

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

**CÉLIA CRISTINA BOJARCZUK FIORAVANTI**

**SISTEMA IMUNOLÓGICO ARTIFICIAL COM APRENDIZAGEM**  
**PROFUNDA PARA DETECTAR DEFEITOS DE SOLDA EM IMAGENS**  
**RADIOGRÁFICAS PDVD DE TUBULAÇÕES DE PETRÓLEO**

**TESE DOUTORADO**

**CURITIBA**

**2020**

**CÉLIA CRISTINA BOJARCZUK FIORAVANTI**

**SISTEMA IMUNOLÓGICO ARTIFICIAL COM APRENDIZAGEM  
PROFUNDA PARA DETECTAR DEFEITOS DE SOLDA EM IMAGENS  
RADIOGRÁFICAS PDVD DE TUBULAÇÕES DE PETRÓLEO**

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

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

Coorientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Myriam Regattieri De Biase Da Silva Delgado

**CURITIBA**

**2020**

Dados Internacionais de Catalogação na Publicação

---

Fioravanti, Célia Cristina Bojarczuk

Sistema imunológico artificial com aprendizagem profunda para detectar defeitos de solda em imagens radiográficas PDVD de tubulações de petróleo [recurso eletrônico] / Célia Cristina Bojarczuk Fioravanti. -- 2020.

1 arquivo texto (152 f.): PDF; 8,16 MB.

Modo de acesso: World Wide Web

Título extraído da tela de título (visualizado em 27 abr. 2020)

Texto em português com resumo em inglês

Tese (Doutorado) - Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Curitiba, 2020

Bibliografia: f. 143-151.

1. Engenharia elétrica - Teses. 2. Diagnóstico radioscópico. 3. Radiografia industrial. 4. Radiografia médica - Técnicas digitais. 5. Radiografia - Qualidade da imagem. 6. Aprendizado do computador. 7. Tubulações industriais - Inspeção. 8. Tubulação - Dinâmica dos fluidos. 9. Juntas soldadas - Inspeção. 10. Petróleo - Transporte - Inspeção. I. Centeno, Tania Mezzadri. II. Delgado, Myriam Regattieri De Biase da Silva. III. Universidade Tecnológica Federal do Paraná - Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. IV. Título.

---

CDD: ed. 23 – 621.3

Biblioteca Central da UTFPR, Câmpus Curitiba

Bibliotecário: Adriano Lopes CRB-9/1429

### TERMO DE APROVAÇÃO DE TESE

A Tese de Doutorado intitulada **Sistema Imunológico Artificial com aprendizagem profunda para detectar defeitos de solda em imagens radiográficas PDVD de tubulações de petróleo**, defendida em sessão pública pelo(a) candidato(a) **Célia Cristina Bojarczuk Fioravanti**, no dia **25 de março de 2020**, foi julgada aprovada em sua forma final para obtenção do título de Doutor em Ciências, Área de Concentração – **Engenharia de Computação**, Linha de Pesquisa – **Visão Computacional**, pelo Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial - CPGEI.

#### BANCA EXAMINADORA:

Profa. Dra. Tania Mezzadri Centeno - UTFPR - Orientador  
Prof. Dr. Julio Cesar Nievola – PUC-PR  
Prof. Dr. Ricardo Dutra da Silva - UTFPR  
Profa. Dra. Carolina Paula de Almeida - UNICENTRO  
Prof. Dr. João Alberto Fabro - UTFPR

A via original deste documento encontra-se arquivada na Secretaria do Programa, contendo a assinatura da Coordenação após a entrega da versão corrigida do trabalho.

Curitiba, 25 de março de 2020.

---

Carimbo e Assinatura do(a) Coordenador(a) do Programa

Dedico este trabalho ao meu esposo Juarez e aos  
meus filhos Daniel, Diego e Denis.

## AGRADECIMENTOS

A Deus, que me ensinou que ao acreditar Nele, eu estaria acreditando em mim e que teria forças em todos os momentos dessa caminhada. E a Santa Rita de Cássia que sempre me lembra que para Deus nada é impossível.

Aos meus pais, Kazmiera Halina Bojarczuk e Enrique Bojarczuk, pelo apoio e pela lição de vida.

Ao meu esposo Juarez e aos meus filhos Daniel, Diego e Denis, pelo apoio, carinho, incentivo e compreensão, durante todo o tempo de realização do Doutorado.

À Prof.<sup>a</sup> Dra. Tania Mezzadri Centeno, pela orientação, paciência e dedicação, compreensão e entendimento que me conduziu durante todo o meu estudo.

À Prof.<sup>a</sup> Dra. Myriam Myriam Regattieri De Biase Da Silva Delgado, pela co-orientação, paciência, dedicação e discernimento; e sempre disposta a discutir técnicas, cooperando com o desenvolvimento desta pesquisa.

Aos professores do CPGEI, da UTFPR, pelo conhecimento recebido durante os estudos.

Aos amigos do Laboratório LIVIC, Marlon, Rafael e Fernando, pela companhia e pelo apoio durante a realização do doutorado.

Ao Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello (CENPES) da Petrobrás, por disponibilizar a biblioteca de imagens radiográficas de soldas em tubulações para a utilização em pesquisas acadêmicas.

À UTFPR e ao DAELT por permitirem o meu afastamento para a realização do doutorado.

Enfim, a todos que contribuíram de alguma maneira para que este trabalho se tornasse uma realidade.

“Nunca é tarde demais para mudar a direção da sua vida. Sempre haverá uma nova rota ou uma nova chance de recomeço.”  
(Santa Rita de Cássia)

“Tudo o que acontece no universo tem uma razão de ser; um objetivo. Nós como seres humanos, temos uma só lição na vida: seguir em frente e ter a certeza de que apesar de as vezes estar no escuro, o sol vai voltar a brilhar.”  
(Irmã Dulce)

## RESUMO

BOJARCZUK FIORAVANTI, Célia Cristina. **Sistema Imunológico Artificial com aprendizagem profunda para detectar defeitos de solda em imagens radiográficas PDVD de tubulações de petróleo.** 2020. 146 folhas. Tese de Doutorado em Engenharia Elétrica e Informática Industrial - Universidade Tecnológica Federal do Paraná. Curitiba, 2020.

Nos últimos anos, pesquisas voltadas para métodos de inspeção radiográfica (semi-automáticas) ganharam mais atenção. O presente trabalho propõe um método para detectar defeitos em imagens radiográficas de juntas soldadas de tubulações de petróleo. Imagens em condições reais obtidas pela técnica de parede dupla vista dupla (PDVD) geralmente apresentam uma qualidade inferior quando comparadas às imagens tradicionalmente consideradas em muitos estudos relatados na literatura. Primeiro, a abordagem proposta detecta descontinuidades em imagens radiográficas PDVD de juntas soldadas e, em seguida, com base em um paradigma híbrido que abrange sistemas imunes artificiais (SIA) e aprendizado profundo (*deep learning* - DL), classifica cada descontinuidade como 'defeito' e 'não defeito'. O método proposto realiza duas fases no módulo SIA: eliminação inicial (com base na seleção negativa) e classificação evolutiva (com base na seleção clonal). Em ambas as fases, a tarefa de reconhecimento de padrões é realizada usando um conjunto de características extraídas de cada descontinuidade por meio de um detector geneticamente codificado nas células imunológicas. Na tentativa de melhorar o desempenho da classificação, modelos DL, do inglês *Deep Learning*, os quais envolvem o uso da AlexNet e *autoencoders* são incorporados com o objetivo de aumentar o número de características extraídas. As experiências realizadas em um conjunto de 727 descontinuidades mostram que a abordagem proposta alcança um *F-score* de 70,7%, superando cada um de seus módulos sendo executados isoladamente: AlexNet com *F-score* = 64,86% e SIA com *F-score* = 66%. Os experimentos mostram ainda que o modelo proposto é capaz de superar classificadores tradicionais como o SVM, cuja melhor configuração alcançou taxas de *F-score* em torno de 60%. Considerando os desafios impostos pelas condições reais na aquisição de imagens e as baixas taxas de falsos negativos, os resultados mostram que a abordagem proposta pode ser usada para auxiliar os especialistas em seus trabalhos de inspeção ao lidar com imagens PDVD.

**Palavras-chave:** Sistemas Imunológicos Artificiais. *Deep Learning*. Imagens Radiográficas. Classificação de Descontinuidade. Detecção de Defeitos.



## ABSTRACT

BOJARCZUK FIORAVANTI, Célia Cristina. **Artificial immune system with deep learning to detect weld defects in DWDI radiographic images of petroleum pipes**. 2020. 146 folhas. Tese de Doutorado em Engenharia Elétrica e Informática Industrial - Universidade Tecnológica Federal do Paraná. Curitiba, 2020.

In recent years, research focused on (semi)automatic radiographic inspection methods has gained more attention. The present work proposes a method for detecting defects in radiographic images of welded joints of oil pipes. Real condition images obtained by the double wall double image (DWDI) technique usually present a lower quality when compared with images traditionally considered in many studies reported in the literature. First, the proposed approach detects discontinuities in DWDI radiographic images of welded joints, and then, based on a hybrid paradigm encompassing artificial immune systems (AIS) and deep learning (DL), it classifies each discontinuity as ‘defect’ and ‘non-defect’. The proposed method performs two phases in the AIS module: early classification (based on negative selection) and evolving classification (based on clonal selection). In both phases, the pattern recognition task is performed using a set of features extracted from each discontinuity through a detector genetically encoded into immune cells. As an attempt to improve the classification performance, DL models (AlexNet and autoencoders) are incorporated aiming to increase the number of extracted features. Experiments performed on a set of 727 discontinuities show that the proposed approach achieves an *F-score* of 70.7%, outperforming each of its modules running by themselves: AlexNet with *F-score* = 64.86% and AIS with *F-score* = 66%. The experiments also show that the proposed model is capable outperforming traditional classifiers such as SVM, whose best implementation has achieved an *F-score* around 60%. Considering the challenges imposed by real conditions on image acquisition and the low rates of false negatives, results demonstrate that the proposed approach can be used to assist experts in their inspection works when dealing with DWDI images.

Keywords: Artificial Immune Systems. Deep Learning. Radiographic Images. Discontinuities Classification. Defect Detection.

## LISTA DE ILUSTRAÇÕES

Figura 1 –	Esquema conceitual de ensaios radiográficos.....	30
Figura 2 –	Técnica de exposição PSVS. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante com destaque do cordão de corda e outros artefatos utilizados na identificação.....	31
Figura 3 –	Técnica de exposição PDVS. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante com destaque do cordão de corda e outros artefatos utilizados na identificação.....	32
Figura 4 –	Técnica de exposição PDVD. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante com destaque do cordão de corda e outros artefatos utilizados na identificação.....	33
Figura 5 –	Falta de fusão. (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul o ponto do defeito e em amarelo destaque feito pelo laudista.....	34
Figura 6 –	Falta de penetração. (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul o ponto do defeito e em amarelo destaque feito pelo laudista.....	34
Figura 7 –	Inclusão de escória. (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul o ponto do defeito e em amarelo destaque feito pelo laudista.....	35
Figura 8 –	Mordedura. (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul o ponto do defeito e em amarelo destaque feito pelo laudista.....	35
Figura 9 –	Porosidade. (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul os pontos dos defeitos e em amarelo destaque feito pelo laudista.....	36
Figura 10 –	Trincas. (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul o ponto do defeito e em amarelo destaque feito pelo laudista.....	36
Figura 11 –	Representação de uma imagem no plano cartesiano.....	37
Figura 12 –	Expansão de histograma para $\text{inf}=0$ , $\text{inter1}$ em torno de 80 e $\text{inter2}$ em torno de 220 e $\text{sup}=255$ . (a) Imagem original. (b) Imagem reescalada. (c) Histograma da imagem original. (d) Histograma reescalado a partir do histograma da imagem original.....	39
Figura 13 –	Equalização de histograma. a) Imagem original. b) Imagem equalizada. c) Histograma da imagem original. d) Histograma equalizado a partir do histograma da imagem original.....	40
Figura 14 –	Exemplo de elementos estruturantes. (a) Cruz 3x3. (b) Quadrado 3x3 .....	42
Figura 15 –	Exemplo de operações morfológicas. (a) Imagem de entrada. (b) Imagem dilatada. (c) Imagem erodida.....	43
Figura 16 –	Estrutura multicamadas do sistema imunológico.....	49
Figura 17 –	Linfócito B. (a) Destaque para o anticorpo em sua superfície. (b) Antígeno reconhecido por um anticorpo.....	52

Figura 18 – Princípio da Seleção Clonal.....	53
Figura 19 – Linfócito T, com destaque para o TCR em sua superfície.....	54
Figura 20 – Esquema das principais interações entre antígenos e linfócitos.....	55
Figura 21 – Diagrama de blocos do algoritmo de seleção clonal, ASC.....	58
Figura 22 – Algoritmo Seleção Negativa.....	60
Figura 23 – Modelo de um neurônio artificial.....	61
Figura 24 – Modelos de arquitetura de redes neurais artificiais. (a) Camada única. (b) Camadas múltiplas.....	63
Figura 25 – Exemplo de uma arquitetura CNN com suas respectivas camadas.....	65
Figura 26 – Exemplo da convolução de um filtro 3x3 e a imagem da entrada.....	66
Figura 27 – Ilustração de como o passo influencia o deslocamento de um filtro 3x3 em duas etapas sucessivas da convolução. As imagens em(a) correspondem a um passo unitário, enquanto as imagens em (b) a um passo igual a 2.....	67
Figura 28 – Aplicação de <i>max pooling</i> em uma imagem 4x4 utilizando um filtro 2x2.....	67
Figura 29 – Esquema de <i>autoencoder</i> utilizado para redução dimensional. Após o treinamento não supervisionado, usa-se a estrutura do <i>autoencoder</i> da camada de entrada para a camada oculta escolhida (geralmente a camada com menos nós) para testar e extrair uma representação reduzida de entradas.....	70
Figura 30 – Esquema de um <i>autoencoder</i> com detalhes.....	71
Figura 31 – Exemplo de uma divisão para o método <i>holdout</i> .....	75
Figura 32 – Modelo de matriz de confusão de duas classes.....	76
Figura 33 – Segmentação do cordão de solda. (a) Recorte da imagem original. (b) Imagem filtrada pelo filtro da média 300x300. (c) Imagem limiarizada. (d) Imagem erodida.....	91
Figura 34 – Imagens das etapas principais na identificação de defeitos candidatos. (a) Original. (b) Região de interesse. (c) Máscara de nitidez equalizada. (d) Imagem segmentada pela técnica de Otsu. (e) Segmentação final das discontinuidades. (f) Identificação dos defeitos candidatos na imagem equalizada. ....	92
Figura 35 – Área de exclusão de defeitos candidatos da extremidade da imagem.....	93
Figura 36 – Exemplo de forma da discontinuidade com indicação dos parâmetros utilizados na extração das características geométricas. (a) Características 1 a 6. (b) Característica 7.....	94
Figura 37 – (a) Imagem com ruído. (b) Imagem com borramento. (c) Imagem com contraste.....	97
Figura 38 – Estrutura para a obtenção da imagem com as discontinuidades, com a localização da região do cordão (laranja) e detecção das discontinuidades para a extração das características (azul).....	99

Figura 39 – Segmentação do cordão de solda: (a) Recorte da imagem original. (b) Imagem filtrada – filtro de média 370x370. (c) Imagem limiarizada. (d) Imagem erodida.....	100
Figura 40 – Imagens das principais fases para identificar os defeitos candidatos. (a) Original. (b) Região de interesse. (c) Máscara de nitidez equalizada, (d) Imagem obtida pela técnica de Otsu. (e) Segmentação final das descontinuidades. (f) Identificação dos defeitos candidatos na imagem equalizada.....	101
Figura 41 – Descontinuidades com vários tamanhos e formas.....	102
Figura 42 – Visão geral da abordagem proposto SIA profundo.....	103
Figura 43 – Sistema SIA puro proposto para a fase de reconhecimento.....	104
Figura 44 – Exemplo de célula T aprimorado pelo aprendizado profundo.....	105
Figura 45 – Exemplo de célula B (anticorpo) aprimorado pelo aprendizado profundo..	106
Figura 46 – EE’s utilizados. (a) Disco de raio 1. (b) Linha com comprimento 3 e ângulo de 45°. (c) Quadrado 2x2. (d) Retângulo 2x3 .....	107
Figura 47 – (a) Descontinuidade original. (b) Descontinuidade alterada com dilatação +3 e EE 1 (disco de raio 1) .....	108
Figura 48 – Pseudocódigo da Seleção Clonal.....	110
Figura 49 – Extração de características da descontinuidade com o AlexNet. (a) Imagem obtida do detector de anticorpos. (b) Imagem dilatada com borda preta. (c) Imagem redimensionada nas dimensões de entrada do AlexNet.....	111
Figura 50 – Método CNN - AlexNet.....	112
Figura 51 – AlexNet e autoencoders ilustrando a obtenção das características e a redução dimensional.....	113
Figura 52 – Imagem do tubo, destacando o recorte realizado manualmente do cordão de solda. (a) Imagem 1. (b) Imagem 2. (c) Imagem 3. (d) Imagem 4. (e) Imagem 5. (f) Imagem 6. (g) Imagem 7. (h) Imagem 8. (i) Imagem 9. (j) Imagem 10. (k) Imagem 11. (l) Imagem 12. (m) Imagem 13. (n) Imagem 14. (o) Imagem 15. (p) Imagem 16. (q) Imagem 17. (r) Imagem 18. (s) Imagem 19. (t) Imagem 20.....	116
Figura 53 – Imagens do cordão de solda. (a) Recorte da imagem original. (b) Laudo com porcessamento realizado manualmente pelo laudista, para uma melhor identificação dos defeitos, sobre a mesma imagem.....	117
Figura 54 – Tamanhos dos defeitos e suas quantidades.....	118
Figura 55 – Tamanhos dos não defeitos e suas quantidades.....	118
Figura 56 – Detecção das descontinuidades a serem utilizadas por todas as abordagens.....	123
Figura 57 – Detecção das descontinuidades de todas as imagens a serem utilizadas por todas as abordagens.....	124- -127
Figura 58 – Valores da sensibilidade para cada valor do limiar $\gamma_d^c$ .....	129
Figura 59 – Precisão versus sensibilidade para cada valor do limiar $\gamma_d^c$ .....	129

Figura 60 – <i>F-score</i> para cada valor de limiar único corrigido ao longo de todas as gerações G.....	131
Figura 61 – <i>F-score</i> de treinamento de cada rodada obtida pela AlexNet.....	132
Figura 62 – Imagem após a classificação das descontinuidades: superior: imagem obtida do classificador SIA puro e relatório de inspeção fornecido por um especialista.....	133
Figura 63 – Imagem após a classificação das descontinuidades: superior: imagem obtida do classificador SIA profundo e relatório de inspeção fornecido por um especialista.....	133
Figura 64 – Imagem após a classificação das descontinuidades: superior: imagem obtida do classificador AlexNet e relatório de inspeção fornecido por um especialista.....	134
Figura 65 – Imagem após a classificação das descontinuidades: superior: imagem obtida do classificador SIA com <i>autoencoder</i> e relatório de inspeção fornecido por um especialista.....	134
Figura 66 – Melhor <i>F-score</i> obtida por cada método.....	135
Figura 67 – Melhor FN obtido por cada método.....	136
Figura 68 – Melhor FP obtido por cada método.....	137

## LISTA DE TABELAS

Tabela 1 – Tamanho dos recortes do cordão de solda.....	115
Tabela 2 – Banco de dados para duas classes: defeito e não defeito.....	118
Tabela 3 – Banco de dados com o número de amostras para cada defeito.....	119
Tabela 4 – Parâmetros e valores.....	120
Tabela 5 – Parâmetros do SVM.....	138
Tabela 6 – Indicadores de desempenho dos Classificadores.....	138

## LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

ABNT	Associação Brasileira de Normas Técnicas
Ab	Anticorpo
Ag	Antígeno
ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i>
API	<i>American Petroleum Institute</i>
ASC	Algoritmo de Seleção Clonal
ASME	<i>American Society of Mechanical Engineers</i>
ASN	Algoritmo de Seleção Negativa
ASNT	<i>American Society for Nondestructive Testing</i>
CENPES	Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello – PETROBRAS
CNN	<i>Convolutional Neural Network</i>
CD	Com Defeito
CLONALG	<i>Clonal Selection Algorithm</i>
CPGEI	Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial – UTFPR
DAELT	Departamento Acadêmico de Eletrotécnica - UTFPR
DTW	<i>Dynamic Time Warping</i>
ELM	<i>Extreme Learning Machines</i>
END	Ensaio Não-Destrutivo
FF	Falta de Fusão
FP	Falta de Penetração
GPU	<i>Graphics Processing Unit</i>
HOG	<i>Histogram of Oriented Gradients</i>
IE	Inclusão de Escória
KNN	<i>K-Nearest Neighbor</i>
LDA	<i>Linear Discriminant Analysis</i>
LIVIC	Laboratório de Imagens e Visão Computacional - CPGEI - UTFPR
MLP	<i>Multi Layer Perceptron</i>
MO	Mordedura
NBR	Norma da Associação Brasileira de Normas Técnicas (ABNT)
PCA	<i>Principal Component Analysis</i>
PDI	Processamento Digital de Imagens
PDVD	Parede Dupla Vista Dupla
PDVS	Parede Dupla Vista Simples
PETROBRAS	Petróleo Brasileiro S.A.
<i>pixel</i>	<i>picture element</i>
PO	Porosidade
PSVS	Parede Simples Vista Simples
RC	Radiografia Computadorizada
ReLU	<i>Rectified Linear Units</i>
RNA	Rede Neural Artificial
SIA	Sistema Imunológico Artificial
SIN	Sistema Imunológico Natural
ROI	<i>Region Of Interest</i>
SD	Sem Defeito
SVM	<i>Support Vector Machines</i>

TIFF	<i>Tagged Image File Format</i>
TR	Trinca
UTFPR	Universidade Tecnológica Federal do Paraná



## LISTA DE SÍMBOLOS (VARIÁVEIS)

$A$	Área do defeito.
$Ab$	Anticorpos.
$Af$	Afinidade
$Ag$	Antígenos.
$b_x$	Vetor de polarização nos modelos de rede neural artificial.
$backup$	Conjunto de células pequenas deixadas para uma avaliação posterior.
$C$	Total de ciclos de evolução realizados pelo algoritmo de seleção clonal.
$D$	Constante de deslocamento.
$K$	Valor constante.
$E_c$	Excentricidade.
$E_x$	Extensão do defeito.
$f$	Matriz ou vetor de entrada.
$f$	Ponto da coordenada.
$F$	Vetor de característica.
$Fa$	Filtro média.
$Fm$	Filtro mediana.
$G$	Total de geração por ciclo evolutivo do SIA.
$inf, sup$	Limites inferior e superior dos valores do pixel.
$inter1, inter2$	Limites intermediários para a expansão do histograma.
$k, m$	0, 1, 2, 3, ....
$k'ou b_k$	Limiar.
$L$	Níveis de cinza.
$La$	Limiar adaptativo para cada posição do <i>pixel</i> na imagem.
$max$	Valor máximo da matriz ou vetor $f$ .
$min$	Valor mínimo da matriz ou vetor $f$ .
$N$	Número de exemplos na base de treinamento.
$n$	Número total de pixels na imagem.
$n_j$	Número de pixels cujo nível de cinza corresponde a $j$ .
$n_k$	Número de pixels da imagem com intensidade $r_k$ .
$Nself^0$	Conjunto de células eliminadas no primeiro processo de <i>matching</i> com não defeitos.
$p$	Perímetro do contorno do defeito.
$P_{Ab}$	População de anticorpos.
$R_1, R_2, R_3$	Razão 1, Razão 2, Razão 3.
$R1, R2, R3, R4$	Resultados intermediários das operações realizados nas imagens para detecção das descontinuidades.
$r_k$	Valor de intensidade correspondendo ao nível de cinza $k$ .
$S$	Saída ou solução.
$\beta$	Solidez.
$s_k$	Novo valor a ser atribuído aos pixels de tom de cinza $k$ .
$self$	Conjunto de células eliminadas na etapa de seleção negativa.
$T$	Valor pré-definido de tom de cinza denominado limiar.
$v$	Variação de ruído.
$v_k$	Saída do combinador linear devido dos sinais de entrada.
$W$	Filtro de Wiener.
$w$	Peso.
$W$	Vetor de pesos.

$W^{(1)}$	Matriz de peso.
$w_{k1}, w_{k2}, \dots, w_{km}$	Pesos sinápticos do neurônio k.
$x, y$	Coordenadas da imagem.
$x_1, x_2, \dots, x_m$	Sinais de entrada do neurônio.
$y_k$	Sinal de saída do neurônio.
$\beta$	Coefficiente para o termo regularização de esparsidade.
$\gamma_d$	Limiar de defeito.
$\gamma_s$	Limiar do próprio.
$\lambda$	Coefficiente para o termo da regularização de peso.
$\mu$	Média.
$\sigma$	Variância.
$\varphi(\cdot)$	Função de ativação no neurônio nos modelos rasos e profundos.
$\alpha$	Coefficiente do <i>F-score</i>
$\Delta$	Conjunto das discontinuidades identificadas na etapa de pré-processamento

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>21</b>
1.1 JUSTIFICATIVA .....	24
1.2 OBJETIVOS .....	26
1.3 CONTRIBUIÇÕES .....	27
1.4 ESTRUTURA DO TRABALHO .....	27
<b>2 FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>29</b>
2.1 RADIOGRAFIA INDUSTRIAL APLICADA A JUNTAS SOLDADAS .....	29
2.1.1 Técnicas de Inspeção para Ensaio Radiográfico de Soldas em Tubulações .....	30
2.1.1.1 Técnica radiográfica parede simples vista simples (PSVS) .....	31
2.1.1.2 Técnica radiográfica parede dupla vista simples (PDVS).....	31
2.1.1.3 Técnica radiográfica parede dupla vista dupla (PDVD).....	32
2.1.2 Classificação Estrutural das Descontinuidades em Juntas Soldadas .....	33
2.2 PROCESSAMENTO DIGITAL DE IMAGENS .....	37
2.2.1 Imagens Digitais .....	37
2.2.2 Histograma .....	38
2.2.2.1 Expansão do histograma.....	38
2.2.2.2 Equalização de histograma .....	39
2.2.3 Filtros para Remoção ou Suavização de Ruídos .....	40
2.2.3.1 Filtro da média.....	40
2.2.3.2 Filtro da mediana .....	41
2.2.3.4 Filtro de Wiener.....	41
2.2.4 Processamento Morfológico de Imagens.....	42
2.2.4.1 Operações morfológicas de erosão, dilatação, abertura e fechamento .....	42
2.2.4.2 Transformação <i>top-hat</i> e <i>bottom-hat</i> .....	43
2.2.4.3 Extração de contornos em imagens binárias por operadores morfológicos .....	44
2.2.5 Limiarização .....	44
2.2.5.1 Limiarização por Otsu .....	45
2.2.5.2 Aplicação Adaptativa de Limiar.....	46
2.2.6 Máscara de Nitidez e Filtragem <i>High-Boost</i> .....	47
2.2.7 Etiquetagem ( <i>Labeling</i> ) .....	47

2.3 SISTEMAS IMUNOLÓGICOS ARTIFICIAIS (SIA).....	48
2.3.1 Sistema Imunológico Natural .....	49
2.3.1.1 Resposta imunológica adaptativa .....	51
2.3.1.2 Princípio da seleção clonal .....	52
2.3.1.3 Distinção próprio/ não próprio .....	53
2.3.2 Sistema Imunológico Artificial .....	55
2.3.2.1 Algoritmo de seleção clonal .....	57
2.3.2.2 Algoritmo de seleção negativa .....	59
2.4 REDE NEURAL ARTIFICIAL .....	60
2.4.1 Redes Neurais Convolucionais.....	63
2.4.1.1 Camada convolucional .....	65
2.4.1.2 Camada de <i>pooling</i> .....	67
2.4.1.3 Camada totalmente conectada .....	68
2.4.2 Arquitetura AlexNet .....	68
2.4.3 <i>Autoencoder</i> .....	69
2.4.3.1 <i>Sparse autoencoder</i> .....	70
2.5 SVM .....	73
2.6 VALIDAÇÃO CRUZADA .....	74
2.6.1 Método <i>Holdout</i> .....	75
2.7 MEDIDAS DE DESEMPENHO DE CLASSIFICADORES .....	76
2.8 CONSIDERAÇÕES FINAIS .....	77
<b>3 ABORDAGENS RELACIONADAS .....</b>	<b>78</b>
3.1 TÉCNICAS RELACIONADAS .....	78
3.1.1 SIA.....	78
3.1.2 CNN como extrator de características .....	79
3.1.3 <i>Autoencoder</i> como Redutor de Dimensionalidade .....	80
3.2 APLICAÇÕES RELACIONADAS .....	81
3.2.1 Detecção e Classificação de Defeitos em Imagens PSVS .....	82
3.2.2 Detecção do Cordão de Solda em Imagens PDVD .....	88
3.2.3 Detecção e Classificação de Defeitos em Imagens PDVD.....	89
3.2.3.1 Segmentação do cordão de solda e detecção de descontinuidades.....	90

3.3 CONSIDERAÇÕES FINAIS .....	95
<b>4 MÉTODO .....</b>	<b>97</b>
4.1 ETAPA DE PRÉ-PROCESSAMENTO .....	98
4.1.1 Pré-processamento .....	98
4.1.2 Extração das Características .....	101
4.2 CONSTRUÇÃO DO BANCO DE DADOS .....	102
4.3 SIA PROFUNDO .....	103
4.3.1 Módulo SIA .....	104
4.3.2 Módulo de Aprendizagem Profunda .....	110
4.3.3 SIA com <i>autoencoder</i> .....	114
4.4 CONSIDERAÇÕES FINAIS .....	114
<b>5 EXPERIMENTOS.....</b>	<b>115</b>
5.1 MATERIAIS .....	115
5.2 PARÂMETROS – SIA PROFUNDO E SIA COM <i>AUTOENCODER</i> .....	119
5.3 ABORDAGENS DE COMPARAÇÃO .....	121
5.4 CONSIDERAÇÕES FINAIS .....	122
<b>6 RESULTADOS E DISCUSSÕES .....</b>	<b>123</b>
6.1 DETECÇÃO DAS DESCONTINUIDADES.....	123
6.2 FASE DE VALIDAÇÃO.....	128
6.2.1 Ajuste de Parâmetros – SIA Puro, SIA Profundo e SIA com <i>autoencoder</i> .....	128
6.2.2 Ajuste de Parâmetros – AlexNet .....	131
6.3 COMPARAÇÃO DE DESEMPENHO.....	132
6.3.1 Modelos: SIA Puro, SIA com <i>autoencoder</i> , SIA Profundo e AlexNet .....	132
6.3.2 SVM .....	138
6.4 CONSIDERAÇÕES FINAIS .....	139
<b>7 CONCLUSÃO.....</b>	<b>140</b>
7.1 TRABALHOS FUTUROS .....	142
<b>REFERÊNCIAS .....</b>	<b>143</b>
<b>APÊNDICE A - CAMADAS DA ALEXNET .....</b>	<b>152</b>

## 1 INTRODUÇÃO

As instalações de redes de tubulações condutoras de fluido são construídas através de um conjunto de tubos, conexões e diversos tipos de componentes e nestas redes de tubulações industriais, a maior parte dessas ligações é realizada por meio de juntas soldadas (NAYAR, 1992; TELLES, 2001; FELISBERTO, 2007). Essas instalações são projetadas para suportar condições críticas de temperatura e pressão. E mesmo com todos os cuidados, falhas ocorrem e quando não solucionadas a tempo, podem ocasionar vazamentos, paradas não programadas, perda de produção, incêndios ou até mesmo acidentes com sérios danos ambientais.

Em função do aparecimento de tais falhas, consequências graves podem ser evitadas por programas de inspeção periódica através de Ensaio Não-Destrutivo (END) (JAGANNATHAN *et al.*, 2000).

O termo Ensaio Não-Destrutivo (*Nondestructive Test/Evaluation*), de acordo com a *American Society for Nondestructive Testing* (ASNT, 2017), consiste em procedimentos e métodos para examinar produtos e materiais sem interferir ou alterar o seu funcionamento. De acordo com Godoi *et al.* (2005) e Andreucci (2017), a radiografia é um dos métodos de END mais utilizados na detecção de defeitos internos em juntas soldadas, pois a imagem do filme radiográfico é o retrato interno da peça.

Segundo Rabello *et al.* (2007), mesmo com os ganhos obtidos pela inspeção radiográfica, os riscos pertinentes à utilização de radiações ionizantes sempre se apresentaram como maiores limitantes relacionados ao emprego da técnica. Contudo, com o surgimento da radiografia computadorizada (RC), a radiologia industrial volta a ganhar espaço devido às vantagens proporcionadas pela nova tecnologia, dentre as quais se evidenciam: possibilidade de redução do tempo de exposição radiográfica e conseqüentemente da área de balizamento, obtenção direta de imagens digitais, eliminação do uso de produtos químicos e a possibilidade de reutilização dos detectores. Com estas características favoráveis, a radiografia computadorizada vem sendo considerada como recurso para análise em radiologia industrial em muitos problemas práticos sem que se conheçam totalmente, no entanto, seus benefícios e limitações.

A inspeção radiográfica das soldas é feita por pessoas com treinamento, qualificação e certificação (ANDREUCCI, 2017), denominadas inspetores de soldagem ou inspetores laudistas, que interpretam as imagens radiográficas com base nas normas especificadas pelas instituições de cada país. No Brasil, as normas são definidas pelo Comitê Brasileiro de Soldagem da Associação Brasileira de Normas Técnicas (ABNT), mais especificamente pela

norma NBR 14842 (2003), nas quais são descritas as atribuições dos inspetores de soldagem e suas devidas responsabilidades. As imagens fornecidas para este trabalho foram analisadas pelo inspetor em conformidade com as normas vigentes no Brasil (NBR 14842).

Considerando a parcialidade e a qualificação necessárias para a análise de imagens radiográficas, tem-se estudado o desenvolvimento de técnicas automatizadas capazes de auxiliar na detecção de defeitos em juntas soldadas. Várias pesquisas (LAWSON; PARKER, 1994; WANG; LIAO, 2002; SILVA, 2003; SHAFEEK *et al.*, 2004; PÁDUA, 2004; ALGHALANDIS; ALAMDARI, 2006; FELISBERTO, 2007; LIAO, 2008; LILING e YINGJIE, 2009; MAHMOUDI; REGRAGUI, 2009; VALAVANIS; KOSMOPOULOS, 2010; ZAPATA *et al.*, 2010; YAHIA *et al.*, 2011; CHEN; MIAO; MING, 2011; MERY, 2011; HALIM *et al.*, 2011; KROETZ *et al.*, 2012; RATHOD; ANAND, 2012; HALIM *et al.*, 2013; SUYAMA, 2015; BOARETTO, 2017) foram desenvolvidas propondo métodos automáticos e/ou semiautomáticos para a detecção de defeitos em juntas soldadas (cordões de solda) a partir de imagens radiográficas. A maioria dos pesquisadores utiliza imagens obtidas pela técnica de exposição parede simples vista simples (PSVS) em seus trabalhos. Alguns poucos trabalhos (KROETZ *et al.*, 2012; SUYAMA, 2015; BOARETTO, 2017; MIRANDA *et al.*, 2017; SUYAMA *et al.*, 2019) se diferenciam por utilizarem imagens obtidas pela técnica de exposição parede dupla vista dupla (PDVD) e diferem entre si pela base de dados utilizada, pela maneira como usam as imagens (por exemplo, utilizando ou não pré-processamento, detecção automática ou manual do cordão de solda, etc.) e pelo objetivo final do trabalho, o qual pode ser a localização da solda, a detecção de defeitos ou a localização da solda em conjunto com a detecção de defeitos.

Em relação à técnica de exposição PDVD, as imagens radiográficas são obtidas em tubulações com diâmetro inferior a 89 milímetros e a fonte radiográfica é posicionada na parte externa, com uma inclinação entre 12 a 15 graus, para obter uma imagem elíptica (BALAKRISHNAN, 2009). Edalati *et al.* (2007) realizaram experiências simulando a dispersão de raios e o contraste de imagens para a radiografia de parede dupla de tubulações e constataram que a sensibilidade requerida nem sempre era alcançável, devido à elevada dispersão. Logo, a detecção de defeitos em imagens de baixo contraste, como as imagens PDVD é ainda um grande desafio no processo de inspeção radiográfica.

Então, este trabalho busca contribuir com a área de inspeção semi-automática de tubulações de petróleo utilizando imagens radiográficas PDVD obtidas em condições reais de operação. Propõe-se um método baseado em sistemas imunológicos artificiais (SIA) e aprendizado profundo (*deep learning* - DL) para classificar discontinuidades como 'defeitos' e

'não defeitos'. Os mecanismos de SIA considerados neste trabalho são 'seleção negativa' e 'seleção clonal'. Com o objetivo de melhorar o desempenho da classificação, a abordagem proposta incorpora modelos de aprendizado profundo (AlexNet e *autoencoders*) para expandir o número de características extraídas além daqueles inicialmente obtidos pelo SIA.

O trabalho proposto é denominado 'SIA profundo' e é inspirado por atividades realizadas por inspetores, como manipulação e análise de imagens radiográficas e pelos mecanismos básicos de funcionamento do sistema imunológico biológico associado a terapias imunológicas artificiais. Dentre as atividades realizadas pelos laudistas destacam-se: a identificação de regiões de atenção na imagem (com ou sem auxílio de técnicas de PDI – Processamento Digital de Imagens), detecção do que é claramente defeito e claramente não defeito e depois auxílio de diferentes técnicas para análise sobre regiões que levantam dúvidas. Dentre as inspirações em SIA destacam-se a utilização do ASN e *matching* para as detecções iniciais e uso do ASC para evolução dos extratores (simulando técnicas de lentes e PDI que aprimoram a identificação dos defeitos). Primeiro, a abordagem proposta pré-processa a imagem, obtendo as regiões de atenção (descontinuidades). Em seguida, separa descontinuidades que podem ser claramente classificadas como não defeitos e defeitos. Para isso, utiliza os mecanismos de censura e monitoramento realizados pelo algoritmo de seleção negativa e inspirados no sistema imunológico. Em seguida, a abordagem inicia a fase de seleção clonal com o objetivo de melhorar a classificação. Para esse fim, primeiro, há uma tentativa de melhorar os dados através da evolução usando transformações semelhantes a lentes realizadas por decodificadores localizados nas células B (anticorpos). Segundo, reduz, de tempos em tempos, o valor limite necessário para classificar uma descontinuidade como um defeito, com o objetivo de reduzir ao máximo as taxas de falsos negativos sem, no entanto, comprometer a taxa de falsos positivos. Os experimentos consideram um conjunto de 20 imagens de PDVD obtidas em condições reais, que resultam em um conjunto de 727 descontinuidades a serem usadas nas fases de treinamento, validação e teste.

O presente trabalho busca avaliar duas hipóteses principais que também representam as duas principais contribuições deste trabalho: 1) Há ganho de desempenho ao se utilizar um limite que varia ao longo do processo evolutivo no corte para medida de compatibilidade entre imagem teste e padrão cujo valor diminua de tempos em tempos no módulo SIA? 2) Há ganho ao se utilizar uma abordagem híbrida (SIA + AlexNet + *autoencoder*) ao invés de se considerar cada um dos módulos sendo executado de forma isolada e independente? Para testar a primeira hipótese, os experimentos comparam um limite estático (fixo desde o início da evolução) com as versões de limite definidas dinamicamente (ou seja que são alteradas a



cada ciclo evolutivo) em um conjunto de dados de validação, dados estes que são usados para o ajuste fino deste importante parâmetro do sistema proposto. Para testar a segunda hipótese, o SIA profundo (versão híbrida) que representa a proposta principal do trabalho é comparado no conjunto de testes com outros três métodos também propostos nessa tese para a aplicação, sendo considerada SIA puro, SIA com *autoencoder* e abordagem de aprendizado profundo puro - AlexNet.

## 1.1 JUSTIFICATIVA

Nos últimos anos houve um aumento nas pesquisas focadas em métodos automáticos e semiautomáticos para apoiar a interpretação radiográfica de soldas e, assim, melhorar o processo de inspeção. Mesmo com um aumento nas pesquisas realizadas nesta área, poucos estudos têm sido realizados para a inspeção automática de imagens radiográficas PDVD, especialmente utilizando imagens reais.

