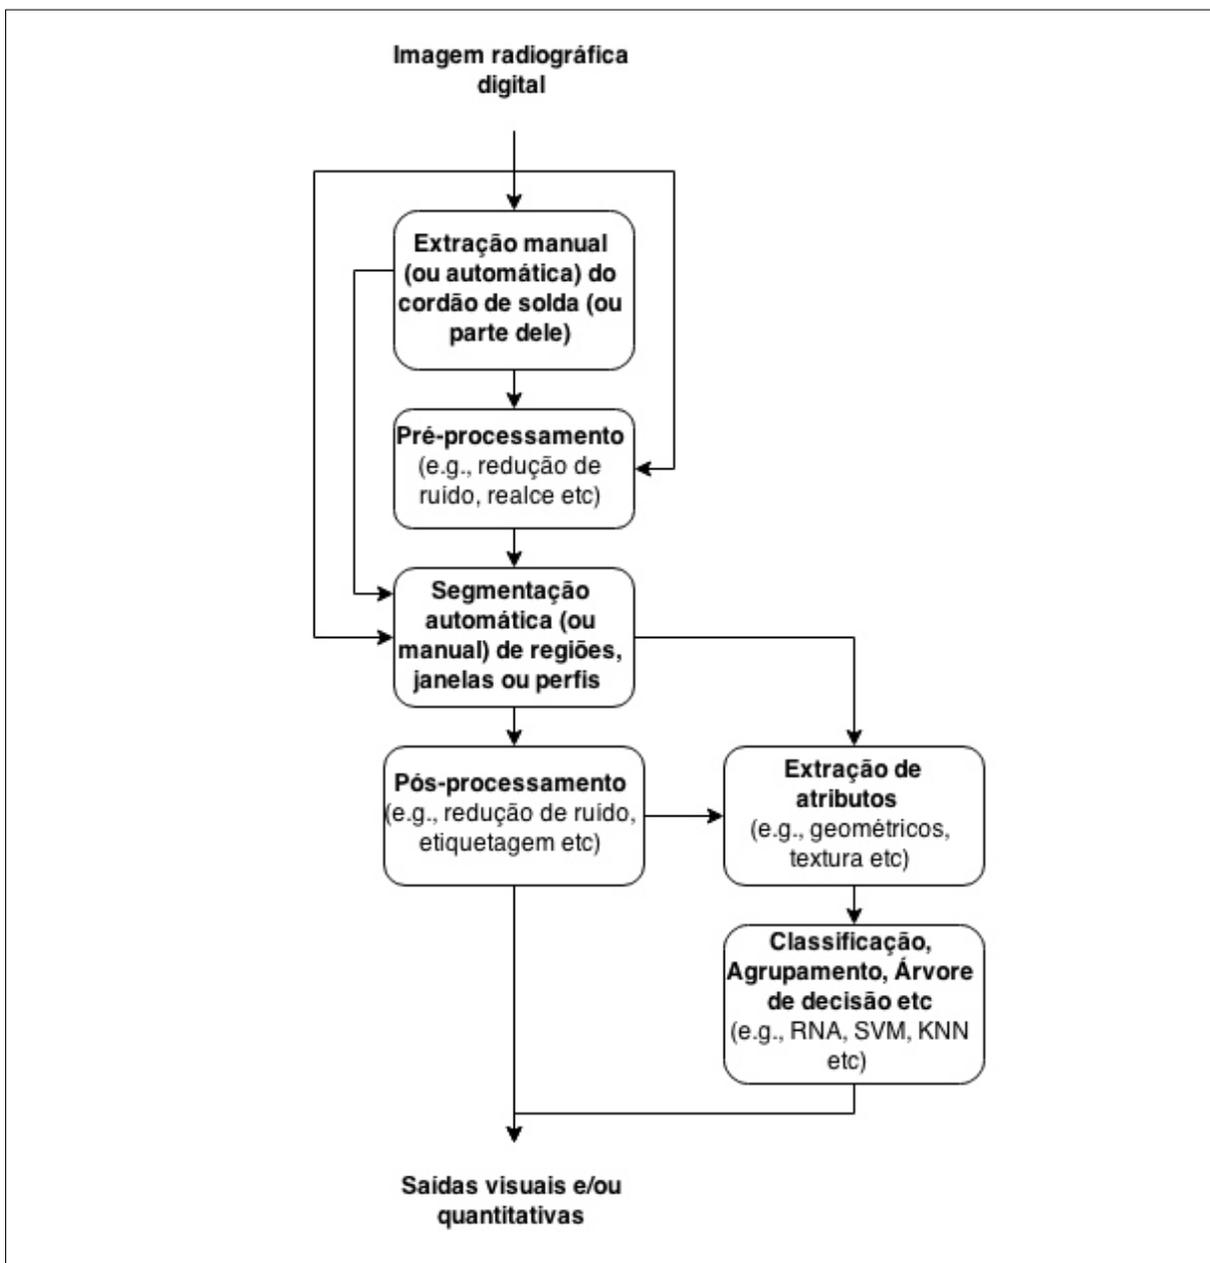


Figura 61 - Processo geral das técnicas de detecção de defeitos de soldagem.

Tabela 2 - Trabalhos com resultados quantitativos para a detecção de defeitos.

(continua)

Trabalho	Vista	ROIs	Defeitos	Método de classificação	Melhores resultados de detecção de defeitos
Liao e Li (1998)	Simples	24 juntas	75	-	95,91% de precisão; 93,33% de cobertura e 94,55% de <i>f-score</i>
Liao et al (1999)	Simples	18 juntas	75	Fuzzy KNN	81,32% de precisão; 93,99% de cobertura e 87,20% de <i>f-score</i>
Nacereddine et al. (2000)	Simples	-	104	RNA	96,00% de cobertura
Lashkia (2001)	Simples	117 janelas de 512x480 pixels	181	Fuzzy	97,79% de cobertura
Mery e Berti (2003)	Simples	1 junta	198	Polinomial, Mahalanobis e Vizinhança mais próxima	64,52% de precisão; 90,91% de cobertura e 74,47% de <i>f-score</i>
Carrasco e Mery (2004)	Simples	10 juntas	728	-	7,23% de precisão; 89,40% de cobertura e 13,37% de <i>f-score</i>
Padua (2004)	Simples	21 juntas	-	RNA ART	100% de cobertura para perfis sem defeito (SD)
Sun et al. (2005)	Simples	-	304	Fuzzy	99,34% de precisão; 99,67% de cobertura e 99,51% de <i>f-score</i>
Wang et al. (2008)	Simples	-	408	SVM	96,15% de cobertura
Vilar et al. (2009)	Simples	98 juntas	235	RNA MLP	Cobertura de 78,30% para as classes CD e 88,39% SD
Valavanis e Kosmopoulos (2010)	Simples	24 juntas	-	SVM, RNA e KNN	Cobertura de 82,14% das classes CD e 78,00% SD com SVM
Yazid et al. (2011)	Simples	60 juntas	-	Clustering (Agrupamento)	94,6% de cobertura

Tabela 2 - Trabalhos com resultados quantitativos para a detecção de defeitos.

(conclusão)

Trabalho	Vista	ROIs	Defeitos	Método de classificação	Melhores resultados de detecção de defeitos
Liling e Yangjie (2011)	Simple	84 juntas	63	Árvore de decisão	97,2% de cobertura
Fylyk e Centeno (2012)	Dupla	22 juntas	30 para teste	RNA	37,5% de precisão; 100% de cobertura e 54,5% de <i>f-score</i>

4 MATERIAIS E MÉTODOS

4.1 INTRODUÇÃO

O presente capítulo descreve as principais características dos materiais e métodos empregados no desenvolvimento desta dissertação. Além disso, este capítulo apresenta informações sobre as propriedades das imagens radiográficas com técnica de exposição PDVD não sobreposta empregadas e as técnicas desenvolvidas para auxiliar na detecção de defeitos de soldagem.

4.2 MATERIAIS

Neste trabalho, foram utilizadas 22 imagens radiográficas computadorizadas com técnica de exposição PDVD não sobreposta de juntas soldadas de tubulações de petróleo cedidas pelo Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello (CENPES). As imagens foram fornecidas na forma de negativos em arquivos no formato *Tagged Image File Format* (TIFF) com 65535 tons de cinza (16 bpp) e dimensões (largura x altura) variadas por se tratarem de recortes manuais (dimensão mínima de ≈ 1800 pixels e dimensão máxima de ≈ 5000 pixels).

Exemplos das imagens utilizadas são exibidos na Figura 62 com três regiões distintas em cada radiografia: o fundo em preto, o *image plate* (IP) em branco e a tubulação em níveis de cinza. A abordagem para a detecção de defeitos desenvolvida foi aplicada sobre o recorte manual de cada junta soldada PDVD não sobreposta. A Figura 63 ilustra exemplos de recortes de cordão de solda PDVD utilizados.



Figura 62 - Exemplos de radiografias computadorizadas.

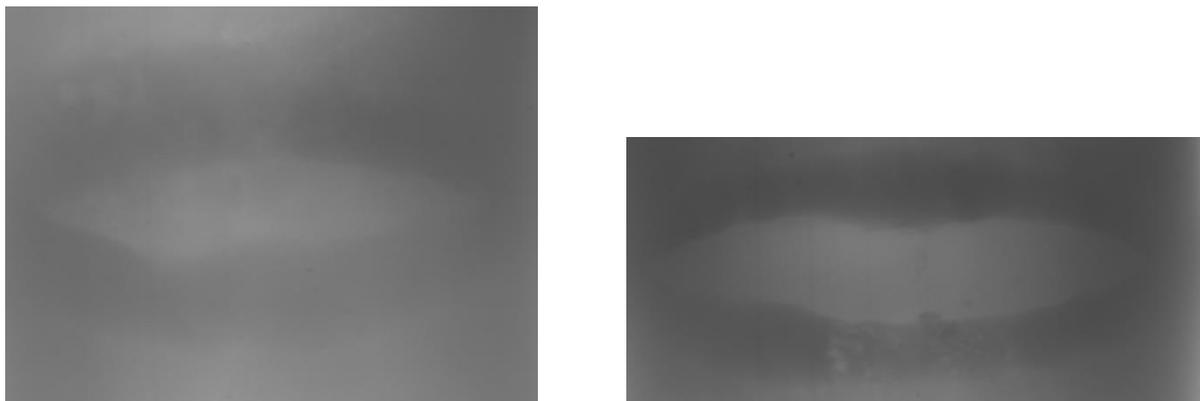


Figura 63 - Exemplos de recortes de cordão de solda PDVD utilizados.

