



REDEMAT

REDE TEMÁTICA EM ENGENHARIA DE MATERIAIS

UFOP – UEMG



Tese de Doutorado

"Detecção de Descontinuidades no Processo de Soldagem por Eletrodo Revestido por meio de Inteligência Computacional"



Autor: José Alberto Naves Cocota Júnior
Orientador: Prof. Dr. Adilson Rodrigues da Costa
Coorientador: Prof. Dr. Milton Sérgio Fernandes de Lima

Dezembro de 2017



REDEMAT

REDE TEMÁTICA EM ENGENHARIA DE MATERIAIS

UFOP – UEMG

José Alberto Naves Cocota Júnior

"Detecção de Descontinuidades no Processo de Soldagem por Eletrodo Revestido por meio de Inteligência Computacional"

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia de Materiais da REDEMAT, como parte integrante dos requisitos para a obtenção do título de Doutor em Engenharia de Materiais.

Área de concentração: Engenharia de Superfícies

Orientador: Dr. Adilson Rodrigues da Costa

Coorientador: Prof. Dr. Milton Sérgio Fernandes de Lima

Ouro Preto, dezembro de 2017

C667d

Cocota Júnior, José Alberto Naves.

Detecção de Descontinuidades no Processo de Soldagem por Eletrodo Revestido por meio de Inteligência Computacional [manuscrito] / José Alberto Naves Cocota Júnior. - 2017.

125f.: il.: color; graf.; tabs.

Orientador: Prof. Dr. Adilson Rodrigues da Costa.

Coorientador: Prof. Dr. Milton Sérgio Fernandes de Lima.

Tese (Doutorado) - Universidade Federal de Ouro Preto. Pró-Reitoria de Pesquisa e Pós-Graduação. REDEMAT. Programa de Pós-Graduação em Engenharia de Materiais.

Área de Concentração: Engenharia de Superfícies.

1. Eletrodos - Soldagem. 2. Instrumentos de medição. 3. Emissão acústica. 4. Testes não-destrutivos. 5. Aprendizado do computador. I. Costa, Adilson Rodrigues da. II. Lima, Milton Sérgio Fernandes de. III. Universidade Federal de Ouro Preto. IV. Título.

CDU: 620.1

Catálogo: www.sisbin.ufop.br



REDE TEMÁTICA EM ENGENHARIA DE MATERIAIS UFOP - UEMG

Pós-Graduação em Engenharia de Materiais, Doutorado, Mestrado e Especialização



“Detecção de Descontinuidade no Processo de Soldagem por Eletrodo Revestido por Meio de Inteligência Computacional”

Autor: José Alberto Naves Cocota Júnior

Tese defendida e aprovada, em 18 de dezembro de 2017, pela banca examinadora constituída pelos professores:

Prof. Adilson Rodrigues da Costa (Doutor) – Orientador
Universidade Federal de Ouro Preto

Prof. Silvério Ferreira da Silva Júnior (Doutor)
CDTN-Centro de Desenvolvimento da Tecnologia Nuclear

Prof. Agnaldo José da Rocha Reis (Doutor)
Universidade Federal de Ouro Preto

Prof. Paulo Marcos de Barros Monteiro (Doutor)
Universidade Federal de Ouro Preto

Prof. Fernando Gabriel da Silva Araújo (Doutor)
Universidade Federal de Ouro Preto

Prof. Milton Sérgio Fernandes de Lima (Doutor) – Coorientador
IEAv-Instituto de Estudos Avançados-São José dos Campos/SP

À minha família, em especial, meus pais, José Alberto Naves Cocota e Denise de Fátima Monteiro Naves Cocota, minha esposa Ariadne Carvalho de Freitas Naves Cocota e minhas filhas Alice de Freitas Cocota e Amanda de Freitas Cocota.

Agradecimentos

À minha esposa, Ariadne, que sempre foi presente e parceira em minha vida profissional.

Ao orientador, Prof. Adilson Rodrigues da Costa, pelo apoio no trabalho e pelos conselhos profissionais e pessoais ao longo do curso.

Ao coorientador, Prof. Milton Sérgio Fernandes de Lima, pela receptividade em São José dos Campos e pela disponibilidade em auxiliar nas diferentes etapas desta pesquisa.

Aos ex-alunos, Gabriel Garcia e Filipe Rocha, por assistirem respectivamente na programação dos classificadores e do robô.

Ao pesquisador Gustavo Medeiros Freitas pelo suporte técnico do Instituto Tecnológico Vale Mineração e apoio para publicação do trabalho.

Ao Prof. Gustavo Paulinelli Guimarães pelo empréstimo de equipamentos para instrumentação e aquisição de dados.

Ao Prof. Geraldo L. de Faria pela disponibilidade do Laboratório de Tratamento Térmico e Microscopia Óptica (LTM) e do corpo técnico.

Aos técnicos Celso Onésimo Nascimento Batista, Graciliano Dimas Francisco e Paulo Sérgio Moreira que não mediram esforços em apoiar o projeto.

Ao técnico Reinaldo Clemente Fortes pela preparação das amostras para soldagem.