Segundo Felisberto (2007), quando um grande volume de imagens necessita ser analisado, cada análise deve ser feita cuidadosamente buscando, durante todo o tempo, a mesma regularidade na aplicação de critérios e isto pode comprometer o tempo e a qualidade do processo da inspeção. Tanto Lawson e Parker (1994) quanto Silva (2001) citam ainda que a interpretação correta depende essencialmente da qualidade da imagem e da experiência, conhecimento e acuidade visual do inspetor. Desta forma, o processo de inspeção de radiografias industriais é bastante subjetivo, pois, o grande volume de imagens a serem laudadas pode tornar a inspeção longa e fatigante, aumentando a possibilidade de erros (FELISBERTO, 2007; GODOI *et al.*, 2005; LOPES *et al.*, 2010). Além disso, os resultados da interpretação visual de radiografias podem variar quando se comparam laudos realizados por inspetores diferentes ou, até mesmo, no caso de laudos realizados pelo mesmo profissional sob circunstâncias que afetem o seu estado psicológico no momento da execução da tarefa.

As imagens utilizadas neste trabalho fazem parte deste grupo pouco investigado, sendo compostas por cordões de solda parede dupla vista dupla (PDVD) e obtidas a partir de condições reais de campo. Apesar desta técnica possibilitar a análise simultânea das duas vistas da junta soldada, as imagens PDVD, normalmente, possuem qualidade inferior quando comparadas às imagens utilizadas na maioria dos estudos publicados na literatura citados anteriormente.

Em relação às técnicas que suportam a abordagem proposta, alguns fatores foram considerados na escolha de cada uma delas. Além das principais características de memória (como por exemplo o banco de células próprias e não próprias utilizadas no presente trabalho e também o fato de componentes do sistema bem sucedidos no reconhecimento poderiam ser armazenados para uma resposta futura mais intensiva e efetiva – essa última características acabou não sendo explorada no presente trabalho mas será tratada em trabalhos futuros), diversidade e capacidade de aprendizado por reforço do SIA, o motivo da escolha desta técnica também se baseia em sua difundida capacidade de reconhecer anomalias e padrões internos e externos do sistema (DE CASTRO, 2001). E mais, no uso de SIA é requerida apenas uma especificação geral, ou aproximada, de alguns aspectos que caracterizam o comportamento global do sistema, como uma medida (ou função) de desempenho, afinidade ou adaptabilidade.

Em SIA, existem diversos modelos computacionais desenvolvidos utilizando-se um ou mais princípios imunológicos, com o objetivo de modelar o sistema biológico e resolver problemas de engenharia. Logo, a escolha do modelo depende do objetivo e das características da questão a ser estudada (DE CASTRO, 2001; BERBERT, 2008; BERBERT; YAMAKAMI, 2009). Assim, nesse trabalho optou-se por escolher dois mecanismos do SIA mais tradicionais (seleção negativa e seleção clonal), tendo em vista o desafio do contexto escolhido para a aplicação.

Por outro lado, visando incluir técnicas do estado da arte em problemas de classificação, outros fatores foram considerados. Além das contribuições de técnicas já consagradas em aprendizado de máquina, algumas contribuições significativas têm sido alcançadas recentemente através do uso de métodos baseados em aprendizado profundo, principalmente através da extração de características usando Redes Neurais Convolucionais (CNN) (WIGGERS *et al.*, 2018). No entanto, devido à enorme quantidade de recursos computacionais necessários para treinar modelos da CNN a partir da inicialização aleatória da estrutura e pesos do modelo (ou seja, treinamento sem nenhum tipo de herança de conhecimento), para este estudo decidiu-se explorar o uso do aprendizado por transferência (*Transfer Learning* - TL). Além de economizar tempo de treinamento, o *Transfer Learning* também pode ser usado para superar a falta de amostras de treinamento em diferentes domínios de aplicação. Zhuang (2015), por exemplo, usa um algoritmo baseado em *autoencoders* para encontrar uma boa representação de instâncias em diferentes domínios. Yosinski (2014) e Oquab (2014) usam uma CNN como um extrator de características genéricas que é pré-treinado usando o conjunto de dados *ImageNet* e depois reutilizado para

outras tarefas. Inspirado na literatura, este trabalho usa um modelo AlexNet pré-treinado com o conjunto de dados *ImageNet* (DENG *et al.*, 2009) e ajusta suas camadas totalmente conectadas para executar duas tarefas diferentes: extração profunda de características e depois como um modelo *baseline* realizando a classificação completa. Portanto, primeiro, o modelo AlexNet é usado na abordagem proposta para fornecer características adicionais que passam por um nível de compactação realizado através de dois *autoencoders*; segundo, nos experimentos, é considerado como um modelo de comparação sendo executado de forma isolada do SIA para executar a tarefa completa de classificação, ao invés de funcionar somente como um extrator de características.

Assim, encerrada esta seção na qual se buscou apresentar as principais justificativas para a escolha, tanto do contexto do problema de aplicação quanto as técnicas consideradas para resolvê-lo, a próxima seção descreve os objetivos (geral e específicos) do presente trabalho.

## 1.2 OBJETIVOS

O objetivo geral desta pesquisa é propor um método para detecção de defeitos em imagens radiográficas de juntas soldadas de tubulações obtidas pela técnica de exposição parede dupla vista dupla (PDVD), adquiridas em situações reais de campo.

Além do objetivo principal, têm-se os seguintes objetivos específicos:

- Gerar um banco de padrões de defeitos e não defeitos, a partir de um conjunto de imagens PDVD laudadas por especialistas, a ser utilizado nos experimentos;
- Segmentar as discontinuidades que representam potenciais defeitos, que serão usadas na classificação dos defeitos das soldagens;
- Criar um protótipo que utiliza algoritmos baseados em sistemas imunológicos artificiais para a detecção de defeitos, mais especificamente, seleção negativa e seleção clonal;
- Incorporar ao protótipo modelos de aprendizado profundo (AlexNet e *autoencoders*) para expandir o número de características extraídas para melhorar a classificação das discontinuidades;

- Validar as hipóteses levantadas neste trabalho em relação ao ganho do uso do limiar dinâmico e uso da abordagem híbrida em comparação com limiares fixos e módulos usados isoladamente.

### 1.3 CONTRIBUIÇÕES

Este trabalho tem como principais contribuições:

- Proposta e implementação de um método para a detecção e classificação das descontinuidades (defeito e não defeito) que possa auxiliar a inspeção realizada por especialistas.
- Criação de um protótipo baseado em SIA para a detecção e classificação das descontinuidades de forma a permitir que as bordas da descontinuidade sejam totalmente envolvidas e apresentadas como resultado final.
- Utilização de características auxiliares cuja extração e redução da dimensionalidade é feita de forma inédita para esse contexto através de modelos de aprendizagem profunda (AlexNet e *autoencoders*);
- Combinação de abordagens distintas resultando num modelo híbrido, SIA e aprendizagem profunda (AlexNet e *autoencoders*), com a finalidade de ampliar as características das descontinuidades e melhorar a classificação das mesmas;
- Combinação de abordagens distintas resultando em outro modelo híbrido, SIA e *autoencoder*, para ampliar as características das descontinuidades e realizar a classificação das mesmas.

E como contribuição em termos de divulgação, os principais resultados obtidos a partir da pesquisa foram publicados no artigo Fioravanti *et al.* (2019).

### 1.4 ESTRUTURA DO TRABALHO

Após essa seção introdutória, o Capítulo 2 detalha os conceitos sobre a radiologia industrial aplicada a juntas soldadas de tubulações, as técnicas de obtenção de imagens radiográficas e a classificação dos principais defeitos encontrados nas juntas soldadas, bem

como fundamentos básicos de processamento digital de imagens, sistemas imunológicos artificiais, redes convolucionais, validação cruzada e medidas de desempenho. O Capítulo 3 apresenta as principais abordagens publicadas na literatura e relacionadas ao tema da pesquisa (em especial aquelas realizadas para a detecção e a classificação de defeitos nos cordões de solda). O Capítulo 4 descreve os métodos utilizados nesta pesquisa, detalhando-se a proposta para a detecção e a classificação automática de defeitos em juntas soldadas. O capítulo 5 detalha os experimentos realizados com os métodos utilizados nesta pesquisa. O Capítulo 6 mostra os resultados obtidos na pesquisa. O Capítulo 7 apresenta a conclusão sobre os resultados obtidos e sugestões para trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA


O objetivo principal deste capítulo é inserir conceitos fundamentais para a compreensão do estudo e está dividido em oito seções. A Seção 2.1 expõe as técnicas de inspeção radiográfica, bem como as principais discontinuidades obtidas nas imagens radiográficas de soldas em tubulações. A Seção 2.2 detalha conceitos e técnicas de processamento digital de imagens utilizadas no desenvolvimento deste trabalho. A Seção 2.3 descreve os princípios do SIA e apresenta os dois algoritmos, seleção negativa e seleção clonal. A Seção 2.4 descreve as redes neurais utilizadas. A Seção 2.5 explica a validação cruzada e a Seção 2.6 apresenta as medidas de desempenho de classificadores para validar o método. E a Seção 2.7 apresenta as considerações finais.

### 2.1 RADIOGRAFIA INDUSTRIAL APLICADA A JUNTAS SOLDADAS

A Radiografia Industrial é um método utilizado para inspeção não destrutiva que se baseia na absorção diferenciada da radiação penetrante pela peça a qual está sendo inspecionada. Por causa das diferenças na densidade e variações na espessura do material, ou mesmo diferenças nas características de absorção causadas por variações na composição do material, diferentes regiões de uma peça absorverão quantidades diferentes da radiação penetrante. Então, a radiografia industrial é utilizada para detectar variação de uma região de um determinado material que apresenta uma diferença em espessura ou densidade comparada com a região vizinha, desta forma, a radiografia é um método capaz de detectar com boa sensibilidade defeitos volumétricos (ANDREUCCI, 2017).

A Figura 1 ilustra como a radiação penetrante pode ser usada para investigar a estrutura interna de uma peça. A absorção diferenciada da radiação que atravessa o material e atinge um dispositivo que contém elementos sensíveis à radiação, neste caso um filme radiográfico, indica a existência de uma falha interna ou defeito no material. Como a região defeituosa possui uma densidade volumétrica diferente da densidade do material ao seu redor, absorve menos radiação, levando à formação de manchas que podem ser observadas nas imagens radiográficas (FELISBERTO, 2007; ANDREUCCI, 2017).

**Figura 1 – Esquema conceitual de ensaios radiográficos.**



**Fonte: Andreucci (2014).**

O grau de escurecimento, denominado densidade óptica, em cada ponto de uma imagem radiográfica é função dos números de fótons totais que atingem esse ponto. O número total de fótons é a soma do número de fótons que atravessam o artefato e o número de fótons espalhados (difração) que atravessam o mesmo depois de ter interagido com ele. Então, os fótons que passam através do objeto fornecem a imagem e os fótons espalhados resultam no aumento de ruído na imagem, borrando e reduzindo o contraste da imagem. Por esse motivo, a radiação dispersa que atinge o filme é um fator importante na redução da qualidade da imagem (EDALATI *et al.*, 2007).

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

A seguir são apresentadas algumas técnicas utilizadas e recomendadas por normas internacionais como ASME (*American Society of Mechanical Engineers*) (2004). Estas técnicas mostram diferentes disposições e arranjos entre a fonte de radiação, a peça e o filme, permitindo assim a aquisição das imagens radiográficas. As Figuras 2, 3 e 4 mostram as disposições entre a fonte-peça-filme para cada técnica apresentada e exemplos de radiografias obtidas com estas técnicas (ANDREUCCI, 2017; FELISBERTO, 2007). A técnica a ser utilizada depende do tipo do tubo, bem como do acesso para realizar o ensaio radiográfico.

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

Na técnica PSVS (Figura 2a) somente a seção da peça que está próxima ao filme é inspecionada e a projeção será em apenas uma dimensão do material. A radiação transmitida pela fonte atravessa a parede da tubulação por apenas um lado (de fora para dentro ou vice-versa). Essa técnica é utilizada em chapas e tubulações, nas quais o filme ou a fonte podem ser posicionados internamente. Como resultado tem-se a imagem de um cordão linear (Figura 2b), com uma qualidade melhor do que as obtidas em outras técnicas, o que torna mais simples sua interpretação.

**Figura 2 – Técnica de exposição PSVS. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante com destaque do cordão de corda e outros artefatos utilizados na identificação.**



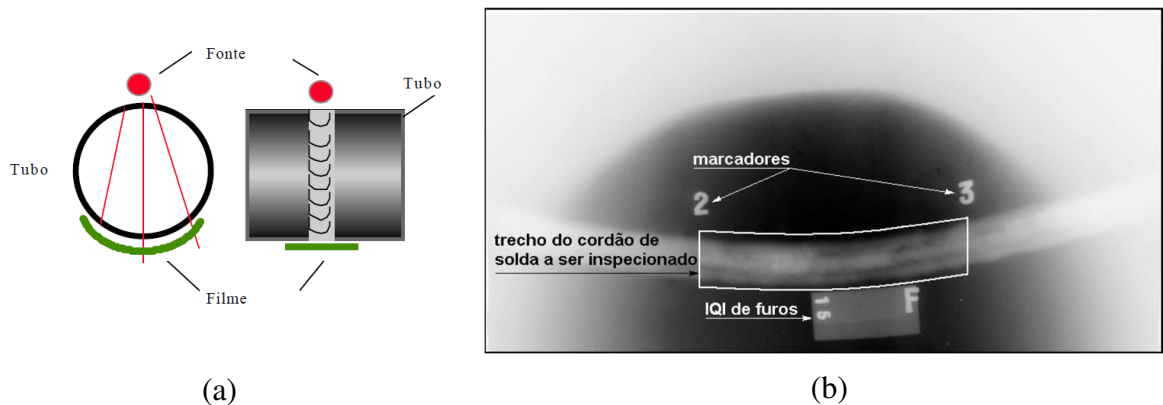
Fonte: Andreucci (2014), Felisberto (2007).

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

A técnica PDVS (Figura 3a) é utilizada, frequentemente, quando não se tem acesso ao interior da tubulação e vasos fechados. A fonte e o filme são posicionados externamente e o feixe de radiação atravessa as duas dimensões da peça, entretanto projeta no filme somente a seção da peça que está mais próxima ao mesmo. Como esta técnica requer que a radiação atravesse duas dimensões da peça, logo o tempo de exposição será maior que a inspeção pela técnica de parede simples. Visto que a radiação atravessa o dobro de material, a difração de raios-X é mais intensa, prejudicando a qualidade da imagem. O posicionamento da fonte, sendo alinhado ou inclinado em relação ao cordão de solda, influencia na geometria obtida para a projeção na imagem radiográfica. Na Figura 3b, tem-se um exemplo de projeção com aspecto curvo, pois a fonte estava inclinada.



**Figura 3 – Técnica de exposição PDVS. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante com destaque do cordão de corda e outros artefatos utilizados na identificação.**



**Fonte: Andreucci (2014), Felisberto (2007).**

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

Na técnica PDVD (Figura 4a) a fonte fica posicionada a uma distância maior da peça e o feixe de radiação também atravessa duas dimensões, projetando no filme a imagem de duas seções da peça. A fonte de radiação pode ser posicionada de duas maneiras: alinhada ao cordão de solda ou com ligeira inclinação. Quando a fonte é alinhada, as projeções do cordão de solda das duas paredes da tubulação se apresentam sobrepostas, quando a fonte possui uma inclinação, as projeções dos dois cordões de solda formam uma elipse (Figura 4b).

Nesta técnica, para o cálculo do tempo de exposição, levam-se em conta as duas espessuras das paredes que serão atravessadas pela radiação. Esta técnica é frequentemente utilizada em tubulações com diâmetros menores que 3½ polegadas (90mm). Como ocorre também nesta técnica, a radiação atravessa o dobro de material, portanto a difração de raios-X é mais intensa e com isso prejudica a qualidade da imagem.

**Figura 4 - Técnica de exposição PDVD. (a) Recomendação da posição da fonte de radiação e do detector. (b) Imagem resultante com destaque do cordão de corda e outros artefatos utilizados na identificação.**



Fonte: Andreucci (2014), Felisberto (2007).


### 2.1.2 Classificação Estrutural das Descontinuidades em Juntas Soldadas

As descontinuidades são quaisquer variações na homogeneidade de uma peça ou material, tanto em sua estrutura como em sua forma e são classificadas em relação à falta de material ou à presença de materiais estranhos (ANDREUCCI, 2017; FELISBERTO, 2007; MARINHO, 2009; MARQUES, 1991; MARQUEZE; QUITES, 1995). Nesta seção são apresentadas as principais descontinuidades, bem como os efeitos que estes produzem nas imagens radiográficas.

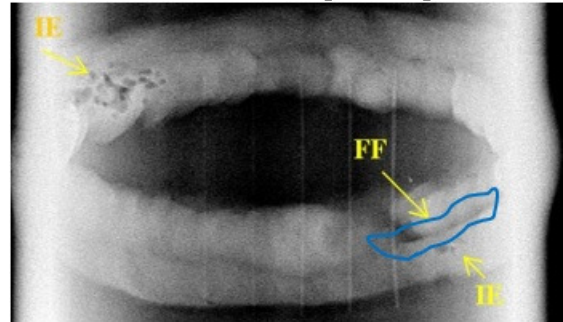
#### - Falta de Fusão (FF)

Esta descontinuidade representa a ausência de união por fusão entre passes adjacentes de solda ou entre a solda e o metal de base, resultante do não aquecimento adequado do metal presente na junta ou da presença de uma camada de óxido suficiente para dificultar a fusão do metal (MARQUES, 1991; MARQUEZE; QUITES, 1995). Na Figura 5 tem-se a representação do defeito (a), bem como o defeito exemplificado numa imagem radiográfica (b).

**Figura 5 – Falta de fusão. (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul o ponto do defeito e em amarelo destaque feito pelo laudista.**



(a)




(b)

Fonte: Marinho (2009), Wainer *et al.* (1992).


### - Falta de Penetração (FP)

Essa descontinuidade, refere-se a falha em se fundir e preencher completamente a raiz da solda (MARQUES, 1991; MARQUEZE; QUITES, 1995). Na Figura 6 tem-se a representação do defeito (a), bem como o defeito exemplificado numa imagem radiográfica (b).

**Figura 6 – Falta de penetração. (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul o ponto do defeito e em amarelo destaque feito pelo laudista.**



(a)



(b)


Fonte: Marinho (2009), Wainer *et al.* (1992).

### - Inclusão de Escória (IE)

Este termo é usado para descrever partículas de óxido e outros sólidos não metálicos aprisionados entre passes de solda ou entre solda e o metal de base (MARQUES, 1991; MARQUEZE; QUITES, 1995). Vários processos de soldagem utilizam fluxos que formam escória que tende a se separar do metal líquido na poça de fusão. Por vários motivos, parte

dessa escória pode ficar presa entre os passes de solda ou entre a solda e o metal de base. Na Figura 7 tem-se a representação do defeito (a), bem como o defeito exemplificado numa imagem radiográfica (b).

**Figura 7 – Inclusão de escória.** (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul o ponto do defeito e em amarelo destaque feito pelo laudista.




Fonte: Marinho (2009), Wainer *et al.* (1992).

#### - Mordedura (MO)

Esta descontinuidade descreve o processo de reentrâncias agudas formadas pela ação da fonte de calor do arco entre um passe de solda e o metal de base, ou outro passe adjacente (MARQUES, 1991; MARQUEZE; QUITES, 1995). Na Figura 8 tem-se a representação do defeito (a), bem como o defeito exemplificado numa imagem radiográfica (b).

**Figura 8 – Mordedura.** (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul o ponto do defeito e em amarelo destaque feito pelo laudista.




Fonte: Marinho (2009), Wainer *et al.* (1992).

#### - Porosidade (PO)

Essa descontinuidade é gerada durante a evolução dos gases durante a solidificação da solda (MARQUES, 1991; MARQUEZE; QUITES, 1995). As bolhas de gás podem ser aprisionadas pelo metal solidificado à medida que a poça de fusão é deslocada. Os poros têm

usualmente um formato esférico, porém poros alongados (porosidade vermicular) podem se formar. Como causa desse tipo de descontinuidade, cita-se a contaminação por sujeiras, umidade, óleo, graxa, ferrugem, entre outros na região da junta soldada. Na Figura 9 tem-se a representação do defeito (a), bem como o defeito exemplificado numa imagem radiográfica (b).

**Figura 9 – Porosidade. (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul os pontos dos defeitos e em amarelo destaque feito pelo laudista.**




Fonte: Marinho (2009), Wainer *et al.* (1992).

#### - Trincas (TR)

São consideradas as descontinuidades mais graves em soldas (MARQUES, 1991; MARQUEZE; QUITES, 1995). São fortes concentradores de tensão e podem favorecer o início da fratura frágil na estrutura soldada. A fratura frágil é uma forma de ruptura caracterizada pela ausência de deformação plástica macroscópica (MODENESI *et al.*, 2012). A trinca é considerada como o resultado da incapacidade do material em responder às solicitações impostas localmente pelas tensões decorrentes do processo da solda. As trincas resultam da atuação de tensões de tração. Na Figura 10 tem-se a representação do defeito (a), bem como o defeito exemplificado numa imagem radiográfica (b).

**Figura 10 – Trincas. (a) Representação do defeito destacando em azul o ponto do defeito. (b) Imagem radiográfica do defeito destacando em azul o ponto do defeito e em amarelo destaque feito pelo laudista.**



Fonte: Marinho (2009), Wainer *et al.* (1992).


## 2.2 PROCESSAMENTO DIGITAL DE IMAGENS

O objetivo desta seção é apresentar conceitos fundamentais e técnicas de processamento digital de imagens com aplicações voltadas ao desenvolvimento deste trabalho.

### 2.2.1 Imagens Digitais

O termo imagem refere-se a uma função bidimensional de intensidade da luz,  $f(x, y)$ , onde  $x$  e  $y$  indicam as coordenadas espaciais (plano) e o valor de  $f$  em qualquer ponto de coordenadas  $(x, y)$  proporcional ao brilho ou nível de cinza da imagem naquele ponto, como ilustra a Figura 11. Uma imagem digital é uma imagem  $f(x,y)$  discretizada tanto espacialmente quanto em amplitude, logo, ela pode ser visualizada como uma matriz onde linhas e colunas identificam um ponto na imagem e o valor do elemento corresponde ao nível de cinza da imagem naquele ponto (MARQUES FILHO e VIEIRA NETO, 1999; GONZALEZ e WOODS, 2010). Os elementos dessa matriz são denominados de elementos da imagem ou “*pixels*” (do inglês *picture element*).

**Figura 11 – Representação de uma imagem no plano cartesiano.**



**Fonte: Marques Filho; Vieira Neto (1999)**

A discretização espacial é denominada de amostragem da imagem e o processo de discretização de amplitude chamado de quantização em níveis de cinza. Na amostragem são selecionados pontos  $(x, y)$  para representar as áreas que compõem a região do plano  $xy$  para a

qual  $f$  é definida. Assim, as coordenadas de  $x$  e  $y$  são discretizadas em valores inteiros:  $i = 0, 1, \dots, m-1$  e  $j = 0, 1, \dots, n-1$ , respectivamente. Na quantização, as amplitudes dos valores de  $f(x,y)$ , para todo  $x = i$  e  $y = j$ , são transformados em um conjunto de níveis de cinza, variando do menor nível (valor 0 - preto) ao maior nível (valor  $L-1$  - branco). O resultado final da discretização é uma matriz de dimensões  $m \times n$  onde cada coordenada  $(i, j)$  representa uma região elementar da imagem analógica ( $f$ ) à qual é atribuído um valor que representa a intensidade luminosa da região.

O número de tons de cinza da imagem é limitado pelo tamanho do código binário usado para representá-lo, sendo  $L = 2^z$  onde  $L$  é o número máximo de níveis distintos de cinza do elemento  $f(x, y)$  e  $z$  é o número de bits.

### 2.2.2 Histograma

O histograma de uma imagem digital com níveis de intensidade no intervalo  $(0, L-1)$  é uma função discreta  $h(r_k) = n_k$ , onde  $r_k$  é o  $k$ -ésimo valor de intensidade e  $n_k$  é o número de pixels da imagem com intensidade  $r_k$  (GONZALES; WOODS, 2010). Visualizando o histograma de uma imagem, é possível ter uma indicação da sua qualidade em relação ao nível de contraste e ao seu brilho médio, ou seja, se a imagem é mais clara ou mais escura.

#### 2.2.2.1 Expansão de histograma

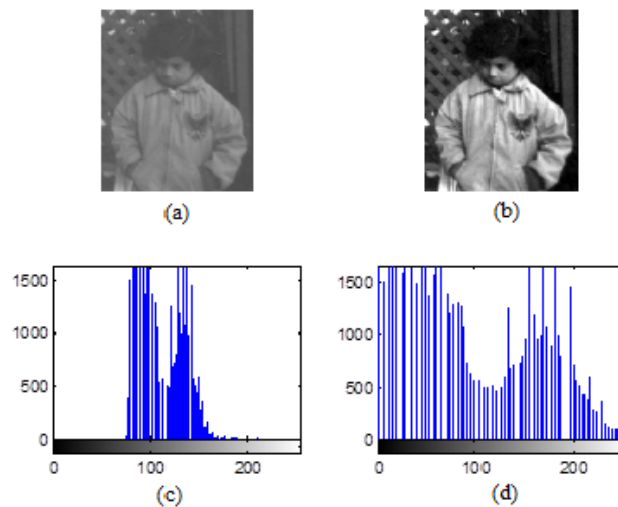
A expansão do histograma é uma operação que alonga a faixa de intensidade de *pixel* da imagem de entrada para que a imagem de saída tenha uma faixa dinâmica mais larga (SOLOMON; BRECKON, 2013). A técnica de expansão de histograma aumenta o contraste da imagem ocupando toda a faixa de cinza da imagem.

Para efetuar o reescalonamento, os limites superior e inferior dos valores de *pixels* a serem obtidos após a operação devem ser conhecidos e estes respectivamente denotados por *inf* e *sup* ao longo dos quais a imagem deve ser normalizada. A escala que determina o maior e o menor valor de nível de cinza da imagem, respectivamente denotados por *inter1* e *inter2*, é obtida pelo histograma da imagem original. Em função destes quatro valores, a faixa de valores de saída do *pixel* é reescalonada segundo a Equação 1 (SOLOMON; BRECKON, 2013):

$$I_{saída}(i, j) = (I_{entrada}(i, j) - inter1) \left( \frac{sup - inf}{inter2 - inter1} \right) + inf. \quad (1)$$

A Figura 12 apresenta o resultado do aprimoramento de contraste utilizando a expansão de histograma e abaixo de cada imagem estão representados os seus respectivos histogramas.

**Figura 12 – Expansão de histograma para  $inf=0$ ,  $inter1$  em torno de 80 e  $inter2$  em torno de 220 e  $sup=255$ . (a) Imagem original. (b) Imagem reescalada. (c) Histograma da imagem original. (d) Histograma reescalado a partir do histograma da imagem original.**



Fonte: Boaretto (2017).

### 2.2.2.2 Equalização de histograma

A equalização de histograma procura redistribuir os valores de tons de cinza dos *pixels* em uma imagem, de modo a obter um histograma uniforme, no qual o número (percentual) de *pixels* de qualquer nível de cinza é praticamente o mesmo. Conforme mostra a Equação 2, a forma mais usual de se equalizar um histograma é utilizar a função de distribuição acumulada da distribuição de probabilidades original (MARQUES FILHO; VIEIRA NETO, 1999):

$$s_k = (L - 1) \sum_{j=0}^k \frac{n_j}{n} \quad (2)$$

onde:

$$0 \leq n_j \leq n$$

$k = 0, 1, \dots, L-1$ , onde  $L$  é o número de níveis de cinza da imagem digitalizada;




$n$  = número total de *pixels* na imagem;

$s_k$  = novo valor a ser atribuído aos *pixels* de tom de cinza  $k$ ;

$n_j$  = número de *pixels* cujo nível de cinza corresponde a  $j$ .

A Figura 13 apresenta o resultado da equalização do histograma para uma imagem radiográfica de solda de 16 bits que apresenta baixo contraste.

**Figura 13 – Equalização de histograma. a) Imagem original. b) Imagem equalizada. c) Histograma da imagem original. d) Histograma equalizado a partir do histograma da imagem original.**



Fonte: Boaretto (2017).

### 2.2.3 Filtros para Remoção ou Suavização de Ruídos

Os filtros são denominados passa-baixas quando atenuam ou eliminam as componentes de alta frequência, tais como regiões de bordas e/ou detalhes finos na imagem. Assim, o efeito da filtragem passa-baixas é a suavização da imagem, provocando um leve borramento na mesma (MARQUES FILHO; VIEIRA NETO, 1999).

Todas as aplicações dos filtros devem ser feitas com critérios para que as informações relevantes não sejam perdidas, de forma a não subdimensionar um defeito e nem causar sua exclusão da imagem. (BOARETTO, 2017).

#### 2.2.3.1 Filtro da média

O filtro de média realiza a convolução de uma imagem com uma máscara cujos coeficientes têm um valor 1 e divide o resultado por um fator de escala (o número total de

pontos na máscara) (MARQUES, 2011). A máscara 3x3 é comumente a mais usada, quanto maior a máscara, maior será a atenuação de contraste na imagem.

Uma das principais limitações do filtro da média em casos onde a finalidade é remoção de ruídos em imagens está na sua incapacidade de preservar bordas e detalhes finos da imagem (MARQUES FILHO; VIEIRA NETO, 1999).

### 2.2.3.2 Filtro da mediana

No filtro da mediana, o nível de cinza de cada *pixel* é substituído pelo valor mediano de níveis de cinza na vizinhança daquele *pixel*. A função principal deste filtro é reforçar os pontos cujas intensidades são próximas dos seus vizinhos eliminando pontos isolados que apareçam na área de filtragem (GONZALEZ; WOODS, 2010).

### 2.2.3.3 Filtro de Wiener

O filtro de Wiener é um filtro adaptativo que utiliza a variância do ruído juntamente com a variância local para calcular o novo valor do *pixel* de referência da janela. Na região de fundo de uma imagem, as variações no valor dos *pixels* são devidas somente ao ruído. Esse filtro é bastante eficaz na redução de uma boa parcela do ruído presente em uma imagem, sem suavizar suas bordas (MARQUES FILHO; VIEIRA NETO, 1999) e pode ser obtido pela Equação 3,

$$W(i, j) = \mu + \frac{\sigma^2 + v^2}{\sigma^2} (I_{entrada}(i, j) - \mu) \quad (3)$$

onde:

- $\mu$  é o resultado da aplicação de um filtro da média local;
- $\sigma$  é a variância local em relação ao pixel;
- $v$  é a variância do ruído.


Os processos descritos anteriormente representam a base do pré-processamento realizado pela abordagem proposta neste trabalho.

## 2.2.4 Processamento Morfológico de Imagens

O princípio básico da morfologia matemática consiste em extrair as informações relativas à geometria e à topologia de um conjunto desconhecido (uma imagem), pela transformação através de outro conjunto completamente definido, chamado elemento estruturante. A Figura 14 apresenta alguns exemplos de elementos estruturantes. Nesta figura o ponto mais escuro indica a origem de seu sistema de coordenadas, ou seja, a posição do *pixel* em que o resultado será atribuído (MARQUES FILHO; VIEIRA NETO, 1999).

As operações morfológicas atuam sobre uma determinada vizinhança dos *pixels*, cuja forma e tamanho são determinadas pela sobreposição do elemento estruturante sobre cada *pixel* da imagem. O novo valor de cada *pixel* da imagem depende dos valores dos *pixels* na vizinhança definida pelo elemento estruturante. O modelo do elemento estruturante, sua forma e tamanho, é essencial para o sucesso das operações morfológicas que as utilizam (MARQUES, 2011) e estes parâmetros serão submetidos ao processo evolutivo na proposta baseada em sistema imunológico artificial que está sendo apresentado neste trabalho.

**Figura 14 – Exemplo de elementos estruturantes. (a) Cruz 3x3. (b) Quadrado 3x3.**



**Fonte: Boaretto (2017).**

### 2.2.4.1 Operações morfológicas de erosão, dilatação, abertura e fechamento

A erosão é definida pela Equação 4, onde A é a imagem de entrada (Figura 15(a)) e B é o elemento estruturante. Assim,  $A \ominus B$ , resulta no conjunto de pontos  $x$  tais que B, transladado de  $x$ , está contido em A (MARQUES FILHO; VIEIRA NETO, 1999) (Figura 15(c)).


$$A \ominus B = \{x \mid (B)_x \subset A\} \quad (4)$$

A dilatação é estabelecida pela Equação 5. O processo de dilatação consiste em obter a reflexão de B sobre sua origem e depois deslocar esta reflexão de  $x$ . A dilatação de A por B é, então, o conjunto de todos os  $x$  deslocamentos para aos quais a interseção de  $(\hat{B})_x$  e A

inclui pelo menos um elemento diferente de zero de forma que B e A se sobreponham pelo menos por um elemento (MARQUES FILHO; VIEIRA NETO, 1999). A Figura 15(b) ilustra o resultado da operação morfológica dilatação.

$$A \oplus B = \{x \mid (\hat{B})_x \cap A \neq \emptyset\} \quad (5)$$

**Figura 15 – Exemplo de operações morfológicas. (a) Imagem de entrada. (b) Imagem dilatada. (c) Imagem erodida.**



Fonte: Autoria própria (2020).

A abertura em geral suaviza o contorno de uma imagem, quebra istmos estreitos e elimina proeminências delgadas. O fechamento por sua vez, funde pequenas quebras e alarga golfos estreitos, elimina pequenos orifícios e preenche lacunas no contorno.

A abertura de um conjunto A por um elemento estruturante B, denotada  $(A \circ B)$ , é definida pela Equação 6, o que equivale a dizer que a abertura de A por B é simplesmente a erosão de A por B seguida de uma dilatação do resultado por B.

$$A \circ B = (A \ominus B) \oplus B \quad (6)$$

O fechamento do conjunto A pelo elemento estruturante B, denotada  $(A \bullet B)$ , é definida pela Equação 7, ou seja, é a dilatação de A por B seguida do resultado erodido pelo elemento estruturante B.

$$A \bullet B = (A \oplus B) \ominus B \quad (7)$$

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

A transformação *top-hat* é definida por Solomon (2013) como a diferença entre uma imagem  $I$  e a imagem que resulta da abertura com o elemento estruturante B, ou seja,  $I -$

$(I \circ B)$ . Esta operação tende a realçar os detalhes claros na presença de sombras, por isso é útil na recuperação de detalhes que se tornaram invisíveis devido à variação de iluminação ou sombreamento da imagem (SOLOMON; BRECKON, 2013).

A transformação *bottom-hat* é o resultado do fechamento de uma imagem  $I$  com o elemento estruturante  $B$  e seguido pela subtração entre este resultado e a própria imagem original, ou seja,  $(I \bullet B) - I$ . Esta operação consegue extrair da imagem seus vales, detalhes escuros da imagem.

#### 2.2.4.3 Extração de contornos em imagens binárias por operadores morfológicos

É possível extrair o contorno de um conjunto  $A$ , denotado por  $\beta(A)$ , executando a erosão de  $A$  por  $B$  e então calculando a diferença entre  $A$  e a sua erosão, como é apresentado na Equação 8 onde  $B$  é um elemento estruturante adequado para aquele conjunto (MARQUES FILHO; VIEIRA NETO, 1999).

$$\beta(A) = A - (A \ominus B) \quad (8)$$

#### 2.2.5 Limiarização

O princípio da limiarização consiste em separar as regiões de uma imagem quando esta apresenta duas classes (o fundo e o objeto). A forma mais simples de limiarização consiste na bipartição do histograma, convertendo os *pixels* cujo tom de cinza é maior ou igual a um certo valor de limiar ( $T$ ) em brancos e os demais em pretos. Assim, imagens em tons de cinza resultam em imagens binárias, cujo objetivo principal é a eliminação de informações irrelevantes, restando apenas os objetos de interesse na imagem, como por exemplo, as discontinuidades existentes no cordão de solda que possam representar defeitos de soldagem (MARQUES FILHO; VIEIRA NETO, 1999; BOARETTO, 2017). A operação de limiarização pode ser descrita como uma imagem de entrada  $f(x, y)$  com  $L$  níveis de cinza e que produz à saída uma imagem  $g(x, y)$  chamada imagem limiarizada ou binarizada. Neste último caso  $g(x, y)$  é definida pela Equação 9.

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) \geq T \\ 0 & \text{se } f(x, y) < T \end{cases} \quad (9)$$

onde  $T$  é um valor pré-definido de tom de cinza denominado limiar.

Se um único limiar for definido para toda a imagem, a limiarização é denominada de global. Ao subdividir a imagem em várias sub-imagens e definir para cada sub-região um limiar, a limiarização é denominada local.

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

### 2.2.5.1 Limiarização por Otsu

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

A aplicação de um limiar global de Otsu trata o histograma da imagem como uma função densidade de probabilidade discreta definida pela Equação 10 (OTSU, 1979).

$$Pr(r_k) = n_k/n \quad , \quad k = 0, 1, 2, \dots, L-1 \quad (10)$$

onde:

$n$  = número total de *pixels* da imagem;

$n_k$  = número de *pixels* com intensidade  $r_k$ ;

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

Um valor  $k'$  para o limiar pode ser escolhido tal que:  $C_0$  seja a classe de *pixels* com níveis entre  $[0, k-1]$  e  $C_1$  seja a classe de *pixels* com níveis entre  $[k, L-1]$ .

O método de Otsu escolhe  $k$  tal que maximize a variância inter-classes definida pela Equação 11.

$$\sigma_B^2 = \omega_0 (\mu_0 - \mu_T)^2 + \omega_1 (\mu_1 - \mu_T)^2 \quad (11)$$

Os parâmetros da Equação (11) são descritos nas Equações 12 a 16:

$$\omega_0 = \sum_{k=0}^{k'-1} p_k(r_k) \quad (12)$$

$$\omega_1 = \sum_{k=k'}^{L-1} p_k(r_k) \quad (13)$$

$$\mu_0 = \sum_{k=0}^{k'-1} kp_k(r_k)/\omega_0 \quad (14)$$

$$\mu_1 = \sum_{k=k_1}^{L-1} kp_k(r_k)/\omega_1 \quad (15)$$

$$\mu_T = \sum_{k=0}^{L-1} kp_k(r_k) \quad (16)$$

Baseado em características globais do histograma, um limiar ótimo é selecionado de forma automática e estável.

### 2.2.5.2 Aplicação adaptativa de limiar

Para superar algumas limitações da técnica de limiar global, a abordagem de aplicação adaptativa de limiar utiliza um limiar diferente para cada posição do *pixel* na imagem. Geralmente, o limiar é definido pelos valores dos *pixels* na vizinhança  $M \times M$  do *pixel* em consideração (SOLOMON; BRECKON, 2013).

Na abordagem adaptativa, o valor do limiar local  $t$  pode ser baseado em diferentes estatísticas. Na maior parte dos casos, o limiar é escolhido sendo:  $t = \text{média} + D$ , onde  $D$  é a constante de deslocamento, levando os  $M \times M$  *pixels* vizinhos do *pixel* em consideração. A escolha de  $M$  é importante e seu valor deve ser suficientemente grande para, em cada ponto, cobrir um número adequado de *pixels* do objeto e do fundo, entretanto não deve ser demasiadamente grande a ponto de permitir que as deficiências de iluminação global interfiram no valor do limiar. Quando o contraste da imagem é baixo, a constante de deslocamento  $K$  é inserida no limiar global para definir um limiar que tenha um valor acima da variância de ruído em áreas de *pixels* uniformes.

O algoritmo de limiarização adaptativa apresentado por Solomon e Breckon (2013) aplica o filtro da média em uma região  $M \times M$  e em seguida adiciona uma constante  $D$

(definida empiricamente) à imagem filtrada para obter uma imagem mais clara. Depois, a imagem resultante é subtraída da imagem original. Essa operação gera valores baixos de níveis de cinza, de forma que os valores acima de zero serão alterados para o nível máximo e valores iguais a zero para o nível mínimo.

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

O processo denominado máscara de nitidez consiste em subtrair da imagem original uma versão não nítida (suavizada) desta mesma imagem de forma a ampliar a nitidez (GONZALEZ; WOODS, 2010).