4.3 MÉTODOS

A principal dificuldade encontrada ao se propor um método auxiliar para detecção de defeitos de soldagem neste trabalho é que as imagens empregadas foram obtidas a partir de condições reais de operação. Por esse motivo, tais imagens não apresentaram um padrão em relação às dimensões da junta soldada, região de interesse (ROI), sendo afetadas por parâmetros distintos de captura e digitalização como: ângulo de captura, distâncias empregadas no procedimento de exposição radiográfica, o posicionamento do detector *Image Plate* (IP), quantidade de radiação e tempo de exposição. Essa grande variação de parâmetros afetou não somente as dimensões das ROIs tratadas, mas também gerou diferentes níveis de luminosidade, ruído e contraste.

O método desenvolvido foi estruturado em duas etapas principais: detecção de discontinuidades (seção 4.3.1) e classificação (seção 4.3.2). A etapa de detecção de discontinuidades segmentou regiões de defeitos em potencial sobre a imagem do cordão de solda PDVD que foram utilizadas na etapa seguinte de classificação na qual se empregou redes MLP, realizando a detecção de defeitos de soldagem.

4.3.1 Detecção de descontinuidades

A etapa de detecção de descontinuidades objetivou segmentar regiões de defeitos em potencial, gerando uma máscara binária (M) empregada na etapa de classificação (seção 4.3.2). Esta etapa utilizou quatro procedimentos principais:

- Realce (seção 4.3.1.1).
- Segmentação de descontinuidades (seção 4.3.1.2).
- Geração da máscara da região central (seção 4.3.1.3).
- Redução do espaço de busca (seção 4.3.1.4).

4.3.1.1 Realce

O procedimento de realce buscou tornar as regiões de defeitos de soldagem mais evidentes de forma a privilegiar a extração de informações sobre regiões da imagem onde não havia diferenças significativas de luminosidade.

Primeiramente, como as imagens tratadas neste trabalho provêm de radiografias que invertem os níveis de cinza, tais imagens foram invertidas, permitindo a visualização tradicional de imagens radiográficas em que a região da junta soldada se apresenta em níveis de cinza mais claros em relação ao material soldado (Figura 64 (a)). Em seguida um filtro da mediana 5x5 foi aplicado com o intuito de reduzir ruídos com essas dimensões. Na imagem resultante, uma sequência de operações morfológicas definidas na equação (67) foi aplicada, onde T_{hat} = operação *Top-Hat* e B_{hat} = operação *Bottom-Hat*, utilizando um elemento estruturante (ee) discoide de raio 32 para evidenciar objetos com essas dimensões.

$$J = J + T_{hat}(J, ee) - B_{hat}(J, ee) \quad (67)$$

Essa operação foi repetida por três vezes consecutivas, proporcionando um realce gradativo das imagens tratadas como apresentado na Figura 64 em I (b) e II (c), resultando na imagem realçada final III (d). A imagem realçada final (J) foi utilizada no procedimento de segmentação de descontinuidades.

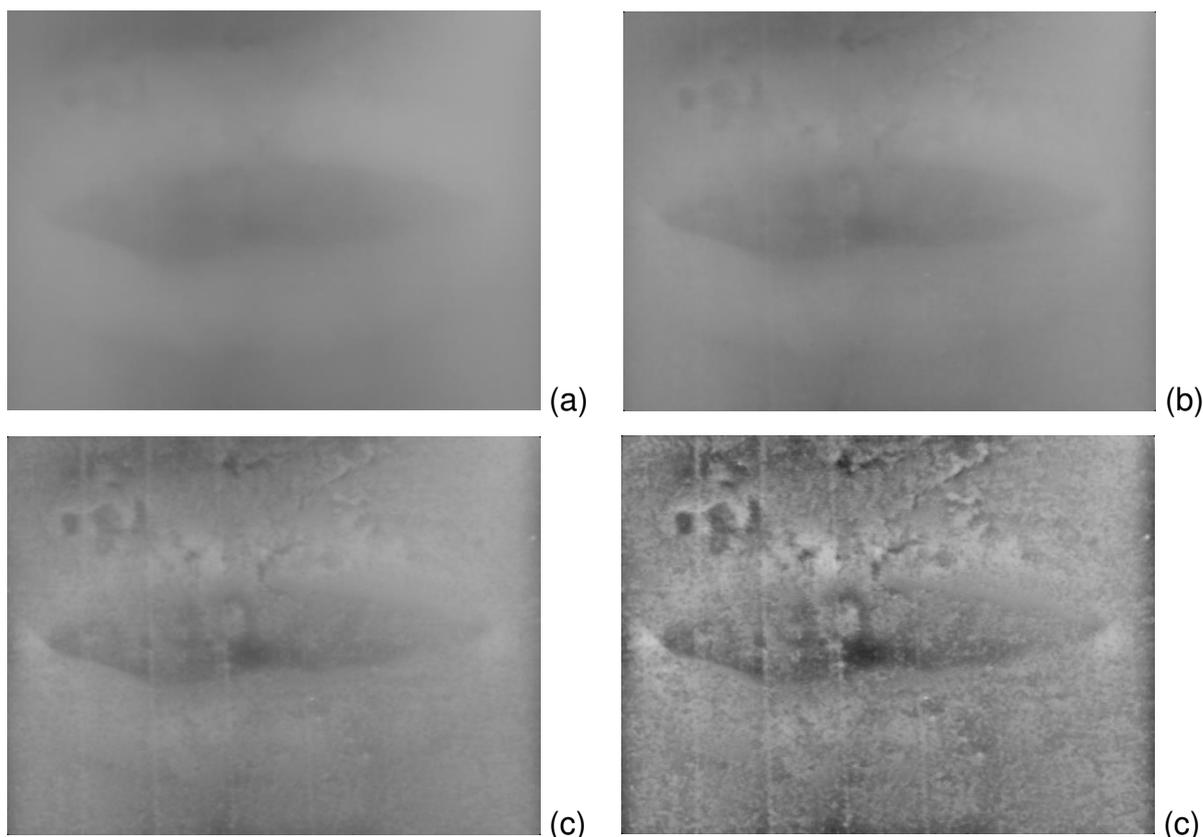


Figura 64 - Procedimento de realce. (a) Negativo da imagem original, (b) imagem realçada I, (c) imagem realçada II, (d) imagem realçada III final.

4.3.1.2 Segmentação de descontinuidades

O procedimento de segmentação de descontinuidades evidenciou regiões internas e externas ao cordão de solda a partir da imagem realçada (*J*) (Figura 65 (a)), gerando uma imagem binária (*K*) (Figura 65 (d)) com as regiões segmentadas.

Este procedimento tratou da segmentação dessas regiões por limiarização global e, para garantir um limiar fixo aplicável a todas às imagens utilizadas, as imagens foram tratadas visando à normalização dos níveis de cinza. Tal procedimento foi aplicado em três passos principais:

- Suavização.
- Aprimoramento do contraste.
- Limiarização global.

A suavização foi realizada pela aplicação de uma abertura por reconstrução seguida de uma abertura morfológica, definida na equação (68) e ilustrada na Figura

65 (b), reduzindo a quantidade de ruídos. A abertura por reconstrução restaurou a forma dos objetos após a erosão, empregando a imagem realçada (J) (Figura 65 (a)) e um elemento estruturante discoide (B_d) com raio de tamanho 7. Após a aplicação da abertura por reconstrução, uma operação de abertura morfológica sobre a imagem resultante foi utilizada para reduzir a ocorrência de picos causados por Indicadores de Qualidade de Imagem (IQIs) verticais com formato linear presentes sobre a região do cordão de solda através de um elemento estruturante retangular (B_r) 7x15 (dimensão aproximada para a redução dos IQIs).

$$K = O_R^{(n)}(J) \circ B_r \quad (68)$$

Na qual:

\circ = operação de abertura morfológica

$O_R^{(n)}(J)$ = operação de abertura por reconstrução de J por B_d .

O aprimoramento do contraste consistiu na aplicação de uma filtragem *High-boost* para realçar a imagem, um filtro da mediana 8x8 para eliminar ruídos não removidos pelo procedimento anterior de suavização e uma expansão de histograma para que toda faixa dinâmica dos níveis de cinza fosse utilizada (Figura 65 (c)), permitindo a normalização das imagens antes da limiarização. A filtragem *High-boost* empregou uma imagem suavizada (K_s) gerada pela aplicação do filtro da média 42x42 na imagem K , diferindo de sua definição clássica por apresentar inversão de operadores na subtração de imagens ($K_s - K$), tal filtragem é descrita pela equação (69), onde o peso foi definido empiricamente como $k = 7$.

$$K = K + k(K_s - K) \quad (69)$$

A limiarização global foi empregada para a obtenção da imagem binária K , ilustrada na Figura 65 (d), com a segmentação de regiões internas e externas ao cordão de solda. O mesmo valor de limiar foi definido empiricamente em 5% da

escala de cinza ($T = 0,05 \cdot (2^{bpp} - 1)$) e adotado para todas as imagens por garantir a maior cobertura e o melhor formato dos defeitos de soldagem.