Com  $\bar{f}(x, y)$  denotando a imagem processada (por um filtro passa-baixa com alterações significativas na imagem) e  $f(x, y)$  a imagem original, a máscara de nitidez é expressa na forma da Equação 17.

$$g_{máscara}(x, y) = f(x, y) - \bar{f}(x, y) \quad (17)$$

Depois, adiciona-se uma porção ponderada da máscara de nitidez à imagem original, com a inserção de um peso  $w$  ( $w \geq 0$ ), representado pela Equação 18.

$$g(x, y) = f(x, y) + w * g_{máscara}(x, y) \quad (18)$$

Se  $w = 1$ , tem-se como resultado a máscara de nitidez, caso  $w > 1$ , o processo é chamado de filtragem *high-boost* (GONZALES; WOODS, 2010). Para atenuar a contribuição da máscara de nitidez pode-se usar  $w < 1$ .

### 2.2.7 Etiquetagem (*Labeling*)

O algoritmo de etiquetagem localiza as componentes conectadas em uma imagem e atribui uma única etiqueta (*label*) a todos os pontos do mesmo elemento.

O algoritmo sequencial utilizado para classificar objetos em imagens binárias (GONZALEZ; WOODS; EDDINS, 2004), tem as seguintes etapas:

1. Varrer a imagem da esquerda para a direita e de cima para baixo.



2. Se o *pixel* tem o valor 1, então analisam-se os vizinhos superior e o da esquerda:
  - a. Se apenas um dos vizinhos, tem *label*, copia-se o *label*.
  - b. Se ambos têm o mesmo *label* então copia-se o *label*.
  - c. Se os *labels* são diferentes então copia-se o *label* superior e armazenam-se os dois *labels* em uma tabela de equivalência como o mesmo *label*.
  - d. Se nenhuma das anteriores for válida, atribui-se um novo *label* para este *pixel*.
3. Se há mais *pixels*, retorne ao passo 2.
4. Varrer novamente a imagem. Substituir cada *label* pelo *label* de valor inferior na tabela de equivalência.

No algoritmo de etiquetagem, o processo de varredura é considerado *pixel a pixel*, da esquerda para a direita e de cima para baixo.

Essa etapa de pré-processamento é necessária devido à dificuldade imposta pelas imagens reais, as quais, além de possuírem baixíssimo contraste, apresentam alto nível de ruído. Embora técnicas de aprendizado profundo fossem alternativas interessantes para lidar com essas questões, a pequena dimensionalidade do conjunto de dados de treinamento dificulta o uso dessas técnicas. Além de permitir que as regiões de atenção possam ser identificadas previamente, as transformações nas imagens realizadas pelas técnicas adotadas por Boaretto (2017) permitem que filtros de aprendizado profundo pré-treinados para outras aplicações possam ser considerados (processo denominado de *Transfer Learning* e que nesse trabalho considera os filtros da AlexNet obtidos pelo treinamento da base *ImageNet*).

### 2.3 SISTEMAS IMUNOLÓGICOS ARTIFICIAIS (SIA)

Em analogia à Computação Evolutiva, Sistemas Imunológicos Artificiais se inspiram na natureza (mais especificamente nos Sistemas Imunes Biológicos), a partir da tentativa de simular mecanismos particulares e criar sistemas artificiais para a resolução de problemas complexos (BERBERT, 2008; BERBERT; YAMAKAMI, 2009). O sistema imunológico natural, cujos conceitos básicos são apresentados na próxima seção, é composto de um complexo conjunto de células e moléculas que formam um mecanismo de defesa rápido e


efetivo contra a invasão de agentes infecciosos no nosso organismo. Parte desse mecanismo é baseada em reconhecimento de padrões e pode dar suporte ao desenvolvimento de técnicas computacionais para a solução de problemas de classificação.

### 2.3.1 Sistema Imunológico Natural

Com o objetivo de manter o organismo saudável, o sistema imunológico natural (SIN) possui mecanismos avançados de reconhecimento e combate a agentes infecciosos externos (chamados patógenos), que por sua vez, possuem assinaturas (padrões) moleculares específicas (chamadas antígenos). Quando estes antígenos são reconhecidos pelas células do SIN, a reação de defesa do organismo é disparada (DE CASTRO, 2001; COELHO, 2011).

Caso um agente externo consiga romper as barreiras (físicas, como a pele, e bioquímicas, como os fluidos - saliva, lágrima e suor) de um organismo e finalmente invadi-lo, a resposta imunológica será disparada em duas frentes: a primeira delas, chamada resposta imunológica inata, é disparada imediatamente pelo sistema imunológico inato; já a segunda, a resposta imunológica adaptativa, é uma resposta mais lenta e específica a cada tipo de patógeno, sendo disparada pelo sistema imunológico adaptativo. Juntos, os sistemas imunológicos inato e adaptativo formam um mecanismo de defesa extremamente eficiente e que opera em paralelo, recorrendo a uma diversidade de agentes e componentes distribuídos espacialmente e operando em rede (Figura 16) (DE CASTRO, 2001; BERBERT, 2008).

**Figura 16 – Estrutura multicamadas do sistema imunológico.**



**Fonte: De Castro (2001).**

As principais células do sistema inato são denominadas fagócitos, pois possuem receptores capazes de reconhecer padrões moleculares presentes em agentes invasores e estão imediatamente disponíveis para combater eventuais infecções. Quando os fagócitos identificam algum agente invasor, eles englobam (fagocitam) o agente identificado, ou seja, envolvem o patógeno e quebram sua estrutura molecular, simultaneamente estimulando a produção de citocinas. As citocinas emitem então sinais para outras células do sistema imunológico e induzem uma resposta inflamatória, cujos principais sintomas são dor, calor, vermelhidão e inchaço no local atingido. Com esta resposta inflamatória, a atividade de alguns patógenos tende a diminuir, enquanto a resposta adaptativa é estimulada (MORIM, 2009; COELHO, 2011).

A resposta adaptativa é bem mais específica a cada agente invasor e, conseqüentemente, requer um certo tempo para que possa surtir efeitos, ao contrário da resposta imunológica inata, que é responsável por um combate inicial e rápido a qualquer infecção. Enquanto as células do sistema inato são capazes de responder a uma ampla gama de agentes invasores sem a necessidade de uma exposição prévia a eles, as células do sistema adaptativo (responsáveis pela liberação dos chamados anticorpos) são ativadas e produzidas em resposta a infecções específicas. Portanto, as infecções se estabelecem toda vez que os agentes invasores não são neutralizados pelo sistema inato (COELHO, 2011).

Os linfócitos são as principais células do sistema imune adaptativo. Há dois tipos: os linfócitos B (células B) e os linfócitos T (células T); e ambos possuem em sua superfície receptores de antígenos com alta especificidade. Estas células atuam na resposta adaptativa através do reconhecimento e da eliminação de patógenos e também através da constituição da chamada memória imunológica. A memória imunológica corresponde basicamente à capacidade que as células do sistema adaptativo têm de reconhecer um mesmo antígeno (ou um antígeno semelhante) quando houver uma reincidência da infecção, levando assim a uma resposta imunológica mais rápida e pode até mesmo evitar o reestabelecimento da doença no organismo. Graças a estes mecanismos, a resposta adaptativa dá ao sistema imunológico a capacidade de aprender e se aprimorar a cada infecção sofrida (DE CASTRO, 2001; COELHO, 2011).

Uma diferença entre as respostas imune adaptativa e inata é que, enquanto a adaptativa resulta na imunidade contra a reinfecção ao mesmo agente infectante, a inata não sofre mudanças expressivas ao longo da vida de um indivíduo, independente da exposição a antígenos. Considerando-se o conjunto, os sistemas contribuem para uma defesa notavelmente eficaz, garantindo que, embora passemos nossas vidas cercados por germes potencialmente


patogênicos, apresentemos resistência às enfermidades (DE CASTRO, 2001; CASTRO, 2009).

### 2.3.1.1 Resposta imunológica adaptativa

Quando um patógeno invade um organismo, ele pode ser englobado por um grupo de células chamadas fagócito (no timo, que é uma pequena glândula do corpo humano atuando no sistema imunológico e exerce o papel de promover a maturação da célula de defesa T que denomina-se macrófago), tendo sua estrutura molecular fragmentada e o macrófago em questão passa a exibir, em sua superfície, peptídeos característicos deste patógeno, que são conhecidos como antígenos (CASTRO, 2009; COELHO, 2011). Estes macrófagos se deslocam para os chamados linfonodos, nódulos espalhados pelo organismo com alta concentração de células do sistema imunológico, onde os antígenos que estão na superfície são reconhecidos pelas células T. Essas células estimulam a reprodução de células B, as quais se diferenciam em células B de memória e células B de plasma. As células B de memória possuem um período de vida mais longo que as outras e circulam pelo sangue e pelos vasos linfáticos e tecidos; além de garantir uma resposta mais rápida a patógenos com antígenos similares que possam vir a invadir o organismo no futuro. Enquanto as células de plasma são as principais células secretoras de anticorpos do organismo.

As células B e T possuem moléculas receptoras em suas superfícies capazes de reconhecer antígenos e o receptor de antígeno da célula é o anticorpo ligado à membrana da mesma. Os anticorpos são estruturas moleculares que se ligam aos antígenos presentes tanto nos patógenos quanto nas moléculas infectadas, funcionando basicamente como sinalizadores que indicam quais indivíduos devem ser eliminados do organismo (Figura 17) (DE CASTRO, 2001; CASTRO, 2009). A região do antígeno em que ocorre a ligação com o anticorpo é denominada epítipo. Embora um anticorpo possua apenas um tipo de receptor de antígeno, um mesmo antígeno pode apresentar múltiplos epítipos, isto é, diferentes anticorpos podem se ligar a um único antígeno. Os anticorpos e os antígenos possuem composições físico-químicas bem definidas, de forma que, quanto melhor forem as afinidades, melhor será a qualidade da ligação entre eles.

**Figura 17– Linfócito B. (a) Destaque para o anticorpo em sua superfície. (b) Antígeno reconhecido por um anticorpo.**

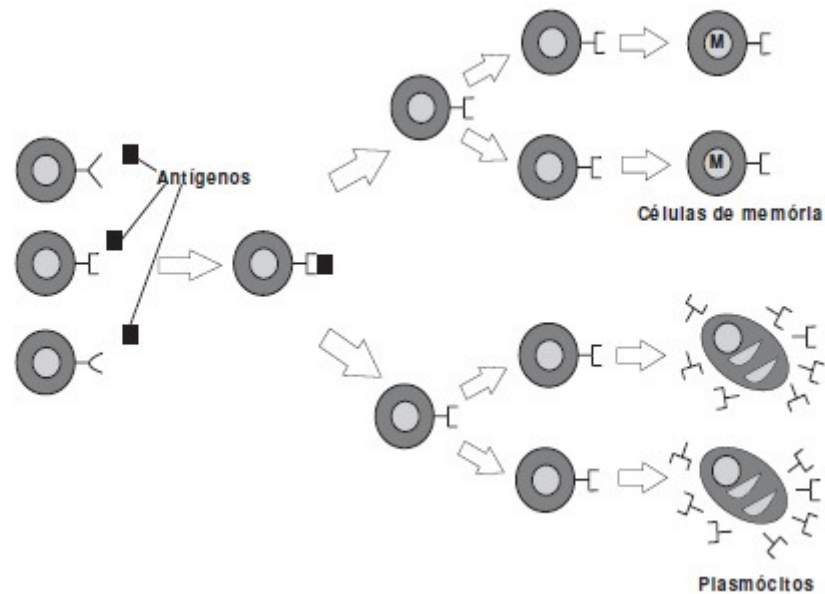


Fonte: De Castro (2001).

### 2.3.1.2 Princípio da seleção clonal

Cada célula apresenta um padrão (forma) distinto de receptor antigênico, assim o número de linfócitos (células B ou T) que podem se ligar a um determinado antígeno é restrito (DE CASTRO, 2001; CASTRO, 2009; COELHO, 2011). A fim de produzir células suficientes para combater a infecção, a célula ativada (aquela que reconheceu o antígeno) deve se proliferar, gerando cópias idênticas (clones) dela mesma (Figura 18). Durante o processo de clonagem, para que haja uma adaptação dos clones gerados aos antígenos invasores, ou seja, para que sejam produzidos anticorpos que tenham maior afinidade com os antígenos, os novos clones sofrem um processo de maturação de afinidade, que é constituído basicamente de duas etapas: hipermutação e seleção.

**Figura 18- Princípio da Seleção Clonal.**



**Fonte: De Castro (2001).**

Durante a proliferação das células B, ocorre também um processo de diferenciação destas células, podendo levar à criação de células B de memória, que são responsáveis por garantir uma resposta mais rápida a futuras infecções por patógenos semelhantes e a criação de células de plasma (plasmócitos), que são as principais células secretoras de anticorpos do organismo (DE CASTRO, 2001; COELHO, 2011).


Na etapa da hipermutação, os clones de cada célula B têm sua estrutura modificada, com taxas de variabilidade genética inversamente proporcionais à sua afinidade com os antígenos, ou seja, aquelas células que possuem maior capacidade de reconhecimento do antígeno sofrem uma variação genética menor, enquanto as células não tão afins sofrem maior variação (DE CASTRO, 2001; CASTRO, 2009). O mecanismo de seleção regula o processo de hipermutação, que é dependente da afinidade do receptor, fazendo que as células com receptores de baixa afinidade continuem sendo mutadas, enquanto células com altas afinidades tenham suas taxas de mutação controladas e até inativadas.

### 2.3.1.3 Distinção próprio/ não próprio

De Castro (2001) afirmou que o sistema imunológico em sua capacidade de reconhecer antígenos é completo, uma vez que as moléculas de anticorpo e os receptores de linfócitos T (TCR) (Figura 19) podem, em essência, reconhecer qualquer molécula própria ou

não própria, até mesmo aquelas artificialmente sintetizadas. E para que o sistema imunológico funcione corretamente, é necessário que ele seja capaz de distinguir entre as células e moléculas do próprio organismo, chamadas de *próprio*, das moléculas estranhas, chamadas *não próprio*, que são, em princípio, indistinguíveis. Se o sistema imunológico não for capaz de realizar esta distinção, então uma resposta imunológica será desencadeada contra os antígenos próprios, causando *doenças autoimunes*.


**Figura 19 – Linfócito T, com destaque para o TCR em sua superfície.**



**Fonte: De Castro (2001).**

De Castro e Timmis (2002) comentaram que além da característica aleatória na produção dos receptores linfocitários, um encontro entre um receptor e um antígeno não resulta inevitavelmente na ativação do linfócito, mas pode casualmente provocar a morte ou inativação (*anergia*) celular (Figura 20). Assim, a existência de um mecanismo de *seleção negativa* evita que os linfócitos autoespecíficos (autorreativos) se tornem autoagressivos, e em função deste princípio, a mesma será utilizada numa das etapas desenvolvidas neste trabalho: reconhecimento do próprio (tubo e cordão de solda). Por outro lado, uma pequena porcentagem de células sofre uma *seleção positiva* tornando-se células capazes de montar uma resposta imune adaptativa, chamadas de *células imunocompetentes*, para constituir o *repertório linfocitário disponível*.

Figura 20 - Esquema das principais interações entre antígenos e linfócitos.



Fonte: De Castro (2001).

### 2.3.2 Sistema Imunológico Artificial

A área de pesquisa dos Sistemas Imunológicos Artificiais é extensa e a escolha dos melhores modelos depende do objetivo e das características do problema a ser estudado. Pela grande quantidade de modelos e aplicações dos Sistemas Imunológicos Artificiais não existe um esquema geral de quais elementos essenciais um algoritmo deve possuir, ao contrário de outras técnicas bio-inspiradas, que possuem um algoritmo geral único.

Os Sistemas Imunológicos Artificiais surgiram a partir de tentativas de modelar e aplicar princípios imunológicos no desenvolvimento de novas ferramentas computacionais em função das suas diferentes características, funcionalidades e propriedades tais como: reconhecimento de padrões, detecção de faltas e anomalias, podendo essas ferramentas serem aplicadas a segurança computacional e de rede, otimização de processos, controle e *scheduling*, robótica, análise de dados e agrupamento, aprendizagem de máquina, processamento de informações, resolução de problemas, dentre outras (DE CASTRO, 2001; GOMES, 2006; BERBERT, 2008; BERBERT, YAMAKAMI, 2009; LIMA, 2013; LIMA *et al.*, 2014; ARRUDA, 2015; DA ROCHA, 2017).

Sob a perspectiva da engenharia, algumas características do Sistema Imunológico podem ser destacadas (DE CASTRO, 2001; BERBERT, 2008):



- Unicidade: cada indivíduo possui seu próprio Sistema Imunológico, tendo suas capacidades e vulnerabilidades particulares;
- Reconhecimento de padrões internos e externos ao sistema: as células e as moléculas que não pertencem ao organismo são reconhecidas e eliminadas pelo Sistema Imunológico;
- Detecção de anomalias: o Sistema Imunológico pode detectar e reagir a agentes patogênicos;
- Detecção imperfeita (tolerância a ruídos): uma detecção perfeita não é necessária;
- Detecção distribuída: as células do Sistema Imunológico estão distribuídas por todo o corpo, não estando sujeitas a um mecanismo de controle central;
- Diversidade: existe uma quantidade limitada de células e moléculas no Sistema Imunológico que são utilizadas para se obter o reconhecimento de um número praticamente infinito de elementos;
- Aprendizagem por reforço: a cada encontro com o mesmo patógeno o Sistema Imunológico melhora a qualidade de sua resposta;
- Memória: os componentes do Sistema Imunológico bem-sucedidos no reconhecimento e combate às patologias são armazenados para uma resposta futura mais intensa e efetiva.

Uma aplicação específica dos Sistemas Imunológicos Artificiais, que pode ser útil para o problema de detecção de defeitos, é o reconhecimento de padrões. Uma vez que o Sistema Imunológico protege o corpo contra as infecções devido ao ataque de um agente causador de doença, as células e as moléculas que não pertencem ao organismo são reconhecidas e eliminadas (SERAPIÃO *et al.*, 2007).

De Castro (2001) propôs quatro ferramentas baseadas na teoria de Sistemas Imunológicos Artificiais, sendo elas: SAND (algoritmo cujo objetivo principal é aumentar a diversidade de um repertório de anticorpos), CLONALG (algoritmo de seleção clonal), ABNET (rede neural artificial booleana baseada na seleção clonal e maturação de afinidade) e AINET (rede imunológica artificial).

Dasgupta, Yu e Nino (2011) apresentaram um estudo citando alguns modelos dos algoritmos de SIA que foram desenvolvidos e adquiriram popularidade; sendo eles: algoritmos de seleção negativa (NSA), redes imunológicas artificiais (AINE), algoritmos de

seleção clonal (CLONALG), algoritmos inspirados na Teoria do Perigo e algoritmos de células dentríticas (DCA).

Dentre os vários modelos que foram estudados e desenvolvidos, serão explicados neste trabalho o algoritmo de seleção clonal e o algoritmo de seleção negativa, considerando que ambos possuem características específicas para a tarefa de reconhecimento de padrões.

Como o algoritmo CLONALG, criado por De Castro (2001) e o algoritmo de seleção clonal utilizam os princípios da seleção clonal (envolvendo a aprendizagem por reforço, memória imunológica e a maturação por afinidade) e ambos resolvem problemas de reconhecimento de padrões, com a diferença de que o CLONALG tem uma adaptação para problemas de otimização (focando o caso multimodal), neste trabalho utiliza-se o algoritmo de seleção clonal, considerando-se o reconhecimento de padrões e não otimização.

### 2.3.2.1 Algoritmo de seleção clonal (ASC)

Este algoritmo baseia-se no princípio da seleção clonal (DE CASTRO, 2001; DASGUPTA, 2006), que descreve as características básicas de uma resposta imune a um estímulo antigênico. Estabelece-se a ideia de que apenas as células que reconhecem o antígeno proliferam. As principais características da teoria da seleção clonal são: as novas células são cópias de seus pais (clone) e são posteriormente submetidas a um mecanismo de mutação com altas taxas; linfócitos recentemente diferenciados que transportam receptores auto-reativos são eliminados; e proliferação e diferenciação em contato das células maduras com antígenos.

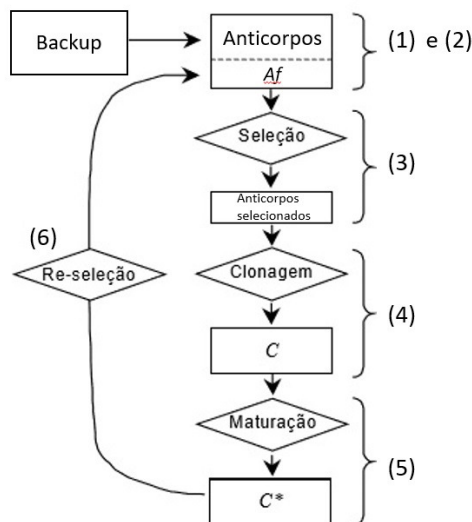
O algoritmo ASC engloba o princípio de seleção clonal e maturação de afinidade, desenvolvido para resolver problemas de reconhecimento de padrões. Também é possível caracterizar o algoritmo como uma abordagem competitiva, uma vez que os anticorpos estão competindo pelo reconhecimento antigênico ou por uma maior afinidade, ou seja, antígenos são os elementos do conjunto de modelos de padrões e anticorpos são os elementos do conjunto de possíveis soluções (YAVUZ *et al.*, 2018; ZHONG; ZHANG, 2013).

O algoritmo de seleção clonal, basicamente, pode ser descrito considerando-se seis etapas (Figura 21) (DE CASTRO; VON ZUBEN, 2000):

1. Gere um conjunto de anticorpos;
2. Apresente cada anticorpo aos antígenos e calcule uma medida de afinidade (função de *fitness*);

3. Selecione anticorpos com as maiores afinidades com os antígenos;
4. Clone os anticorpos na proporção de suas afinidades: quanto maior a afinidade, maior o número de clones;
5. Envie clones para o processo de maturação por afinidade (via hipermutação): cada um deles muda a uma taxa inversamente proporcional à sua afinidade: quanto maior a afinidade, menor a taxa de mutação;
6. Se o número de iterações estiver completo, termine o algoritmo; caso contrário, retorne à etapa 2.

**Figura 21 – Diagrama de blocos do algoritmo de seleção clonal, ASC.**



**Fonte: Adaptado de De Castro (2001).**

Em cada iteração, o algoritmo ASN permite que o sistema imunológico artificial se torne cada vez melhor para executar a tarefa de reconhecimento de padrões.

Segundo Dasgupta (2006), este algoritmo assemelhou-se aos algoritmos evolutivos baseados em mutação com algumas características interessantes, tais como: tamanho da população dinamicamente ajustável; exploração do espaço de busca; boa capacidade de busca pela solução ótima (ou perto da ótima); capacidade de manutenção de soluções ótimas locais e critério de parada definido.

Neste trabalho, os princípios básicos do ASC serão usados para a tarefa que mescla evolução e reconhecimento de padrões. A evolução dos parâmetros dos elementos estruturantes permite a modificação na janela a partir da qual serão extraídas as características confrontadas com aquelas guardadas no banco de dados.

### 2.3.2.2 Algoritmo de seleção negativa (ASN)

Dasgupta e Gonzalez (2005) e Dasgupta (2006) citaram que dentre as várias finalidades do sistema imunológico, uma delas era reconhecer todas as células (ou moléculas) dentro do corpo e categorizar essas células como próprias (conhecidas, como células, proteínas e, em geral, qualquer molécula que pertença ou seja produzida pelo organismo) ou não próprias (desconhecidas, como o antígeno representados por bactérias e vírus). As células não próprias foram ainda categorizadas de modo a induzir um tipo apropriado de mecanismo de defesa. O sistema imunológico, através da evolução, aprende a distinguir entre antígenos estranhos (por exemplo, bactérias, vírus, etc.) e as células do próprio corpo ou moléculas. O objetivo da seleção negativa é fornecer tolerância para as células independentes (anticorpos naturais) lidando com a capacidade do sistema imunológico para detectar antígenos desconhecidos. As células T no timo reagem contra proteínas próprias e são destruídas; assim, apenas aquelas que não se ligam às autoproteínas (proteínas inofensivas - não infecciosas - produzidas pelo organismo) são autorizadas a sair do timo. Estas células T maduras, em seguida, circulam ao longo do corpo para executar funções imunológicas e proteger o corpo contra antígenos estranhos.

Definindo o repertório de padrões de células próprias, o algoritmo de seleção negativa gera um conjunto de detectores capazes de identificar todos os elementos que não pertencem ao conjunto de células próprias. Como representado na Figura 22, o algoritmo é executado em duas fases, conforme descrito abaixo (DASGUPTA, 2006):

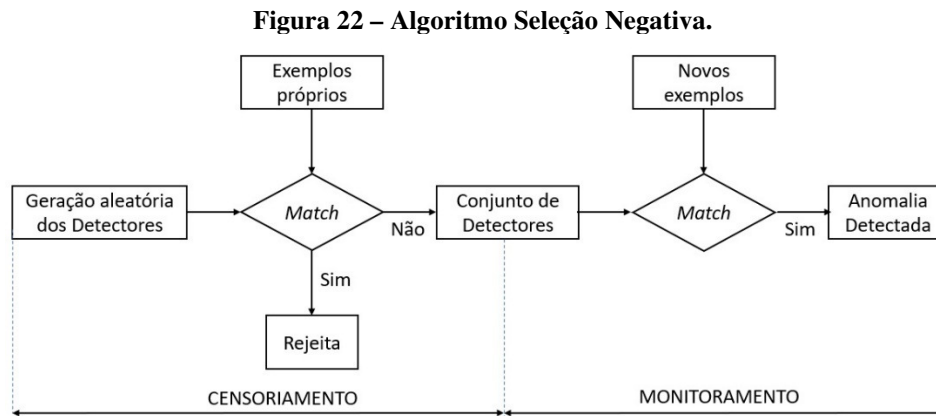
#### 1. Censoriamento:

- Defina o conjunto de padrões próprios (S);
- Gere aleatoriamente um conjunto de amostras candidatas (C) e avalie a afinidade (correspondência) entre cada amostra e o conjunto de padrões próprios. Se um elemento do conjunto S for reconhecido por uma amostra em C, ou seja, se a afinidade for maior que um determinado valor (denominado "limiar próprio"), exclua a amostra de C; caso contrário, guarde-o em um conjunto de detectores (R).

Após a geração do conjunto de detectores R, o monitoramento do sistema é realizado para detectar elementos que não são eles mesmos.

#### 2. Monitoramento:

- Dado o conjunto de cadeias para monitorar (cadeias monitoradas), avalie a afinidade entre cada um deles e o conjunto do detector R. Se a afinidade for maior que um determinado limite, um elemento não próprio foi identificado.



**Fonte: Adaptado de Forrest *et al.* (1994).**

## 2.4 REDE NEURAL ARTIFICIAL

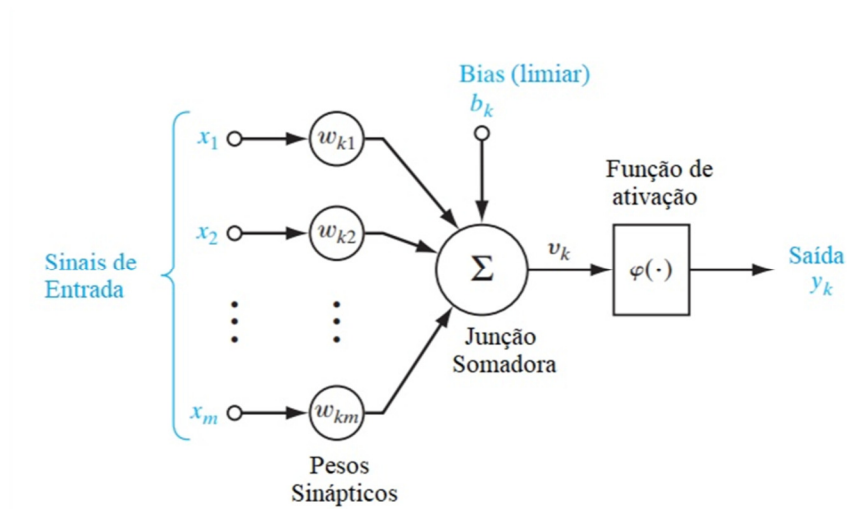
Uma rede neural artificial (RNA) é um modelo computacional baseado em redes neurais biológicas, que pode ser entendido como um sistema de processamento (rede) paralelo de informações constituído pela interconexão de unidades básicas (neurônios artificiais) de processamento simples, que tem a aptidão natural para armazenar o conhecimento experimental e torná-lo acessível para uso. Segundo Haykin (2009), a rede neural se aproxima do cérebro em dois pontos:

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

O processo de aprendizagem é baseado num algoritmo, cuja função é modificar os pesos sinápticos da rede de uma forma ordenada para atingir um objetivo de projeto esperado (HAYKIN, 2009).

Um neurônio recebe sinais de entrada, realiza o processamento de informações e produz sinais de saída. A Figura 23, mostra um modelo de um neurônio artificial, base para a elaboração de diversos tipos de arquitetura de redes neurais artificiais.

Figura 23 - Modelo de um neurônio artificial.



Fonte: Adaptado de Haykin (2009).

Um neurônio é composto pelos seguintes elementos:

1. Um conjunto de sinapses, cada qual tendo seu próprio peso sináptico. Uma entrada  $x_m$ , conectada ao neurônio  $k$  através da sinapse  $w_{km}$  é multiplicada pelo peso sináptico  $w_{km}$ . O índice  $k$  se refere ao neurônio em questão e o  $m$  se refere à entrada que o peso conecta. O peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos e positivos.
2. Um somador para somar os sinais de entrada da rede, ponderados pelas respectivas sinapses do neurônio, executando uma combinação linear com um sinal de polarização  $b_k$  e resultando num valor chamado de potencial de ativação.
3. Uma função de ativação para, na maioria das vezes, limitar a amplitude da saída de um neurônio. A função de ativação é também referida como função restritiva já que usualmente limita o intervalo de amplitude do sinal de saída a um valor finito. Tipicamente, o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo unitário fechado  $[0,1]$  ou alternativamente  $[-1,1]$ .

O modelo do neurônio artificial da Figura 23 contém uma polarização (ou *bias*) aplicada ao neurônio que pode ser representado por  $b_k$ . Esse limiar tem o propósito de aumentar ou diminuir a entrada da função de ativação, dependendo se ele é positivo ou negativo.

O neurônio  $k$  da Figura 23, pode ser descrito em termos matemáticos pelas Equações 19 e 20:

$$v_k = \sum_{m=1}^n w_{km}x_m + b_k \quad (19)$$

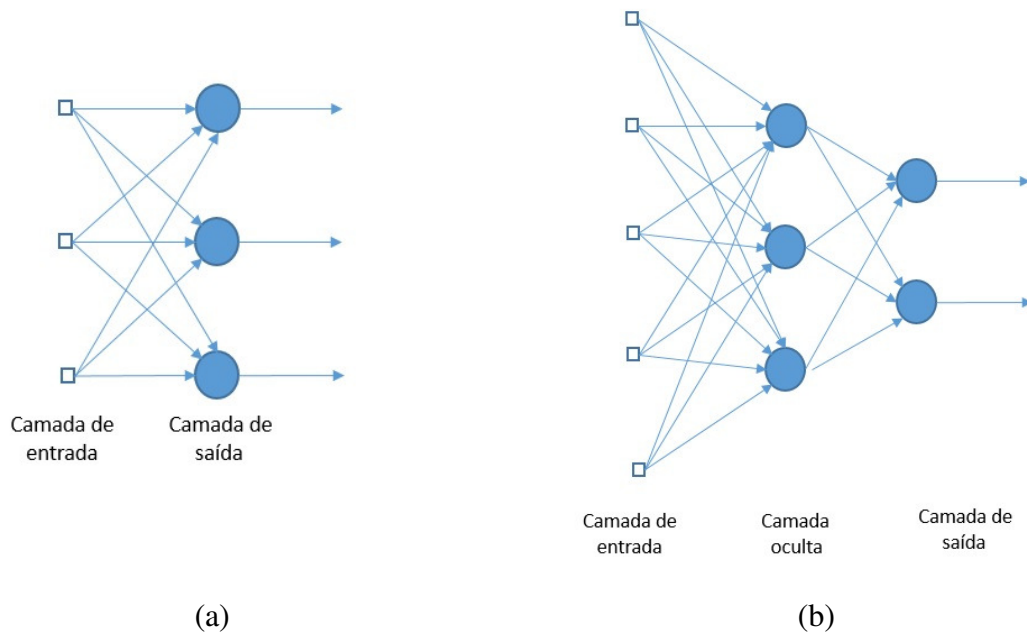
$$y_k = \varphi(v_k) \quad (20)$$

Onde  $x_1, x_2, \dots, x_m$  são os sinais de entrada;  $w_{k1}, w_{k2}, \dots, w_{km}$  são os pesos sinápticos do neurônio  $k$ ;  $v_k$  é a saída do combinador linear devido dos sinais de entrada;  $b_k$  é o *bias*;  $\varphi(\cdot)$  é a função de ativação; e  $y_k$  é o sinal de saída do neurônio (HAYKIN, 2009).

A função de ativação de um neurônio artificial determina o novo valor do estado de ativação deste neurônio, a partir do seu potencial de ativação e pode assumir diversas formas: linear, rampa, degrau, sigmoide ou tangente hiperbólica até a função ReLU mais utilizada nos modelos profundos.

A arquitetura da RNA pode ser formada por uma ou mais camadas de neurônios, com conexões entre elas. A Figura 24 ilustra graficamente a arquitetura completamente conectada de uma RNA de camada única (Figura 24(a)) também denominada de *perceptron* e um *perceptron* de múltiplas camadas (Figura 24(b)). Os neurônios são representados por pequenos quadrados na camada de entrada, recebendo as informações, e por círculos nas camadas oculta ou de saída, realizando o processamento interno da rede, e de saída, fornecendo o resultado. Os pesos das conexões são representados pelas linhas. Conforme a complexidade do problema ser estudado, uma RNA pode conter uma ou várias camadas ocultas (HAYKIN, 2009).

**Figura 24 - Modelos de arquitetura de redes neurais artificiais. (a) Camada única. (b) Camadas múltiplas.**



**Fonte: Adaptado de Haykin (2009).**

Na forma mais simples de uma rede, tipo *feedforward*, têm-se uma camada de entrada que se direciona unicamente para a camada de saída, sendo que o inverso não ocorre (HAYKIN, 2009).

#### 2.4.1 Redes Neurais Convolucionais

A rede convolucional (LECUN *et al.*, 1989), também conhecida como rede neural convolucional, ou CNN (*convolutional neural network*), é uma rede multicamadas projetada especificamente para reconhecer formas bidimensionais com alto grau de invariância de translação, redimensionamento (escala), inclinação (rotação) e outras formas de distorção (HAYKIN, 2009). Essa tarefa difícil é aprendida de maneira supervisionada por meio de uma rede cuja estrutura inclui (LECUN; BENGIO, 1995; HAYKIN, 2009):

- Extração de características: cada neurônio recebe seus sinais de entrada de um campo receptivo local na camada anterior, o que o força a extrair características locais. Uma vez que a característica seja extraída, sua localização exata se torna irrelevante, desde que sua posição para outras características seja mantida.

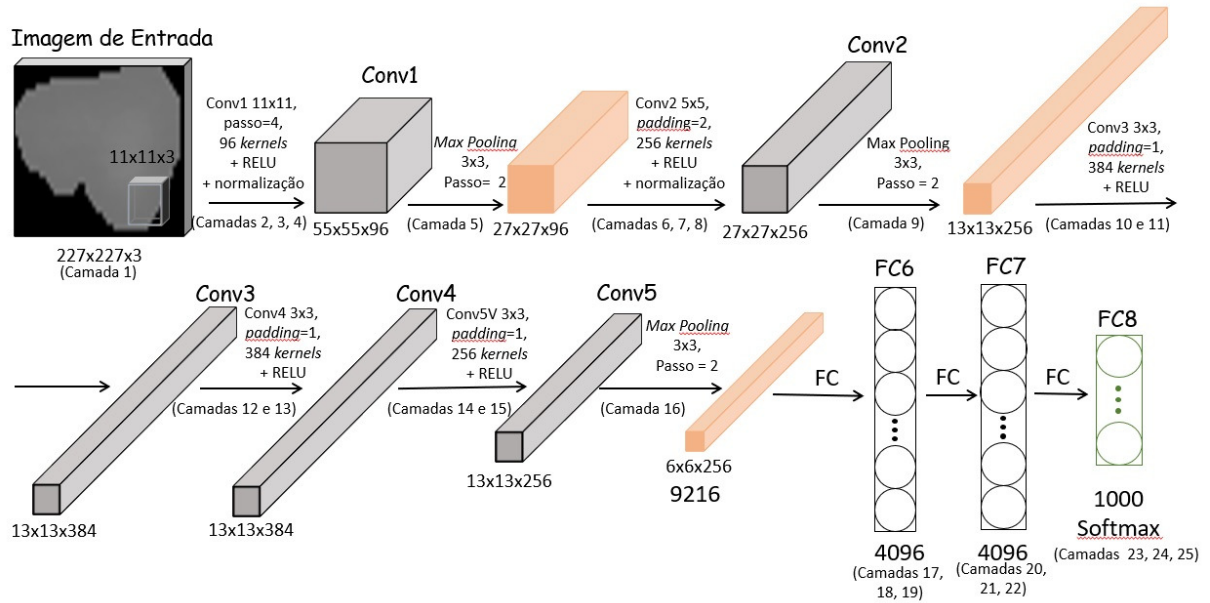


- Mapeamento de características: cada camada computacional da rede é composta de múltiplos mapas de características, sendo cada mapa de características na forma de um plano dentro do qual os neurônios individuais estão restritos a compartilhar o mesmo conjunto de pesos sinápticos. Esta segunda forma de restrição estrutural tem os seguintes efeitos benéficos:
  - o Invariância a deslocamento, introduzida na operação de um mapa de características através do uso de convolução com um núcleo (*kernel*) de tamanho pequeno, seguido por uma função sigmoide (limitadora).
  - o Redução do número de parâmetros livres, obtida através do uso de compartilhamento de pesos.
- Subamostragem: cada camada de convolução é, em geral, seguida por uma camada que realiza uma subamostragem, reduzindo desta forma a resolução do mapa de características. Esta operação tem o efeito de reduzir a sensibilidade da saída do mapa de características em relação a deslocamentos e outras formas de distorção.

Ressalta-se que, exceto nos experimentos envolvendo *Transfer Learning*, todos os pesos em todas as camadas de uma rede convolucional são aprendidos por meio de treinamento. Além disso, a rede aprende a extrair suas próprias características automaticamente (HAYKIN, 2009).

As CNNs são formadas por sequências de camadas e cada uma destas possui uma função específica na propagação do sinal de entrada. A Figura 25 ilustra a arquitetura de uma CNN específica denominada AlexNet (KRIZHEVSKY *et al.*, 2012) com suas respectivas camadas. As três principais camadas de uma CNN são: convolucionais, *pooling* e camadas totalmente conectadas. As camadas convolucionais extraem atributos dos volumes de entrada (três canais sendo largura, altura e profundidade, cada um deles). Numa imagem colorida o volume representa as cores (*RedGreenBlue*). Para imagens em níveis de cinza é possível adaptar o conceito de volume através da repetição da mesma imagem nos três canais. As camadas de *pooling* reduzem a dimensionalidade do volume resultante após as camadas convolucionais e ajudam a tornar a representação invariante a pequenas translações na entrada. As camadas totalmente conectadas são responsáveis pela propagação do sinal por meio da multiplicação ponto a ponto e o uso de uma função de ativação. A saída da CNN é a probabilidade da imagem de entrada pertencer a uma das classes para qual a rede foi treinada. As Seções 2.4.1.1, 2.4.1.2 e 2.4.1.3 detalham cada uma dessas camadas da CNN.

Figura 25 – Exemplo de uma arquitetura CNN com suas respectivas camadas.



Fonte: Adaptado de Krizhevsky *et al.* (2012).

#### 2.4.1.1 Camada convolucional

As camadas convolucionais são compostas por um conjunto de filtros (*kernels*) aprendidos com um treinamento. Cada filtro possui dimensão reduzida, porém ele se estende por toda a profundidade da imagem de entrada. Por exemplo, se a imagem for colorida, então ela possui três canais e o filtro da primeira camada convolucional terá tamanho 5x5x3 (cinco pixels de altura e largura e profundidade igual a três). Automaticamente, durante o processo de treinamento da rede, esses filtros são ajustados para que sejam ativados em presença de características relevantes identificadas na imagem, como orientação de bordas ou manchas de cores (KARPATHY, 2017). Cada um desses filtros gera uma estrutura conectada localmente que percorre toda a extensão da imagem, operação conhecida como convolução, a qual é ilustrada na Figura 26 e tem por base a Equação 21.


$$s(t) = (x * w)(t) \quad (21)$$

Os valores resultantes após a operação de convolução passam por uma função de ativação, sendo a função ReLU (*Rectified Linear Units*), a mais comum (KARPATHY, 2017) e pode ser calculada pela Equação 22.

$$\varphi(s) = \max(0, s(t)) \quad (22)$$

Para controlar todas as dimensões da imagem resultante da camada convolucional, existem três parâmetros: profundidade (*depth*), passo (*stride*) e *zero-padding* (KARN, 2016). A profundidade da imagem resultante é igual ao número de filtros utilizados, e cada um desses será responsável por extrair características diferentes na imagem de entrada. Portanto, quanto maior o número de filtros maior o número de características extraídas, porém a complexidade computacional, relativa ao tempo e ao uso de memória, também será maior.


**Figura 26 – Exemplo da convolução de um filtro 3x3 e a imagem da entrada.**



Fonte: Araújo *et al.* (2017).

A profundidade da imagem resultante depende somente do número de filtros utilizados, enquanto a altura e largura da imagem resultante dependem do passo (*stride*) e do *zero-padding*. O passo especifica o tamanho do salto na operação de convolução, como ilustrado na Figura 27. Quanto maior o valor do passo menor serão a altura e largura da imagem resultante, porém características importantes podem ser perdidas. Por esse motivo, é incomum utilizar o valor de passo maior que 2. A operação de *zero-padding* é uma técnica que permite preservar o tamanho da imagem original adicionando uma borda de pixels à imagem de entrada e todas com o valor zero.

**Figura 27 – Ilustração de como o passo influencia o deslocamento de um filtro 3x3 em duas etapas sucessivas da convolução. As imagens em(a) correspondem a um passo unitário, enquanto as imagens em (b) a um passo igual a 2.**




Fonte: Araújo *et al.* (2017).

#### 2.4.1.2 Camada de *pooling*

Após uma camada convolucional, geralmente existe uma camada de *pooling*. O objetivo dessa camada é reduzir progressivamente a dimensão espacial da imagem de entrada, consequentemente diminuindo o custo computacional da rede e evitando *overfitting* (KARPATHY, 2017). Na operação de *pooling*, os valores pertencentes a uma determinada região do mapa de atributos, gerados pelas camadas convolucionais, são substituídos por alguma métrica dessa região. A forma mais comum de *pooling* consiste em substituir os valores de uma região pelo valor máximo (GOODFELLOW *et al.*, 2016), como ilustra a Figura 28. Essa operação é conhecida como *max pooling* e é útil para eliminar valores desprezíveis, reduzindo a dimensão da representação dos dados e acelerando a computação necessária para as próximas camadas. Além disso, cria uma invariância para pequenas mudanças e distorções locais. Vale destacar que a profundidade do volume de entrada não é alterada pela operação de *pooling*.

**Figura 28 – Aplicação de *max pooling* em uma imagem 4x4 utilizando um filtro 2x2.**



Fonte: Araújo *et al.* (2017).

### 2.4.1.3 Camada totalmente conectada

O termo “totalmente conectada” significa que todos os neurônios da camada anterior estão conectados a todos os neurônios da camada seguinte. A saída das últimas camadas convolucionais e de *pooling* representa as características extraídas da imagem de entrada e são a entrada da camada totalmente conectada. O objetivo da camada totalmente conectada é usar essas características para classificar a imagem em uma classe pré-determinada, como ilustrado na Figura 25. As camadas totalmente conectadas são exatamente iguais a uma rede neural artificial convencional (*Multi Layer Perceptron* ou *MLP*) (HAYKIN, 2009) que usa a função de ativação *SoftMax* (ARAÚJO *et al.*, 2017), definida pela Equação 23, na última camada (de saída).

$$S(y_k) = \frac{e^{x_k}}{\sum_j e^{x_k}} \quad (23)$$

onde  $y_k$  representa a entrada do neurônio  $k$  e  $S(y_k)$  representa sua saída. A função de ativação do *SoftMax* recebe um conjunto de valores como entrada e produz a distribuição probabilística das classes nas quais a rede foi treinada.

Uma técnica conhecida como *dropout* (GOODFELLOW *et al.* 2016) também é amplamente usada entre camadas totalmente conectadas para reduzir o tempo de treinamento e evitar *overfitting*. Essa técnica consiste em remover - aleatoriamente em cada iteração de treinamento - uma determinada porcentagem de neurônios de uma camada e depois adicioná-los novamente à próxima iteração. Essa técnica também oferece à rede a capacidade de aprender atributos mais robustos, uma vez que um neurônio não pode depender da presença específica de outros neurônios.

### 2.4.2 Arquitetura AlexNet

O modelo AlexNet, proposto por Krizhevsky *et al.* (2012), envolve uma arquitetura básica, simples e eficaz da CNN composta principalmente de estágios em cascata de camadas de convolução, função de ativação ReLU, *maxpooling*, camadas de *dropout* e camadas totalmente conectadas, totalizando 25 camadas apresentadas na Tabela A - no Apêndice A.

Nesta arquitetura, os filtros são obtidos durante a fase de treinamento com base em rotinas de otimização com o algoritmo Gradiente Descendente Estocástico (*Stochastic Gradient Descent* - SGD). Camadas convolucionais geralmente atuam na entrada dos mapas

de características com filtros deslizantes para gerar mapas de características. Conforme discutido na Seção 2.4.1.2, as camadas de *pooling* operam em mapas de características para agregar informações da região de vizinhança, com operação de *maxpooling*. Outra característica do AlexNet consiste em algumas estratégias práticas, como a função de ativação ReLU e a técnica de *dropout*.

Como será discutido no Capítulo 4, o modelo AlexNet é usado neste trabalho para expandir o conjunto de características a serem usadas no processo de comparação do SIA. Nesse caso, a camada imediatamente anterior à camada totalmente conectada é utilizada como vetor de entrada para uma cascata de dois *autoencoders* usados para reduzir a dimensionalidade do vetor original (i.e., do vetor de características fornecidas pelo AlexNet). No Capítulo 5 - no teste de comparação, o modelo da AlexNet é adaptado para executar uma tarefa de classificação de 2 classes em modo independente.

### 2.4.3 Autoencoder

*Autoencoder* é uma rede neural multicamada com um mínimo de três camadas cuja saída é definida com o mesmo número de nós que a camada de entrada (GOODFELLOW *et al.*, 2016; PRIORI, 2017). Essa rede tem o objetivo de aprender a reproduzir na saída  $y$  os seus próprios dados de entrada  $x$ . Internamente, a rede possui uma camada oculta  $h$  que descreve um código usado para representar a entrada. A rede pode ser entendida como contendo duas partes: o codificador com função  $h = f(x)$  e o decodificador com função  $r = g(h)$ ; assim o *autoencoder* pode ser descrito pela função  $g(f(x)) = r$  (LI *et al.*, 2019).


A Figura 29 apresenta um exemplo de *autoencoder* que reduz a dimensionalidade enquanto mantém as informações principais. A camada oculta é menor que a camada de entrada e pode ter várias camadas (PRIORI, 2017).

Os níveis hierárquicos de representação de dados - níveis alto e baixo - podem ser organizados por abstrações, características e conceitos. Por exemplo, características de baixo nível que são invariantes a pequenas variações geométricas (como detectores de borda dos filtros Gabor) transformam gradualmente essas características (para torná-los invariantes a alterações de contraste e inversão de contraste), a fim de detectar subsequentemente os mais frequentes padrões e obter características de alto nível (BENGIO, 2009).

Uma rede de camada única pode extrair características vistas como de baixo nível, mas adicionando uma segunda camada e a saída da primeira sendo a entrada da segunda, a

característica extraída pode ter um nível um pouco mais alto (BENGIO, 2009). Portanto, a saída gerada pelo treinamento da camada oculta do primeiro *autoencoder* se torna a entrada de treinamento do segundo *autoencoder* e, portanto, um novo pré-treinamento é realizado pelo segundo *autoencoder*. A saída gerada pela camada oculta do segundo *autoencoder* representa as características de alto nível.

**Figura 29 – Esquema de *autoencoder* utilizado para redução dimensional. Após o treinamento, usa-se a estrutura do *autoencoder* da camada de entrada para a camada oculta escolhida (geralmente a camada com menos nós) para testar e extrair uma representação reduzida de entradas.**



Fonte: Adaptado de Priori (2017).

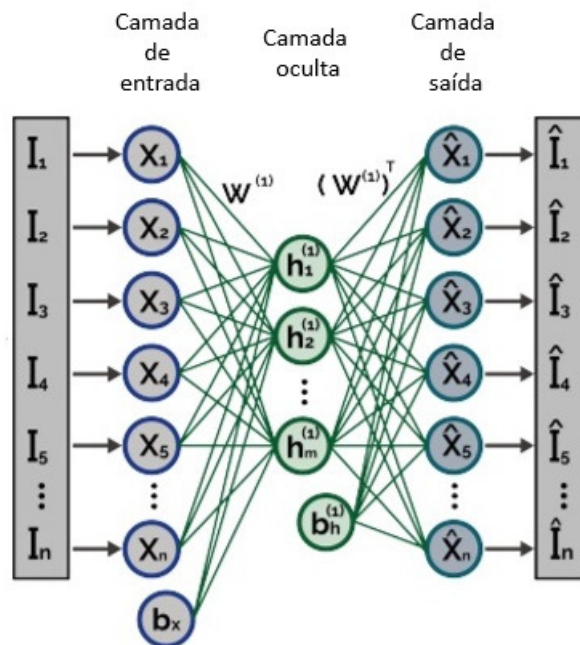
#### 2.4.3.1 Autoencoders esparsos

*Autoencoders* esparsos são *autoencoders* aos quais são adicionadas restrições de esparsidade (PRIORI, 2017) e que normalmente são utilizados para aprender processos

(recursos) para outras tarefas, como a classificação (GOODFELLOW *et al.*, 2016). Em termos computacionais, as restrições esparsas são baseadas nos neurônios que são considerados ativados, quando os valores de saída forem próximos de 1 e considerados inibidos, quando os valores de saída forem próximos a 0. A esparsidade é estimulada pela adição de um termo de regularização à equação de ajuste dos pesos, que busca levar o valor médio de ativação do neurônio da camada oculta para um valor desejado.

A função de ativação da codificação e decodificação do *autoencoder* é em geral a sigmoide (BENGIO, 2009). Para detalhar o *autoencoder*, nesta seção será considerado um modelo com uma camada de entrada, uma camada oculta e uma camada de saída, conforme ilustra a Figura 30.

Figura 30 – Esquema de um *autoencoder* com detalhes.



Fonte: Adaptado de Priori (2017).

Se na camada de entrada tem-se um vetor  $x$ , então o codificador mapeia a entrada para outro vetor  $h$ , conforme mostrado na Equação 24:

$$h = \varphi (W^{(1)}x + b_x) \quad (24)$$

onde  $\varphi(\cdot)$  é a função de ativação,  $W^{(1)}$  é a matriz de peso e  $b_x$  é o vetor de polarização. O decodificador mapeia o vetor  $h$ , codificado de volta para uma estimativa do vetor de entrada original,  $x$  (Equação 25):



$$\hat{x} = \varphi \left( (W^{(1)})^T h + b_h \right) \quad (25)$$

onde  $(W^{(1)})^T$  representa a matriz de peso transposta.

Um conceito importante para os *autoencoders* esparsos é a medida de ativação da saída média  $\hat{\rho}_i$  de um neurônio  $i$  conforme definido pela Equação 26:

$$\hat{\rho}_i = \frac{1}{N} \sum_{j=1}^n h_i^{(1)}(x_j) = \frac{1}{N} \sum_{j=1}^n \varphi(w_i^{(1)T} x_j + b_i^{(1)}) \quad (26)$$

onde  $N$  é o número total de exemplos de treinamento,  $w_i^{(1)T}$  é a  $i$ -ésima linha da matriz de peso  $W^{(1)}$ ,  $x_j$  é o  $j$ -ésimo exemplo de treinamento e  $b_i^{(1)}$  é a  $i$ -ésima entrada do vetor de polarização. Como dito antes, um neurônio é ativado se seu valor de ativação de saída é alto, portanto, próximo a 1. Um valor de ativação de saída baixa, próximo a 0, significa que o neurônio na camada oculta é ativado em resposta a um pequeno número de exemplos de treinamento. Adicionar um termo à função custo que restringe o valor de  $\hat{\rho}_i$  a ser baixo, permite ao *autoencoder* aprender uma representação em que cada neurônio na camada oculta é ativado para um pequeno número de exemplos de treinamento. Ou seja, cada neurônio é especializado em responder a alguma característica que está presente apenas em um pequeno subconjunto dos exemplos de treinamento.

Para trabalhar com esparsidade e evitar *overfitting* nos *autoencoders*, regularizadores são adicionados à função de custo. A função de custo usada em *autoencoders* esparsos, com regularizadores, é definida na Equação 27:

$$E = \underbrace{\frac{1}{N} \sum_{n=1}^N \sum_{k=1}^K (x_{kn} - \hat{x}_{kn})^2}_A + \underbrace{\lambda * \Omega_{weights}}_B + \underbrace{\beta * \Omega_{sparsity}}_C \quad (27)$$

em que, o termo A é uma equação tradicional de erro quadrático médio, o termo B é o primeiro regularizador denominado regularizador de peso e o termo C é o segundo regularizador denominado regularizador de esparsidade.  $\lambda$  é o coeficiente para o termo da regularização de peso e  $\beta$  é o coeficiente para o termo regularização de esparsidade. O termo regularizador de peso busca reduzir a norma do vetor de pesos  $W^{(1)}$  e diminuir os valores de  $h$

(Equação 24), para deixar o regulador de dispersão baixo (PRIORI, 2017). Este termo é definido na Equação 28, por:

$$\Omega_{weights} = \frac{1}{2} \sum_l^H \sum_j^N \sum_i^n (w_{ji}^{(l)})^2 \quad (28)$$

onde  $H$  é o número de camadas ocultas,  $N$  é o número de amostras e  $n$  é o número de variáveis (de uma amostra) nos dados de treinamento.

O termo regularizador de esparsidade da Equação 29, referindo-se à função de custo, tenta impor uma restrição à dispersão da saída da camada oculta.

$$\Omega_{sparsity} = \sum_{i=1}^{D^{(1)}} KL(\rho || \hat{\rho}_i) = \sum_{i=1}^{D^{(1)}} \rho \log\left(\frac{\rho}{\hat{\rho}_i}\right) + (1 - \rho) \log\left(\frac{1 - \rho}{1 - \hat{\rho}_i}\right) \quad (29)$$

onde  $D^{(1)}$  é o número de neurônios na camada oculta. A esparsidade pode ser estimulada pela adição de um termo de regularização, que tem um valor alto, quando o valor médio de ativação ( $\hat{\rho}_i$  de um neurônio  $i$ ) e o valor desejado ( $\rho$ ), não são valores próximos (PRIORI, 2017). Em outras palavras, o termo de regularização é uma penalidade para a função de erro que impedirá as ativações de se afastarem muito do  $\rho$  desejado. O termo de regularização de esparsidade é a divergência de *Kullback-Leibler* ( $KL$ ) (NG, 2011), como definido na Equação 28.

A divergência de *Kullback-Leibler* é uma função para medir a entropia relativa, isto é, a diferença entre duas distribuições, em que o valor é zero quando  $\rho$  e  $\hat{\rho}_i$  são iguais entre si e se torna maior quando divergem um do outro. Assim, esse termo deve ser pequeno para que a função de custo seja minimizada.

## 2.5 SUPPORT VECTOR MACHINES

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

Os algoritmos de aprendizagem de máquina SVM determinam os limites de decisão que produzem uma separação ótima entre classes por meio da minimização dos erros

(VAPNIK, 1995). Essa classificação é baseada no princípio de separação ótima entre classes, tal que se as classes são separáveis, a solução é escolhida de forma a separar o máximo as classes.

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

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

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

## 2.6 VALIDAÇÃO CRUZADA

A validação cruzada é uma técnica para avaliar a capacidade de generalização de um modelo, a partir de um conjunto de dados (KOHAVI, 1995). Esta técnica busca estimar o seu desempenho para um novo conjunto de dados. O conceito central das técnicas de validação cruzada é o particionamento do conjunto de dados em subconjuntos mutuamente exclusivos, e posteriormente, utiliza-se alguns destes subconjuntos para a estimação dos parâmetros do modelo (dados de treinamento) e o restante dos subconjuntos são empregados no teste do modelo.

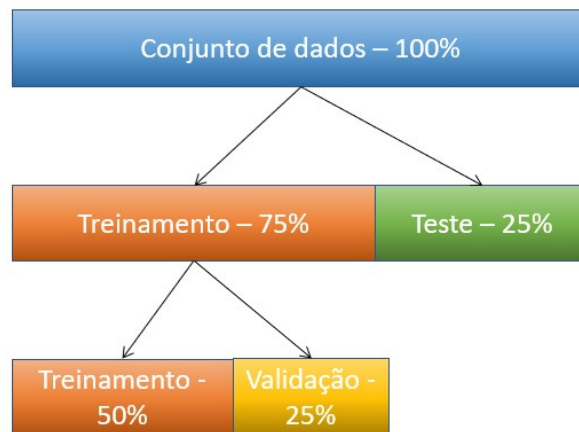
Diversas formas de realizar o particionamento dos dados são sugeridas na literatura, sendo as três mais utilizadas: *holdout*, *k-fold* e *leave-one-out* (KOHAVI, 1995). O método utilizado neste estudo, o *holdout* (sem repetição), é definido em função do tempo para o processamento das imagens utilizadas e será detalhado na Seção 2.6.1. Outro aspecto que

dificulta o uso de outros métodos envolve a partição dos dados para cada etapa. Como a metodologia proposta foi idealizada para realizar a detecção do defeito por imagem (e não por descontinuidade) a utilização da validação cruzada do tipo *k-fold* ou *holdout* com repetição se torna extremamente difícil, uma vez que cada imagem tem um número de defeitos diferente.

### 2.6.1 Método *Holdout*

Esse método consiste em dividir o conjunto total de dados em dois subconjuntos mutuamente exclusivos, um para treinamento (estimação de parâmetros) e outro para teste (validação). O conjunto de dados pode ser separado em quantidades iguais ou não. Uma proporção muito comum é considerar 2/3 dos dados para treinamento e o 1/3 restante para teste (KOHAVI, 1995). Já De Castro (1998) cita que as abordagens mais clássicas sugerem que o conjunto seja dividido da seguinte forma: primeiro conjunto com 50% dos dados para treinamento, segundo conjunto com 25% para validação e terceiro conjunto com 25% para teste, conforme o exemplo da Figura 31. Esta foi a metodologia usada nos experimentos realizados no presente trabalho.

**Figura 31– Exemplo de uma divisão para o método *holdout*.**



**Fonte: Autoria própria (2020).**

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

Na subamostragem aleatória, o método de validação é repetido  $n$  vezes e a precisão estimada é derivada calculando a média das rodadas.

## 2.7 MEDIDAS DE DESEMPENHO DE CLASSIFICADORES

Um classificador pode ter o seu desempenho avaliado por vários métodos. A eficácia de uma classificação pode ser avaliada como: número de amostras da classe corretamente reconhecidas (verdadeiros positivos); número de amostras que foram corretamente atribuídas como não pertencentes à classe (verdadeiros negativos); amostras que foram incorretamente atribuídas à classe (falsos positivos) e, finalmente, amostras que foram incorretamente classificadas como não pertencentes à classe (falsos negativos). Estas quatro medidas compõem uma matriz de confusão mostrada na Figura 32, para o caso de uma classificação binária (SOKOLOVA & LAPALME, 2009).

**Figura 32 – Modelo de matriz de confusão de duas classes.**

		Classe real	
		Classe prevista	Verdadeiro positivo (VP)
Falso negativo (FN)	Verdadeiro negativo (VN)		

Fonte: Adaptado de Fawcett (2006).

Sokolova e Lapalme (2009) e Powers (2011) realizam estudos para comprovar que a partir da matriz de confusão têm-se alguns resultados estatísticos, tais como: acurácia, sensibilidade e precisão. Estes resultados são calculados em função dos valores de verdadeiros e falsos positivos e negativos, sendo:

- Acurácia: calculada pela razão entre o número total de amostras que são classificadas corretamente e o número total de amostras (Equação 29).

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (29)$$

- Precisão: calculada pela razão entre o número de verdadeiros positivos e o total de amostras classificadas como positivas (Equação 30).

$$Precisão = \frac{VP}{VP + FP} \quad (30)$$

- Sensibilidade: calculada pela razão entre o número de verdadeiros positivos e o número de amostras realmente positivas (Equação 31).

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (31)$$

- *F-score*: calculada pela média ponderada de precisão e sensibilidade (Equação 32). A medida *F-score* é um indicativo de desempenho global do classificador. Essa medida estatística, frequentemente, é a combinação de precisão e sensibilidade. Tem-se o coeficiente  $\alpha$  que permite que sejam definidos pesos diferentes para as classes, sendo valor um o mais usual.

$$Fscore = \frac{(\alpha + 1) \times (Precisão \times Sensibilidade)}{\alpha \times (Precisão + Sensibilidade)} \quad (32)$$

## 2.8 CONSIDERAÇÕES FINAIS

Este capítulo enfocou as técnicas de exposição radiográfica utilizadas em juntas soldadas de tubulações, descrevendo suas características e os tipos de discontinuidades mais comuns encontradas em juntas soldadas. Em seguida, foram apresentados os conceitos sobre processamento de imagens, Sistemas Imunológicos Artificiais e os conceitos básicos para o entendimento dos modelos de redes neurais utilizados no desenvolvimento da pesquisa. Por fim, foi explicada a validação cruzada, bem como as medidas de desempenho utilizadas no desenvolvimento dos protótipos propostos.

A utilização de tais técnicas visa à detecção e classificação automática das discontinuidades em duas classes (defeitos e não defeitos), atendendo o objetivo do presente trabalho, que é propor um método para detecção de defeitos em imagens radiográficas de juntas soldadas de tubulações obtidas pela técnica de exposição parede dupla vista dupla (PDVD), adquiridas em situações reais de campo.

### 3 ABORDAGENS RELACIONADAS

Este capítulo relata pesquisas desenvolvidas que abordam as técnicas utilizadas no escopo deste trabalho, bem como a detecção de defeitos de soldagem em imagens radiográficas obtidas pelas técnicas de exposição PSVS e PDVD com outras abordagens. A Seção 3.1 apresenta uma breve revisão bibliográfica de mesmas técnicas em outras aplicações com imagens. A Seção 3.2 relata a mesma aplicação, detecção de cordão de solda e detecção de defeitos de soldagem em imagens radiográficas, com outras técnicas. E a Seção 3.3 apresenta as considerações finais.

#### 3.1 TÉCNICAS RELACIONADAS

Esta seção apresenta as técnicas (SIA, CNN e *autoencoders*) utilizadas no desenvolvimento deste trabalho sendo utilizadas em outras aplicações com o enfoque para imagens.

##### 3.1.1 SIA

O *V-detector*, proposto por Ji e Dasgupta (2009), é um algoritmo de seleção negativa reforçado, com características únicas de forma a ampliar as chances de ser aplicado com sucesso em vários domínios. Suas principais características são: abordagem estatística integrada (analisa a cobertura do detector em um algoritmo de seleção negativa); detectores de diferentes tamanhos (maior cobertura com número limitado de detectores); e a utilização de um algoritmo *Boundary-aware* que interpreta os pontos de treinamento como uma coleção em vez de forma independente (o limite do grupo de pontos de formação pode ser detectado).

Ji *et al.* (2006) realizaram um estudo utilizando SIA, mais especificamente o algoritmo *V-detector*, para auxiliar o diagnóstico clínico odontológico. Para diagnosticar uma deformidade dental, como a má oclusão, realizou-se uma medição manual de certa geometria nas imagens de raio-X com visão lateral do crânio, que se baseava em análise subjetiva para determinar os pontos de referência. Neste estudo, o método de extração de características se baseava na distribuição do brilho da imagem e não nas partes anatômicas. O *V-detector* foi utilizado para gerar um conjunto de detectores de anomalia com todas as imagens normais, sem a ocorrência da má oclusão, disponíveis como dados de treino e em seguida todas as

imagens disponíveis foram testadas com o detector regulado para ser normal ou anormal. Os autores definiram que o detector regulado como normal não tem a ocorrência de má oclusão e quando anormal, tem a ocorrência de má oclusão. Para medir a similaridade utilizaram a distância Euclidiana. As estatísticas foram baseadas em 100 repetições com os mesmos parâmetros de controle. Os autores obtiveram melhores resultados quando comparados com o *SVM (Support Vector Machine)*.

Fu, Yu e Wang (2012) realizaram um estudo de algoritmo de segmentação para imagens infravermelhas com alvos ocultos baseado em SIA. Os autores propuseram um algoritmo de segmentação baseado no algoritmo de seleção negativa, onde o algoritmo proposto pode extrair o objeto em uma imagem infravermelha. Num segundo momento, propuseram um algoritmo de segmentação que combina a entropia da informação com o algoritmo de seleção clonal para evitar as desvantagens de decidir subjetivamente o limiar de segmentação. Após a realização de vários experimentos, os autores compararam os dois algoritmos e concluíram que o de seleção negativa podia ser utilizado quando o tempo de processamento era rigoroso, mas resultados de baixa precisão fossem aceitáveis; enquanto que o de seleção clonal podia ser utilizado quando o tempo de processamento não era rigoroso, mas o resultado da análise deveria apresentar uma alta precisão.

Neste trabalho o algoritmo de seleção clonal será usado para eliminar os exemplos próprios (cordão e tubulação) e o algoritmo de seleção clonal para evoluir os extratores de características para a detecção dos defeitos na solda.

### 3.1.2 CNN como Extrator de Características

Srinivas *et al.* (2016) realizaram experimentos onde exploraram as CNNs para extrair características representativas e discriminativas de imagens de raio-X e classificá-las. Extraíram-se também características baseadas em *wavelets*, textura e HOG para serem utilizadas com um classificador SVM. O desempenho obtido na classificação foi de 67% (*wavelets*), 85% (textura), 93,6% (HOG) e 97,6% (CNN).

Taha *et al.* (2017) realizaram um estudo com imagens de colonoscopia, utilizando uma CNN, mais especificamente a AlexNet, para a extração de características e o SVM para realizar a classificação. Foram investigadas as características das camadas intermediárias e seguintes, com o objetivo de encontrar as características mais eficazes que as da camada final. Os autores obtiveram uma sensibilidade de 96% e uma precisão de 92,7% e concluíram que as



características derivadas de uma arquitetura CNN incorporam muitas informações relevantes para as análises.

Kido *et al.* (2018) realizaram um estudo onde desenvolveram um sistema de diagnóstico assistido por computador com imagens radiológicas pulmonares com CNN. A extração das características foi realizada pela CNN, que posteriormente foram utilizadas para treinar um SVM. Os autores esclarecem a grande dificuldade de definir corretamente os vários tipos de anormalidades pulmonares e ressaltam que o estudo contribuiu para o diagnóstico realizado pelos radiologistas.

Zare *et al.* (2018) realizaram experimentos com três técnicas de classificação automática de radiologias médicas. Um modelo *bag-of-visual-words* e uma CNN foram utilizados para extrair características das imagens. Para a extração das características pela CNN, foi utilizada a saída da camada totalmente conectada, que no caso, era um vetor de características de 4096 dimensões. Os dois grupos de vetores de características extraídos foram usados para treinar um classificador SVM. O terceiro experimento utilizou uma rede CNN para classificação, no caso a AlexNet. Os resultados experimentais mostraram que a CNN superou as outras duas técnicas com uma precisão geral de classificação de 86,74% na base de dados utilizada. As três técnicas apresentaram resultados competitivos com base nos resultados experimentais de todo o conjunto de dados, havendo entre elas uma diferença em torno de 2% de precisão.

### 3.1.3 *Autoencoder* como Redutor de Dimensionalidade

Priori (2017) realizou um trabalho no qual aplicou técnicas de aprendizado de máquina, em especial alguns modelos de redes neurais e técnicas de análise de dados, para encontrar um modelo que apresentasse um desempenho satisfatório na tarefa de predição do tamanho projetado das partículas atmosféricas cristalinas. Para a redução da dimensionalidade dos dados, realizou-se um comparativo entre PCA e *autoencoders*. O modelo com o melhor resultado foi o que utilizava conceitos de *deep learning* com *autoencoders*, com uma performance de 99,14% na predição de tamanho projetado para as menores partículas, cuja predição apresentou desempenho inferior com outros modelos propostos.

Chen *et al.* (2018) utilizaram três bases de dados para investigar a redução da dimensionalidade, a capacidade de reter informações e a tentativa de utilizar dois métodos diferentes. Os métodos estudados para a redução foram: análise de componentes principais

(PCA), análise discriminante linear (LDA), *autoencoder*, PCA e *autoencoder*, *autoencoder* e PCA. Os autores verificaram que a redução da dimensionalidade diminui o consumo de tempo e melhora o desempenho da classificação, porém houve perda de informação. O resultado mostrou que quando a dimensão se torna menor, o PCA e o LDA têm uma alta perda de informações, enquanto que com o *autoencoder* apresentou um melhor desempenho e uma menor perda de informações do que outros métodos de redução da dimensionalidade.

Zapana *et al.* (2017) propuseram um método baseado no *autoencoder* para extrair vetores de características de séries temporais de alta dimensão. A redução da dimensionalidade foi realizada com várias arquiteturas: *autoencoder* simples, *autoencoder* multicamadas, *autoencoder* com aprendizado por transferência e *autoencoder* sem aprendizado por transferências. Pelas medidas de qualidade, definidas pelos autores, tanto um *autoencoder* simples como um *autoencoder* multicamadas demonstraram alta competitividade em relação à outras técnicas tradicionais de redução da dimensionalidade em dados de séries temporais. Para os outros dois *autoencoders*, os resultados não foram promissores.

Sriram *et al.* (2017) propuseram um método para redução da dimensionalidade, classificação e recuperação para imagens de raio-X médicas. De cada imagem são extraídas projeções de radônio, características HOG e pixels brutos para encontrar as entradas com melhor habilidade de discriminação para o *autoencoder*. A classificação foi realizada com uma rede neural *perceptron* multicamada. As características extraídas das projeções de radônio obtiveram o melhor desempenho, alcançando 81,93% de acurácia, e que o *autoencoder*, ao reduzir a dimensionalidade, removeu as redundâncias do vetor de entrada.

Alkabawi *et al.* (2017) propuseram um novo método, com a utilização de *autoencoders* para reduzir a dimensionalidade e extrair características chaves de imagens de ressonância magnética, considerando a alta dimensionalidade destas informações. Para comparar a precisão de previsão, os autores utilizaram também o PCA para reduzir a dimensionalidade, bem como os classificadores de análise discriminante linear e regressão logística. Os resultados experimentais mostraram que com o uso de *autoencoders*, a precisão de classificação foi 8% melhor em comparação ao PCA.

### 3.2 APLICAÇÕES RELACIONADAS

Esta seção relata pesquisas desenvolvidas que abordam a detecção de defeitos de soldagem em imagens radiográficas obtidas pelas técnicas de exposição PSVS e PDVD.

Nestas pesquisas são apresentadas: a aplicação de várias técnicas para a detecção de cordões de solda bem como de defeitos em imagens radiográficas e, na sequência, a classificação.

### 3.2.1 Detecção e Classificação de Defeitos em Imagens PSVS

Wang e Liao (2002) implementaram um sistema para reconhecer os diferentes tipos de defeitos de soldas em imagens radiográficas, sendo o mesmo composto por três etapas: processamento digital de imagens, extração de características e classificação de padrões. Técnicas de processamento de imagens como a subtração do fundo e a limiarização do histograma foram implementadas para separar defeitos do fundo da imagem. Na extração de características foi obtido um conjunto de doze atributos (sendo alguns: forma, tamanho, localização e intensidade) que pudessem ser descritos nos defeitos de soldagem. As características extraídas das imagens foram utilizadas para classificar diferentes tipos de falhas de soldas, sendo utilizados dois classificadores: *fuzzy KNN* e *MultiLayer perceptron* (redes neurais). Em testes iniciais, a rede neural alcançou uma precisão de 92,39% (em média, 25 dos 27 defeitos para validação foram corretamente classificados), enquanto *fuzzy KNN* alcançou uma precisão de 91,57%. Com base nestes resultados, os autores perceberam a necessidade de se estabelecer um conjunto de imagens de referência para realizar uma comparação nos métodos e avançar mais nesta área de pesquisa.

Pádua *et al.* (2003) apresentaram uma metodologia para a extração do cordão de solda através dos perfis transversais, utilizando redes neurais para implementação dos classificadores de padrões. Inicialmente foi realizado um pré-processamento nas imagens radiográficas – redução do ruído e realce do contraste – antes da extração da solda, com o objetivo de melhorar a qualidade da imagem e proporcionar a redução na taxa de erros deste procedimento. Aos perfis obtidos, foi aplicado o filtro *Savitzky-Golay* para suavizar o ruído ainda existente após o pré-processamento. A partir do perfil suavizado, realizou-se uma regressão não linear do perfil segundo a curva de Gauss para definir o limite de corte para a extração do cordão de solda. Posteriormente, os perfis resultantes foram utilizados em classificadores lineares de padrões desenvolvidos com redes neurais artificiais para separação entre perfis contendo defeitos no cordão de solda e perfis sem defeito. A precisão desta metodologia foi de 100% na detecção dos perfis sem defeito (SD) e o resultado total de classificação foi de 98%.

Shafeek *et al.* (2004) propuseram um sistema para inspeção de cordões de solda de gasoduto, onde combinaram, inicialmente, várias técnicas para aprimorar as imagens, sendo: conversão das imagens para tons de cinza, nível de cinza pelo histograma e cálculo de um limiar. Depois, os autores incluíram a segmentação, a detecção de bordas e algoritmos de extração, uma vez que o objetivo principal era extrair os defeitos da solda. Para as imagens adquiridas (o filme radiográfico foi colocado em uma mesa captadora com luz de fundo e em seguida a câmera adquiriu uma imagem e salvou em um arquivo) e para cada defeito foi calculadas as informações necessárias. Na sequência, o algoritmo de identificação de defeitos foi utilizado para classificar os mesmos, sendo a identificação baseada em três fatores principais: forma, orientação e localização; e, segundo os autores, alguns fatores secundários: largura, tamanho e linearidade. Após a identificação utilizou-se o algoritmo de decisão, onde as dimensões dos defeitos foram comparadas com os padrões internacionais para o aceite, sendo utilizado o código padrão *American Petroleum Institute (API)* e contando também com o auxílio de especialistas de inspeção de solda. Os autores utilizaram cinco imagens de radiografias PSVS com somente um tipo de defeito em cada uma para validação, não apresentando a precisão.

Silva *et al.* (2003) realizaram um estudo de classificador de padrões não lineares e com redes neurais classificaram os defeitos da solda existentes em radiografias de cordões de solda, visando principalmente incrementar o percentual de sucesso no reconhecimento obtido com classificadores lineares. Foi realizado um pré-processamento nas imagens para reduzir o ruído e melhorar o contraste, facilitando a visualização da linha de solda, bem como a detecção dos defeitos. As características geométricas das classes de defeitos foram usadas como dados de entrada dos classificadores. Foi utilizada uma nova abordagem para esta área de pesquisa, onde um critério de relevância neural foi aplicado para avaliar a capacidade de discriminação das classes estudadas pelas características utilizadas, com o objetivo de demonstrar que a qualidade das características é mais importante que a quantidade de características utilizadas.

Nacereddine e Tridi (2005) propuseram uma classificação, que consistiu em dividir os principais tipos de defeitos de solda em quatro categorias, conforme as características morfológicas dos defeitos encontrados normalmente na prática. Para a caracterização da região de defeitos de solda, procuraram-se características que fossem invariantes em relação às transformações geométricas, uma vez que o mesmo defeito podia ser observado a partir de vários ângulos de acordo com a orientação e a distância a partir da estrutura soldada à fonte de radiação. Assim, foi proposto um conjunto de atributos que caracterizavam formas

geométricas invariantes do defeito. A técnica de análise do componente principal foi utilizada, a fim de reduzir o número de variáveis de atributos para fornecer uma melhor performance para a classificação do defeito. Posteriormente, foi utilizada a rede neural *backpropagation* para a classificação de defeitos de solda.

Alghalandis e Alamdari (2006) propuseram um método de reconhecimento e separação entre o que seria um defeito ou não em imagens radiográficas de soldas. Numa primeira etapa foi realizado o pré-processamento da imagem com o filtro da mediana e equalização do histograma, juntamente com a preservação dos tons de cinza informados na imagem, para reduzir o ruído e melhorar o contraste da mesma. Na sequência, a solda foi extraída a partir da imagem de fundo e aplicada a limiarização utilizando-se operadores binários com a manutenção das informações da imagem crítica. As características extraídas geraram as informações para o classificador de rede neural, que em combinação com a lógica binária, introduzida na fase de classificação, gerou uma estrutura híbrida denominada neuro-lógica.

Arulmozhi *et al.* (2007) apresentaram um trabalho, cujos objetivos foram: comparar a imagem do filme radiográfico adquirido em três resoluções diferentes; realizar a redução de ruído nessas imagens com a utilização do filtro Log-Gabor e com o filtro *wavelet*; e descobrir o melhor filtro que fornecesse o máximo de detalhes da imagem radiográfica adquirida. A proposta apresentada centrou-se na qualidade da imagem do filme radiográfico contendo defeitos de solda, como por exemplo a porosidade. Como resultado, os detalhes máximos da imagem radiográfica de solda e assim as dimensões do defeito calculadas com maior precisão foram obtidas utilizando o filtro Log-Gabor.

Liao (2008) realizou uma pesquisa referente a dados desbalanceados na classificação de diferentes tipos de falhas na solda, um problema de classificação multi-classe, onde o esquema um contra todos foi adotado para realizar a mesma. Na extração de características foi obtido um conjunto de doze atributos que descrevem a forma, o tamanho, a localização e a informação de intensidade dos defeitos dos cordões de solda. Três algoritmos foram utilizados como classificadores: distância mínima, *KNN* e *fuzzy KNN*. A eficácia deste método de 22 dados pré-processados para lidar com dados desbalanceados foi avaliada em termos de 8 critérios para determinar se algum método poderia dominar os outros. De todos os defeitos de solda, o autor observou que a trinca é a mais difícil para ser reconhecida. Os classificadores *KNN* e *fuzzy KNN* superaram o de distância mínima.

Mahmoudi e Regragui (2009a) apresentaram um método de segmentação de imagens radiográficas digitalizadas de soldas, baseando-se em técnicas de limiarização,

especificamente limiarização de Otsu. Um pré-processamento para melhorar o ruído e contraste foi realizado antes da limiarização nas imagens. Otsu foi aplicado para isolar o cordão de solda, enquanto que para detectar os defeitos utilizou-se um limiar local, denominado limiar de Sauvola. O limiar de Sauvola foi utilizado em função da escolha do tamanho da janela dos vizinhos locais. Para o trabalho proposto, os autores obtiveram bons resultados, pois o algoritmo foi mais rápido, eficaz e prático em comparação com outros métodos.

Mahmoudi e Regragui (2009b) propuseram uma técnica para a segmentação de imagens que se baseou na análise do histograma, no realce de contraste e no limiar da imagem. Inicialmente foi realizado um pré-processamento das imagens e a região de interesse foi identificada com algumas técnicas como limiarização e operações morfológicas. Ainda, no pré-processamento, utilizou-se filtragem homomórfica para realçar o contraste e corrigir a não uniformidade das imagens. Com base no histograma, a limiarização por Otsu global foi selecionada. Como o objetivo principal era eliminar todas as pequenas áreas e manter a maior área identificada como o cordão de solda, inicialmente várias erosões foram aplicadas, com elementos estruturantes de tamanhos pequenos, até que restasse apenas a maior área. Numa segunda etapa, foi aplicado o mesmo número de dilatações para a área do cordão fazendo com que ele assumisse novamente a sua forma original. Depois do cordão isolado, métodos de limiarizações locais foram utilizados para uma melhor detecção de pequenos e grandes defeitos.