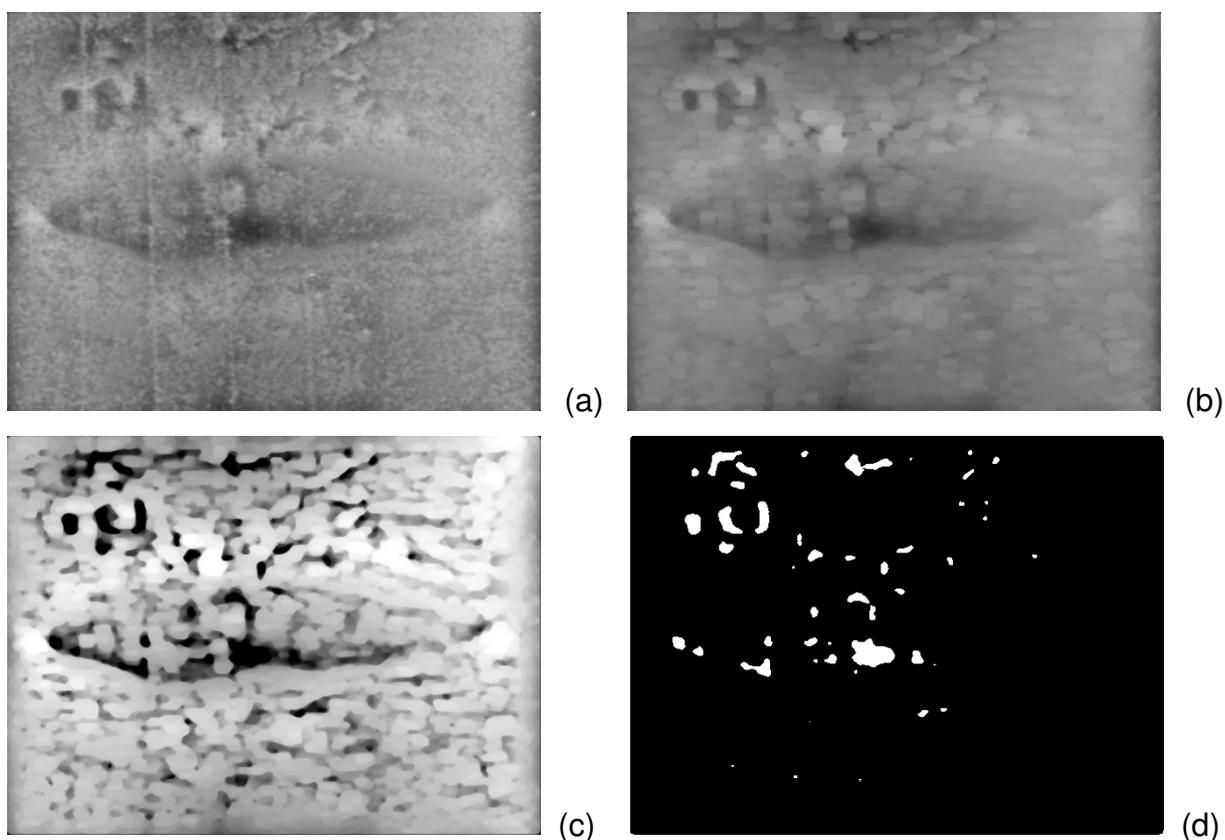


Figura 65 - Procedimento de segmentação de discontinuidades. (a) Imagem realçada, (b) suavização, (c) aprimoramento do contraste, (d) limiarização resultando na imagem com discontinuidades segmentadas.

4.3.1.3 Geração da máscara da região central

A região elipsoidal interna formada pela imagem radiográfica do cordão de solda do tipo PDVD não sobreposto, denominada aqui de região central do cordão de solda, não faz parte da junta soldada. Sendo assim, foi considerado interessante reduzir o espaço de busca ao excluir essa região da detecção de defeitos de soldagem. Neste sentido, este procedimento tratou da obtenção de uma máscara binária (L) com a região central do cordão de solda segmentada para ser empregada no procedimento de redução do espaço de busca (seção 4.3.1.4). Este procedimento foi baseado nos trabalhos de Suyama et al. (2013; 2015), diferindo pelo espaço de busca reduzido (limitado à janela da junta soldada) e pela seleção do

maior objeto conexo na decisão de qual objeto corresponde à região central do cordão de solda PDVD não sobreposto.

A geração da máscara da região central consistiu na aplicação de três passos principais:

- Aprimoramento do contraste.
- Limiarização global e redução de ruídos.
- Detecção da região central e correção de contorno.

O aprimoramento do contraste permitiu evidenciar a região central do cordão de solda PDVD além de outras regiões pela subtração da imagem original por uma imagem estimada do fundo. A imagem estimada do fundo (I^C_S) foi obtida pela aplicação de um filtro da média 100x100 na imagem I^C (negativo da imagem original I). O resultado foi ponderado por um peso $k = 1000$ conforme definido na equação (70). Neste passo, o valor elevado do peso k causou a saturação dos pixels em tons no máximo e no mínimo da escala de cinza, tornando a imagem praticamente binária conforme ilustrada na Figura 66 (b). A saturação da imagem permitiu a fixação de um limiar para o passo seguinte de limiarização global.

$$L = k * (I^C_S - I^C) \quad (70)$$

A limiarização global segmentou objetos para a detecção da região central através de um limiar em 50% da escala de cinza ($T = 0,5 \cdot (2^{bpp} - 1)$) a partir da imagem L^C . Contudo, além da região central outras regiões que correspondem a ruídos acabaram sendo evidenciadas. Para a redução de ruídos, um fechamento morfológico seguido de uma erosão foram aplicados com os elementos estruturantes (ee) discoides de raios 3 e 7 respectivamente, definida na equação (71). Na imagem resultante foi aplicada uma técnica de reconstrução por dilatação conhecida como “preenchimento de buracos” (descrita na seção 2.3.8.2) para preencher os buracos dos objetos.

$$L = (L \cdot ee_{discoide\ 3}) \ominus ee_{discoide\ 7} \quad (71)$$

O terceiro, e último passo, tratou da segmentação da região central da junta soldada PDVD pela etiquetagem dos objetos obtidos no passo anterior e pela seleção do objeto que apresentou a maior área, removendo os demais objetos da imagem. Visando corrigir o contorno da região central do cordão de solda, aplicou-se uma abertura com elemento estruturante (ee) linear 1x42, seguida de uma dilatação e um fechamento com os elementos estruturantes (ee) discoides de raios 9 e 42 respectivamente, tais operações são definidas na equação (72).

$$L = ((L \circ ee_{linear\ 1x42}) \oplus ee_{discoide\ 9}) \bullet ee_{discoide\ 42} \quad (72)$$

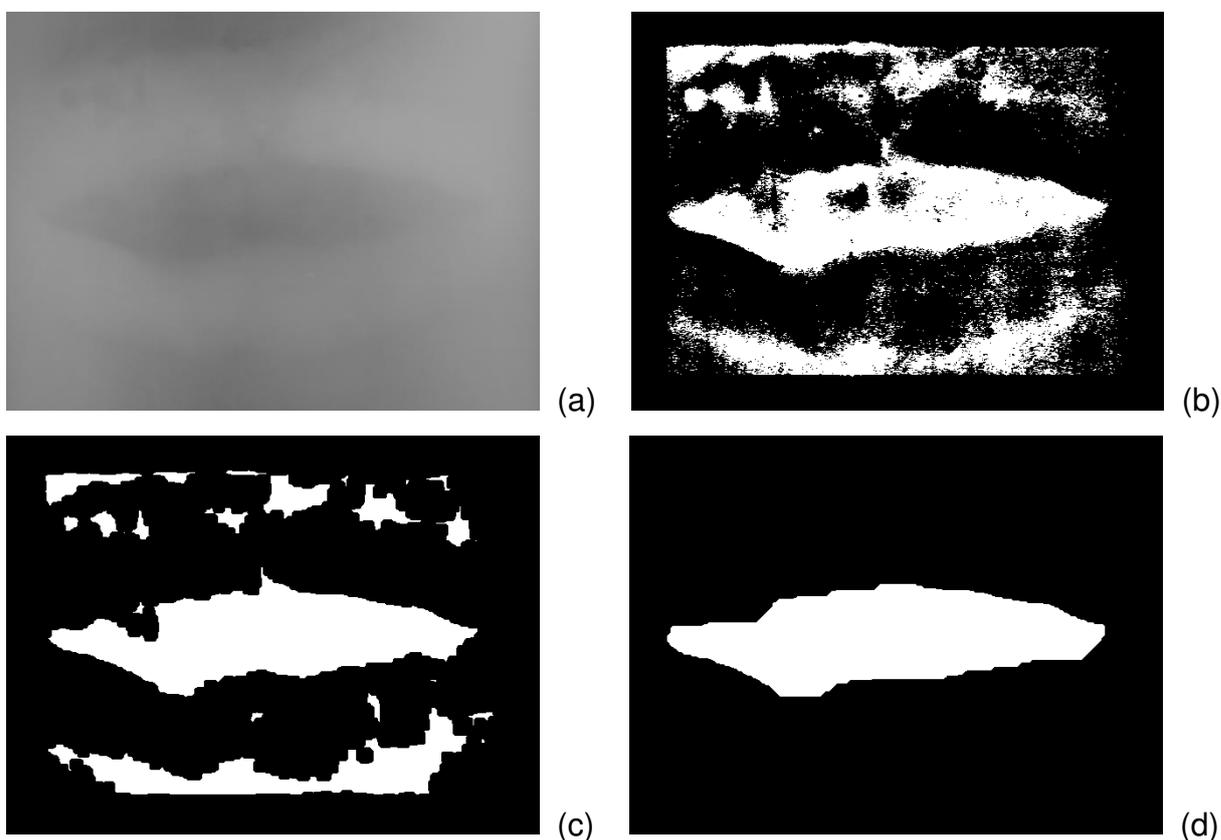


Figura 66 - Procedimento de geração da máscara da região central. (a) Negativo da imagem original, (b) resultado após a subtração do fundo estimado, (c) limiarização e redução de ruído, (d) detecção da região central e correção de contorno resultando na máscara da região central do cordão de solda.

4.3.1.4 Redução do espaço de busca

A redução do espaço de busca, definido pela equação (73), foi realizado pela subtração de discontinuidades da imagem K (Figura 67 (a)) através da região central definida pela máscara (L) (Figura 67 (b)), objetivando a eliminação das discontinuidades completamente inscritas na região central do cordão de solda, que como já observado anteriormente, não constituem defeitos.