Valavanis e Kosmopoulos (2010) apresentaram um sistema que utilizava características de textura e geometria para permitir um modelamento dos defeitos em soldas. Para o pré-processamento foi selecionado o objeto de interesse e em seguida utilizada a segmentação, onde um conjunto de 43 descritores correspondentes às medições de textura e características geométricas foram extraídos de cada região segmentada e utilizadas como entrada pra três algoritmos: *Support Vector Machine* (SVM), Rede Neural Artificial e *K-Nearest Neighbor* (KNN). Pelo KNN os resultados obtidos foram significativamente inferiores em comparação aos outros algoritmos. 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) pelo SVM e RNA, respectivamente. Contudo, as janelas foram posicionadas sobre os defeitos, de forma que a abordagem foi usada mais como um método de auxílio de análise pontual de detecção dos defeitos do que um método de detecção sobre a junta soldada como um todo.

Zapata *et al.* (2010) desenvolveram um sistema de inferência *neuro-fuzzy* para reconhecer defeitos de soldas em imagens radiográficas. Inicialmente obteve-se o pré-

processamento da imagem com o objetivo específico de reduzir/eliminar o ruído e melhorar o contraste. Depois, a região da solda foi isolada dos outros elementos que formavam a imagem, para analisar e detectar os possíveis defeitos, sendo este processo desenvolvido em três etapas: encontrar um limite global, ideal, que poderia ser utilizado para converter a imagem em cinza para uma imagem binária; rotular os objetos conectados na imagem binária; e estabelecer a área máxima, como um critério para seleção entre os objetos rotulados. Como uma preparação da fase seguinte, um pequeno retângulo contendo a região do cordão foi selecionado. Depois, um conjunto de 12 características geométricas que caracterizavam a forma, tamanho, localização e orientação do defeito foi utilizado para extrair os defeitos. Numa terceira etapa, usando como entrada as características geométricas para determinar o tipo de defeito, foi utilizado um sistema de inferência *neuro-fuzzy* (ANFIS) para classificação de defeitos de solda, bem como uma rede neural artificial. Como resultado, obteve-se uma acurácia de 78,9% para a rede MLP e de 82,6% para o sistema ANFIS.

Baniukiewicz e Sikora (2011) apresentaram um método que utiliza algoritmos para segmentação automática de imagens radiográficas de juntas soldadas. A radiografia foi dividida em partes que continham a linha de solda, os indicadores de qualidade de imagem (IQI's) e possíveis defeitos. Depois cada parte foi analisada separadamente por algoritmos especializados no sistema automático de análise de radiografia. As linhas de solda foram segmentadas realizando-se a soma da função gaussiana com a função linear, depois detectou-se o centro das soldas com a função gaussiana máxima. Análises de sinais com suas equações matemáticas foram utilizadas para o desenvolvimento do método proposto.

Halim *et al.* (2011) realizaram um estudo para extrair os defeitos da solda e avaliar a suas características geométricas. Os autores extraíram a fronteira do defeito através da conversão da imagem para binária e as coordenadas dos pixels de fronteira foram armazenadas e utilizadas para calcular a informação de características do defeito, que poderiam ser aproveitadas para interpretar um defeito. Para eliminar o ruído de impulso e preservar os detalhes da imagem, os autores aplicaram filtro da mediana. A técnica de detecção de contorno foi utilizada para detectar o limite do defeito, sendo que a imagem era binarizada. Os pixels pretos sendo designados como pontos de fronteira. As características de defeitos foram descritas geometricamente com base no perímetro, na área, na densidade, na largura, no comprimento e no alongamento para que em outros estudos, possam ser utilizados para a classificação de defeitos.

Halim *et al.* (2013) pesquisaram métodos para detectar defeitos em imagens radiográficas. A partir das imagens radiográficas adquiridas, foi definida a região de interesse

onde os defeitos estavam localizados, reduzindo o tempo de processamento. Um pré-processamento, com o filtro da mediana, foi realizado para remover o ruído da imagem. Para detectar os limites do defeito da solda, a segmentação baseada no modelo *Chan-Vese* (CHAN; VESE, 2001) foi aplicada pela definição do contorno da imagem de entrada inicial e dois tamanhos diferentes de retângulos como contornos iniciais do defeito: área interna e área externa. Para a extração de características foi utilizada a região do pixel para determinar a área e o perímetro, sendo a área calculada pelo número total de *pixels* brancos, na região e o perímetro pelo número total dos pontos do contorno que rodeiam o objeto de interesse.

Yahia *et al.* (2011) desenvolveram um trabalho para o controle automático de inspeção e de defeitos de soldas. Redes neurais artificiais foram utilizadas na detecção de bordas e a rede consistia em identificar as discontinuidades da imagem e eliminar o cordão de solda, sendo o restante considerado como defeito. Um pré-processamento foi realizado sobre a imagem para eliminar ruídos que pudessem comprometer a identificação de bordas e em seguida, realizou-se a segmentação. Com este controle, o objetivo final era a classificação e o aumento na porcentagem do reconhecimento correto dos defeitos.

Yazid *et al.* (2011) apresentaram uma abordagem para a detecção de defeitos em soldas em imagens radiográficas baseada no método de limiarização de superfícies. Numa primeira fase foi utilizado o método *fuzzy c-means* para identificar e isolar a área que continha defeitos, supondo que a mesma se encontrava no centro da imagem e era mais brilhante que o resto da superfície. Depois, o método *fuzzy c-means* segmentou a imagem em cinco regiões, sendo duas com maior intensidade que foram consideradas como áreas onde estavam os defeitos do cordão. As outras três foram excluídas do processamento. Para a detecção da borda, o operador *Prewitt* foi utilizado para obter as informações na área de interesse. Então, a limiarização de Otsu foi aplicada sobre a imagem resultante da borda para separar os pixels; definindo como zero todos os pixels fracos e eliminando-os. Os fortes foram mantidos no processamento. A limiarização de Otsu foi aplicada novamente, após a detecção dos vales por operadores morfológicos, com a mesma ideia anterior, mantendo os pixels fortes e eliminando os fracos. Uma imagem invertida foi construída a partir da imagem original de entrada e a imagem da borda para a detecção de defeitos na área de interesse e o resultado foi combinado com a imagem obtida pela limiarização dos vales. A imagem da detecção dos vales complementou a superfície invertida, especialmente para a detecção de pequenos defeitos onde as bordas fracas frequentemente são desconsideradas pela limiarização inversa. A detecção de defeitos obteve uma cobertura de 94,6%.



Mery (2011) apresentou uma nova abordagem para a detecção de defeitos de solda sem segmentação com base em janelas deslizantes. A classificação foi realizada por SVM (*Support Vector Machine*) que determinava se a janela possuía ou não defeito e em caso positivo o contorno da janela era marcado. Segundo Mery (2011), esta metodologia teve um desempenho de 94% de precisão na classificação de janelas com defeito e não defeito.

### 3.2.2 Detecção do Cordão de Solda em Imagens PDVD

A identificação do cordão de solda é uma etapa importante, pois ela permite a delimitação da região a realizar a detecção de defeitos e na sequência a classificação dos mesmos.

Miranda *et al.* (2017) apresentam uma abordagem automática de detecção de cordões de solda em imagens radiográficas PDVD, combinando duas técnicas: otimização por enxame de partículas (*Particle Swarm Optimization* - PSO) e distorção dinâmica no tempo (*Dynamic Time Warping* - DTW). Os perfis verticais dos cordões de solda são obtidos a partir das coordenadas das janelas codificadas por partículas e comparadas, via DTW, com um modelo predefinido. Os experimentos foram realizados em duas fases: na primeira, os testes são realizados para definir a configuração padrão e, em seguida, o sistema configurado (denominado *WBdetect*) é avaliado. Resultados mostram que o *WBdetect* converge, na maioria das vezes, para a janela que permite uma segmentação adequada do cordão de solda, sendo a precisão média alcançada de  $93,63 \pm 12,91\%$ .

Suyama *et al.* (2019) apresentam uma metodologia para detectar juntas de solda em tubulações de petróleo em imagens radiográficas com exposição PDVD. A abordagem proposta extrai informações (janelas de pixels) da região da tubulação na imagem radiográfica e, em seguida, aplica os modelos de Rede Neural Convolutiva (CNN) para identificar quais janelas correspondem às juntas soldadas. Os experimentos consideram 13 modelos CNN e três configurações de entrada CNN: esticada, V proporcional e H proporcional. Como, ocasionalmente, as imagens radiográficas podem ser alteradas por alguns tipos de ruído (por exemplo, branco, impulsivo), também incluíram experimentos considerando sua influência no comportamento das CNNs e seus resultados relacionados. A melhor combinação forneceu uma média de *F-score* de 96,00% (VGG-VD-16 com entradas esticadas) na detecção da junta soldada.

Apesar dos resultados bastante animadores obtido em Suyama *et al.* (2019), no presente trabalho a extração do cordão foi feita de forma manual tendo em vista que os

resultados obtidos na detecção automática de Suyama *et al.* (2019) não puderam ser incorporados a tempo para a detecção dos defeitos realizada na presente pesquisa.

### 3.2.3 Detecção e Classificação de Defeitos em Imagens PDVD

Kroetz *et al.* (2011) desenvolveram um método baseado em otimização por enxame de partículas e algoritmos genéticos para a detecção e realce de defeitos em cordões de solda em imagens radiográficas obtidas pela técnica PDVD. O método utilizou-se de técnicas de morfologia matemática para a detecção e realce de descontinuidades (possíveis defeitos) na região segmentada. A operação *bottom-hat* evidenciou as descontinuidades sobre a região do cordão de solda, em seguida aplicou-se uma limiarização manual para controlar a quantidade de descontinuidades visíveis na imagem final. A limiarização manual foi realizada para cada imagem, uma vez que não se obteve sucesso com a limiarização padrão para todo o conjunto de imagens.

Fylyk e Centeno (2012) utilizaram o método desenvolvido por Kroetz (2012) para detecção do cordão de solda em imagens radiográficas obtidas pela técnica PDVD. Para destacar e marcar regiões de defeitos em cordões de solda foi utilizado um *ensemble* com 10 redes neurais, sendo *ensemble* a combinação de um número de redes para a tomada de decisão final de saída da rede, que pode reduzir o risco de sobreajuste (*overfitting*) da rede neural e conduzir a um melhor desempenho na generalização (HUANG *et al.*, 2006). A seleção de padrões para treinamento de redes neurais *MultiLayer Perceptron* foi manual. O sistema obteve como resultado uma sensibilidade de 100%, entretanto, a precisão foi de apenas 37,5%, resultando em um *F-score* de 54,5%.

Suyama (2015) desenvolveu um trabalho para auxiliar na detecção de defeitos em imagens PDVD recortadas manualmente contendo o cordão de solda a ser analisado. Sobre a imagem foi aplicada a operação de realce com o objetivo de destacar a região onde se encontravam os defeitos a serem detectados. Uma redução do espaço de busca foi obtida pela eliminação da região central da junta soldada. Na região reduzida o método busca segmentar descontinuidades (possíveis defeitos) que posteriormente foram classificados por Redes Neurais *MultiLayer Perceptron* (MLP) em defeitos e não defeitos. Como resultado, o método obteve uma detecção de 96,53% dos defeitos, com uma precisão de 77,67% e um *F-score* de 86,06%.

Boaretto (2017) desenvolveu um algoritmo para detecção automática de defeitos em cordões de solda utilizando técnicas de processamento de imagens e classificadores com redes neurais *MultiLayer Perceptron* e *Extreme Learning Machines* (HUANG *et al.*, 2006). Um conjunto de características foi extraído das descontinuidades detectadas para que fossem utilizadas como entrada do classificador. Com um conjunto de oito imagens radiográficas obtidas pelo sistema de radiografia computadorizada Dürr, o autor obteve o melhor *F-score*, com MLP, de 87,5% para os dados de teste. Já com o uso de ELM, o melhor *F-score* obtido para os dados de teste foi de 88,57%, representando um ganho em comparação com a MLP.

O trabalho apresentado por Boaretto (2017) realiza a segmentação do cordão de forma manual para a posterior detecção automática das descontinuidades. Assim, optou-se por utilizar esta parte do trabalho (detecção automática de descontinuidades) como pré-processamento na presente pesquisa. Essa etapa é detalhada na Seção 3.2.3.1.


### 3.2.3.1 Segmentação do cordão de solda e detecção de descontinuidades

Boaretto (2017) apresenta um procedimento para detectar descontinuidades. Na primeira etapa, localiza-se a região do cordão de solda, para em seguida detectar as descontinuidades e realizar a extração das características.

A segmentação da região de cordão da soldagem é executada no recorte da imagem original (Figura 33(a)) objetivando limitar a região de pesquisa para uma posterior detecção de descontinuidades. Esta etapa inicial é realizada com técnicas de processamento de imagens. Inicia-se o processo aplicando-se um filtro de mediana sobre a imagem original com a finalidade de reduzir o nível de ruído. Depois é aplicado um filtro de média na imagem filtrada visando a um “borramento” da imagem, conforme mostra a Figura 33(b). À imagem resultante é adicionada uma constante, que é subtraída da imagem filtrada pelo filtro de mediana, obtendo assim uma máscara de nitidez entre as duas imagens. O autor utiliza parâmetros específicos cujos valores foram definidos experimentalmente e adotados para todas as imagens, visando a uma maior cobertura dos defeitos de soldagem. Sobre a máscara obtida é aplicada a limiarização descrita na Seção 2.2.5.2. As regiões escuras com área inferior a um determinado limiar são eliminadas, deixando somente a imagem do cordão de solda. A limiarização obtida pode ser vista na Figura 33(c). Todos os valores dos parâmetros utilizados foram definidos experimentalmente com a finalidade de reduzir o espaço de busca e não excluir descontinuidades pertencentes à região do cordão de solda. Para que as descontinuidades existentes na margem do cordão de solda sejam preservadas, a imagem

resultante é morfologicamente erodida. Um exemplo do resultado da aplicação da erosão pode ser observado na Figura 33(d), somente as descontinuidades localizadas na região escura desta figura são consideradas nas etapas seguintes.

**Figura 33 – Segmentação do cordão de solda. (a) Recorte da imagem original. (b) Imagem filtrada pelo filtro da média 300x300. (c) Imagem limiarizada. (d) Imagem erodida.**




**Fonte: Boaretto (2017).**

Após a localização da região de interesse, realiza-se a etapa final, a detecção de descontinuidades existentes na região do cordão de solda, bem como extraem-se as características das descontinuidades detectadas. Sobre o recorte da imagem original mostrada na Figura 34(a) é aplicado o filtro adaptativo de Wiener, sendo que esta técnica procura reduzir o nível de ruído das imagens, preservando as bordas e outras descontinuidades de alta frequência. Sobre esta imagem é aplicada a operação *top-hat*, com elemento estruturante disco e a imagem resultante somada com a imagem filtrada pelo filtro de Wiener realça os detalhes brilhantes salientando as descontinuidades. Como estas operações não apresentam alterações visíveis para as imagens utilizadas, o resultado só pode ser visualizado após a limiarização.

Com a técnica utilizada de forma semelhante na identificação da região do cordão de solda, aplica-se o filtro da média 55x55 sobre a imagem resultante, sendo este valor definido, empiricamente, para o grupo de imagens. A esta imagem soma-se uma constante e o resultado é subtraído da imagem filtrada pela operação *top-hat*, obtendo uma máscara de nitidez. Com a finalidade de melhorar o brilho e o contraste, sobre a máscara de nitidez aplica-se a equalização de histograma, cujo resultado é apresentado na Figura 34(c). E na sequência é aplicada a limiarização de Otsu, tendo como resultado a imagem mostrada na Figura 34(d). O resultado é somado com a imagem limiarizada da região de interesse que representa o cordão de solda (Figura 34(b)).

**Figura 34 – Imagens das etapas principais na identificação de defeitos candidatos. (a) Original. (b) Região de interesse. (c) Máscara de nitidez equalizada. (d) Imagem segmentada pela técnica de Otsu. (e) Segmentação final das descontinuidades. (f) Identificação dos defeitos candidatos na imagem equalizada.**



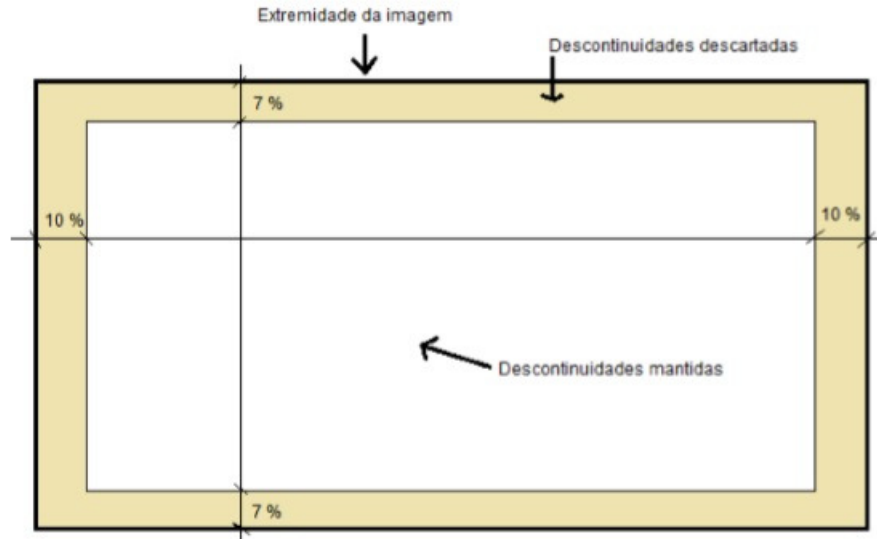
**Fonte: Boaretto (2017).**

Depois de executar as operações descritas e após a etapa de *labeling*, todos os objetos com área superior a um limiar mínimo e inferior a um limiar máximo são considerados defeitos candidatos. E todos os defeitos localizados dentro de uma faixa de 10% nas extremidades direita e esquerda da imagem bem como 7% nas extremidades superior e inferior são descartados (Figura 35). As descontinuidades encontradas nesta faixa não são consideradas como defeitos potenciais, uma vez que não estão nos laudos. Os resultados após executar esta etapa e a etapa anterior podem ser visualizados na Figura 34(e). Todos os valores utilizados no trabalho, foram definidos experimentalmente com comparações realizadas entre as imagens segmentadas e as imagens laudadas.

Os defeitos candidatos da Figura 34(e) (objetos brancos da imagem) são identificados por um algoritmo de rotulagem (GONZALEZ; WOODS; EDDINS, 2004) e suas

bordas são identificadas pelos contornos do gradiente morfológico. A Figura 34(f) mostra as descontinuidades detectadas (possíveis defeitos).

**Figura 35 – Área de exclusão de defeitos candidatos da extremidade da imagem.**




Fonte: Boaretto (2017).

O algoritmo, proposto por Boaretto (2017), extrai o seguinte conjunto de atributos, características geométricas de forma, para cada descontinuidade identificada (Figura 36):

1. Área: área da descontinuidade (defeito) detectada, ou seja, número total de pixels dentro da descontinuidade, inclusive com seu contorno ( $A$ );
2. Extensão: razão entre a área do defeito e a área do menor retângulo que envolve o defeito ( $E_x = A/A_r$ );
3. Razão 1: razão entre o menor eixo ( $d$ ) do retângulo que envolve o defeito e a área do defeito ( $R_1 = d/A$ );
4. Razão 2: razão entre o maior eixo ( $D$ ) do retângulo que envolve o defeito e a área do defeito ( $R_2 = D/A$ );
5. Razão 3: razão entre o maior eixo e o menor eixo do retângulo que envolve o defeito ( $R_3 = D/d$ );
6. Arredondamento: razão  $p^2/4 \cdot \pi \cdot A$ , onde  $p$  é o perímetro do contorno do defeito e  $A$  é a área do defeito;
7. Excentricidade: razão entre a distância entre os focos da elipse que envolve o defeito e o comprimento do seu eixo principal ( $E_c = c/a$ );
8. Solidez: razão entre a área do defeito e a área poligonal convexa do defeito ( $\beta = A/A_c$ ).

**Figura 36 – Exemplo de forma da descontinuidade com indicação dos parâmetros utilizados na extração das características geométricas. (a) Características 1 a 6. (b) Característica 7.**



Fonte: Boaretto (2017).

Além do conjunto de atributos, referente às características geométricas de forma, o algoritmo também gera para cada descontinuidade identificada as seguintes características de textura:

1. Diferença: diferença entre o menor e o maior nível de cinza do defeito;
2. Contraste: razão entre a Diferença e a variação do nível de cinza presente no recorte da imagem;
3. Desvio padrão: medida de dispersão em relação à média de níveis de cinza do defeito;
4. Entropia: número quantificador da aleatoriedade dos níveis de cinza do defeito. Quanto maior for este número, mais irregular, atípica ou despadronizada será a imagem analisada.  $Entropia = -\sum_{i=0}^k \sum_{j=0}^k N_g(i,j) \log[N_g(i,j)]$ , onde  $N_g$  é a matriz de co-ocorrência, sendo que os elementos desta matriz descrevem a frequência com que ocorrem transições nos níveis de cinza em uma imagem;
5. Assimetria: assimetria em relação ao centro dos valores de níveis de cinza do defeito.  $Assimetria = \frac{1}{n\sigma^3} \sum_{i=1}^n (g_i - \mu)^3$ , onde  $\mu$  é a média (valor esperado da distribuição dos níveis de cinza presentes na textura),  $\sigma$  é a variância (descreve quanto os valores estão dispersos em torno da média) e  $g_i$  representa o tom de cinza para o  $i$ -ésimo *pixel*.

Estas características compõem um banco de padrões contendo um conjunto com  $F$  vetores. Cada vetor contém as características de um defeito, sendo 8 características

geométricas e 5 características de textura. Estas características são utilizadas parcialmente ou na sua totalidade como entrada nos classificadores.

Embora os trabalhos citados nesta seção tenham obtido taxas de acerto maior que o apresentado neste estudo, não é possível uma comparação direta de valores. Isso porque cada pesquisador, na sua base de imagens, fez um recorte manual diferente das imagens a serem analisadas e conseqüentemente têm-se tamanhos diferentes bem como diferentes técnicas de processamento utilizadas, bem como as bases de imagens também são diferentes.

### 3.3 CONSIDERAÇÕES FINAIS

Com base na revisão das abordagens relacionadas, verificou-se que existem vários trabalhos utilizando as técnicas empregadas no estudo em outras aplicações (JI; DASGUPTA, 2009; FU; YU; WANG, 2012; NOOR; YAZID, 2015; SRIRAM *et al.*, 2017; KIDO *et al.*, 2018; ZARE *et al.*, 2018; CHEN *et al.*, 2018). Também foi possível observar uma maior concentração na detecção de defeitos em imagens radiográficas de cordões de solda obtidas pelas técnicas PSVS (MERY, 2011; YAHIA, 2011; VALAVANIS; KOSMOPOULOS, 2010; MAHMOUDI; REGRAGUI, 2009; HALIM *et al.*, 2013). Constatou-se que existem poucos trabalhos que abordam a técnica PDVD (KROETZ, 2012; FYLYK e CENTENO, 2012; SUYAMA, 2015; BOARETTO, 2017; MIRANDA *et al.*, 2017; SUYAMA *et al.*, 2019), alguns voltados para a identificação do cordão de solda e outros para a detecção de defeitos e somente um na identificação do cordão de solda em conjunto com a detecção de defeitos.

De uma forma geral, os trabalhos, destacados nesta seção e voltados para outras aplicações, têm como objetivo detalhar as técnicas utilizadas evidenciando as diferentes aplicações.

As pesquisas para a detecção de defeitos, visam detectar e analisar discontinuidades encontradas sobre as regiões de interesse. Os métodos propostos na literatura geralmente seguem os mesmos caminhos para a detecção de defeitos: delimitação da região de interesse; pré-processamento para redução de ruídos e realce; segmentação de regiões e o pós-processamento para eliminação de ruídos e a extração de características e a classificação das discontinuidades.

Neste sentido, a pesquisa realizada segue a mesma linha adotada por muitos dos trabalhos relatados: pré-processamento seguido da extração de características de regiões



segmentadas com possíveis defeitos para realizar ao final a classificação entre defeito e não defeito.

Além disso, muitos trabalhos usam imagens ideais em vez de imagens de campo reais, que geralmente são de baixa qualidade. Além disso, para fins de classificação, a maioria dos pesquisadores usa apenas um sistema (Redes Neurais) para reconhecimento de padrões. Desta forma, o presente trabalho busca inovar dentro do contexto das abordagens relacionadas, primeiro ao aplicar algumas técnicas de processamento de imagens, como: filtros de redução de ruído, histograma, equalização, operações morfológicas, entre outras, para destacar as discontinuidades existentes no cordão de solda tendo em vista a pequena base de dados disponíveis para a extração automática dos filtros via aprendizagem profunda. Depois, a proposta também apresenta inovação, pois para a classificação de uma discontinuidade como defeito ou não defeito (reconhecimento de padrões), duas técnicas são usadas no mesmo modelo: aprendizado profundo e SIA. A escolha do SIA é baseada em suas principais características (singularidade, reconhecimento de padrões internos e externos do sistema, detecção de anomalias, detecção imperfeita, detecção distribuída, diversidade, aprendizado por reforço, memória) (SERAPIÃO *et al.*, 2007; DASGUPTA, 2006). O aprendizado profundo foi aplicado com sucesso a muitas tarefas de reconhecimento de padrões como a realizada neste trabalho, embora apenas um trabalho tenha sido encontrado lidando com radiografias de tubulações de petróleo (SUYAMA *et al.*, 2019). O presente trabalho inova ao apresentar aprendizado profundo com *Transfer Learning* associado ao SIA.

O diferencial da pesquisa desenvolvida nesta tese é que com as características obtidas para realizar a análise das discontinuidades, desenvolve-se um sistema híbrido com duas técnicas distintas e consideram-se as características individuais de cada técnica objetivando a classificação das discontinuidades.

No próximo capítulo detalha-se o método proposto para segmentação, extração das características e classificação de discontinuidades em imagens radiográficas de soldas em tubulações, para imagens obtidas pela técnica de exposição radiográfica PDVD.

## 4 MÉTODO

Este capítulo explica a metodologia proposta para a detecção e a classificação de descontinuidades em imagens radiográficas de soldas em tubulações. São apresentados os procedimentos e técnicas para identificar a região do cordão de solda, detectar e identificar as descontinuidades, e em seguida, extrair as características a serem utilizadas nas abordagens propostas de forma a classificar essas descontinuidades como defeito ou não defeito. A proposta principal envolve a utilização das características extraídas para realizar a classificação tendo por base um sistema híbrido que une sistemas imunológicos artificiais e aprendizado profundo.

A principal dificuldade encontrada ao propor uma metodologia para detecção e classificação de descontinuidades está associada ao fato de que o cordão de solda pode apresentar diversas alterações (ruído, borramento e baixo contraste) de uma imagem para outra (Figura 37).


**Figura 37– (a) Imagem com ruído. (b) Imagem com borramento. (c) Imagem com baixo contraste.**



**(a)**



**(b)**



**(c)**

**Fonte: Autoria própria (2020).**

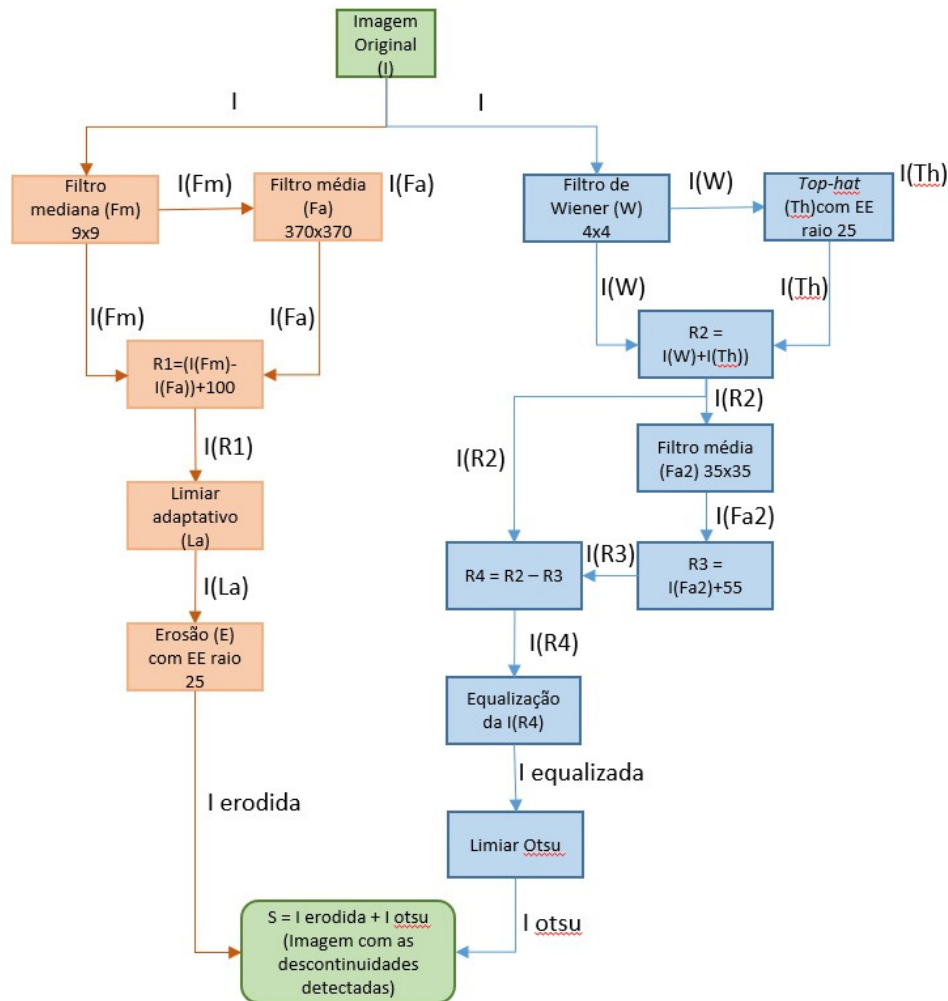
## 4.1 ETAPA DE PRÉ-PROCESSAMENTO DE IMAGEM

A etapa de pré-processamento realizada neste trabalho segue a ideia apresentada por Boaretto (2017). Vários testes foram realizados considerando as imagens obtidas pelos recortes realizados nas imagens iniciais. Para chegar a um resultado capaz de detectar as discontinuidades nos cordões de soldas, em todas as imagens utilizadas, os valores dos filtros, da máscara de nitidez e da limiarização tiveram seus valores alterados e estão descritos nesta seção.

### 4.1.1 Pré-processamento

Conforme mostra a Figura 38, a etapa de pré-processamento envolve duas fases principais: (i) segmentação do cordão de solda (blocos em cor rosa na Figura 38); (ii) identificação das discontinuidades (blocos em cor azul na Figura 38). A segmentação da região do cordão de solda (fase (i)) é realizada no recorte da imagem original (Figura 39(a)) e destina-se a delimitar a região de estudo para a fase (ii), ou seja, é uma etapa anterior à detecção das discontinuidades. Descontinuidades encontradas fora da região de estudo (cordão segmentado), conforme ilustra a Figura 35, não são consideradas na fase de treinamento nem na detecção e classificação de defeitos.


**Figura 38– Estrutura para a obtenção da imagem com as discontinuidades, com a localização da região do cordão (laranja) e detecção das discontinuidades para a extração das características (azul).**



Fonte: Autoria própria (2020).

Seguindo a ideia de Boaretto (2017), sobre a imagem recortada aplica-se um filtro de mediana e depois um filtro de média 370x370 (Figura 39(b)). À imagem resultante da subtração (imagem filtrada pela mediana menos a imagem filtrada pela média) acrescenta-se uma constante de valor 100. Sobre essa imagem resultante é aplicada uma limiarização adaptativa (SOLOMON; BRECKON, 2013) (Figura 39(c)). Mantendo as discontinuidades existentes na margem do cordão de solda, a imagem obtida na limiarização é erodida morfologicamente com um elemento estruturante disco de raio 25, sendo o valor do raio obtido experimentalmente, o resultado é apresentado na Figura 39(d).

**Figura 39– Segmentação do cordão de solda: (a) Recorte da imagem original. (b) Imagem filtrada – filtro de média 370x370. (c) Imagem limiarizada. (d) Imagem erodida.**




Fonte: Autoria própria (2020).

Após a imagem ser segmentada, realiza-se a detecção das descontinuidades existentes na região de interesse, como ilustra a Figura 35, bem como, extraem-se as características das mesmas, sendo estas utilizadas como entrada do sistema proposto.

A detecção de descontinuidades (Figura 40(a)) inicia na imagem original, utilizando o filtro de Wiener, para em seguida realizar a operação *top-hat*, com elemento estruturante disco de raio 25. A imagem resultante da operação *top-hat* é somada com imagem filtrada pelo filtro de Wiener na qual é aplicado o filtro de média 35x35 e somada uma constante de valor 55. Com esta imagem obtida, após a soma da constante, realiza-se a subtração com a imagem obtida da operação *top-hat* e aplica-se na imagem resultante a equalização do histograma (Figura 40(c)). Realiza-se a limiarização de Otsu (Figura 40(d)) e o resultado soma-se com a imagem limiarizada da região de interesse (Figura 40(b)). Os defeitos candidatos são aqueles com uma área entre 15 e 6000 pixels (Figura 40(e)). Todos os defeitos localizados dentro de um espaço de 10% a partir das extremidades direita e esquerda da imagem e 7% das extremidades superior e inferior são descartados, uma vez que não estão nos laudos, os quais seguem as normas de avaliação de ensaios não destrutivos para imagens de raio-X (ASM HANDBOOK, 2007). Os defeitos candidatos são identificados por um algoritmo de etiquetagem (GONZALEZ; WOODS; EDDINS, 2004) e suas bordas são evidenciadas através de contornos pelo gradiente morfológico. O resultado final das descontinuidades detectadas (possíveis defeitos) é apresentado na Figura 40(f).

**Figura 40 – Imagens das principais fases para identificar os defeitos candidatos. (a) Original. (b) Região de interesse. (c) Máscara de nitidez equalizada, (d) Imagem obtida pela técnica de Otsu. (e) Segmentação final das descontinuidades. (f) Identificação dos defeitos candidatos na imagem equalizada.**



Fonte: Autoria própria (2020).


#### 4.1.2 Extração das Características

O método inicial de extração de características utilizado neste trabalho é o mesmo apresentado por Boaretto (2017) (Seção 3.2.3.1) e conta com oito atributos geométricos (área, excentricidade, solidez, extensão, razão 1, razão 2, razão 3 e arredondamento) e cinco atributos de textura (diferença, contraste, desvio, assimetria e entropia), totalizando 13 características básicas em cada vetor e compondo um banco de dados com F vetores, que são as características utilizadas pelo módulo SIA.

Para realizar a extração de características pela CNN, são utilizadas as mesmas descontinuidades usadas na extração das características pelo método de Boaretto (2017). As

descontinuidades obtidas possuem tamanhos diferentes e diversas formas, como ilustrado na Figura 41.

**Figura 41– Descontinuidades com vários tamanhos e formas.**



**Fonte: Autoria própria (2020).**

As características são normalizadas com o propósito de minimizar problemas oriundos do uso de unidades e dispersões distintas entre as variáveis. O objetivo é ajustar as escalas de valores dos atributos para o mesmo intervalo [0, 1] para evitar uma maior influência de atributos com grande intervalo de valores.

Uma das formas de normalização, utilizada no trabalho, é definida na Equação 33, onde a matriz ou vetor de entrada  $f$  possui apenas valores reais finitos e os elementos são distintos,  $f_{norm}$  é o elemento da matriz normalizada ou do vetor normalizado,  $min$  é o valor mínimo de  $f$  e  $max$  é o valor máximo de  $f$ .

$$f_{norm} = \frac{f - min}{max - min} \quad (33)$$

## 4.2 CONSTRUÇÃO DO BANCO DE DADOS

A construção do banco de dados se faz necessária, uma vez que é preciso alimentar o SIA com os dados de treinamento (para o *matching*), validação ou teste. Dois bancos de dados são então construídos: o conjunto de não defeitos e o conjunto de defeitos. Parte do conjunto não defeito compõe o banco de células próprias e parte do conjunto de defeitos compõe o banco de não próprios (chamado "banco de antígenos"). A outra parte compõe o conjunto de amostras usadas na fase de validação e teste. Um dos principais desafios deste trabalho é a escassez de dados para compor o treinamento, a validação e o conjunto de testes, cuja

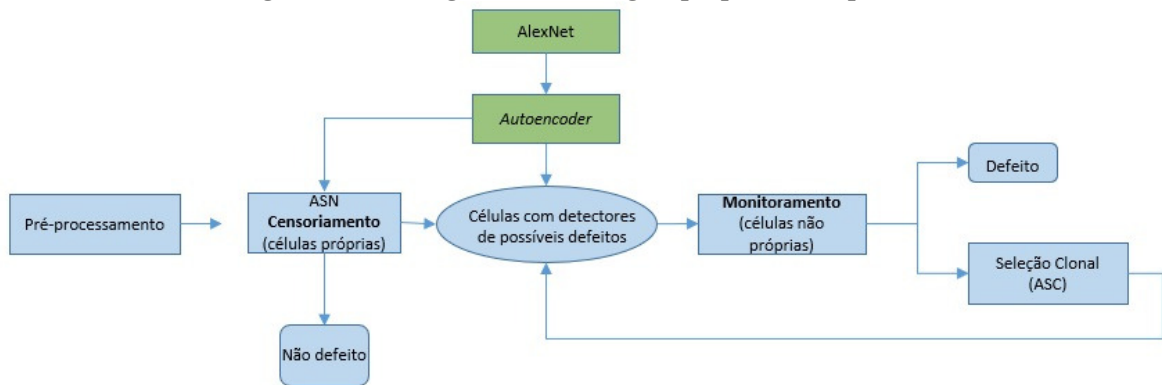
rotulagem depende de especialistas em tubulações de petróleo, considerando que o laudo sempre é fornecido por um especialista.

### 4.3 SIA PROFUNDO

Para a classificação das discontinuidades detectadas na fase de pré-processamento, é proposto um sistema híbrido unindo sistema imunológico artificial e aprendizado profundo. Conforme representado na Figura 42, o módulo SIA (caixas azuis) abrange o algoritmo de seleção negativa (ASN) e o algoritmo de seleção clonal (ASC) e é usado para:

1. Separar células próprias (não defeitos detectados na fase de sensoriamento do ASN);
2. Separar células não próprias (defeitos detectados na fase de monitoramento do ASN);
3. Evoluir, por meio do ASC, anticorpos visando melhorar a detecção de elementos não próprios.

**Figura 42 – Visão geral da abordagem proposta: SIA profundo.**



**Fonte: Autoria própria (2020).**

O módulo de aprendizado profundo (caixas verdes na Figura 42) engloba dois modelos de redes neurais (AlexNet e *autoencoder*) e é usado para aumentar o número de características utilizados na fase de *matching* do ASN e ASC.

Inicialmente, na fase de pré-processamento, cujos detalhes foram descritos na Seção 4.1, são detectadas discontinuidades nas imagens recortadas do cordão de solda. As discontinuidades são identificadas pelas coordenadas dos seus centroides ( $x, y$ ) (adequado à identificação da posição das mesmas) e os limites são baseados nas bordas, que são obtidas por meio de técnicas de processamento de imagem. Como será detalhado na Seção 4.3.1, o

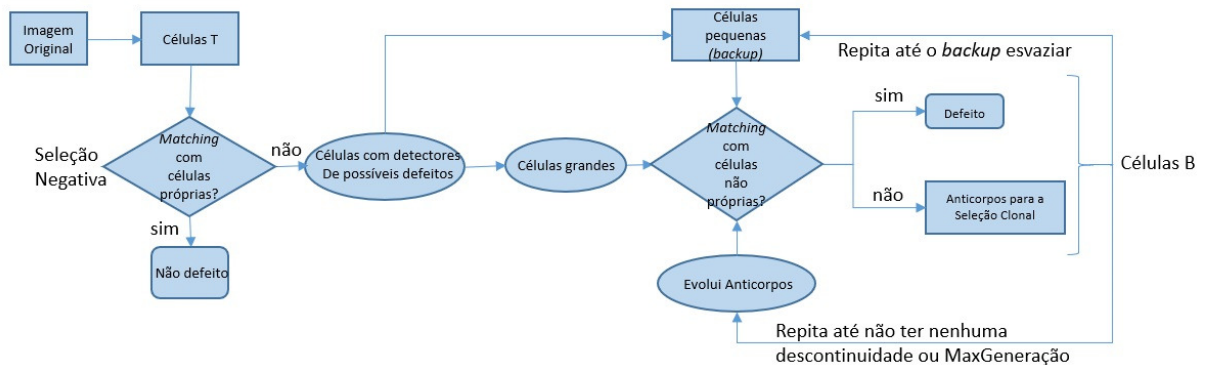


tamanho da descontinuidade permitirá classificar os possíveis defeitos em duas categorias de células no contexto do SIA: células grandes e células pequenas. Em seguida, o método extrai características da janela que abrange a descontinuidade.

#### 4.3.1 Módulo SIA

Como ilustrado na Figura 42 e detalhado na Figura 43, o módulo SIA é composto por algoritmos de seleção negativa e seleção clonal cujos componentes básicos são as células T e B. No contexto desta aplicação, cada célula T representa um conjunto composto por um detector e as características extraídas da imagem a partir deste detector (13 características para o SIA puro e 113 para o SIA com aprendizagem profunda); e cada célula B é semelhante a uma célula T (elas diferem apenas na codificação genética do detector, uma vez que as células B consideram todos os alelos detectores e as células T desconsideram os dois últimos genes: operador morfológico (OM) e elemento estruturante (EE)) (ver a Figura 45 para mais detalhes).

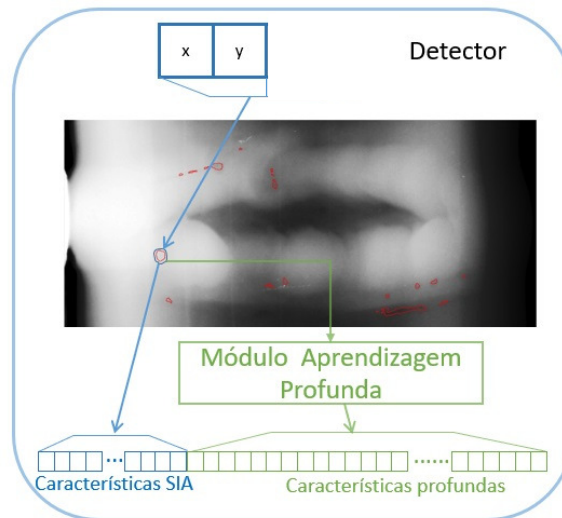
**Figura 43 – Sistema SIA puro proposto para a fase de reconhecimento.**



**Fonte: Autoria própria (2020).**

O primeiro passo é realizado pelo algoritmo de seleção negativa (ASN). Ao reconhecer seus próprios elementos, elimina descontinuidades que representam claramente não defeitos. Para isso, o ASN calcula a afinidade entre a célula T (Figura 44) que representa a descontinuidade pré-detectada e cada célula armazenada no repositório próprio (banco de próprios). Como será detalhado na fase de seleção clonal, a afinidade é calculada com base em uma métrica de distância entre os vetores de características de ambas as células.

Figura 44 – Exemplo de célula T aprimorado pelo aprendizado profundo (em verde).



Fonte: Autoria própria (2020).

Uma descontinuidade é reconhecida como não defeito se corresponder a uma das células presentes no repertório de próprios. Em outras palavras, é reconhecida se sua afinidade com uma célula própria é maior que o limiar do próprio ( $\gamma_s$ ). Um valor alto para  $\gamma_s$  deve ser definido para seleção negativa, de modo que apenas descontinuidades fortemente caracterizadas como não defeitos sejam excluídas do processo.

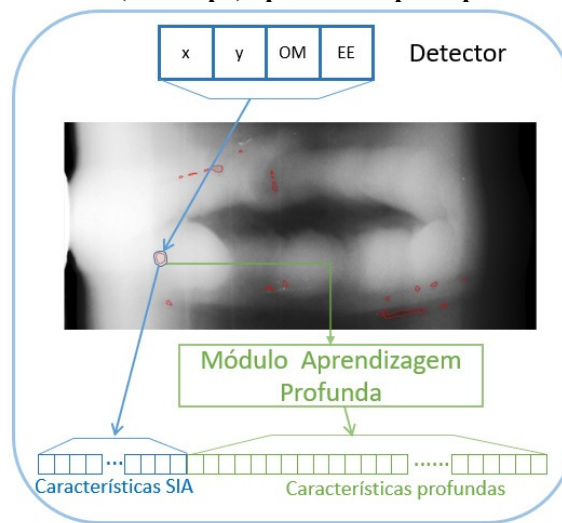
No ASN, as células que fazem *matching* com as células próprias são eliminadas e as descontinuidades associadas são rotuladas na imagem original. Descontinuidades não associadas com células próprias, ou seja, aquelas que não são eliminadas pelo ASN, são possíveis defeitos e devem ser analisadas posteriormente com o banco de antígenos. O conjunto de possíveis células defeitos é dividido em dois grupos, em função do seu tamanho em pixels: células grandes (de 40 a 6000 pixels) e pequenas (de 15 a 39 pixels). Conforme ilustrado na Figura 43, o grupo de células grandes é usado diretamente na fase de *matching* com células não próprias. O grupo de células pequenas é armazenado no *backup* do sistema para análise posterior.

Durante a fase de teste dos não próprios, o conjunto atual de células em análise é comparado com o banco de antígenos, para fins de classificação. As células classificadas como defeitos (isto é, aquelas com afinidade maior que o limiar inicial,  $\gamma_d^0$ ) têm suas descontinuidades marcadas na imagem original e são excluídas do processo. As demais células (que darão origem às células B) ainda são considerados como defeitos potenciais e evoluem com base no algoritmo de seleção clonal (ASC), que é baseado na evolução de anticorpos.

Cada anticorpo possui um detector (Figura 45) composto pelos seguintes genes:

- Posição da descontinuidade associada (coordenadas  $x$  e  $y$ ) (obtida pelo centroide);
- Um valor numérico que determina não apenas o operador morfológico (erosão ou dilatação), mas também o número de vezes em que esse operador será aplicado à descontinuidade;
- um valor numérico indicando qual elemento estruturante (EE) será usado para realizar a operação morfológica.

**Figura 45 – Exemplo de célula B (anticorpo) aprimorado pelo aprendizado profundo (em verde).**




**Fonte: Autoria própria (2020).**

Assim, cada detector codificado num anticorpo é representado por um conjunto de genes que codificam dois alelos de localização e dois alelos morfológicos, conforme mostrado na Figura 45.

Os valores de  $x$  e  $y$  identificam a posição (linha, coluna) do centroide da descontinuidade em toda a imagem. O valor do operador morfológico (OM) pode variar de  $(-M$  a  $+M)$  onde  $M \in \mathbb{N}$  (números naturais), permitindo diferentes variações. Alguns operadores não evidenciavam as alterações necessárias nas descontinuidades e por este motivo foram mantidos apenas os operadores de erosão e a dilatação. Por exemplo,  $-3$  codifica três iterações de erosão e  $+3$  codifica três iterações de dilatação. O valor do elemento estruturante (EE) pode variar no intervalo  $(0$  a  $|\{EE\}|)$  que codifica um tipo de EE ou nenhum EE (0). Após realizar muitos testes, empiricamente, com vários tipos de EE, alguns tipos obtiveram bons resultados e são usados nos métodos propostos, como mostrados na Figura 46: (a) disco de raio 1, (b) linha com comprimento 3 e ângulo de  $45^\circ$ , (c) quadrado  $2 \times 2$  e (d) retângulo  $2 \times 3$ . Alguns tipos de EE assemelham-se, como os vistos na Figura 46(a) e

na Figura 46(c), lembrando que um é disco raio 1 e que tem um diâmetro 2 com uma forma redonda e que o outro tipo é um quadrado reto 2x2.

**Figura 46 – EE's utilizados. (a) Disco de raio 1. (b) Linha com comprimento 3 e ângulo de 45°. (c) Quadrado 2x2. (d) Retângulo 2x3.**



**Fonte: Autoria própria (2020).**

No ASC, durante a inicialização da população, cada célula T dá origem a uma célula B ou anticorpo (Figura 45), definindo aleatoriamente os valores dos alelos OM e EE na codificação genética do detector. É importante salientar que, além das características extraídas na fase de pré-processamento que podem ser aprimorados ainda mais pelo detector evoluído pelo ASC, o conjunto pode ser expandido através do módulo profundo, conforme detalhado na Seção 4.3.2. Na abordagem proposta, na primeira geração do ASC, existe uma população  $P_{Ab}$  de anticorpos que evoluirão ao longo de  $C$  ciclos de evolução. Cada antígeno no banco de antígenos também é representado por seu vetor de característica  $f$ . No entanto, diferentemente dos anticorpos, os alelos dos antígenos não mudam durante o processo evolutivo, bem como suas características associadas, que permanecem fixas ao longo de todo o processo.

Como mencionado anteriormente, durante a inicialização da população de  $P_{Ab}$ , os alelos  $x$  e  $y$  definem a posição da janela usada para extrair as características e os outros alelos (OM e EE) recebem valores aleatórios. Durante o processo de clonagem, cada anticorpo cria  $K$  clones de si mesmo, cada clone passa por um processo de hipermutação que altera os alelos de seu detector. Assim como no SI natural, aqui a seleção clonal controla a taxa de hipermutação relacionada ao valor de afinidade. Como são duas variáveis a serem alteradas (OM e EE), definiu-se que se a afinidade for um valor igual ou acima de 0,5, a taxa de hipermutação é menor, ou seja, somente uma das variáveis sofre alterações. Caso a afinidade seja um valor abaixo de 0,5, a taxa de hipermutação é maior, onde as duas variáveis sofrem alterações.

Durante o processo de *matching* que ocorre em cada geração da fase de seleção clonal, as afinidades são calculadas entre cada anticorpo e todos os antígenos pela Equação 34:

$$Af_i = \max_{j=1, \dots, |Ag|} Af(Ab_i, Ag_j) = \max_{j=1, \dots, |Ag|} (1 - d_{ij}) \quad (34)$$

onde  $|P_{Ab}|$  é o total de indivíduos (anticorpos) na população atual e  $|Ag|$  é a cardinalidade do conjunto de antígenos (banco de antígenos).


A afinidade de cada anticorpo  $Ab_{Nin P_{Abi}}$  é dada pelo valor máximo de afinidade entre este e todos os antígenos e  $d_{ij}$  é uma métrica qualquer usada para calcular a distância entre as características dos vetores do anticorpo  $Ab_i$  e o antígeno  $Ag_j$ , com o intervalo  $[0, 1]$ .

Se  $Af_i$  for maior ou igual a  $\gamma_d^c$  (ou seja, se  $Af_i$  for maior que o limiar de defeito que foi definido no atual ciclo  $c$  de evolução), o anticorpo é considerado um defeito. Os anticorpos classificados como defeito têm sua descontinuidade associada rotulada na imagem original e são suprimidos do processo evolutivo. Essa eliminação cria espaço para a análise e evolução adicional das células de *backup* (células menores) escolhidas aleatoriamente. Por outro lado, se a afinidade não exceder o valor de  $\gamma_d^c$ , o atual anticorpo permanece como um defeito em potencial e, modificando seus alelos detectores ou pela diminuição do limiar  $\gamma_d^c$ , pode ser classificado como um defeito (a partir do *matching* com uma célula no banco de antígenos) em estágios mais avançados no processo da evolução.

No contexto da inspiração biológica, visando melhorar a eficiência da resposta imune após contato próximo com antígenos, os anticorpos da população  $P_{Ab}$  passam por processos de clonagem e hipermutação. No contexto do processamento de imagens, considera-se que a imagem das descontinuidades detectadas nem sempre cobre um defeito precisamente devido a alguma falha na detecção. Portanto, a evolução dos anticorpos é como uma tentativa de melhorar as características extraídas para fins de classificação. Para esse fim, a hipermutação causa variações nos genes detectores de anticorpos (que por sua vez podem causar variações na dimensão e no contorno da descontinuidade cujas características serão extraídas).

Os genes detectores funcionam, portanto, como lentes e alteram a atual relação de vizinhança entre os pixels, pois codificam alterações a serem feitas pela maneira como cada descontinuidade associada ao anticorpo é visualizada (a imagem original não é alterada). O objetivo é permitir que o anticorpo se ajuste melhor aos antígenos, transformando os genes detectores, com o objetivo de melhorar o valor de afinidade que o classifica como defeito. Assim, cada descontinuidade localizada nas coordenadas  $(x, y)$  tem suas dimensões e forma alteradas de acordo com os valores dos genes detectores. Um exemplo dessa transformação é mostrado na Figura 47.

**Figura 47 – (a) Descontinuidade original. (b) Descontinuidade alterada com dilatação +3 e EE 1 (disco de raio 1).**



**Fonte: Autoria própria (2020).**

Neste exemplo, os alelos OM e EE são 3 e 1, respectivamente; portanto, a descontinuidade sofre três iterações de dilatação com EE definido como disco de raio 1. Devido à hipermutação, as descontinuidades podem ser sujeitas a diferentes tipos de modificação combinando variações de OM e EE. A etapa de hipermutação gera alterações aleatórias de anticorpos e ajuda o algoritmo proposto a evitar valores ótimos locais, criando um maior nível de diversidade.

Na abordagem proposta, os anticorpos da população  $P_{Ab}$  são desenvolvidos com base nas etapas mostradas na Figura 48.

Além dos passos já descritos na etapa do ASC, um aspecto importante a ser destacado é a atualização dos valores do limiar do *matching* (linha 4). Esse limiar dinâmico representa uma importante contribuição da proposta como será mostrado na seção dos experimentos.

Todo o processo evolutivo é concluído quando um dos seguintes critérios de parada é atendido: não há mais descontinuidades a serem classificadas ou o número máximo de gerações é atingido.

Figura 48 – Pseudocódigo da Seleção Clonal.

Algoritmo 1: Seleção Clonal	
1:	<b>Enquanto</b> condição de parada não for atendida
2:	<b>Para</b> ciclo $c=1, \dots, C$
3:	<b>Para</b> gen = $1, \dots, G=MaxGerPorCiclo$
4:	Atualize o valor do limiar $\gamma_d^c$ .
5:	Apresente cada antígeno à população atual de anticorpos ( $P_{Ab}$ ) e, usando Eq. 35, calcule a afinidade $Afi$ para cada anticorpo $i \in P_{Ab}, i=1, \dots,  P_{Ab} $ .
6:	Compare cada $Afi$ com o limiar do defeito atual $\gamma_d^c$ .
7:	<b>Se</b> ( $Afi > \gamma_d^c$ )
8:	Rotule a descontinuidade localizada na posição $(x, y)$ como defeito e remova $i$ da $P_{Ab}$ .
9:	Escolha aleatoriamente uma célula pequena armazenada no backup (não está vazio) e crie um novo anticorpo a partir desta célula pequena, definindo aleatoriamente seus valores OM e EE.
10:	Inclua o novo anticorpo na $P_{Ab}$ .
11:	Clone todos os anticorpos na $P_{Ab}$ proporcionalmente aos seus valores de afinidade. Isso significa gerar $K = \lfloor Afi \rfloor$ clones para cada anticorpo $i$ , onde $\lfloor \_ \rfloor$ significa 'função piso'.
12:	Hipermutação a cada clone com o objetivo de melhorar seu detector de anticorpos.
13:	Atualize as características com o clone hipermutado bem como sua afinidade com o banco de antígenos.
14:	Para cada anticorpo $i$ selecione o clone hipermutado com a maior afinidade (melhor clone).
15:	Compare a afinidade do melhor clone com a afinidade de seu pai, substituindo-o com o melhor.
16:	gen = gen + 1;
17:	<b>fim</b> para gen
18:	c = c + 1;
19:	<b>fim</b> para ciclo
20:	<b>fim</b>

Fonte: Autoria própria (2020).

#### 4.3.2 Módulo de Aprendizagem Profunda

Conforme mostrado na Figura 42, o sistema proposto para classificar descontinuidades, SIA profundo, utiliza um módulo SIA, juntamente com o aprendizado profundo. O módulo de aprendizado profundo foi incluído como uma tentativa de melhorar o desempenho da classificação aumentando o número de características a serem analisadas, tanto no ASN (classificação de não defeitos) quanto nas etapas de *matching* inicial e ASC (classificação de defeitos).

Na primeira abordagem proposta, dois modelos de aprendizado profundo (uma CNN e um *autoencoder*) são conectados ao módulo SIA para expandir as informações armazenadas no vetor de características. Esta etapa é inspirada nas terapias imunológicas presentes em alguns tratamentos de doenças nas quais a resposta imune é alavancada por mecanismos


artificiais externos, como por exemplo a utilização no paciente de plasma de outras pessoas com anticorpos para a doença sendo tratada ou até mesmo de doenças semelhantes.

Primeiro, considera-se o modelo CNN AlexNet - descrito na Seção 2.4.1 - para extrair características. Segundo, o *autoencoder* - descrito na Seção 2.4.3 - é utilizado para reduzir a dimensionalidade das características extraídas pela CNN.

A rede AlexNet considera imagens de dimensões  $227 \times 227 \times 3$  (227 linhas, 227 colunas e 3 canais de cores) (KARPATHY, 2017), como entrada. Como os tamanhos da janela de imagem das descontinuidades detectadas podem ser incompatíveis com as dimensões da imagem usadas pelos testes preliminares da AlexNet, alguns procedimentos nas imagens de descontinuidade devem ser executados antes da aplicação da etapa de redimensionamento necessária (Figura 49 e Figura 50 com a versão modificada da AlexNet, descrita na Seção 5.3).

Para cada descontinuidade, uma iteração de dilatação é aplicada com o EE disco de raio 5 e seu retângulo englobante é obtido. A região fora do limite da descontinuidade é preenchida com o nível de cinza 0 (preto) (Figura 49b) para que outros elementos presentes na imagem não influenciem a extração das características. Todas as imagens de descontinuidades são redimensionadas para serem utilizadas como entradas da AlexNet. Partindo do seu tamanho original, cujas dimensões variam de  $4 \times 6$  até  $51 \times 452$ , as imagens são centralizadas e reescaladas para o tamanho usado pela AlexNet ( $227 \times 227$ ), sendo que para adaptação de volume, a imagem é replicada 3 vezes (cada imagem passa a ter 3 canais conforme ilustra a Figura 49c). Esse processo é utilizado tanto na fase de treinamento como na fase de teste.

**Figura 49 – Extração de características da descontinuidade com AlexNet. (a) Imagem obtida do detector de anticorpos. (b) Imagem dilatada com borda preta. (c) Imagem redimensionada nas dimensões de entrada do AlexNet.**

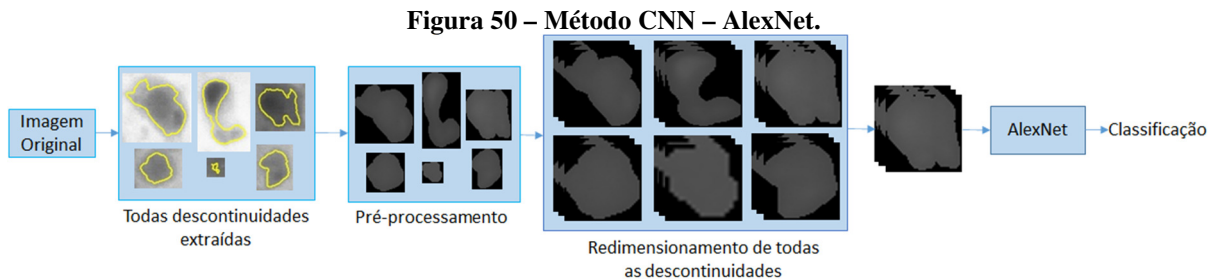


**Fonte: Autoria própria (2020).**

O primeiro nível de características profundas é obtido na primeira camada totalmente conectada, resultando em um vetor com 4096 elementos, conforme descrito na Seção 2.4.2. A Figura 25, Seção 2.4.1 e o Apêndice A mostram, respectivamente, o modelo AlexNet usado neste trabalho e a descrição detalhada de cada camada, bem como os respectivos valores dos parâmetros utilizados. Enquanto que o sistema de aprendizado profundo puro é ilustrado na



Figura 50 e considera apenas o modelo AlexNet com camada totalmente conectada adaptada para classificar em duas classes as descontinuidades detectadas na fase de pré-processamento.

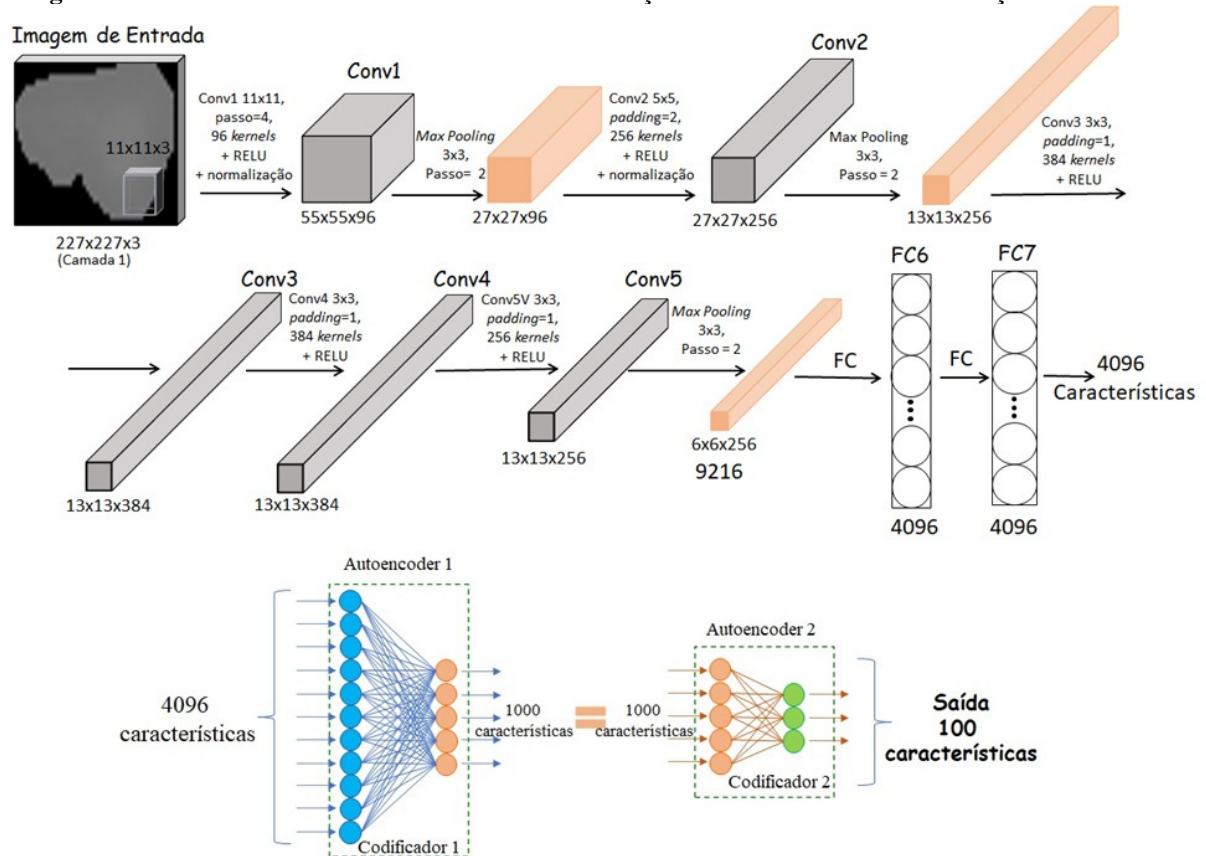


No sistema de aprendizagem profundo puro, utilizando o *software* MatLab R2018a, as três últimas camadas da AlexNet (camadas 23, 24 e 25) são ajustadas de acordo com o método descrito por Park *et al.* (2016), Nawaz *et al.* (2018), Oza e Patel (2018) e Xiao, Yan e Deng (2017). Estas três camadas são removidas da arquitetura e define-se o novo número de classes para as camadas 23 e 25, sendo nesta proposta duas classes para as descontinuidades (defeito e não defeito). Depois, reorganiza-se a estrutura da AlexNet mantendo as configurações para a camada 24 e as camadas 23 e 25 reduzidas para o novo total de classes. Finalmente, a nova formação é treinada e depois executa-se a classificação das descontinuidades, ressaltando que a mesma é efetuada somente com as características obtidas pelo AlexNet.

Características extraídas pelo módulo SIA podem ser usadas em conjunto com as características obtidas diretamente pela rede AlexNet. No entanto, alguns experimentos iniciais mostraram que, devido ao grande número de características obtidas (4096 características), essa combinação não teve um bom desempenho. Assim, no SIA profundo proposto, a dimensionalidade do vetor de característica obtida pela rede AlexNet é reduzida usando *autoencoders*.

Na versão proposta para o SIA profundo, para reduzir a dimensionalidade do vetor de características obtidas pela AlexNet e aumentar simultaneamente o nível de características, dois *autoencoders* são usados, como ilustra a Figura 51.

**Figura 51 – AlexNet e *autoencoders* ilustrando a obtenção das características e a redução dimensional.**



Fonte: Autoria própria (2020).

A camada de entrada do primeiro *autoencoder* recebe os vetores de treinamento, cada um com 4096 características. Após concluir o primeiro processo de treinamento do *autoencoder*, a saída fornecida pela camada oculta do primeiro *autoencoder* é usada como entrada para o segundo *autoencoder*. Após o processo de treinamento, o segundo *autoencoder* retorna o vetor de características profundo (parte verde de todo o vetor na Figura 45) como sua saída. O vetor de características obtido pelo *autoencoder* fornece então parte do conjunto de características (parte em verde do vetor de características na Figura 45) utilizadas quando há aprendizado profundo, ou seja 100 do total de 113 características utilizadas pelo modelo SIA profundo).

O *autoencoder* utilizado é do tipo esparsa, que utiliza regularizadores para aprender uma representação esparsa e que é controlado definindo-se alguns parâmetros, que são:

- $\lambda$  – coeficiente para o termo da regularização de peso,
- $\beta$  – coeficiente para o termo regularização de esparsidade, e
- Proporção de esparsidade – controla a dispersão da saída da camada oculta.

Os valores adotados para estes parâmetros, definidos empiricamente, após vários testes, são:  $\lambda = 0,001$ ;  $\beta = 4$  e proporção de esparsidade = 0,005.

### 4.3.3 SIA com *autoencoder*

Uma segunda abordagem com SIA e aprendizagem profunda é proposta, somente com a utilização do *autoencoder*, que é conectado ao módulo SIA para expandir as informações armazenadas no vetor de características. Nesta segunda abordagem, o *autoencoder* para a extração de características é descrito na Seção 2.4.3.1.

Características extraídas pelo módulo SIA são usadas em conjunto com as características obtidas pelo *autoencoder*. Para realizar a extração das características, bem como reduzir a sua dimensionalidade, dois *autoencoders* são utilizados. A entrada do primeiro *autoencoder* recebe como entrada as mesmas imagens utilizadas pela AlexNet. A saída fornecida pela camada oculta do primeiro *autoencoder* é usada como entrada para o segundo *autoencoder*. O segundo *autoencoder* retorna o vetor de características (similar à parte verde de todo o vetor do SIA profundo da Figura 45) como sua saída. O vetor de características é então conectado às características do SIA (parte azul do vetor de características na Figura 45).

## 4.4 CONSIDERAÇÕES FINAIS

Com a utilização dos métodos propostos apresentados neste capítulo, pode-se destacar alguns aspectos presentes na proposta:

- Utilização de técnicas de SIA em conjunto com o aprendizado profundo, com um ou dois modelos, para reconhecimento de padrões em uma metodologia de classificação de descontinuidades em imagens radiográficas industriais;
- Utilização da técnica de seleção clonal para adaptar o detector codificado no anticorpo (tipo e frequência das operações para extração de características), durante a análise;
- Utilização de técnicas de SIA para reconhecimento de padrões verificando o seu desempenho na classificação de descontinuidades em imagens radiográficas industriais;
- Utilização de um limiar dinâmico para o cálculo do *matching* dos anticorpos com o banco de antígenos.

Esta metodologia foi testada nas imagens radiográficas disponíveis conforme alguns parâmetros e valores definidos, que estão detalhadas no próximo capítulo.

## 5 EXPERIMENTOS

Este capítulo apresenta o conjunto de imagens radiográficas disponibilizado para o desenvolvimento da pesquisa, bem como os parâmetros utilizados nos experimentos e seus valores. Também é explicado como a CNN e o *autoencoder* são utilizados de forma isolada para realizar a tarefa de classificação com o propósito de realizar uma comparação com as abordagens desenvolvidas.

### 5.1 MATERIAIS


Nesta pesquisa utilizaram-se vinte imagens radiográficas computadorizadas de juntas soldadas, todas obtidas pelos sistemas de radiografia computadorizada GE ou Dürr. As imagens fornecidas inicialmente foram extraídas a partir do tubo com o cordão de solda na forma de negativos em arquivos do formato *Tagged Image File Format* (TIFF) com 65.536 tons de cinza (16 bpp) e dimensões (largura x altura) diferentes. As mesmas foram recortadas manualmente, eliminando as partes do tubo que não faziam parte do cordão de solda e assim os recortes também possuem dimensões diferentes, tendo como dimensão mínima o valor de 961x511 pixels e máxima de 1974x736 pixels (Tabela 1). Essa coleção de imagens foi cedida pela PETROBRAS e obtida através da técnica parede dupla vista dupla (PDVD). Estas imagens foram obtidas a partir de condições reais de operação e afetadas por diferentes parâmetros de captura e digitalização, tais como: quantidade de radiação e tempo de exposição, o que acabou ocasionando diferentes níveis de luminosidade, ruído e contraste. A Figura 52 apresenta os cordões de solda, recortados manualmente dos tubos, utilizados no treinamento do sistema proposto.

**Tabela 1 – Tamanho dos recortes do cordão de solda.**

IMAGEM	DIMENSÕES	IMAGEM	DIMENSÕES	IMAGEM	DIMENSÕES	IMAGEM	DIMENSÕES
1	1026x434	6	999x480	11	1961x407	16	1027x589
2	1274x571	7	1927x526	12	1277x493	17	1439x520
3	1286x616	8	1909x627	13	1270x522	18	1480x669
4	1845x708	9	1974x736	14	1258x596	19	1009x444
5	961x511	10	1895x601	15	1043x541	20	1175x573

Fonte: Autoria própria (2020).

**Figura 52 - Imagem do tubo, destacando o recorte realizado manualmente do cordão de solda. (a) Imagem 1. (b) Imagem 2. (c) Imagem 3. (d) Imagem 4. (e) Imagem 5. (f) Imagem 6. (g) Imagem 7. (h) Imagem 8. (i) Imagem 9. (j) Imagem 10. (k) Imagem 11. (l) Imagem 12. (m) Imagem 13. (n) Imagem 14. (o) Imagem 15. (p) Imagem 16. (q) Imagem 17. (r) Imagem 18. (s) Imagem 19. (t) Imagem 20.**




**Fonte: Autoria própria (2020).**


Nas imagens utilizadas, laudadas por especialistas, encontram-se as discontinuidades mais frequentes de defeitos em juntas soldadas: trincas (TR), falta de fusão (FF), falta de penetração (FP), mordedura (MR), inclusão de escória (IE) e porosidade (PO). A Figura 53(b)

mostra o laudo da imagem da Figura 53(a) processada manualmente pelo laudista para uma melhor identificação dos defeitos, onde se observa a presença dos defeitos: porosidade e inclusão de tungstênio. O pré-processamento realizado para os resultados mostrados nesta seção possui uma sequência de técnicas definidas por Boaretto (2017) cujos parâmetros foram ajustados experimentalmente para o presente trabalho, conforme descrito na Seção 4.1.1. Estas técnicas podem ser bastante diferentes daquelas utilizadas pelos laudistas uma vez que o processo do laudo é manual e específico dependendo de ferramentas e conhecimentos de cada laudista individualmente.

**Figura 53 - Imagens do cordão de solda. (a) Recorte da imagem original. (b) Laudo com processamento realizado manualmente pelo laudista, para uma melhor identificação dos defeitos, sobre a mesma imagem.**



(a)



(b)

**Fonte: Autoria própria (2020).**

Com o objetivo de se definir um conjunto balanceado para a classificação das discontinuidades, o banco foi separado entre 362 exemplos próprios (não defeitos) e 365 exemplos não próprios (defeitos), como pode ser visto na Tabela 2. Além da quantidade de amostras, a Tabela 2 apresenta o valor médio do tamanho e seu desvio padrão, sendo que os valores obtidos para o desvio padrão indicam que existe uma alta diversidade nos tamanhos das amostras. As Figuras 54 e 55 apresentam histogramas da distribuição do tamanho das


amostras, de defeito e não defeito, respectivamente, sendo os limites de tamanho definidos entre 15 e 6000 pixels.

**Tabela 2 – Banco de dados para duas classes: defeito e não defeito.**

DEFEITOS	AMOSTRAS	MÉDIA DO TAMANHO ±DP
Defeito	365	164,246 ± 399,798
Não defeito	362	57,577 ± 140,263
<b>TOTAL</b>	<b>727</b>	<b>109,355 ± 333,632</b>

Fonte: Autoria própria (2020).

**Figura 54 - Tamanhos dos defeitos e suas quantidades.**



Fonte: Autoria própria (2020).

**Figura 55 - Tamanhos dos não defeitos e suas quantidades.**



Fonte: Autoria própria (2020).

Tendo por base as descontinuidades detectadas no pré-processamento descrito na Seção 4.1, um banco de imagens foi obtido com 727 descontinuidades com um alto desbalanceamento entre os tipos de defeitos, como pode ser observado na Tabela 3.

**Tabela 3 – Banco de dados com o número de amostras para cada defeito.**

DEFEITOS	AMOSTRAS
Porosidade (PO)	302
Inclusão de escória (IE)	12
Falta de fusão (FF)	8
Trinca (TR)	42
Mordedura (MO)	1
<b>TOTAL</b>	<b>365</b>

**Fonte: Autoria própria (2020).**

## 5.2 PARÂMETROS - SIA PROFUNDO E SIA COM *AUTOENCODER*

Nos experimentos realizados no presente trabalho, são consideradas 13 características básicas para o SIA: geométricas e de textura (área, extensão, razão 1, razão 2, razão 3, arredondamento, excentricidade, solidez, diferença, contraste, desvio padrão, entropia e assimetria). Além disso, 100 características obtidas a partir da saída do segundo *autoencoder* no módulo de aprendizado profundo são adicionadas às 13 características (geometria e textura), totalizando 113 características em todo o vetor considerado no SIA profundo proposto, bem como no SIA com *autoencoder* proposto. A tabela 4 apresenta os parâmetros e valores utilizados tanto no SIA profundo, como no SIA com *autoencoder*.



Tabela 4 – Parâmetros e valores.

Parâmetros	Valores	Descrição Detalhada
$\gamma_s$	0,99	Valor de limiar de próprio utilizado na fase de sensoriamento.
$\gamma_d^0$	0,99	Limiar inicial de defeito usado na fase de monitoramento.
$\gamma_d^c$	{0,99; 0,98; 0,97; 0,96; 0,95; 0,90; 0,85; 0,80; 0,75; 0,70; 0,60; 0,50}	Valores de limiares variáveis de defeitos testados na fase da seleção clonal.
<b>C</b>	4	Total de ciclos da evolução.
<b>G</b>	25	Geração máxima por ciclo.
MaxGeração	C*G	4*25 = 100.
[-M, M]	{-3, -2, ..., 2, 3}	Intervalo de valores do OM.
EE	4	Total de tipos do EE.

Fonte: Autoria própria (2020).

O tamanho da população de anticorpos  $|P_{Ab}|$  é um parâmetro definido automaticamente em função do total de discontinuidades apontadas na etapa de pré-processamento e classificações realizadas antes da etapa de seleção clonal:

$$|P_{Ab}| = |\Delta| - |self| - |Nself^0| - |backup| \quad (35)$$

onde:

$\Delta$  = conjunto das discontinuidades identificadas na etapa de pré-processamento;

$self$  = conjunto de células eliminadas na etapa de seleção negativa;

$Nself^0$  = conjunto de células eliminadas no primeiro processo de *matching* com não defeitos;

$backup$  = conjunto de células pequenas deixadas para uma avaliação posterior.

Nos experimentos, assume-se que o valor de afinidade do anticorpo  $Ab_i$  com o antígeno  $Af$  esteja dentro do intervalo [0, 1] usando a distância euclidiana (d). O número de clones (K) gerados a partir de cada anticorpo é proporcional ao valor de afinidade  $Afi$ ,

$$K = 10 * d. \quad (36)$$

Em relação à taxa de hipermutação, os genes detectores de anticorpos sofrem uma única alteração no gene atual se ( $A_{fi} \geq 0,5$ ) e duas alterações se ( $A_{fi} < 0,5$ ).

### 5.3 ABORDAGENS DE COMPARAÇÃO

O sistema SIA profundo consiste em dois módulos: SIA e aprendizado profundo. Portanto, para enfatizar a necessidade de abordagem híbrida proposta, o sistema SIA puro e o sistema de aprendizado profundo puro são considerados como abordagens de comparação, bem como o sistema SIA com *autoencoder*.

O sistema SIA puro considera apenas o módulo SIA (Figura 43) para classificar as descontinuidades. O sistema de aprendizado profundo puro (Figura 50) considera, na primeira abordagem, apenas o modelo AlexNet para classificar as descontinuidades detectadas na fase de pré-processamento.

Conforme explicado na Seção 2.4.2, a rede AlexNet é um modelo de aprendizado profundo de 25 camadas usado para classificar 1000 classes (categorias). No entanto, é possível classificar outro grupo de imagens com um número diferente de classes (categorias), a partir de aprendizado por transferência. Para esse fim, as três últimas camadas são ajustadas para o novo problema de classificação. A CNN pré-treinada é adaptada ao nosso conjunto de dados usando uma técnica de ajuste fino na qual os pesos da parte convolucional da CNN pré-treinada são congelados e apenas as três últimas camadas da AlexNet são treinadas. Essas camadas são treinadas com imagens de entrada do tamanho  $227 \times 227 \times 3$  (ver a Figura 49 para obter mais detalhes) usando o algoritmo de descida do gradiente estocástico (*Stochastic Gradient Descent - SGD*) e a função de ativação sigmóide (WIGGERS *et al.*, 2018).

O sistema SIA com *autoencoder* realiza a classificação das descontinuidades considerando-se o módulo SIA puro em conjunto com o *autoencoder*.

Finalizando, utilizando-se o *software* MatLab R2018a, modela-se o SVM (*Support Vector Machine*) para realizar a classificação das descontinuidades, com os mesmos dados utilizados para o sistema SIA e para o modelo AlexNet.

#### 5.4 CONSIDERAÇÕES FINAIS

Experimentos foram realizados com as imagens nas abordagens propostas e os parâmetros foram definidos experimentalmente. Os resultados são apresentados e discutidos no próximo capítulo.


## 6 RESULTADOS E DISCUSSÕES

Este capítulo inicia com os resultados obtidos na etapa de pré-processamento para a detecção das discontinuidades e na sequência apresenta os resultados obtidos pela abordagem proposta SIA profundo para a classificação de discontinuidades em defeitos e não defeitos. Além disso, a proposta é comparada com versões independentes do SIA e de aprendizagem profunda, bem como é realizada a comparação com uma abordagem tradicional em aprendizado de máquina, o SVM (*Support Vector Machine*).