Ao executar tal procedimento os objetos conectados às margens das imagens também foram removidos devido à última operação de “limpeza de bordas” aplicada na equação (73). Apesar disso, os defeitos de soldagem não foram perdidos, pois as regiões de interesse (ROIs) que correspondem aos cordões de solda PDVD não se encontravam posicionados sobre as bordas das imagens. A imagem resultante da redução do espaço de busca é ilustrada na (Figura 67 (c)).

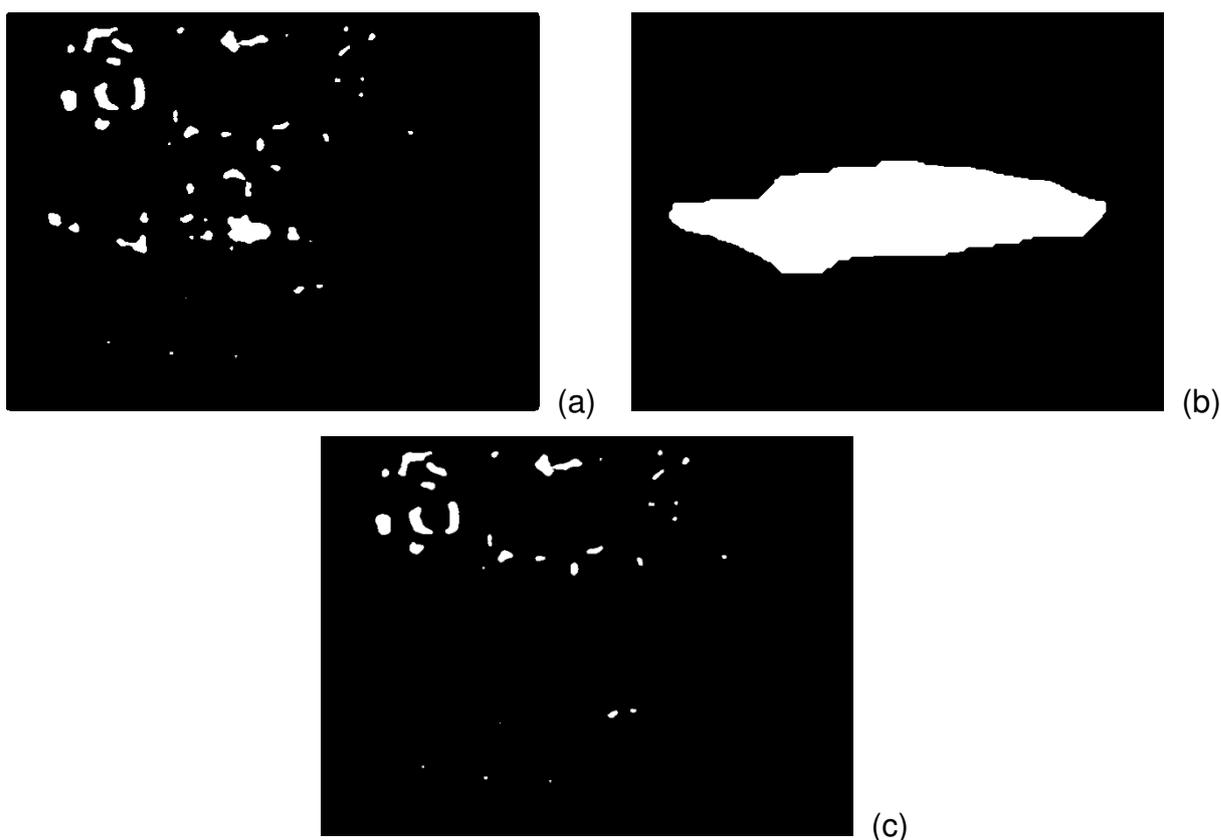


Figura 67 - Procedimento de redução de discontinuidades. (a) Imagem com discontinuidades segmentadas, (b) região central do cordão de solda, (c) imagem resultante da redução do espaço de busca.

$$M = l_{bor}(K - l_{bor}((K - L)^C)) \quad (73)$$

Na qual:

l_{bor} = operação de “limpeza de bordas” descrita na seção 2.3.8.2

X^C = operação de negativo da imagem X .

4.3.2 Classificação

A etapa de classificação foi realizada por redes MLP com o objetivo de identificar as descontinuidades detectadas (seção 4.3.1) em duas classes: com defeito (CD) e sem defeito (SD). Para tanto, quatro procedimentos que definiram a estrutura e utilização de tais redes são apresentados com base na:

- Coleta e tratamento de dados (seção 4.3.2.1).
- Separação de conjuntos (seção 4.3.2.2).
- Configuração da rede neural (seção 4.3.2.3).
- Treinamento e teste (seção 4.3.2.4).

4.3.2.1 Coleta e tratamento de dados

A coleta de dados de entrada-saída ($x-t$) para o treinamento supervisionado das redes MLP consistiu na extração de atributos (definição de entradas x) e na discriminação da classe de saída (t) de cada região descontinuidade obtida na etapa anterior de detecção de descontinuidades (seção 4.3.1).

Sem diferenciar os tipos de defeitos de soldagem, tais regiões foram etiquetadas e discriminadas manualmente em duas classes (t): com defeito (CD) ou sem defeito (SD) de soldagem às quais foram atribuídas, respectivamente, os valores 1 e 0.

Após esta discriminação de classes, foi considerada e analisada a extração de dez atributos de cada descontinuidade detectada para a definição do número de entradas (x) das redes MLP: área (A), perímetro (P), entropia (E), bem como, os sete

momentos invariantes à escala, rotação e translação descritos por Hu (1962) (ϕ_1 , ϕ_2 , ϕ_3 , ϕ_4 , ϕ_5 , ϕ_6 e ϕ_7) (Tabela 3). Os cálculos de P e ϕ_1 , ϕ_2 , ϕ_3 , ϕ_4 , ϕ_5 , ϕ_6 e ϕ_7 foram realizados considerando que a região de referência foi dilatada por um elemento estruturante discoide de diâmetro 5 para incluir informações do contorno.

Entretanto, devido aos valores extremamente baixos (bem próximos de zero) obtidos pelos cálculos dos momentos invariantes ϕ_2 , ϕ_3 , ϕ_4 , ϕ_5 , ϕ_6 e ϕ_7 em relação aos demais atributos que afetaram negativamente a separabilidade do espaço de busca, apenas os quatro atributos restantes (ϕ_1 , A , P e E) foram utilizados como entrada (x) das redes MLP.

Os dados de entrada-saída ($x-t$) obtidos das regiões de descontinuidades foram processados para a verificação e o tratamento da ocorrência de contradição e redundância. Neste caso, dados com classes de saída contraditórias (dados com atributos x iguais e classes de saída t conflitantes), o dado que representasse a classe de saída CD seria mantido e o dado da classe SD seria removido do processo de aprendizado a fim de diminuir o número de falsos negativos na detecção de defeitos. Por exemplo, se $x_1 = \{-0,1; 0,5; 0,1; 0,2\}$; $t_1 = \{1\}$; $x_2 = \{-0,1; 0,5; 0,1; 0,2\}$ e $t_2 = \{0\}$, o dado x_1-t_1 seria mantido e o dado x_2-t_2 seria eliminado, prevalecendo o dado com a classe CD ($t_1 = \{1\}$).

Além disso, dados redundantes (dados com atributos x e classes de saída t iguais) deveriam ser eliminados, restando apenas uma das ocorrências dos dados repetidos para o treinamento da rede. Essa operação foi realizada com o intuito de evitar que o processo de treinamento se tornasse tendencioso pela ocorrência de conjuntos de dados com dados idênticos entre si (e.g., conjunto de treinamento com o mesmo dado presente nos conjuntos de validação e/ou teste). Por exemplo, se $x_1 = \{-0,1; 0,5; 0,1; 0,2\}$; $t_1 = \{1\}$; $x_2 = \{-0,1; 0,5; 0,1; 0,2\}$ e $t_2 = \{1\}$; apenas um dos dados x_1-t_1 ou x_2-t_2 seria utilizado.

Todos os atributos de entrada (x) foram normalizados no intervalo -1 e 1 para adaptá-los à faixa dinâmica das funções de ativação do tipo tangente hiperbólica das redes MLP empregadas. A configuração das redes MLP empregadas neste trabalho é descrita na seção 4.3.2.2.

Tabela 3 - Atributos extraídos e avaliados de cada região de defeito em potencial.

Símbolo	Definição
A	área (quantidade de pixels que compõem a região)
P	perímetro (quantidade de pixels que compõe o contorno da região)
E	entropia ($E = -\sum_{i=1} p_i \log_2(p_i)$), onde p_i é a frequência da intensidade i
ϕ_1	$\phi_1 = n_{20} + n_{02}$
ϕ_2	$\phi_2 = (n_{20} - n_{02})^2 + 4n_{11}^2$
ϕ_3	$\phi_3 = (n_{30} - 3n_{12})^2 + (3n_{21} - n_{03})^2$
ϕ_4	$\phi_4 = (n_{30} - n_{12})^2 - (n_{21} - n_{03})^2$
ϕ_5	$\phi_5 = (n_{30} - 3n_{12})(n_{30} + n_{12})[(n_{30} + n_{12})^2 - 3(n_{21} + n_{03})^2]$ $+ (3n_{21} - n_{03})(n_{21} + n_{03})[3(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2]$
ϕ_6	$\phi_6 = (n_{20} - n_{02})[(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2] + 4n_{11}(n_{30} + n_{12})(n_{21} + n_{03})$
ϕ_7	$\phi_7 = (3n_{21} - n_{03})(n_{30} + n_{12})[(n_{30} + n_{12})^2 - 3(n_{21} + n_{03})^2]$ $+ (n_{30} - 3n_{12})(n_{21} + n_{03})[3(n_{30} + n_{12})^2 - (n_{21} + n_{03})^2]$

4.3.2.2 Configuração da rede neural artificial

O paradigma neural adotado foi do tipo *Perceptron* de múltiplas camadas, *Multilayer Perceptron* (MLP), com topologia composta por três camadas distintas (Figura 68): entrada, oculta e saída. Como definido no procedimento de coleta de dados, foram utilizados quatro sinais (entradas x) na camada de entrada da rede. A quantidade de neurônios na camada oculta foi definida em seis conforme apresentado no capítulo 5. A quantidade de neurônios na camada de saída foi fixada em um, pelo fato da saída do sistema ser binária, representando as classes de saída (t) com defeito (CD) e sem defeito (SD).