### 6.1 DETECÇÃO DAS DESCONTINUIDADES

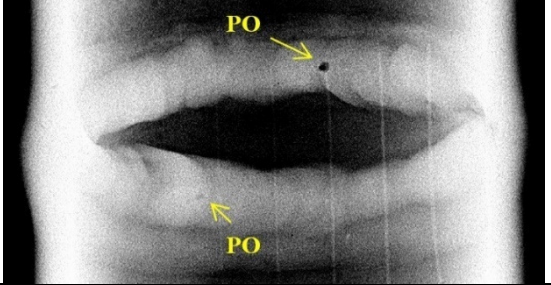
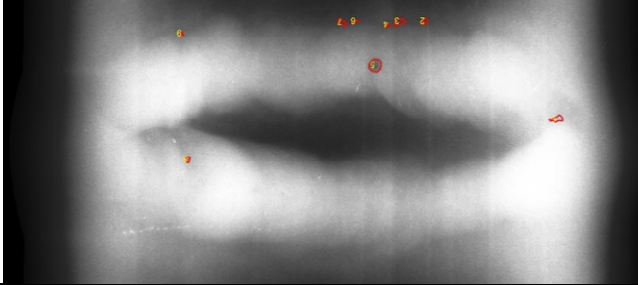
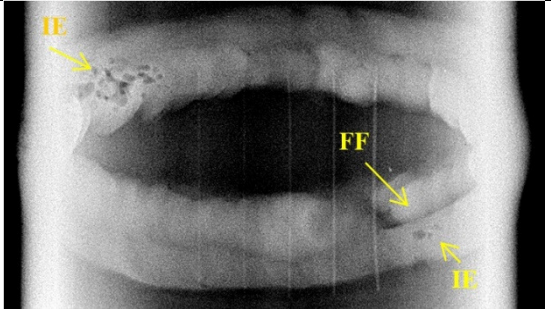
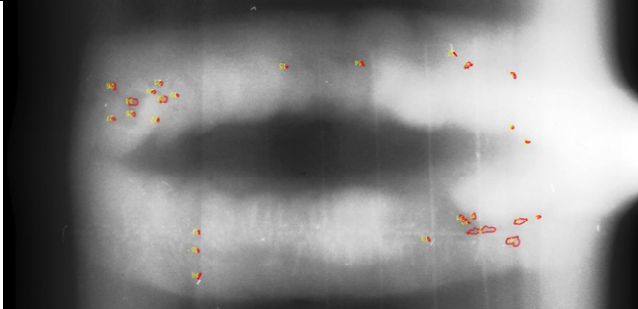
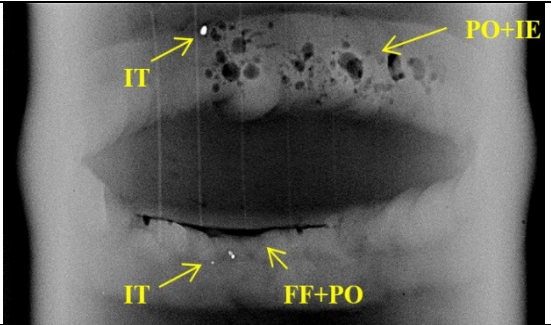
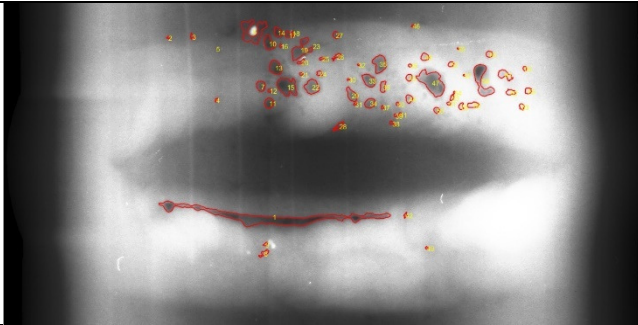
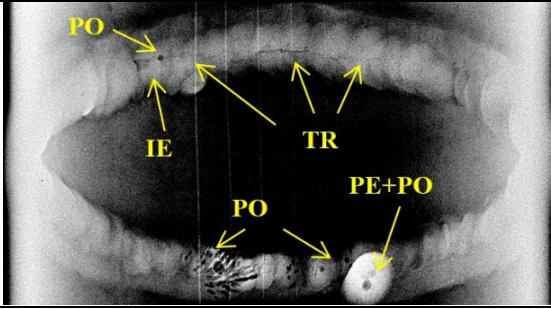
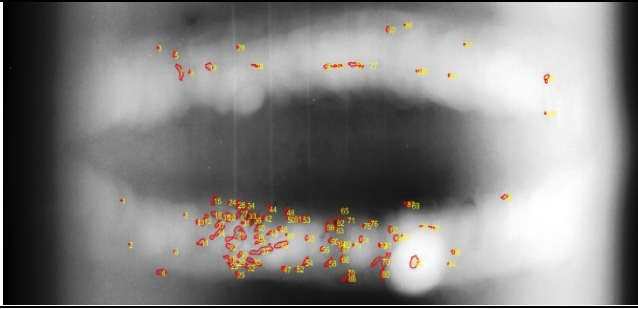
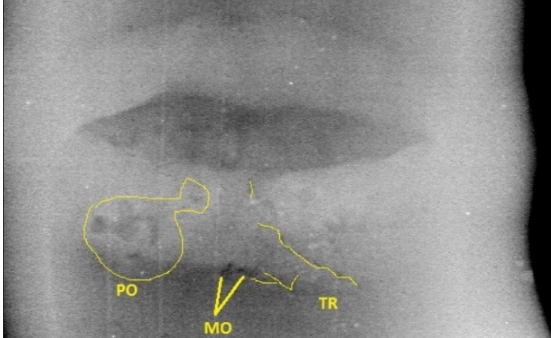
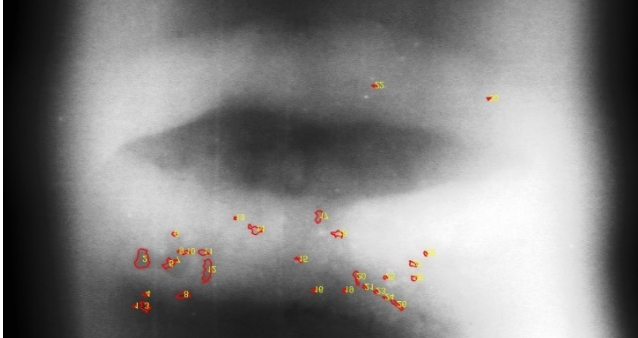
Um primeiro procedimento é realizado na fase de pré-processamento: detectar as discontinuidades nas imagens de recorte do cordão de solda. É importante ressaltar que embora esta fase de pré-processamento adotada no presente trabalho utilize a mesma metodologia desenvolvida em Boaretto (2017), houve a necessidade de ajuste dos parâmetros uma vez que os dados considerados foram diferentes (impossibilitando inclusive uma comparação entre resultados). A Figura 56 apresenta os resultados do pré-processamento para uma das imagens, nas quais as discontinuidades detectadas são destacadas, enquanto a Figura 57 apresenta o resultado para cada uma das imagens utilizadas no trabalho, nas quais as discontinuidades detectadas (potenciais defeitos) estão realçadas, onde a primeira coluna mostra as imagens laudadas e a segunda coluna, as imagens obtidas após a etapa de detecção das discontinuidades.

**Figura 56 – Detecção de discontinuidades a serem usadas por todas as abordagens.**




**Fonte: Autoria própria (2020).**

**Figura 57 – Detecção das discontinuidades de todas as imagens a serem utilizadas em todas as abordagens.**

Laudos fornecidos das imagens	Imagens obtidas com algoritmo proposto
<b>09 discontinuidades localizadas</b>	
	
<b>27 discontinuidades localizadas</b>	
	
<b>65 discontinuidades localizadas</b>	
	
<b>100 discontinuidades localizadas</b>	
	
<b>30 discontinuidades localizadas</b>	
	

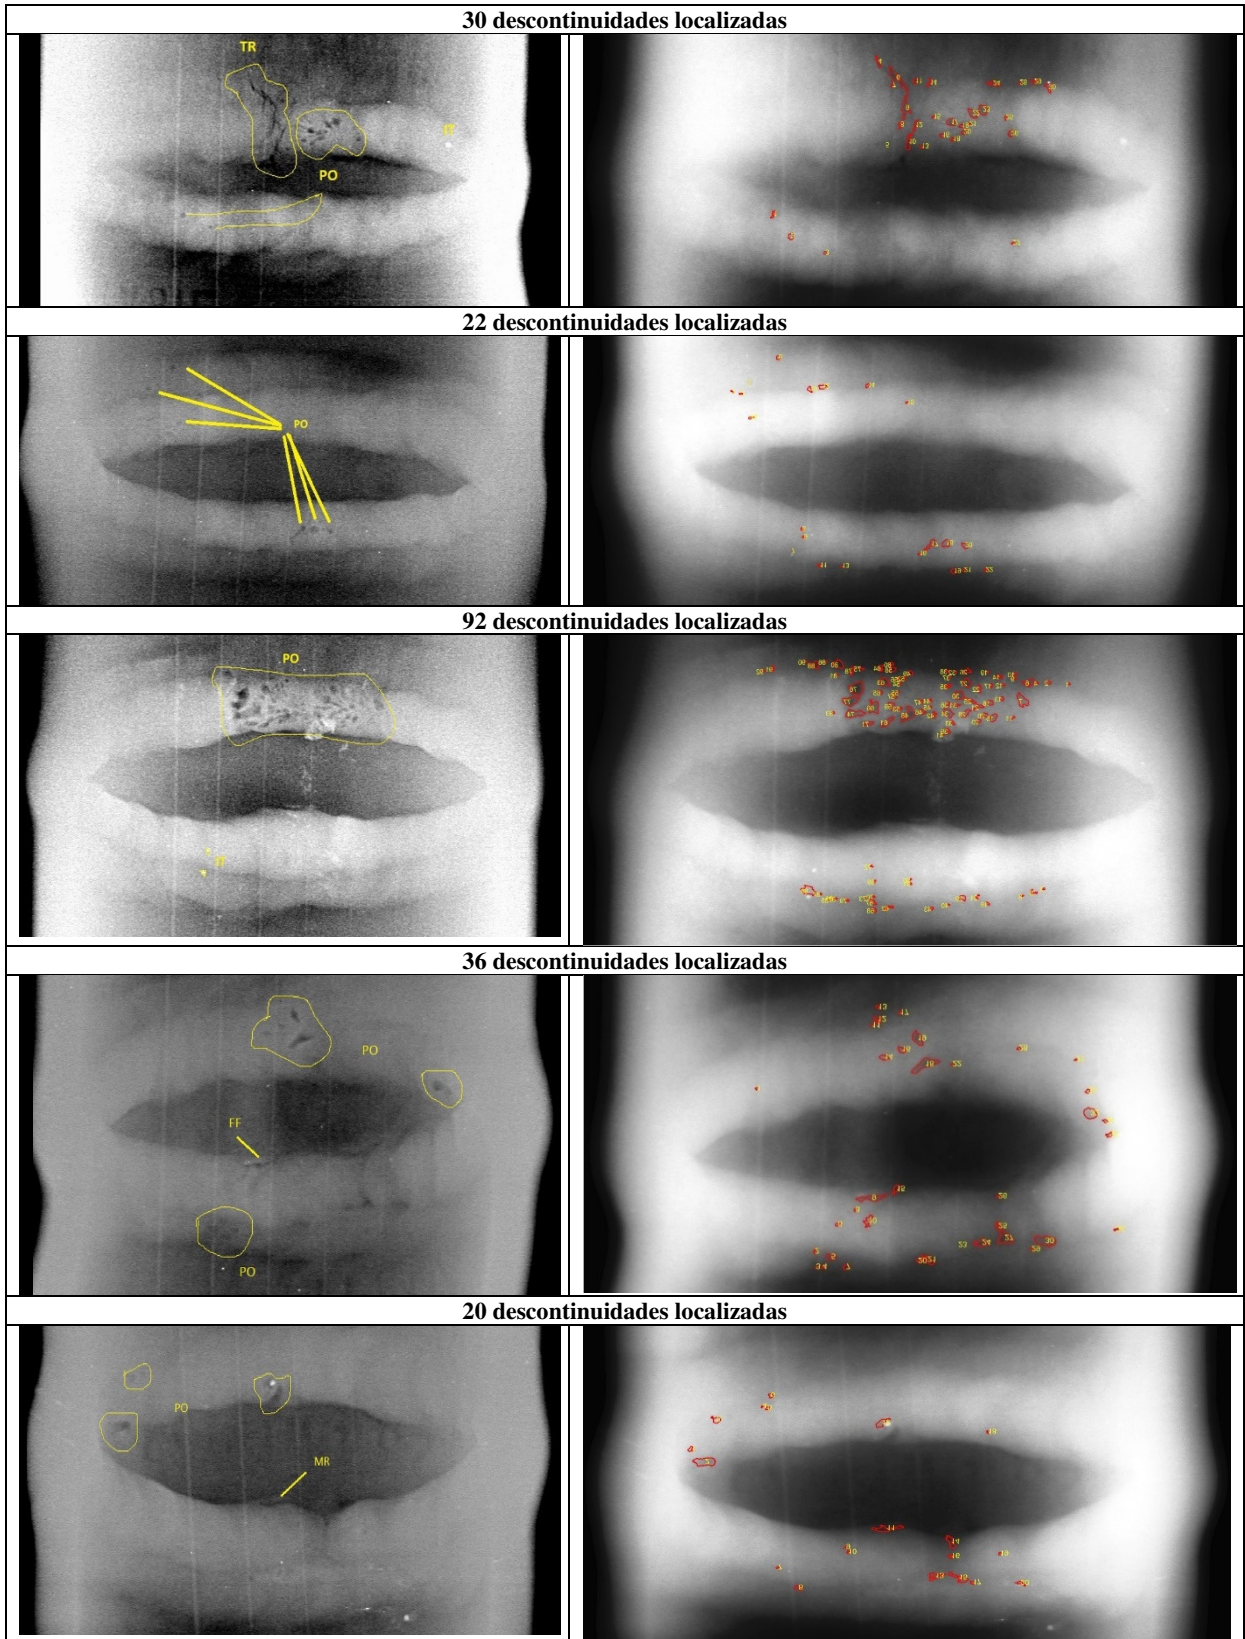
Fonte: Autoria própria (2020).

**Figura 57 (continuação) – Detecção das discontinuidades de todas as imagens a serem utilizadas em todas as abordagens.**



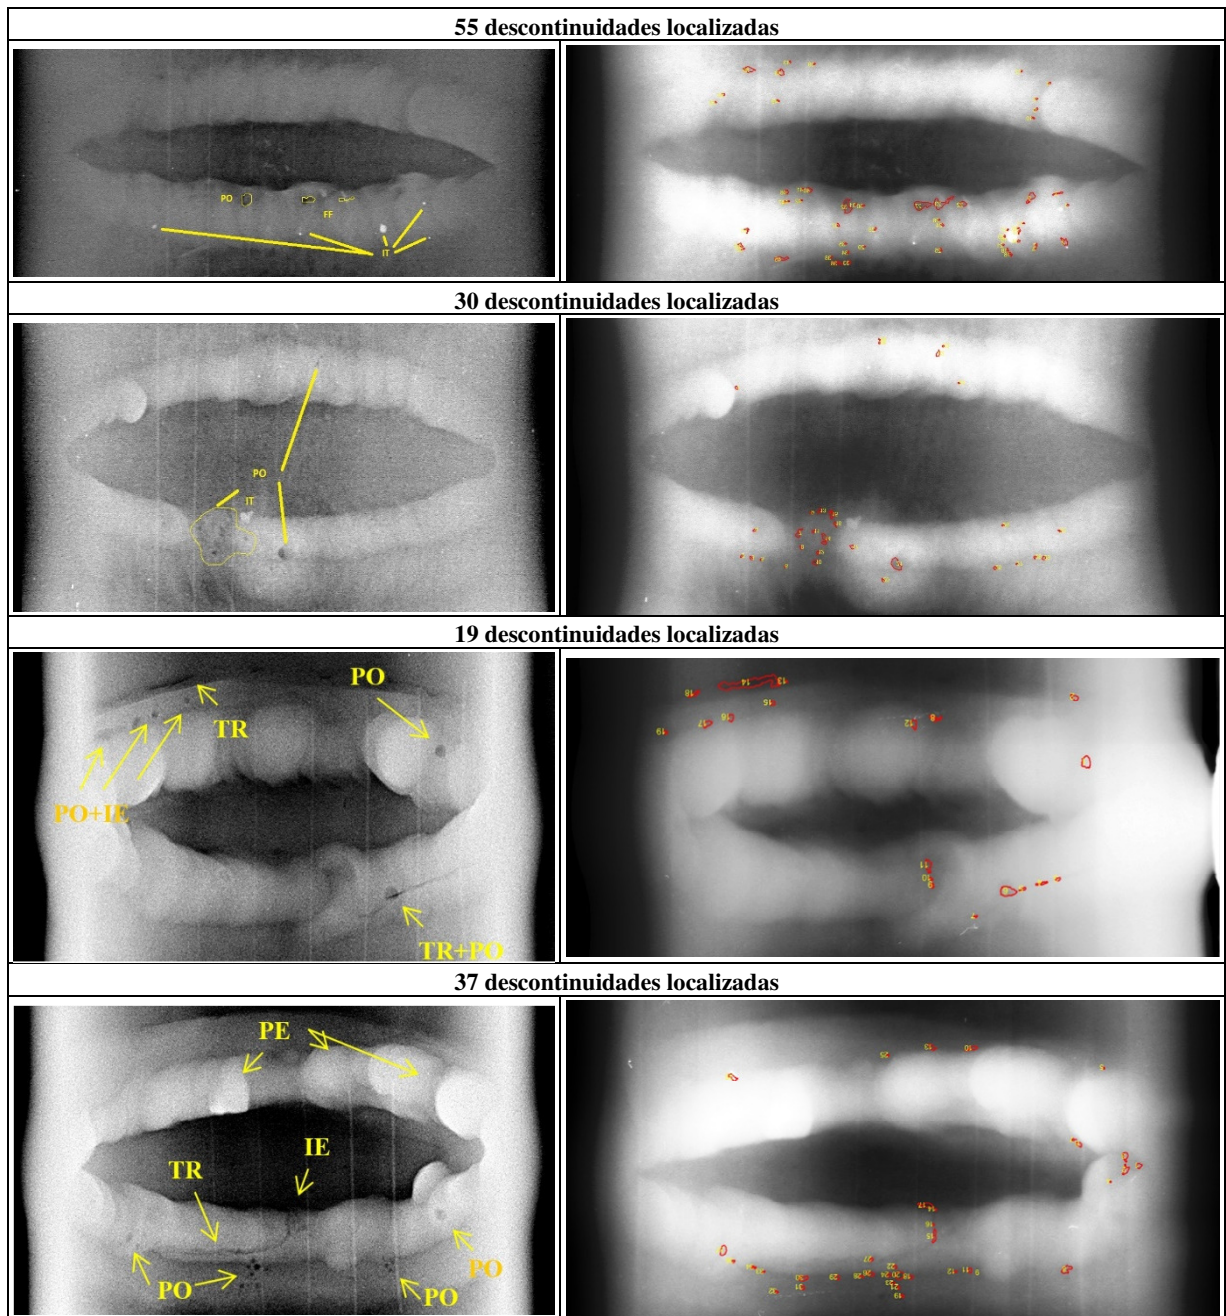
Fonte: Autoria própria (2020).

**Figura 57 (continuação) – Detecção das discontinuidades de todas as imagens a serem utilizadas em todas as abordagens.**



Fonte: Autoria própria (2020).

**Figura 57 (continuação) – Detecção das discontinuidades de todas as imagens a serem utilizadas em todas as abordagens.**



Fonte: Autoria própria (2020).

Com todas as discontinuidades detectadas, todo o conjunto de dados é dividido em três conjuntos: treinamento (50%), validação (25%) e teste (25%). Esse método de divisão dos dados, o *holdout* (sem repetição) é utilizado em função do tempo para o processamento das imagens e da metodologia adotada que considera cada imagem como um bloco único de discontinuidades a serem classificadas. A fase de treinamento da abordagem proposta abrange a definição dos dados próprios e não próprios no módulo SIA, bem como o treinamento dos modelos de aprendizagem profunda. O conjunto de validação é usado para



ajustar alguns parâmetros de cada modelo quando submetido a um teste controlado. Por fim, o conjunto de testes é usado para avaliar efetivamente as abordagens ao classificar discontinuidades de defeito ou não, com os parâmetros fixados com os valores definidos na fase de validação.


## 6.2 FASE DE VALIDAÇÃO

### 6.2.1 Ajuste de Parâmetros – SIA Puro, SIA Profundo e SIA com *autoencoder*

Apesar de muitos parâmetros presentes na abordagem SIA profundo terem sido definidos empiricamente (especialmente aqueles referentes aos modelos profundos), esta seção tem como objetivo investigar os valores de  $\gamma_d^c$  usados em cada ciclo do módulo SIA, uma vez que foi observado que houve uma alta sensibilidade deste módulo a este parâmetro (Figuras 58 e 59). Algumas conclusões podem ser obtidas a partir da análise das Figuras 58 e 59, sendo: a) observando-se cada bloco de barras individualmente, representando cada um os quatro ciclos do processo evolutivo com limiar fixo ao longo de todo o processo, verifica-se que para valores altos (limiar  $\geq 0,95$ ) não há grande ganho/perda de desempenho no processo evolutivo como um todo (desde o primeiro ciclo até o último os valores de desempenho estão muito próximos), enquanto que para valores de limiar médios e baixos (limiar  $< 0,95$ ). Há algum ganho/perda nas primeiras iterações, mas não muito, depois disso (essas observações valem tanto para precisão quanto para sensibilidade); b) observando-se o comportamento dos gráficos à medida que os limiares fixos, ao longo de todo o processo, se aproximam do valor mínimo possível 0,50, observa-se que, conforme esperado, a sensibilidade aumenta e a precisão diminui; c) observando-se conjuntamente o desempenho de precisão e sensibilidade (Figura 59), é possível observar que mesmo para valores fixos de limiar entre 0,90 e 0,85 não seria possível obter uma combinação de valores com desempenho conjunto acima de 70%, isso pode ser observado na Figura 60 que mostra que usando-se um limiar fixo os maiores valores de F-score obtidos (com limiar fixado em 0,5) foram menores que 60%.


Essas conclusões indicaram que um limiar dinâmico ao longo do processo evolutivo permitiria incrementar a precisão para ciclos iniciais (quando os valores estariam altos) e incrementar a sensibilidade para ciclos finais de forma a não comprometer o desempenho do sistema proposto em comparação com aquele usando um limiar fixo ao longo de todo o processo. Dessa forma o processo evolutivo foi dividido em fases (definição do próprio e não-próprio e na sequência o processo evolutivo definido em 4 ciclos, cada um contendo um valor de limiar diferente).

**Figura 58 – Valores da sensibilidade para cada valor de  $\gamma_a^c$ .**



Fonte: Autoria própria (2020).

**Figura 59 – Precisão versus Sensibilidade para cada valor de  $\gamma_a^c$ .**



Fonte: Autoria própria (2020).

É preciso ter em mente que, após a fase de pré-processamento nos dados de treinamento para a formação dos bancos e pré-processamento nos dados de validação e teste, as discontinuidades identificadas nestes últimos conjuntos são avaliadas pelo ASN, com o objetivo de separar, dentre todas as discontinuidades, aquelas que são claramente não defeitos. A afinidade entre os vetores de características de cada célula T e o banco de células próprias é calculada e comparada com  $\gamma_s$  (definido como 0,99 de acordo com a Tabela 4). Ao definir um valor alto, apenas as discontinuidades fortemente caracterizadas como não defeitos são classificadas como próprias, identificadas na imagem original e eliminadas do processo. Portanto, apenas possíveis defeitos permanecem para análise futura.

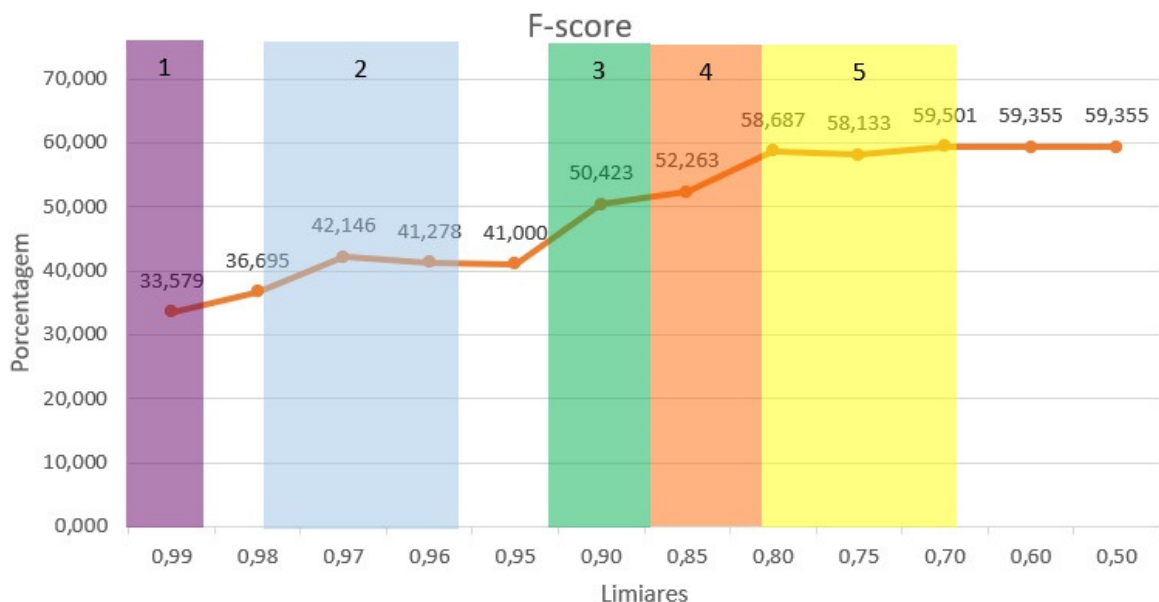
Posteriormente, as células que representam possíveis defeitos são comparadas com células não próprias. Nesse processo de reconhecimento, a correspondência entre vetores de características é calculada e comparada com um limiar de defeito inicial ( $\gamma_d^0$ ) definido na primeira etapa da fase de monitoramento. É importante enfatizar que o objetivo principal deste trabalho é propor um método para detectar defeitos, verificando a eficácia dos sistemas imunológicos artificiais na evolução do repertório de anticorpos, em vez de classificar todas as discontinuidades no início do processo. Para isso, no *matching* com os não próprios, o limite é inicialmente definido com um valor alto ( $\gamma_d^0 = 0,99$ ). Na classificação não própria, as células classificadas como defeito (afinidade com antígenos  $> \gamma_d^0$ ) têm suas discontinuidades marcadas na imagem original e deixam o processo. As células restantes sofrem seleção clonal.

Em cada geração do ASC, a afinidade entre *Ab* e *Ag* é comparada com um limite dinâmico  $\gamma_d^c$ . Diferentes valores foram testados para a atualização do valor de  $\gamma_d^c$ : 0,99, 0,98, 0,97, 0,96, 0,95, 0,90, 0,85, 0,80, 0,75, 0,70, 0,60 e 0,50.

Com o objetivo de definir como a evolução ocorre considerando valores diferentes para o limiar estático ( $\gamma_d$ ), cada valor foi testado configurando-o e executando o SIA com esse valor fixo do início até o final (ou seja, de 1 a  $C \cdot G$  gerações) conforme mostra o Algoritmo 1, na Figura 48. A Figura 60 mostra o desempenho (*F-score* no eixo *y*) alcançado para cada valor testado de  $\gamma_d$  (eixo *x*). Observa-se que: a) há espaço para melhorias no desempenho, diminuindo os valores limite; b) existem cinco níveis diferentes de desempenho: um com  $\gamma_d$  alto (nível 1 em roxo e próximo ao valor  $\gamma_d^0$ ) e quatro outros (nível 2 em azul, nível 3 em verde, nível 4 em laranja e nível 5 em amarelo). Os níveis roxo, azul, verde, laranja e amarelo, representam regiões com alguma mudança de desempenho termos de *F-score*: (i) região marcada em **roxo** identifica um **desempenho muito baixo** por conta do rigor em termos de precisão imposto pelo alto valor do limiar (0,99); (ii) região marcada em **azul**

(envolvendo os limiares [0,98, 0,96]) identifica um **desempenho baixo** ( $F$ -score em torno de 40%), (iii) região marcada em **verde** (envolvendo o limiar 0,9) identifica um **desempenho médio baixo** ( $F$ -score em torno de 50%), (iv) região marcada em **laranja** (envolvendo o limiar 0,85) identifica um **desempenho médio** ( $F$ -score levemente acima de 50%), (iii) região marcada em **amarelo** (envolvendo os limiares [0,80, 0,70]) identifica um **desempenho médio alto** ( $F$ -score em torno de 60%). Assim, decidiu-se dividir todo o processo evolutivo em uma fase inicial (com alto nível de exigência imposto pelo limiar alto) e quatro ciclos (cada um rodando por gerações  $G$  com um valor diferente de  $\gamma_d$ ) nos quais a exigência vai sendo relaxada na tentativa de se diminuir os falsos negativos. Durante a fase de ajuste, diferentes combinações de valores foram testadas para atualizar o parâmetro  $\gamma_d^c$ . A conclusão foi que os valores  $\gamma_d^0 = 0,99$  e  $\gamma_d^c = \{0,97$  (para  $c = 1$ ),  $0,90$  (para  $c = 2$ ),  $0,85$  (para  $c = 3$ ) e  $0,75$  (para  $c = 4\}$  alcançam uma boa harmonização entre precisão e sensibilidade medida pela métrica  $F$ -score. Portanto, esses valores foram escolhidos para serem utilizados nas versões padrão das abordagens SIA puro, SIA profundo e SIA com *autoencoder* consideradas nas seções seguintes.

**Figura 60** –  $F$ -score para cada valor de limiar único corrigido ao longo de todas as gerações  $G$ .



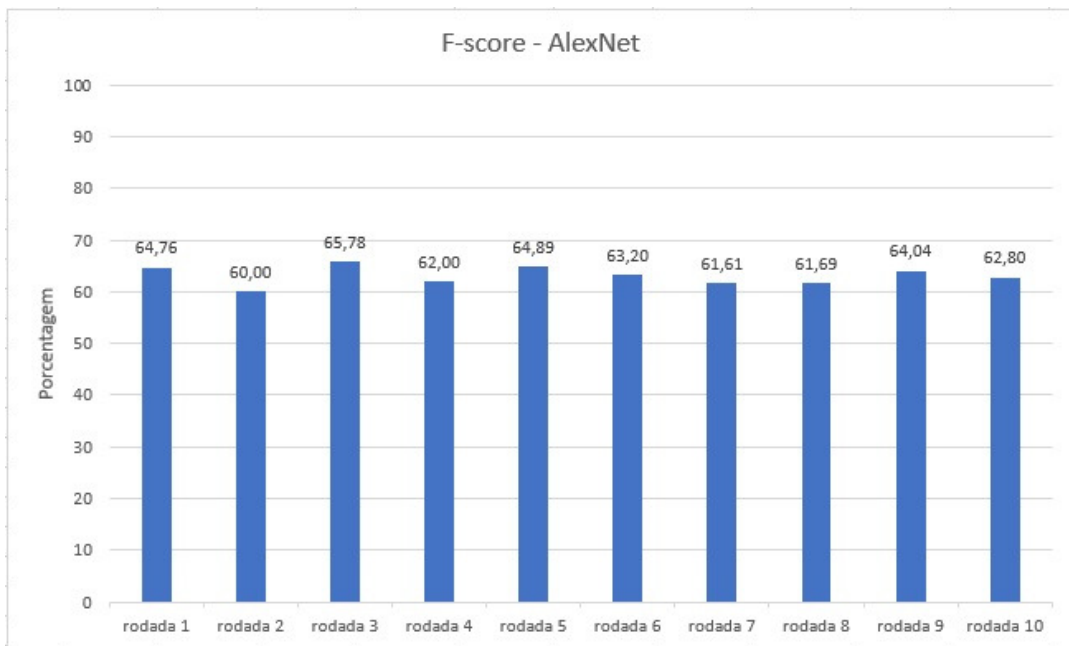
Fonte: Autoria própria (2020).

### 6.2.2 Ajuste de Parâmetros – AlexNet

O modelo CNN AlexNet é usado para classificar defeitos ou não defeitos de descontinuidades em imagens de cordões de solda, mostrado na seção 4.3.2. Dez rodadas são

realizadas com diferentes pesos iniciais determinados aleatoriamente. A Figura 61 ilustra os valores obtidos durante o treinamento. O melhor modelo foi escolhido como a versão padrão do modelo de aprendizagem profunda puro.

**Figura 61 – F-score de treinamento de cada rodada obtida pela AlexNet.**



**Fonte: Autoria própria (2020).**

## 6.3 COMPARAÇÃO DE DESEMPENHO


### 6.3.1 Modelos: SIA puro, SIA com *autoencoder*, SIA profundo e AlexNet

Nesta seção, as discontinuidades na imagem de saída são codificadas por cores: as discontinuidades classificadas como defeitos são mostradas em vermelho e as discontinuidades classificadas como não defeitos são mostradas em amarelo. Com o objetivo de avaliar visualmente o desempenho da classificação das diferentes abordagens de comparação (processo que considera como exemplos positivos (defeitos) as discontinuidades classificadas como tal pelos laudistas e exemplos negativos (não defeitos) todas as outras discontinuidades), a imagem do laudo foi inserida no canto inferior esquerdo de cada abordagem de comparação.

Um exemplo da imagem de saída do classificador SIA puro de duas classes (defeito e não defeito) pode ser visto na Figura 62 (à direita). Para esta imagem, das 19 discontinuidades pré-processadas, sete discontinuidades são classificadas incorretamente,

cinco são classificadas como defeitos (falsos positivos) e dois defeitos são classificados como não defeitos (falsos negativos), de acordo com a imagem laudada.

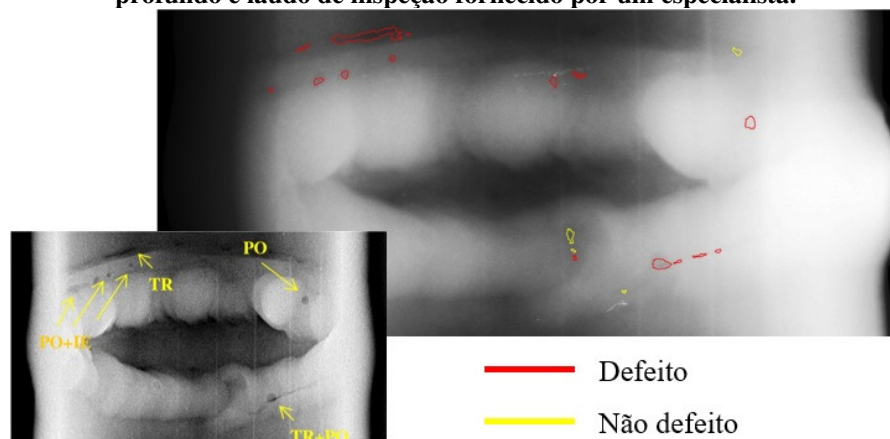
**Figura 62 – Imagem após a classificação das descontinuidades. Imagem obtida do classificador SIA puro e laudo de inspeção fornecido por um especialista.**



Fonte: Autoria própria (2020).

Um exemplo da imagem de saída do classificador SIA profundo de duas classes (defeito e não defeito) pode ser visto na Figura 63 (à direita). Para esta imagem, das 19 descontinuidades pré-processadas da imagem, cinco descontinuidades não são classificadas corretamente: quatro falsos positivos e um falso negativo, como pode ser observado na imagem laudada. O falso negativo está na trinca inferior, composta de várias descontinuidades. A marcação em amarelo faz parte da trinca e deveria estar em vermelho.

**Figura 63 – Imagem após a classificação das descontinuidades. Imagem obtida pelo classificador SIA profundo e laudo de inspeção fornecido por um especialista.**




Fonte: Autoria própria (2020).

Um exemplo de uma imagem de saída AlexNet para ambas as classes (defeito e não defeito) pode ser visto na Figura 64. Para esta imagem, das 19 descontinuidades pré-processadas, seis descontinuidades não são classificadas corretamente - dois falsos positivos e

quatro falsos negativos - como pode ser observado com a imagem laudada. Apesar da diferença apenas no erro, a AlexNet forneceu quatro falsos negativos, o que pode ser mais perigoso que os falsos positivos.


**Figura 64 – Imagem após a classificação das discontinuidades. Imagem obtida pelo classificador AlexNet e laudo de inspeção fornecido por um especialista.**



Fonte: Autoria própria (2020).

Um exemplo da imagem de saída do classificador SIA com *autoencoder* de duas classes (defeito e não defeito) pode ser visto na Figura 65 (à direita). Para esta imagem, das 19 discontinuidades pré-processadas da imagem, oito discontinuidades não são classificadas corretamente: quatro falsos positivos e quatro falsos negativos, como pode ser observado na imagem laudada.

**Figura 65 – Imagem após a classificação das discontinuidades. Imagem obtida pelo classificador SIA com *autoencoder* e laudo de inspeção fornecido por um especialista.**




Fonte: Autoria própria (2020).

Analisando os critérios de valores *F-score* obtidos para cada um dos quatro métodos (Figura 66), considerando-se todas as imagens do teste, observa-se que o SIA com

*autoencoder* teve o pior desempenho, com um *F-score* de 55,497%, seguido pelo SVM, com um *F-score* de 59,43% e pelo AlexNet, com um *F-score* de 64,86%, enquanto a abordagem SIA profundo obteve o melhor desempenho, com um *F-score* de 70,732%, obtendo um ganho de 4,335% sobre o SIA puro, cujo índice de pontuação é 66,376%.

**Figura 66 – Melhor *F-score* obtida por cada método.**



**Fonte: Autoria própria (2020).**

Uma hipótese para o fraco desempenho do AlexNet pode ser o pequeno conjunto de treinamento disponível. Como a CNN deve funcionar bem em grandes conjuntos de treinamento, pode-se concluir que, para esta aplicação, a CNN pode não ser adequada para executar toda a tarefa de classificação mesmo com o uso de aprendizado por transferência. Neste trabalho esse teste foi feito considerando-se a AlexNet funcionando isoladamente. Para isso, a própria rede AlexNet pré-treinada com o conjunto de dados *ImageNet* foi adaptada para que a camada totalmente conectada pudesse mapear as 1000 saídas da base *ImageNet* para as 2 classes consideradas (defeito x não defeito).

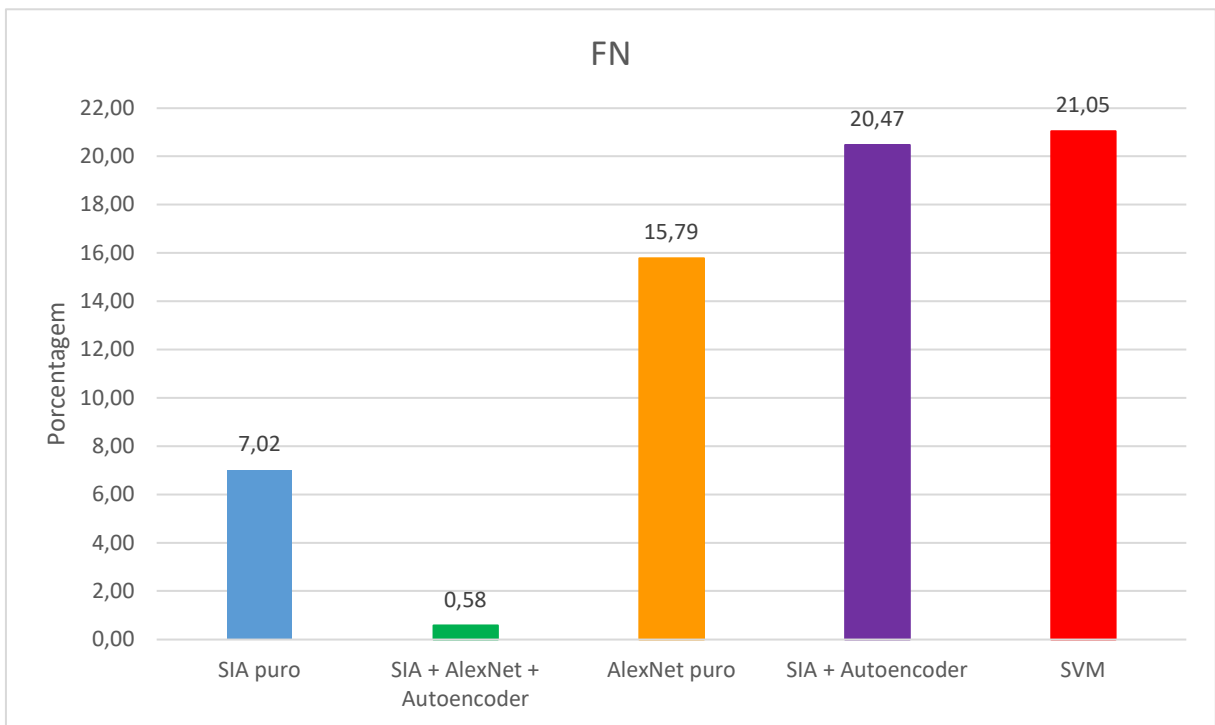
Já para o fraco desempenho do SIA com *autoencoder*, pode-se concluir que as características obtidas pelo *autoencoder* diretamente não ajudaram a executar a tarefa de classificação. Com este resultado, percebe-se que ao hibridizar sistemas, com a finalidade de aumentar as características, deve-se levar em conta a qualidade das imagens, pois nem todos os métodos conseguem obter um bom desempenho com imagens reais de campo, ou seja, com



baixa qualidade. Em alguns casos, um método específico como aquele proposto na etapa de pré-processamento é fundamental para garantir um mínimo de desempenho.