As funções de ativação empregadas deveriam ser deriváveis para que o algoritmo de treinamento fosse utilizado. Portanto, os neurônios da camada oculta empregaram uma função de ativação do tipo tangente hiperbólica (saída entre -1 e 1) e o único neurônio na camada de saída utilizou uma função de ativação sigmóide logística (saída entre 0 e 1). A função tangente hiperbólica foi empregada, pois é uma função de ativação comumente empregada em nodos de camadas ocultas em redes MLP. A função de ativação sigmóide logística foi utilizada por permitir o mapeamento das classes de saída rede. A forma de separação do conjunto de dados é apresentada na seção 4.3.2.3.

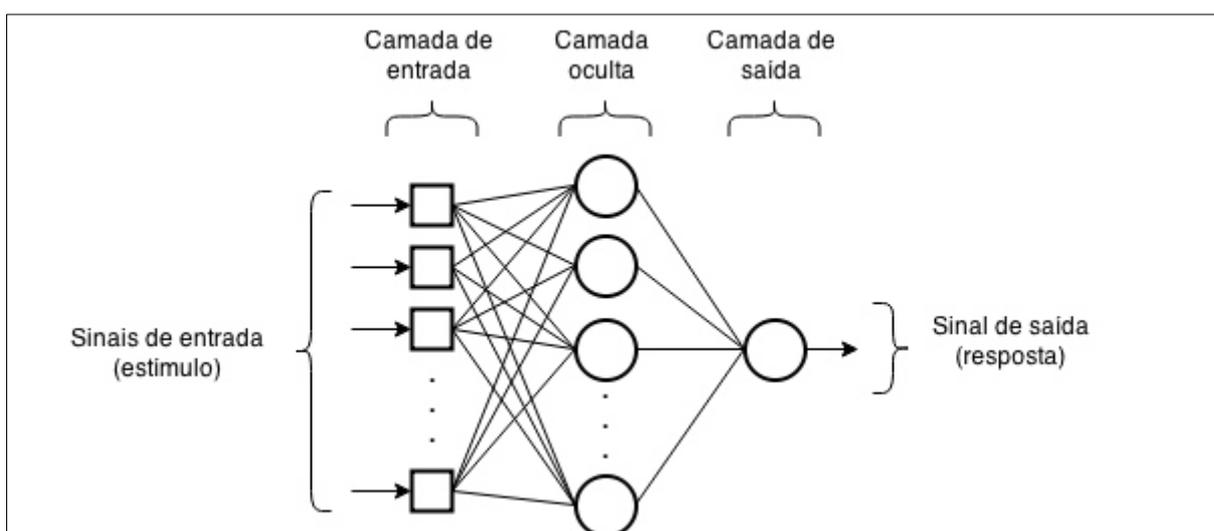


Figura 68 - Configuração da rede MLP.

4.3.2.3 Separação de conjuntos

Os dados coletados para as rotinas de treinamento das redes foram separados de forma aleatória em quantidades proporcionais de cada classe de saída da rede (CD e SD), resultando em três conjuntos de dados distintos em:

- **Treinamento** (70% dos dados): aplicado para o ajuste dos pesos da rede.
- **Validação do treinamento** (15% dos dados): empregado para a análise de desempenho e, por conseguinte, como critério de parada do algoritmo de treinamento na busca da generalização da rede.
- **Validação da configuração da RNA** (15% dos dados): utilizado para a análise do impacto da variação do número de neurônios na camada oculta da rede.

Essa distribuição aleatória de dados ($x-t$) e equilibrada de classes de saída (t) (CD e SD) entre os conjuntos de dados a cada rotina de treinamento objetivou aperfeiçoar a capacidade de generalização do conhecimento adquirido pela rede, evitando privilegiar conjuntos específicos de dados. As rotinas de treinamento e teste são descritas na seção 4.3.2.4.

4.3.2.4 Treinamento e teste

Os recortes de juntas soldadas PDVD foram separados em dois grupos de imagens com 11 imagens cada: um grupo para o treinamento das redes e outro grupo para testar as melhores redes obtidas. O algoritmo empregado para o treinamento das redes MLP foi o de Gradiente Conjugado Escalonado (*Scaled Conjugate Gradient*) (SCG). O método adotado para o cálculo de desempenho foi o de erro quadrático médio (MSE). Os critérios de parada utilizados pelo algoritmo de treinamento foram:

- número máximo de épocas = 1000,
- desempenho minimizado até o valor 0,
- gradiente de desempenho $< 10^{-6}$,

- se o desempenho do conjunto de validação cresceu mais de 6 vezes desde a última vez que decresceu.

A variação do número de nodos na camada oculta da rede foi testada para 8 valores diferentes (4 a 11 nodos na camada oculta). A cada configuração da rede testada foram selecionadas as dez redes com os melhores desempenhos de um total de mil redes criadas. O cálculo do desempenho de cada rede obtida foi realizado pelo MSE para os conjuntos de validação da configuração da RNA.

Esta rotina foi empregada pelo fato dos resultados obtidos a cada rotina de treinamento diferirem pelo carácter estocástico de inicialização dos pesos da rede e de distribuição dos dados entre os conjuntos de dados utilizados. Dessa forma, a obtenção do resultado médio de classificação buscou reduzir problemas de associação de ordem de apresentação dos dados.

Conforme apresentado no capítulo 5, as dez melhores redes obtidas a partir das imagens de treinamento utilizaram 6 nodos na camada oculta. A aplicação desse conjunto de redes ao grupo de imagens de teste foi realizada para 10 combinações distintas de redes (1 a 10 redes). Assim, uma descontinuidade foi classificada como defeito de soldagem se a média das saídas das redes fosse superior a um limiar definido de forma empírica.

4.4 CONSIDERAÇÕES FINAIS

Todas as rotinas do método proposto e apresentado neste capítulo foram implementadas no programa *Matlab*, em plataforma *Windows 7*. Tal método foi desenvolvido e testado em imagens radiográficas computadorizadas de juntas soldadas de tubulações de petróleo com técnica de exposição do tipo PDVD não sobreposta. Os resultados são apresentados e discutidos no próximo capítulo.

5 RESULTADOS E DISCUSSÃO

5.1 INTRODUÇÃO

Neste capítulo, são expostas as análises dos resultados, bem como, as considerações do método proposto e desenvolvido.

5.2 ETAPA DE DETECÇÃO DE DESCONTINUIDADES

A etapa de detecção de descontinuidades foi capaz de evidenciar cinco tipos de defeitos de soldagem existentes nos 22 recortes de juntas soldadas PDVD não sobreposta conhecidos como: Porosidade (PO), Trinca (TR), Inclusão de Tungstênio (IT), Falta de Fusão (FF) e Mordedura (MO). O procedimento proposto de geração da máscara da região central obteve 100% de acerto em todas as imagens utilizadas, com contornos bem definidos. Não houve perda na detecção de defeitos de soldagem pela aplicação do procedimento de redução do espaço de busca, pois apenas descontinuidades completamente inscritas na região central do cordão de solda e posicionadas na borda da imagem que não constituíam defeitos foram removidas.

5.3 ETAPA DE CLASSIFICAÇÃO

Todas as descontinuidades obtidas a partir do grupo de imagens utilizado para o treinamento das redes foram discriminadas como regiões com defeito (CD) ou sem defeito (SD), sendo 54,91% (95/173) da classe CD e 45,09% (78/173) da classe SD. Após a definição de classes, a extração de atributos foi realizada e permitiu observar que os dados de entrada-saída ($x-t$) da rede quando comparados entre si não apresentaram a ocorrência de redundância (dados com atributos x e classes de saída t iguais) nem contradição (dados com atributos x iguais e classes de saída t distintas). Deste modo, nenhum dado de entrada-saída ($x-t$) da rede necessitou ser removido. Como estes dados permaneceram inalterados, as proporções das classes CD e SD se mantiveram.

A Figura 69 ilustra a separabilidade do espaço de busca do problema tratado por meio de quatro gráficos em relação à área (A), ao perímetro (P), à entropia (E) e ao primeiro momento invariante (ϕ_1), justificando a abordagem do problema através de redes MLP por não se tratar de um problema linearmente separável. Tais gráficos apresentam possíveis configurações de distribuição espacial de discontinuidades CD e SD provenientes do grupo de imagens utilizadas para os treinamentos das redes. Os valores de cada atributo são apresentados de forma normalizada entre 1 e -1, ou seja, os valores de máximo e mínimo de cada atributo foram convertidos à esta escala na qual os dados ($x-t$) foram repassados para as redes.

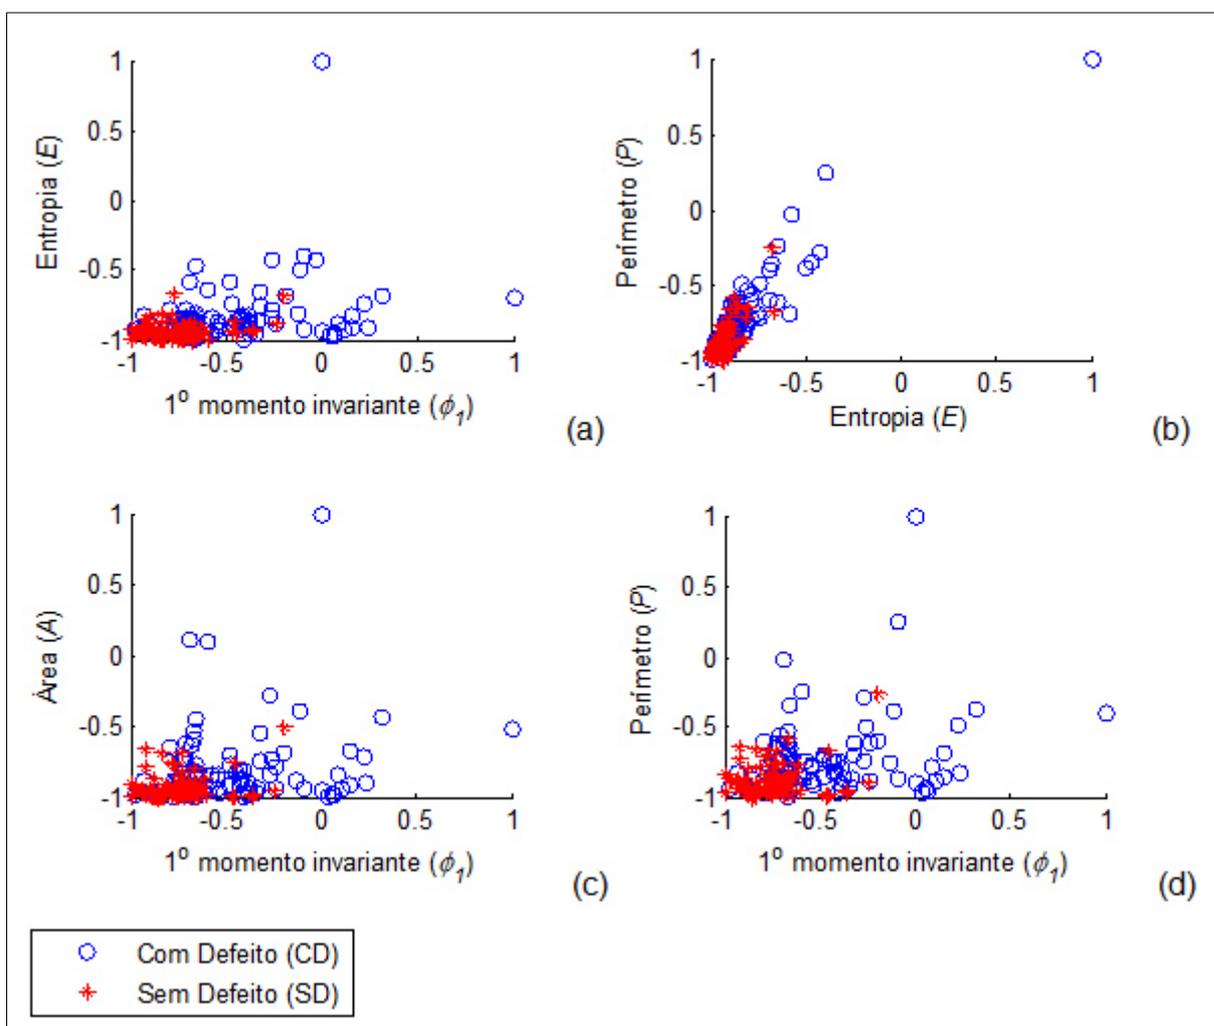


Figura 69 - Separabilidade do espaço de busca. (a) Entropia x 1º momento invariante, (b) Perímetro x Entropia, (c) Área x 1º momento invariante, (d) Perímetro x 1º momento invariante.

Os desempenhos médios de classificação, apresentados na Tabela 4, foram obtidos com base na diminuição do erro quadrático médio (MSE) para o conjunto de dados de validação da configuração da RNA. Ao todo, foram criadas e testadas 1000 redes para cada valor de número de nodos na camada oculta, variando de 4 a 11 nodos na camada oculta. O melhor resultado obtido foi com 6 nodos na camada oculta.

Tabela 4 - Desempenho médio para os conjuntos de validação de configuração das RNAs.

Número de nodos na camada oculta	Desempenho médio (1 - MSE) %
4	91,17
5	92,14
6	<u>92,51</u>
7	91,57
8	91,23
9	91,32
10	91,41
11	91,34

Assim, as 10 melhores redes obtidas na fase de treinamento com 6 nodos na camada oculta foram aplicadas para as imagens do grupo de teste. Os resultados de detecção para 10 combinações diferentes de redes neurais são apresentados na Tabela 5 para o maior valor de *f-score* (média harmônica entre cobertura e precisão) de cem valores de limiares testados no intervalo [0; 1].

A Tabela 6 apresenta os resultados de detecção de defeitos de soldagem por imagem pela utilização das duas melhores redes com um limiar igual a 0,25 com o maior valor de *f-score* alcançado de 86,06%.

Tabela 5 - Resultados de detecção de soldagem pela combinação das redes obtidas.

Redes	Limiar [0; 1]	F-score (%)
1 ^a	0,30	85,04
1 ^a a 2 ^a	0,25	<u>86,06</u>
1 ^a a 3 ^a	0,21	85,86
1 ^a a 4 ^a	0,23	85,86
1 ^a a 5 ^a	0,24	85,86
1 ^a a 6 ^a	0,29	85,86
1 ^a a 7 ^a	0,28	85,86
1 ^a a 8 ^a	0,26	85,86
1 ^a a 9 ^a	0,25	85,64
1 ^a a 10 ^a	0,25	85,64

Tabela 6 - Resultados de detecção de defeitos de soldagem por imagem.

Imagem	Falsos Positivos	Verdadeiros Positivos	Falsos Negativos	Cobertura (%)	Precisão (%)	F-score (%)
1	1	15	0	100,00	93,75	96,77
2	0	2	0	100,00	100,00	100,00
3	0	18	1	94,74	100,00	97,30
4	7	1	0	100,00	12,50	22,22
5	15	12	1	92,31	44,44	60,00
6	3	10	0	100,00	76,92	86,96
7	0	5	1	83,33	100,00	90,91
8	0	26	1	96,30	100,00	98,11
9	19	4	0	100,00	17,93	29,63
10	0	35	0	100,00	100,00	100,00
11	3	39	2	95,12	92,86	93,98
TOTAL	<u>48</u>	<u>167</u>	<u>6</u>	<u>96,53</u>	<u>77,67</u>	<u>86,06</u>

É importante salientar que o defeito de soldagem do tipo inclusão de tungstênio (IT) foi o único tipo de defeito que não permitiu a seleção correta do contorno por se tratar de um tipo de defeito claro, enquanto que os demais são escuros. Porém, devido à etapa de detecção de descontinuidades, regiões escuras foram formadas no contorno de defeitos do tipo IT.

Tais regiões atuaram como sementes da detecção, pois, na etapa de extração de atributos, os cálculos de entropia e do 1º momento invariante consideraram as regiões analisadas e seus contornos, tornando possível, portanto, a detecção de ITs pelas MLPs. A Figura 70 ilustra a detecção de defeitos de soldagem na imagem 2 da Tabela 6 com um defeito do tipo Porosidade (PO) (canto superior esquerdo) e outro do tipo Inclusão de Tungstênio (IT) (porção inferior direita).

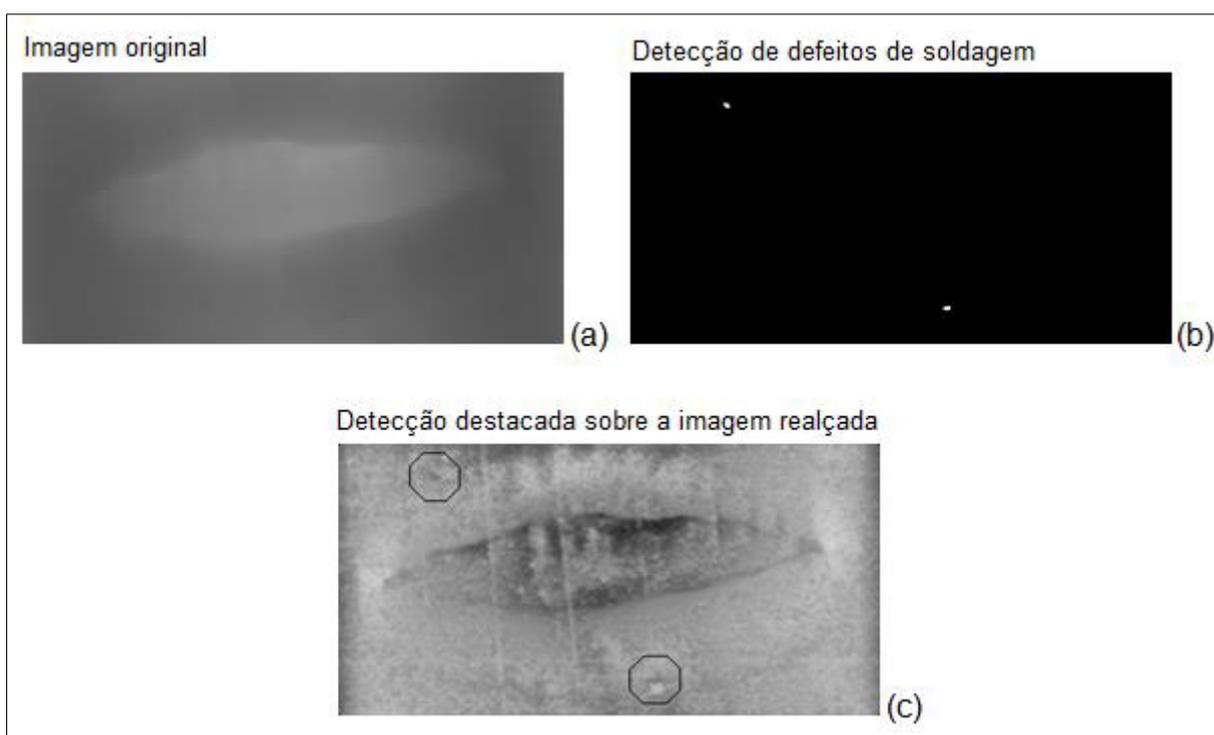


Figura 70 - Exemplo de detecção de defeitos de soldagem pelo método proposto. (a) Imagem original, (b) detecção de defeitos: Porosidade (PO) no canto superior esquerdo e Inclusão de Tungstênio (IT) na porção inferior direita, (c) detecção de defeitos destacada sobre a imagem realçada.