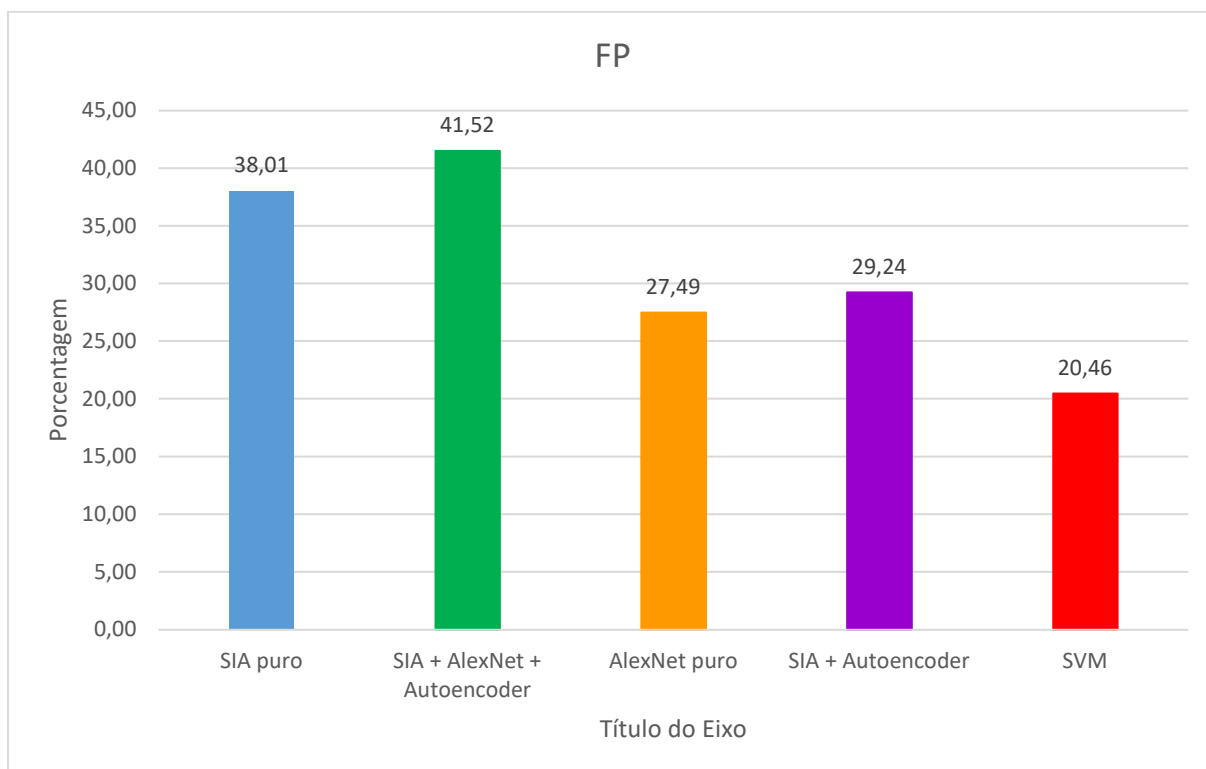
Além do melhor *F-score*, o classificador proposto SIA com AlexNet e *autoencoder* obteve - na fase de teste - a menor taxa de falso negativo (FN) quando comparado a outras abordagens apresentadas na pesquisa atual, como pode ser observado na Figura 67. No presente caso, o valor FN mais baixo indica que existem poucas amostras classificadas incorretamente como não pertencentes à classe de defeitos. Ao mesmo tempo que o classificador proposto obteve - na fase de teste - a maior taxa de falso positivo (FP) quando comparada a outras abordagens apresentadas na pesquisa atual, como pode ser observado na Figura 68. Neste caso, o valor FP alto indica que existem muitas amostras classificadas incorretamente como pertencentes à classe de não defeitos.

**Figura 67 – Melhor FN obtido por cada método.**



**Fonte: Autoria própria (2020).**

**Figura 68 – Melhor FP obtido por cada método.**



**Fonte: Autoria própria (2020).**

Assim, comparando-se os resultados de F-score mostrados na Figura 66 das abordagens SIA puro e SIA profundo (as quais possuem limiar dinâmico – ou seja limiar de defeito que diminui ao longo do processo evolutivo) com aqueles obtidos na Figura 60 cujo módulo SIA possui limiar estático (cujos valores fixos foram avaliados para o range [0,99, 0,50]), conclui-se que o limiar dinâmico permite ao SIA tirar proveito das altas taxas de precisão que ocorrem no início da busca e das altas taxas de sensibilidade que ocorrem ao final.

Apesar do sistema não ter sido executado considerando-se ASN e ASC rodando isoladamente (ao invés de cooperativamente como no sistema proposto) há algumas considerações para justificar o uso de ambos. Primeiro porque a seleção e eliminação das células próprias realizada pelo ASN logo no início permite que a população de anticorpos possa contemplar mais células com potencial de defeito. Caso não fossem liberadas pelo ASN estas células com baixo potencial de defeito ficariam participando do processo evolutivo até o final por não conseguirem *matching* com o banco de defeitos impedindo por exemplo que algumas ou todas as células do *backup* pudessem ser incorporadas em algum momento da evolução. No outro sentido, ou seja, executar o sistema proposto considerando apenas o ASN não permitira categorizar como defeitos todas as células que não fossem eliminadas pelo

ASN. Isso porque conforme mostram os resultados da validação (cálculo do limiar dinâmico) o processo evolutivo dos anticorpos com redução gradativa de limiar é fundamental para o bom desempenho do sistema (visto que o sistema rodando apenas com limiar fixo apresentou resultados piores do que aqueles com limiar dinâmico).

### 6.3.2 SVM

Nesta seção, as descontinuidades são classificadas com a utilização do SVM, onde os parâmetros principais são apresentados na Tabela 5, tendo como entrada os mesmos vetores obtidos pelas abordagens desenvolvidas para este estudo. A Tabela 6 apresenta um comparativo entre os valores obtidos pelas abordagens desenvolvidas e pelo SVM.

**Tabela 5 – Parâmetros do SVM**

Nome dos Parâmetros	Parâmetros utilizados
<i>ClassNames</i>	[defeito, não_defeito]
<i>Bias</i>	7,1818
<i>Kernel (função)</i>	linear
<i>Kernel (escala)</i>	1

Fonte: Autoria própria (2020).

**Tabela 6 – Indicadores de desempenho dos Classificadores**

Classificadores	<i>F-score</i> (%)	FN (%)	FP (%)
SIA puro	66,376	7,02	38,01
SVM_características SIA puro	42,62	36,26	4,67
SIA profundo	70,732	0,58	41,52
SVM_características SIA profundo	50	32,16	6,43
ALEXNET	64,86	15,79	27,49
SVM_características ALEXNET	59,43	21,05	20,46
SIA com <i>autoencoder</i>	55,497	20,47	29,24
SVM_características SIA com <i>autoencoder</i>	42,86	35,67	6,43

Fonte: Autoria própria (2020).

Na Tabela 6 verifica-se que os resultados de *F-score* obtidos pelo SVM, ao se comparar com as mesmas características de entrada, obtiveram um valor menor que as obtidas pelas abordagens desenvolvidas, sendo o melhor modelo de SVM o que utiliza as características obtidas pelo modelo AlexNet (verde). E seguindo a mesma linha de

comparação, nos valores do FN observa-se que os resultados dos falsos negativos foram bem elevados, contribuindo para o fraco desempenho do SVM.

Em função dos valores apresentados na Tabela 6, conclui-se que para estas imagens radiográficas PDVD obtidas em condições reais, as abordagens desenvolvidas para a classificação das descontinuidades conseguem um melhor desempenho por ter um melhor controle de análise ou seja um controle realizado em diferentes etapas do processo (seleção negativa e evolução dos extratores de características realizada no processo de seleção clonal com a utilização de um limiar dinâmico que permite reduzir a incidência de falsos negativos sem piorar a precisão do modelo).

Sobre o tempo de execução dos métodos apresentados, apesar dos que envolvem o módulo SIA terem tempo de treinamento inferior (uma vez que essa tarefa envolve apenas a definição dos dados de treinamento – banco de próprios e não próprios), estes apresentam um desempenho por resposta mais demorada devido ao processo evolutivo que ocorre no teste. Assim, considerando-se que a análise é realizada por imagem e cada uma delas mesma possui quantidades diferentes de descontinuidades, a opção pelo modelo precisa ponderar as prioridades em termos de desempenho na fase de teste (que beneficia os modelos baseados em SIA) ou de tempo de processamento (outros modelos).

#### 6.4 CONSIDERAÇÕES FINAIS

A partir dos resultados, pode-se concluir que com as abordagens propostas, foi possível identificar automaticamente as descontinuidades e classificá-las em defeitos e não defeitos, destacando o resultado na imagem. E dentre todos as abordagens, a que apresentou melhor desempenho combina SIA e aprendizagem profunda. Utilizou-se também o SVM, muito utilizado para a tarefa de classificação, com as mesmas entradas obtidas pelas abordagens desenvolvidas, mas este apresentou resultados pouco competitivos. As conclusões gerais são apresentados no próximo capítulo.

## 7 CONCLUSÃO

Muitos estudos foram realizados para projetar e desenvolver sistemas de inspeção automáticos ou semi-automáticos, com o objetivo de auxiliar na interpretação de imagens radiográficas de solda e, assim, melhorar a robustez, precisão e agilidade no processo de inspeção. Mesmo com um grande número de publicações de pesquisa nessa área, existem poucos estudos relacionados à inspeção automática de imagens radiográficas PDVD, principalmente com condições do mundo real na aquisição de imagens e muito menos na detecção de defeitos.

A principal ideia por trás da abordagem proposta neste trabalho é a tentativa de reproduzir a maneira como um ser humano inspeciona imagens radiográficas (primeiro identificando as regiões de atenção que são claramente defeitos e não defeitos para depois analisar mais detalhadamente aquelas que deixam dúvidas, para isso utiliza diferentes técnicas (inclusive lentes que podem deformar as imagens através da alteração de vizinhanças) e para não incorrer em falsos negativos pode em alguns momentos baixar o nível de exigência para que uma descontinuidade possa ser classificada como defeito) e também buscar inspiração no mecanismo de funcionamento do sistema imunológico biológico. Primeiro, o sistema proposto utiliza uma sequência de técnicas de processamento de imagens para identificar as descontinuidades que representam regiões de atenção para o sistema de detecção (etapa nomeada de pré-processamento). Em seguida, separa descontinuidades que podem ser claramente classificadas como não defeitos (células próprias) e defeitos (células não-próprias). Em seguida, o sistema inicia um processo com o objetivo de 1) melhorar os dados não classificados por meio de transformação do tipo lente utilizada para a visualização dos defeitos, transformação essa realizada pela evolução dos anticorpos que codificam essas “lentes” (operadores morfológicos que permitem a extração das características a serem confrontadas com o banco de não-próprios) e 2) reduzir, de tempos em tempos, o valor limiar necessário para classificar uma descontinuidade como defeito visando para reduzir as taxas de falsos negativos, tanto quanto possível. Foram realizados experimentos com imagens radiográficas PDVD obtidas em situações reais de campo e que, na maioria dos casos, apresentam imagens de menor qualidade quando comparadas às utilizadas em outros estudos.

Este trabalho comparou a principal abordagem proposta (SIA puro) com três outros métodos também propostos no âmbito deste trabalho (SIA puro, SIA com *autoencoder* e uma abordagem de aprendizado profundo – AlexNet com processo de *Transfer Learning*) para detecção automática de defeitos em soldas em tubulações de petróleo. Essa comparação teve

como objetivo responder à pergunta: é realmente necessário adotar uma abordagem híbrida para executar esta tarefa?

O SIA puro usa algoritmos de seleção negativa e seleção clonal e um conjunto de 13 características representando o antígeno defeituoso (não próprio) e não defeituoso (próprio) para compor o banco de dados. Os resultados obtidos demonstram que o sistema SIA puro é uma alternativa interessante, uma vez que alcançou um *F-score* de 66,376%. Enquanto o sistema SIA com *autoencoder* demonstrou que nem toda combinação de SIA puro com outra abordagem obtém resultados interessantes, uma vez que este método obteve um *F-score* de 55,497%.

A abordagem proposta (SIA profundo) usa uma CNN AlexNet acoplada a uma sequência de *autoencoders* incorporada ao módulo SIA. O modelo AlexNet é usado com o objetivo de extrair outras características que são adicionadas às características geométricas e de textura para melhorar a classificação. O *autoencoder* é usado para reduzir o número de características extraídas pelo AlexNet para as 100 características consideradas no presente trabalho. A versão padrão da abordagem proposta atinge um *F-score* de 70,732%, superando o SIA puro.

Usando apenas a rede AlexNet para executar todo o processo - da extração de características à classificação de descontinuidades de defeito ou não - o modelo de aprendizado profundo puro atinge um *F-score* de 64,86%, indicando o segundo menor desempenho entre abordagens puras. Esse resultado provavelmente se deve à baixa cardinalidade do conjunto de treinamento, mesmo com o uso do aprendizado por transferência, no entanto, uma investigação mais profunda se torna necessária para a verificação de outros fatores. É importante ressaltar que, além de resultados pouco competitivos, a AlexNet obteve o segundo maior valor de FN, indicando que muitas descontinuidades pertencentes à classe de defeitos foram classificadas como não defeito; o que é um grande problema no contexto de classificação considerado. Por outro lado, a versão híbrida, SIA profundo, superou as demais não apenas em termos de *F-score*, mas também com o menor valor de FN.

Para se avaliar o modelo proposto dentro do contexto do aprendizado de máquina padrão, este foi comparado com o SVM com as mesmas características utilizadas em cada classificador. O melhor resultado foi obtido quando o SVM utilizou os dados de entrada do modelo AlexNet, obtendo um *F-score* de 59,43% (sendo um resultado mais baixo que o obtido pelas outras abordagens).

Além dos melhores resultados, outra vantagem dos modelos SIA é a capacidade de aprendizado on-line. Diferente dos modelos da CNN, que exigem processos de retreino custoso, a incorporação de novas informações nos bancos próprio e não próprio é bem fácil para os modelos de SIA. Desde que as novas descontinuidades detectadas sejam classificadas como próprias e não próprias com um alto nível de confiança, elas podem ser facilmente incorporadas ao repositório de próprios e banco de antígenos e novas descontinuidades podem tirar proveito desse banco expandido.

Durante o desenvolvimento desta tese também foi possível contribuir com um artigo publicado cuja referência é apresentada a seguir:

FIORAVANTI, C. C. B.; CENTENO, T. M.; DA SILVA, M. R. B. A Deep Artificial Immune System to Detect Weld Defects in DWDI Radiographic Images of Petroleum Pipes. **IEEE Access**, v. 7, p. 180947-180964, 2019.

## 7.1 TRABALHOS FUTUROS

A partir dos experimentos realizados, pode-se concluir que, utilizando a abordagem proposta, foi possível identificar automaticamente as descontinuidades e classificá-las em defeitos e não defeitos, destacando o resultado na imagem. A imagem resultante ajuda o especialista a preparar relatórios técnicos.

Com os resultados obtidos, novas perspectivas emergem para serem exploradas nesse campo, como a análise e/ou incorporação de outros métodos para extrair as características; incorporação de outros métodos de inteligência artificial (incluindo outros modelos da CNN que também poderão ser testados isoladamente e realizando a tarefa completa de detecção de defeito) ao método SIA puro, uma vez que este teve um desempenho relativamente bom quando usado em modo independente; redimensionar o volume da imagem, para que, além do canal em nível de cinza oriundo da imagem original, outros dois sejam acrescentados com modificações na imagem em nível de cinza de forma a introduzir informação nova que possa auxiliar a classificação da imagem. E por fim, outro tópico bastante importante é a exploração da capacidade de aprendizado online do módulo SIA. Neste sentido, descontinuidades classificadas na fase de próprio e não próprio com limiar alto e possivelmente com o aval do laudista poderiam ser incorporadas aos respectivos bancos incrementando o poder de discriminação do método proposto.

## REFERÊNCIAS

ABNT (Associação Brasileira de Normas Técnicas). **NBR 14842: Critérios para qualificação e certificação de Inspetores de Soldagem**. Rio de Janeiro, 2003.

ALGHALANDIS, S. M.; ALAMDARI, G.H.N. Welding defect pattern recognition in radiographic images of gas pipelines using adaptive feature extraction method and neural network classifier. In: **23rd World Gas Conference, Amsterdam**. 2006. p. 1-13.

ALKABAWI, E. M.; HILAL, A. R.; BASIR, O. A. Feature abstraction for early detection of multi-type of dementia with sparse auto-encoder. In: **Systems, Man, and Cybernetics (SMC), 2017 IEEE International Conference on**. IEEE, 2017. p. 3471-3476.

ANDREUCCI, R. **Radiologia Industrial**. São Paulo: ABENDE, 2017, disponível em: [http://www.abendi.org.br/abendi/Upload/file/radiologia\\_maio\\_2017.pdf](http://www.abendi.org.br/abendi/Upload/file/radiologia_maio_2017.pdf), acesso em: 04/08/2017.

ANDREUCCI, R. **Radiologia Industrial**. 5 edição, São Paulo: ABENDE, 2002, disponível em: [www.slideshare.net/WillameNascimento/radiologia-industrial](http://www.slideshare.net/WillameNascimento/radiologia-industrial), acesso em: 10/10/2014.

ASME Boiler & Pressure Vessel Code, Section V, Subsection A, Article 2, Nonmandatory Appendices, Appendix A: Recommended Radiographic Technique Sketches for Pipe or Tube Welds, pp. 34-37, **The American Society of Mechanical Engineers (ASME)**, New York, 2004.

ASM HANDBOOK, Metals Handbook, Ninth Edition, Volume 17, **Nondestructive Evaluation and Quality Control**, published by ASM International, 2007, ISBN-10 No. 0-87170-023-9.

ASNT (American Society for Nondestructive Testing). **Introduction to Nondestructive Testing**. 2017. Disponível em: <https://www.asnt.org/MinorSiteSections/AboutASNT/Intro-to-NDT.aspx>. Acessado em 04/08/17.

ARAÚJO, F. H. D. *et al.* Redes Neurais Convolucionais com Tensorflow: Teoria e Prática. **SOCIEDADE BRASILEIRA DE COMPUTAÇÃO. III Escola Regional de Informática do Piauí. Livro Anais-Artigos e Minicursos**, v. 1, p. 382-406, 2017.

ARRUDA, B. W DE S. **Classificação de distúrbios de energia elétrica baseada em sistemas imunológicos artificiais**. Dissertação de Mestrado. Universidade Federal da Paraíba, João Pessoa, 2015.

ARULMOZHI, N. *et al.* Isolation of defects in radiographic weld images with wavelet denoising using Log-Gabor filter. In: **iccima**. IEEE, 2007. p. 394-399.

BALAKRISHNAN, R. **Innovative RT Technique to Evaluate Flaws Location and Sensitivity in Tube Butt Welds in DWDI Technique**. Proceedings of the National Seminar & Exhibition on Non-Destructive Evaluation, India, 2009.



BANIUKIEWICZ, P.; SIKORA, R. Automatic detection of objects in radiographic images. In: **Nonlinear Dynamics and Synchronization (INDS) & 16th Int'l Symposium on Theoretical Electrical Engineering (ISTET), 2011 Joint 3rd Int'l Workshop on.** IEEE, 2011. p. 1-4.

BENGIO, Y. *et al.* Learning deep architectures for AI. **Foundations and trends® in Machine Learning**, v. 2, n. 1, p. 1-127, 2009.

BERBERT, P. C. **Sistema imunológico artificial para otimização multiobjetivo.** Dissertação de Mestrado, Universidade Estadual de Campinas, Campinas, SP, Brasil, 2008.

BERBERT, P.C.; YAMAKAMI, A. Algoritmo Bio-inspirado para Otimização Multiobjetivo. **XLI SBPO 2009 - Pesquisa Operacional na Gestão do Conhecimento.** Porto Seguro, BA, 2009.

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

BOARETTO, N. **Classificação de Defeitos de Soldagem em Imagens Radiográficas PDVD de Tubulações de Petróleo: Uma abordagem com Ensemble de Extreme Learning Machines.** Tese de Doutorado, CPGEI-UTFPR, Curitiba, 2017.

CASTRO, P. A. D. DE. **Sinergia entre Sistemas Imunológicos Artificiais e Modelos Gráficos Probabilísticos.** [s.l.] Tese de doutorado. Doutorado em Engenharia Elétrica. 2009. Campinas, Unicamp, 2009.

CHAN, T. F.; VESE, L. A. Active contours without edges. **IEEE Transactions on image processing**, v. 10, n. 2, p. 266-277, 2001.

CHEN, W.; MIAO, Z.; MING, D. Automated inspection using x-ray imaging. In: **Trust, Security and Privacy in Computing and Communications (TrustCom), 2011 IEEE 10th International Conference on.** IEEE, 2011. p. 1769-1772.

CHEN, C. Y.; LEU, J. S.; PRAKOSA, S. W. Using autoencoder to facilitate information retention for data dimension reduction. In: **2018 3rd International Conference on Intelligent Green Building and Smart Grid (IGBSG).** IEEE, 2018. p. 1-5.

COELHO, G. **Redes Imunológicas Artificiais para Otimização em Espaços Contínuos: Uma Proposta Baseada em Concentração de Anticorpos.** [s.l.] Tese de Doutorado, 2011.

DASGUPTA, D. Advances in artificial immune systems. **IEEE computational intelligence magazine**, v. 1, n. 4, p. 40-49, 2006.

DASGUPTA, D.; GONZALEZ, F. Artificial immune systems in intrusion detection. **Enhancing computer security with smart technology**, p. 165-208, 2005.

DASGUPTA, D.; YU, S.; NINO, F. Recent advances in artificial immune systems: models and applications. **Applied Soft Computing**, v. 11, n. 2, p. 1574-1587, 2011.

DA ROCHA, E. F. N. R. **Deteção e caracterização de perturbações de preços de mercado com base em sistemas imunológicos artificiais. Dissertação de Mestrado.** Universidade do Porto. Porto, Portugal, 2017.

DE CASTRO, L.N., **Análise e Síntese de Estratégias de Aprendizado para Redes Neurais Artificiais.** Campinas: FEEC, UNICAMP, setembro de 1998. Dissertação de Mestrado – Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, pp. 250.

DE CASTRO, L. N. **Engenharia Imunológica: Desenvolvimento e Aplicação de Ferramentas Computacionais Inspiradas em Sistemas Imunológicos Artificiais.** Tese Doutorado, FEEC - UNICAMP, Campinas, 2001.

DE CASTRO, L. N.; TIMMIS, J. **Artificial immune systems: a new computational intelligence approach.** Springer Science & Business Media, 2002.

DE CASTRO, L. N.; TIMMIS, J. An artificial immune network for multimodal function optimization. In: **Evolutionary Computation, 2002. CEC'02. Proceedings of the 2002 Congress on.** IEEE, 2002. p. 699-704.

DE CASTRO, L. N.; VON ZUBEN, F. J. The clonal selection algorithm with engineering applications. In: **Proceedings of GECCO.** 2000. p. 36-39.

DENG, Jia et al. Imagenet: A large-scale hierarchical image database. In: **2009 IEEE conference on computer vision and pattern recognition.** Ieee, 2009. p. 248-255.

EDALATI, K. *et al.* Scattering and image contrast simulation for double wall radiography of pipes. **International journal of pressure vessels and piping**, v. 84, n. 7, p. 441-450, 2007.

FAWCETT, T. An introduction to ROC analysis. **Pattern recognition letters**, v. 27, n. 8, p. 861-874, 2006.

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

FIORAVANTI, C. C. B.; CENTENO, T. M.; DA SILVA, M. R. B. A Deep Artificial Immune System to Detect Weld Defects in DWDI Radiographic Images of Petroleum Pipes. **IEEE Access**, v. 7, p. 180947-180964, 2019.

FORREST, Stephanie *et al.* Self-nonsel self discrimination in a computer. In: **Proceedings of 1994 IEEE computer society symposium on research in security and privacy.** Ieee, 1994. p. 202-212.

FU, D.; YU, X.; WANG, T. Segmentation algorithm study for infrared images with occluded target based on artificial immune system. In: **2012 Eighth International Conference on Computational Intelligence and Security.** IEEE, 2012. p. 350-353.

FYLYK, V. M.; CENTENO, T. M. Detecção de defeitos em cordões de solda por redes neurais. In: **Sicite 2012, XVII Seminário de Iniciação Científica e Tecnológica da UTFPR**. Curitiba, 2012.

GODOI, W. C.; DA SILVA, R. R.; SWINKA-FILHO, V. Pattern recognition in the automatic inspection of flaws in polymeric insulators. **Insight-Non-Destructive Testing and Condition Monitoring**, v. 47, n. 10, p. 608-614, 2005.

GOMES, L. C. T. **Inteligência Computacional na Síntese de Metaheurísticas para Otimização Combinatória e Multimodal**, Tese de Doutorado, FEEC/Unicamp, 2006.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. U. **Digital Image Processing Using MATLAB**: Pearson Prentice Hall. **Upper Saddle River, New Jersey**, 2004.

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

GOODFELLOW, Ian *et al.* **Deep learning**. Cambridge: MIT press, 2016, disponível em <http://www.deeplearningbook.org>, acesso em 16/08/2018.

HALIM, S. A. *et al.* The geometrical feature of weld defect in assessing digital radiographic image. In: **Imaging Systems and Techniques (IST), 2011 IEEE International Conference on**. IEEE, 2011. p. 189-193.

HALIM, S. A. *et al.* Weld defect features extraction on digital radiographic image using Chan-Vese model. In: **Signal Processing and its Applications (CSPA), 2013 IEEE 9th International Colloquium on**. IEEE, 2013. p. 67-72.

HAYKIN, S. S. **Neural networks and learning machines**. Upper Saddle River. Pearson, 2009.

HUANG, G.; ZHU, Q.; SIEW, C. Extreme learning machine: theory and applications. **Neurocomputing**, v. 70, n. 1-3, p. 489-501, 2006.

JAGANNATHAN, H. *et al.* A step towards automatic defect pattern analysis and evaluation in industrial radiography using digital image processing. In: **Proceedings of 15th World Conference on Non Destructive Testing, Roma. Oct. 2000**. p. 15-21.

JI, Z. *et al.* Analysis of dental images using artificial immune systems. In: **Evolutionary Computation, 2006. CEC 2006. IEEE Congress on**. IEEE, 2006. p. 528-535.

JI, Z.; DASGUPTA, D. V-detector: An efficient negative selection algorithm with “probably adequate” detector coverage. **Information sciences**, v. 179, n. 10, p. 1390-1406, 2009.

KARN, U. An intuitive explanation of convolutional neural networks. **The Data Science Blog**, 2016.

KARPATY, A.; LI, F. F.; JOHNSON, J. CS231n: Convolutional neural networks for visual recognition, 2016. URL <http://cs231n.github.io>, 2017.

KIDO, S.; HIRANO, Y.; HASHIMOTO, N. Detection and classification of lung abnormalities by use of convolutional neural network (CNN) and regions with CNN features (R-CNN). In: **Advanced Image Technology (IWAIT), 2018 International Workshop on**. IEEE, 2018. p. 1-4.

KOHAVI, Ron et al. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: **Ijcai**. 1995. p. 1137-1145.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: **Advances in neural information processing systems**. 2012. p. 1097-1105.

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

KROETZ, M. G.; CENTENO, T. M.; DELGADO, M. Otimização por Enxame de Partículas Aplicada à Detecção do Cordão de Solda em Radiografias Parede Dupla Vista Dupla. **III Mostra de Pesquisa e Pós-Graduação da UTFPR**, Curitiba, 2011.

LAWSON, S.W.; PARKER, G. A. Intelligent segmentation of industrial radiographic images using neural networks. In: **Machine Vision Applications, Architectures, and Systems Integration III**. International Society for Optics and Photonics, 1994. p. 245-256.

LECUN, Y. Generalization and network design strategies. **Connectionism in perspective**, p. 143-155, 1989.

LECUN, Y.; BENGIO, Y. Convolutional networks for images, speech, and time series. **The handbook of brain theory and neural networks**, v. 3361, n. 10, p. 1995, 1995.

LI, Bin; SUN, Fuqiang; ZHANG, Yonghan. Building Recognition Based on Sparse Representation of Spatial Texture and Color Features. **IEEE Access**, v. 7, p. 37220-37227, 2019.

LIAO, T. W. Classification of weld flaws with imbalanced class data. **Expert Systems with Applications**, v. 35, n. 3, p. 1041-1052, 2008.

LIMA, F. P. A. **Análise de distúrbios de tensão em sistemas de distribuição de energia elétrica baseada em sistemas imunológicos artificiais**. Dissertação de Mestrado. São Paulo: UNESP, 2013.

LIMA, F.P. A. *et al.* Reconhecimento de Caracteres Manuscritos Utilizando Sistemas Imunológicos Artificiais. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v. 2, n. 1, 2014.

LILING, G.; YINGJIE, Z. Hierarchical segmentation approach to detection of defects on welding radiographic images. In: **Industrial Electronics and Applications, 2009. ICIEA 2009. 4th IEEE Conference on**. IEEE, 2009. p. 2089-2094.

LOPES, D. *et al.* **Visão geral sobre a inspeção em cordões de solda através de técnicas não destrutivas ultrassônicas.** V Congresso Norte-Nordeste de Pesquisa e Inovação. V CONNEPI, Maceió, 2010.

MAHMOUDI, A.; REGRAGUI, F. Fast segmentation method for defects detection in radiographic images of welds. In: **Computer Systems and Applications, 2009. AICCSA 2009. IEEE/ACS International Conference on.** IEEE, 2009a. p. 857-860.

MAHMOUDI, A.; REGRAGUI, F. Welding defect detection by segmentation of radiographic images. In: **Computer Science and Information Engineering, 2009 WRI World Congress on.** IEEE, 2009b. p. 111-115.

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

MARQUES, O. **Practical Image and Video Processing Using Matlab.** New Jersey: John Wiley & Sons, Inc., 2011.

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

MARQUES FILHO, O; VIEIRA NETO, H. **Processamento digital de imagens.** Brasport, 1999.

MARQUEZE, C. M.; QUITES, A. M. **Descontinuidades em Soldas.** Florianópolis, 1995.

MATLAB. 9.4.0.813654 (R2018a). Natick, Massachusetts: The MathWorks Inc .; 2018.

MERY, D. Automated detection of welding discontinuities without segmentation. **Materials Evaluation**, v. 69, n. 6, p. 656-663, 2011.

MIRANDA, R. *et al.* WBdetect: Particle Swarm Optimization for Segmenting Weld Beads in Radiographic Images. In: **Designing with Computational Intelligence.** Springer, Cham, 2017. p. 217-236.

MODENESI, P. J.; MARQUES, Paulo V.; SANTOS, Dagoberto B. Introdução à metalurgia da soldagem. **Belo Horizonte: UFMG**, 2012.

MORIM, D. DOS S. **Uso de Detectores de Dimensões Variáveis Aplicados na Detecção de Anomalias Através de Sistemas Imunológicos Artificiais.** Dissertação de Mestrado. Rio de Janeiro: UERJ, 2009.

NACEREDDINE, N.; TRIDI, M. Computer-aided shape analysis and classification of weld defects in industrial radiography based invariant attributes and neural networks. In: **Image and Signal Processing and Analysis, 2005. ISPA 2005. Proceedings of the 4th International Symposium on.** IEEE, 2005. p. 88-93.

NAWAZ, W. *et al.* Classification of breast cancer histology images using alexnet. In: **International Conference Image Analysis and Recognition.** Springer, Cham, 2018. p. 869-876.

NG, A. CS294A Lecture notes.

**Dosegljivo:**[https://web.stanford.edu/class/cs294a/sparseAutoencoder\\_2011new.pdf](https://web.stanford.edu/class/cs294a/sparseAutoencoder_2011new.pdf).  
[Dostopano 20. 7. 2016], 2011.

NOOR, N. S. M.; YAZID, H. Shapes matching based on chain code and dynamic time warping. In: **Signal Processing & Its Applications (CSPA), 2015 IEEE 11th International Colloquium on**. IEEE, 2015. p. 52-56.

OQUAB, Maxime *et al.* Learning and transferring mid-level image representations using convolutional neural networks. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2014. p. 1717-1724.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE transactions on systems, man, and cybernetics**, v. 9, n. 1, p. 62-66, 1979.

OZA, P.; PATEL, V. M. One-class convolutional neural network. **IEEE Signal Processing Letters**, v. 26, n. 2, p. 277-281, 2018.

PÁDUA, G. X. *et al.* Extração do cordão de solda e detecção de defeitos em radiografias usando redes neurais. **3th Panamerican Conference for Nondestructive Testing PANNDT**, 2003.

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

PARK, S. *et al.* Driver drowsiness detection system based on feature representation learning using various deep networks. In: **Asian Conference on Computer Vision**. Springer, Cham, 2016. p. 154-164.

PRIORI, D. **Comparison of neural network models applied to size prediction of atmospheric particles based on their two-dimensional light scattering patterns**. Dissertação de Mestrado, UFSC, Florianópolis, 2017.

RABELLO, J. M. B. *et al.* Utilização da técnica de radiografia computadorizada na inspeção de soldas circunferenciais na técnica de parede dupla-vista simples. In: **IV Conferência Panamericana de END, Buenos Aires**. 2007.

RATHOD, V. R.; ANAND, R. S. A comparative study of different segmentation techniques for detection of flaws in NDE weld images. **Journal of Nondestructive Evaluation**, v. 31, n. 1, p. 1-16, 2012.

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

SHAFEEK, H. I. *et al.* Assessment of welding defects for gas pipeline radiographs using computer vision. **NDT & e International**, v. 37, n. 4, p. 291-299, 2004.

SERAPIÃO, A. B. DE S.; MENDES, J. R. P.; MIURA, K. Sistema de Reconhecimento Imunológico Artificial para Identificação de Operações de perfuração em Poços Petrolíferos. **Anais do VIII Simpósio Brasileiro de Automação Inteligente, UFSC, Florianópolis, 2007**

SILVA, R. R. *et al.* Radiographics pattern recognition of welding defects using linear classifiers. **Insight**, v. 43, n. 10, p. 669-74, 2001.

SILVA, R. R. Reconhecimento de Padrões de defeitos de Soldagem em Radiografias Industriais. **Doctora Degree, COPPE/UFRJ, Rio de Janeiro (in Portuguese), 2003.**

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

SOLOMON, C.; BRECKON, T. **Fundamentos de processamento digital de imagens: uma abordagem prática com exemplos em Matlab.** Grupo Gen-LTC, 2013.

SRINIVAS, M.; ROY, D.; MOHAN, C. K. Discriminative feature extraction from X-ray images using deep convolutional neural networks. In: **Acoustics, Speech and Signal Processing (ICASSP), 2016 IEEE International Conference on.** IEEE, 2016. p. 917-921.

SRIRAM, A. *et al.* Learning autoencoded radon projections. In: **Computational Intelligence (SSCI), 2017 IEEE Symposium Series on.** IEEE, 2017. p. 1-5.

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

SUYAMA, F. M. *et al.* Deep neural networks based approach for welded joint detection of oil pipelines in radiographic images with Double Wall Double Image exposure. **NDT & E International**, v. 105, p. 46-55, 2019.

TAHA, B.; DIAS, J.; WERGHI, N. Convolutional neural networkasa feature extractor for automatic polyp detection. In: **Image Processing (ICIP), 2017 IEEE International Conference on.** IEEE, 2017. p. 2060-2064.

TELLES, P. C. S. **Tubulações Industriais - Materiais, Projeto e Montagem.** 10ª ed. Rio de Janeiro: LTC, 2001.

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

VALAVANIS, I.; KOSMOPOULOS, D. 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.

XIAO, L.; YAN, Q.; DENG, S. Scene classification with improved AlexNet model. In: **2017 12th International Conference on Intelligent Systems and Knowledge Engineering (ISKE).** IEEE, 2017. p. 1-6.

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

WAINER, E.; BRANDI, S. D.; MELLO, F. D. H. Soldagem: processos e metalurgia. **São Paulo: Edgard Blücher Ltda**, 1992.

WIGGERS, K. L. *et al.* Document image retrieval using deep features. In: **2018 International Joint Conference on Neural Networks (IJCNN)**. IEEE, 2018. p. 1-8.

YAHIA, N. B. *et al.* Automatic detection of welding defects using radiography with a neural approach. **Procedia Engineering**, v. 10, p. 671-679, 2011.

YAVUZ, Burcu Çarklı; YURTAY, Nilüfer; OZKAN, Ozhan. Prediction of protein secondary structure with clonal selection algorithm and multilayer perceptron. **IEEE Access**, v. 6, p. 45256-45261, 2018.

YAZID, H. *et al.* Discontinuities detection in welded joints based on inverse surface thresholding. **NDT & e International**, v. 44, n. 7, p. 563-570, 2011.

YOSINSKI, Jason *et al.* How transferable are features in deep neural networks? In: **Advances in neural information processing systems**. 2014. p. 3320-3328.

ZAPANA, R. A. *et al.* Characterization of climatological time series using autoencoders. In: **Computational Intelligence (LA-CCI), 2017 IEEE Latin American Conference on**. IEEE, 2017. p. 1-6.

ZAPATA, J.; VILAR, R.; RUIZ, R. An adaptive-network-based fuzzy inference system for classification of welding defects. **NDT & e International**, v. 43, n. 3, p. 191-199, 2010.

ZARE, M. R.; ALEBIOSU, D. O.; LEE, S. L. Comparison of Handcrafted Features and Deep Learning in Classification of Medical X-ray Images. In: **2018 Fourth International Conference on Information Retrieval and Knowledge Management (CAMP)**. IEEE, 2018. p. 1-5.

ZHONG, Yanfei; ZHANG, Liangpei. Sub-pixel mapping based on artificial immune systems for remote sensing imagery. **Pattern Recognition**, v. 46, n. 11, p. 2902-2926, 2013.

ZHUANG, Fuzhen *et al.* Supervised representation learning: Transfer learning with deep autoencoders. In: **Twenty-Fourth International Joint Conference on Artificial Intelligence**. 2015.



## APÊNDICE A – CAMADAS DA ALEXNET

Número	Descrição	Detalhamento
1	Imagem de entrada	Imagens de tamanho 227x227x3 com normalização 'zero central'
2	Convolução	96 convoluções 11x11x3 com passo [4 4] e <i>zero-padding</i> [0 0 0 0]
3	ReLU	ReLU
4	Normalização de canal cruzado	Normalização de canal cruzado com 5 canais por elemento
5	<i>Maxpooling</i>	<i>maxpooling</i> 3x3 com passo [2 2] e <i>padding</i> [0 0 0 0]
6	Convolution	256 convoluções 5x5x48 com passo [1 1] e <i>padding</i> [2 2 2 2]
7	ReLU	ReLU
8	Normalização de canal cruzado	Normalização de canal cruzado com 5 canais por elemento
9	<i>Maxpooling</i>	<i>maxpooling</i> 3x3 com passo [2 2] e <i>padding</i> [0 0 0 0]
10	Convolution	384 convoluções 3x3x256 com passo [1 1] e <i>padding</i> [1 1 1 1]
11	ReLU	ReLU
12	Convolution	384 convoluções 3x3x192 com passo [1 1] e <i>padding</i> [1 1 1 1]
13	ReLU	ReLU
14	Convolution	256 convoluções 3x3x192 com passo [1 1] e <i>padding</i> [1 1 1 1]
15	ReLU	ReLU
16	<i>Maxpooling</i>	<i>maxpooling</i> 3x3 com passo [2 2] e <i>padding</i> [0 0 0 0]
17	Totalmente conectada	4096 saídas da camada totalmente conectada
18	ReLU	ReLU
19	<i>Dropout</i>	50% <i>dropout</i>
20	Totalmente conectada	4096 saídas da camada totalmente conectada
21	ReLU	ReLU
22	<i>Dropout</i>	50% <i>dropout</i>
23	Totalmente conectada	1000 saídas da camada totalmente conectada
24	<i>Softmax</i>	<i>softmax</i>
25	Classificação de saída	entropia cruzada com 'tench' e 999 outras classes