5.4 CONCLUSÕES

Os resultados de detecção de defeitos de soldagem para as imagens do grupo de teste das redes neurais apresentados na Tabela 6 permitem observar que:

- Dos 173 defeitos existentes 6 não foram detectados, representando uma detecção de 96,53% dos defeitos, ou seja, uma cobertura de 96,53%.
- A detecção de 48 regiões de falsos positivos representou 22,33% do total de regiões consideradas como defeitos pelas redes neurais, ou seja, precisão de 77,67%.
- A média harmônica geral entre a precisão e a cobertura (*f-score*) da detecção de defeitos de soldagem obtida foi de 86,06%.

As conclusões gerais e perspectivas para trabalhos futuros são apresentados no próximo capítulo.

6 CONCLUSÕES E PERSPECTIVAS PARA TRABALHOS FUTUROS

O principal objetivo deste trabalho foi desenvolver e/ou aprimorar técnicas auxiliares na automatização do processo de inspeção de imagens radiográficas de juntas soldadas obtidas a partir de condições reais de operação, visando à aplicabilidade prática de tais técnicas. Para tanto, o método proposto e desenvolvido nesta dissertação buscou atuar, especificamente, na detecção de defeitos de soldagem em tubulações de petróleo em radiografias computadorizadas com técnica de exposição PDVD não sobreposta, permitindo agregar melhorias à detecção de defeitos de soldagem em relação aos trabalhos correlatos expostos no estado da arte.

Porém, faz-se necessária a observação de conclusões resultantes do método apresentado nesta dissertação com relação à aplicabilidade, às limitações e aos resultados obtidos. Além disso, este capítulo apresenta a definição de caminhos para trabalhos futuros e as referências das publicações científicas produzidas durante o desenvolvimento deste trabalho.

O método para a detecção de defeitos de soldagem em radiografias PDVD não sobreposta desenvolvido neste trabalho consistiu na aplicação de duas etapas principais: detecção de descontinuidades e classificação. A etapa de detecção de descontinuidades possibilitou a classificação por redes MLP de regiões de defeitos em potencial em regiões: com defeito (CD) e sem defeito (SD).

A detecção de descontinuidades foi composta por quatro procedimentos: realce, segmentação de descontinuidades, geração da máscara da região central e redução do espaço de busca. Estes procedimentos permitiram, respectivamente:

- Evidenciar detalhes.
- Segmentar regiões internas e externas ao cordão de solda.
- Detectar e definir a região central do cordão de solda.
- Reduzir a quantidade de descontinuidades detectadas que não fazem parte da região de interesse para a detecção de defeitos de soldagem.

A redução do espaço de busca permitiu tratar, especificamente, da eliminação de regiões de descontinuidades completamente inscritas na região central do cordão de solda PDVD e posicionadas na fronteira da imagem. Como a região central do cordão de solda PDVD e o contorno da imagem não fazem parte da região de interesse do cordão de solda, conseqüentemente, este procedimento não resultou na perda de regiões de defeitos de soldagem.

Outro aspecto importante é que poucos trabalhos usaram imagens obtidas a partir de condições reais de operação no desenvolvimento de seus métodos de detecção de defeitos de soldagem com diferentes níveis de luminosidade, ruído e contraste como este trabalho empregou. Além disso, as imagens utilizadas não apresentam um padrão em relação às dimensões da junta soldada PDVD, região de interesse (ROI) de aplicação deste método.

As descontinuidades detectadas permitiram delimitar o contorno correto de defeitos de soldagem com coloração escura como Porosidade (PO), Trinca (TR), Falta de Fusão (FF) e Mordedura (MO). Contudo, a detecção de defeitos de soldagem do tipo Inclusão de Tungstênio (IT), com coloração clara, não apresentou uma definição correta dos contornos. Apesar disso, defeitos do tipo IT foram detectados por apresentarem regiões escuras em suas fronteiras e, portanto, evidenciadas na etapa de segmentação de descontinuidades. Assim, com base na extração de atributos de regiões através dos cálculos de entropia e 1º momento invariante que consideraram as regiões de fronteira da descontinuidade, defeitos do tipo IT foram detectados.

Ao selecionar as dez redes com o melhor desempenho de classificação, foi possível a definição empírica da quantidade de nodos na camada oculta da rede MLP. Esse conjunto redes MLP treinadas foi aplicado a um grupo de imagens que não participou do processo de treinamento, caracterizando um teste prático do método. Deste modo, tal método proporcionou uma elevada taxa de detecção de defeitos de soldagem com cobertura de 96,53% e uma baixa taxa de falsos positivos de aproximadamente 22,33% (i.e., precisão de 77,67%), resultando em um *f-score* de 86,06%.

Para trabalhos futuros, propõe-se:

- O aperfeiçoamento da técnica de segmentação de descontinuidades, visando obter o contorno real de defeitos do IT, pela utilização do complemento da imagem cordão de solda em que a solda fica escura em relação ao fundo.
- A introdução de novos atributos para a análise de textura, formato e posição, como a distância em relação à região central do cordão de solda PDVD.
- A análise do impacto dos atributos extraídos de cada descontinuidade, especialmente, para a redução de falsas detecções.
- A obtenção de um banco de imagens maior e proporcional de cada classe de defeito de soldagem, de modo, a permitir a classificação de descontinuidades de soldagem por tipo de defeito.
- A inclusão e a comparação de resultados obtidos pela introdução de diferentes tipos de algoritmos de treinamento para redes MLP, além de novos classificadores, tais como: máquinas de vetor de suporte e sistemas *fuzzy*.
- A incorporação do método aqui apresentado em futuras versões do programa de computador desenvolvido e mantido pela equipe do LIVIC que consiste em uma ferramenta de auxílio ao processo de inspeção radiográfica.

Durante o desenvolvimento desta dissertação também foi possível contribuir com alguns trabalhos científicos apresentados em congressos nacionais e outro publicado em periódico internacional cujas referências completas são apresentadas, respectivamente, nas tabelas 7 e 8.

Tabela 7 - Artigos publicados em anais de congressos nacionais

Referências

SUYAMA, Fernando M.; KREFER, Andriy G.; FARIA, Alex R.; CENTENO, Tania M. Identificação da região central de cordões de solda em imagens radiográficas de tubulações de petróleo do tipo parede dupla vista dupla. **X Encontro Nacional de Inteligência Artificial e Computacional (ENIAC)**, 2013, Fortaleza. Anais do X Encontro Nacional de Inteligência Artificial e Computacional (ENIAC). Belo Horizonte: Biblioteca Digital Brasileira de Computação. v. 1. p. 1-11. 2013.

MARINHO, Carla A.; CENTENO, Tania M.; REAGATTIERI, Myriam D.; LUCAS, Luís A.; FYLYK, Vitor M.; SOLIS, Thayse M.; SUYAMA, Fernando M. Implementação de um Sistema Computacional de Suporte à Interpretação de Radiografias de Soldas. **Congresso Nacional de Ensaio não Destrutivos e Inspeção**, 2014, São Paulo. Anais do CONAEND&IEV2014. São Paulo: ABENDI. v. 1. p. 121. 2014.

Tabela 8 - Artigo publicado em periódico internacional

Referência

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.

REFERÊNCIAS

AGGARWAL, Nitin; KARL, William Clem. Line detection in images through regularized Hough transform. Image Processing, **IEEE Transactions on**, v. 15, n. 3, p. 582-591, 2006.

ASME (AMERICAN SOCIETY OF MECHANICAL ENGINEERS). **V - Nondestructive Examination**. ASME Boiler and Pressure Vessel Committee on Nondestructive Examination - 2010.

ASNT (AMERICAN SOCIETY FOR NONDESTRUCTIVE TESTING). **Introduction to Nondestructive Testing**. 2014. Disponível em: <<https://www.asnt.org/MinorSiteSections/AboutASNT/Intro-to-NDT>>, acessado em 01/11/14.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 14842**: Critérios para a qualificação e certificação de inspetores de soldagem. Rio de Janeiro, 2003.

AWS (AMERICAN WELDING SOCIETY). **Welding Handbook - Weld Science & Technology**, v.2, 9a ed., Miami: AWS, 2001.

BARNEA, Daniel I.; SILVERMAN, Harvey F. A class of algorithms for fast digital image registration. **Computers, IEEE Transactions on**, v. 100, n. 2, p. 179-186, 1972.

BSI BS EN 14784 - Non-Destructive Testing – **Industrial Computed Radiography with Storage Phosphor Imaging Plates – Part 1: Classifications of Systems, -2: General Principles for Testing of Metallic Materials Using X-Rays and Gamma Rays**, 2005.

BEUCHER, Serge; LANTUÉJOL, Christian. Use of watersheds in contour detection. **International workshop on image processing, real-time edge and motion detection**. 1979.

BEUCHER, Serge. The Watershed Transformation applied to Image Segmentation. **10th Pfeifferkorn Conf. on Signal and Image Processing in Microscopy and Microanalysis**, p. 16-19. set.1991.

CARPENTER, Gail A.; GROSSBERG, Stephen. The ART of adaptive pattern recognition by a self-organizing neural network. **Computer**, v. 21, n. 3, p. 77-88, 1988.

CARRASCO, M. A.; MERY, Domingo. Segmentation of welding defects using a robust algorithm. **Materials Evaluation**, v. 62, n. 11, p. 1142-1147, 2004.

DAVIS, J.R. **METALS HANDBOOK**. Desk Ed., 2nd Ed., ASM International, 1998.

DE PINA, Aline A. **Metodologias de Análise, Síntese e Otimização de Sistemas Para Produção de Petróleo Offshore Através de Metamodelos e Enxame de Partículas**. 2010. 176 f. Tese (Doutorado) - Universidade Federal do Rio de Janeiro, 2010.

DIERCKX, Paul. **Curve and surface fitting with splines**. Oxford University Press, Inc., 1993.

FELISBERTO, Marcelo K. **Técnicas Automáticas para Detecção de Cordões de Solda e Defeitos de Soldagem em Imagens Radiográficas Industriais**. 2007. 192 f. Tese (Doutorado) - Universidade Tecnológica Federal do Paraná, 2007.

FELZENSZWALB, Pedro F.; HUTTENLOCHER, Daniel P. Efficient graph-based image segmentation. **International Journal of Computer Vision**, v. 59, n. 2, p. 167-181, 2004.

FÜCSÖK, Ferenc; MULLER, Christina; SCHARMACH, Martina. Human factors: the NDE reliability of routine radiographic film evaluation. **Proceedings of the 15th world conference on non-destructive testing**. 2000.

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

FYLYK, Vitor Mota; CENTENO, Tania Mezzadri. **DETECÇÃO DE DEFEITOS EM CORDÕES DE SOLDA POR REDES NEURAIS**. In: Sicite 2012. 2012.

GAYER, A.; SAYA, A.; SHILOH, A. Automatic recognition of welding defects in real-time radiography. **NDT International**, v. 23, n. 3, p. 131-136, 1990.

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

HALMSHAW, Ron; KOWOL, Tom. Image quality indicators in industrial radiography. **IE-NDT LTD technical materials**, 2001.

HAYKIN, S. **Neural Networks and Learning Machines**. 3rd ed., Prentice-Hall, 2008.

HEBB, Donald O. **The Organization of Behavior**. Willey, New York, 1949.

HU, Ming Ki. Visual pattern recognition by moment invariants. **Information Theory, IRE Transactions on**, v. 8, n. 2, p. 179-187, 1962.

JAGANNATHAN, H., BHASKAR, N., SRIRAMAN, C. N., VIJAY, N. A. A Step Towards Automatic Defect Pattern Analysis and Evaluation in Industrial Radiography using Digital Image Processing. Proceedings of WCNDT-2000, 15th World **Conference on Nondestructive Testing**. Roma: idn 673, 2000.

JUNIOR, S. F. S.; MARQUES, P. V. **Ensaio Não Destrutivo**. Belo Horizonte: Universidade Federal de Minas Gerais, 2006.

KROETZ, Marcel G. **Sistema de Apoio Na Inspeção Radiográfica Computadorizada De Juntas Soldadas de Tubulações de Petróleo**. 2012. 108 f. Dissertação (Mestrado) - Universidade Tecnológica Federal do Paraná, 2012.

LASHKIA, George V. Defect detection in X-ray images using fuzzy reasoning. **Image and Vision Computing**, v. 19(5), p. 261-269, abr. 2001.

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.

LEVENBERG, K. A method for the solution of certain non-linear problems in least squares, **Quart. Appl. Math.**, vol. 12, pp. 164–168, 1944.

LIAO, Warren T.; NI, Jiawei. An automated radiographic ndt system for weld inspection: Part I – weld extraction. **NDT E International**, v. 29(3), p. 157-162, 1996.

LIAO, Warren T.; LI, Yueming. An automated radiographic ndt system for weld inspection: Part II – flaw detection. **NDT & E International**, v. 31(3):183-192, 1998.

LIAO, T. W.; LI, D.-M.; LI, Y.-M. Detection of welding flaws from radiographic images with fuzzy clustering methods. **Fuzzy sets and Systems**, v. 108, n. 2, p. 145-158, 1999.

LILING, Ge; YINGJIE, Zhang. Weld defect detection in industrial radiography based on image segmentation. **Insight-Non-Destructive Testing and Condition Monitoring**, v. 53, n. 5, p. 263-269, 2011.

LIM J. **Two-dimensional signal and image processing**. Englewood Cliffs, NJ: Prentice-Hall; p. 536-540. 1990.

LIPPMANN, R. P. An introduction to computing with Neural Nets. **IEEE/ASSP Magazine**, v. 4, p. 4-22, 1987.

MARINHO, Carla A.; CENTENO, Tania M.; REAGATTIERI, Myriam D.; LUCAS, Luís A.; FYLYK, Vitor M.; SOLIS, Thayse M.; SUYAMA, Fernando M. Implementação de um Sistema Computacional de Suporte à Interpretação de Radiografias de Soldas. **Congresso Nacional de Ensaio não Destrutivos e Inspeção**, 2014, São Paulo. Anais do CONAEND&IEV2014. São Paulo: ABENDI. v. 1. p. 121. 2014.

MARQUARDT, D. W. An algorithm for least-squares estimation of nonlinear parameters, **J. Soc. Indust. Appli. Math.**, vol. 11, no. 2, pp. 431–441, June, 1963.

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

MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115-133, 1943.

MERY, Domingo; BERTI, Miguel. Automatic detection of welding defects using texture features. **Insight-Non-Destructive Testing and Condition Monitoring**, v. 45, n. 10, p. 676-681, 2003.

MERY, Domingo; FILBERT, Dieter. Automated flaw detection in aluminum castings based on the tracking of potential defects in a radioscopic image sequence. **Robotics and Automation, IEEE Transactions on**, v. 18, n. 6, p. 890-901, 2002.

MINSKY, Marvin; PAPER, Seymour. Perceptron: an introduction to computational geometry. **The MIT Press, Cambridge, expanded edition**, v. 19, p. 88, 1969.

MINSKY, M.; PAPER, S. **Artificial Intelligence Progress Report. Technical Report**. UMI Order Number: AIM-252. Massachusetts Institute of Technology Press, Massachusetts, 1972.

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

NACEREDDINE, Nafaâ; REDOUANE, Draï; AMAR, Benchaala. Weld defect Extraction and Classification in radiographic testing based Artificial Neural Networks. **15th World Conference on NDT**, Rome. 2000.

NASCIMENTO, J. R. **Estudo Comparativo de Sistemas de Radiografia Industrial na Inspeção de Solda**. 2012. 124 f. Dissertação (Mestrado) - Universidade Federal do Rio De Janeiro, 2012.

OLIVEIRA, Davi F.; LOPES, Ricardo T. Avaliação da qualidade de imagem em sistemas de radiografia computadorizada e image plates. **IV Conferencia Panamericana de END**, Buenos Aires. 2007.

OTSU, Nobuyuki. A Threshold Selection Method from Gray-level Histograms. **IEEE Transactions on Systems, Man and Cybernetics**, v. SMC 9, no 1, pp.62-66, 1979.

PADUA, Germano X. **Detecção e Classificação de Defeitos de Soldagem em Radiografias Utilizando Perfil Transversal ao Cordão de Solda**. Tese (Doutorado) - Universidade Federal do Rio de Janeiro, 2004.

POWERS, David Martin. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. **Technical Report SIE-07-001**. School of Informatics and Engineering Flinders University. Adelaide, Australia: 2007.

QUITES, Almir. **Inspeção de juntas soldadas por radiografia**. Soldasoft. mai. 2009. Disponível em: <<http://www.soldasoft.com.br/portal/generalidades/INSPE%C3%87%C3%83O%20DE%20JUNTAS%20SOLDADAS%20POR%20RADIOGRAFIA.pdf>>, acessado em 01/11/14.

RARAJAGOPALAN, C.; VENKATRAMAN, B.; JAYAKUMAR, T.; KALYANASUNDARAM, P.; BALDEV, R. A novel tool for automated evaluation of radiographic weld images. **16th World conference on NDT**, ago. 2004.

ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386, 1958.

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning Internal Representations by Error Propagation. **Parallel Distributed Processing: Explorations in the Microstructures of Cognition, V. 1: Foundations**, Rumelhart, D. E., et al. (eds.), MIT Press, Cambridge, Mass, 1986.

SHAPIRO, Linda G. Connected component labeling and adjacency graph construction. **Machine Intelligence and Pattern Recognition**, v. 19, p. 1-30, 1996.

SHI, Jianbo; MALIK, Jitendra. Normalized cuts and image segmentation. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 22, n. 8, p. 888-905, 2000.

SILVA, Leandro N. C. **Análise e síntese de estratégias de aprendizado para redes neurais artificiais**. 1998. 210 f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia Elétrica e Computação. Universidade Estadual de Campinas, Campinas. 1998.

SILVA, Romeu R.; SIQUEIRA, Marcio H. S.; CALÔBA, Luiz P.; REBELLO, João. M. A. Radiographics pattern recognition of welding defects using linear classifiers. **Insight**, v. 43, n. 10, p. 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.

SOPHOCLES, J. O. **Introduction to Signal Processing**, Prentice-Hall, 1995.

SUN, Yi; BAI, Peng; SUN, Hong-yu; ZHOU, Ping. Real-time automatic detection of weld defects in steel pipe. **NDT & E International**, v. 38, n. 7, p. 522-528, 2005.

SUYAMA, Fernando M.; KREFER, Andriy G.; FARIA, Alex R.; CENTENO, Tania M. Identificação da região central de cordões de solda em imagens radiográficas de tubulações de petróleo do tipo parede dupla vista dupla. **X Encontro Nacional de Inteligência Artificial e Computacional (ENIAC)**, Fortaleza. Anais do X Encontro Nacional de Inteligência Artificial e Computacional (ENIAC). Belo Horizonte: Biblioteca Digital Brasileira de Computação, v. 1. p. 1-11, 2013.

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.

TOWSEY, Michael; ALPSAN, Dogan; SZTRIHA, Laszlo. Training a neural network with conjugate gradient methods. **Neural Networks, 1995. Proceedings., IEEE International Conference on.** IEEE, 1995. p. 373-378.

VALAVANIS, Ioannis; KOSMOPOULOS, Dimitrios. Multiclass defect detection and classification in weld radiographic images using geometric and texture features. **Expert Systems with Applications**, v. 37, n. 12, p. 7606-7614, 2010.

VILAR, Rafael; ZAPATA, Juan; RUIZ, Ramon. An automatic system of classification of weld defects in radiographic images. **NDT & E International**, v. 42, n. 5, p. 467-476, 2009.

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, Y.; SUN, Y.; LV, P.; WANG, H. Detection of line weld defects based on multiple thresholds and support vector machine. **NDT & E International**, v. 41, n. 7, p. 517-524, 2008.

WIDROW, Bernard; HOFF, Marcian E. Adaptive switching circuits. **IRE WESCON Convention Record**, New York IRE, p. 96-104, 1960.

YAZID, H.; AROF, H.; YAZID, H.; AHMAD, S.; MOHAMED, A. A.; AHMAD, F. Discontinuities detection in welded joints based on inverse surface thresholding. **Ndt & E International**, v. 44, n. 7, p. 563-570, 2011.