Ao Prof. Paulo Graça Castanheira Júnior pela orientação na qualificação das descontinuidades dos cordões de solda.

À Profª. Margarida Márcia Fernandes Lima pela disponibilidade da lupa Olympus SZ61.

Sumário

Lista de Figuras	ix
Lista de Tabelas	xv
Lista de Notações	xvii
Resumo	xviii
Abstract	xix
1. Introdução	1
2. Objetivos	5
2.1 Objetivos Específicos	5
3. Revisão Bibliográfica	6
3.1 Soldagem com Eletrodos Revestidos	6
3.1.1 Vantagens do Processo	7
3.1.2 Limitações do Processo	7
3.2 Conceitos da Metalurgia da Soldagem	8
3.2.1 Transformações de Fases em Aço de Baixo Carbono	8
3.2.2 Fluxo de Calor	9
3.3 Instrumentação	11
3.3.1 Transdutor Microfone	11
3.3.2 Transdutor Ultrassônico	12
3.3.2.1 Emissão Acústica Sólida	14
3.4 Sistema de Aquisição de Dados	14
3.5 Extração de Características	16
3.6 Aprendizado de Máquina	17
3.6.1 Conceitos Básicos de Aprendizado Estatístico	18
3.6.2 Classificação Binária e Multiclasse	19
3.6.3 Máquinas de Vetor de Suporte	19
3.6.4 Redes Neurais Artificiais	24
3.6.5 Observações Finais	29

3.7 Robotização do Processo de Soldagem com Eletrodos Revestidos	30
4. Materiais e Métodos	32
4.1 Aço de Baixo Carbono	32
4.2 Eletrodo Revestido E 6013	33
4.3 Estação de Soldagem.....	33
4.4 Instrumentação	35
4.4.1 Transdutor Microfone.....	35
4.4.2 Transdutor Ultrassônico	36
4.5 Sistema de Aquisição de Dados	37
4.6 Extração de Características	40
4.6.1 Segmentação dos Dados.....	41
4.6.2 Transformada de Fourier Discreta.....	42
4.6.3 Decimação por Média	42
4.6.4 Transformada <i>Wavelet</i>	43
4.7 Soldagem com Eletrodos Revestidos	44
4.7.1 Preparação das Amostras para Soldagem.....	44
4.7.2 Configuração dos Parâmetros Operacionais	45
4.7.3 Experimentos de Soldagem.....	45
4.8 Classificadores de Padrões	48
4.8.1 Treinamento, Validação e Teste dos Classificadores.....	49
4.8.2 Avaliação dos Classificadores	50
4.9 Preparações Metalográficas.....	50
4.10 Análises Macro e Microscópicas.....	51
5. Resultados e Discussões	54
5.1 Descontinuidades nos Cordões de Solda.....	54
5.2 Análises Macroscópicas	59
5.2.1 Seções Transversais.....	59
5.2.2 Seções Longitudinais.....	63
5.3 Análises Microscópicas	67

5.3.1 Cordão de Solda da Classe Normal.....	67
5.3.2. Cordão de Solda da Classe Cratera	70
5.3.3 Micro Trincas e Trincas	72
5.4 Pré-processamento de Sinais.....	77
5.4.1 Emissões Acústicas Aéreas.....	77
5.4.2. Emissões Acústicas Sólidas.....	79
5.5 Imagens de Gravações em Vídeo	82
5.5.1 Câmera 1 – Vista da Poça de Fusão	82
5.5.2. Câmera 2 – Vista do Arco Elétrico	83
5.6 Classificação de Padrões	83
5.6.1 Máquinas de Vetor de Suporte	84
5.6.2. Rede Neural Artificial	97
5.6.3 Discussão dos Resultados de Classificação	105
6. Conclusões.....	110
7. Sugestões para Trabalhos Futuros.....	112
Referências Bibliográficas	113
Publicações do Autor Relacionadas com o Trabalho	121
Anexo A – Diagrama de Blocos no LabVIEW	122
Anexo B – Fluxograma do Script em MATLAB	123

Lista de Figuras

Figura 3.1 – Representação esquemática de soldagem com eletrodo revestido.....	6
Figura 3.2 – Elementos típicos que compõem circuito do processo SMAW	7
Figura 3.3 – Diagrama Fe-C com representação esquemática de microestruturas para uma liga de aço carbono hipoeutetóide	9
Figura 3.4 – Curva de repartição térmica e regiões de uma solda por fusão. A – Zona Fundida (ZF), B – Zona Termicamente Afetada (ZTA), C – Metal de Base (MB), T_p – Temperatura de Pico, T_f – Temperatura de Fusão e T_c – Temperatura Crítica	10
Figura 3.5 – Sensor de pressão capacitivo	11
Figura 3.6 – Diagrama esquemático da cápsula de eletreto	12
Figura 3.7 – A força aplicada sobre o cristal piezo elétrico provoca o surgimento de cargas .	13
Figura 3.8 – Circuito equivalente simplificado de um sensor piezo elétrico	13
Figura 3.9 – Montagem recomendada de fixação de sensor piezo elétrico para medição de vibração	14
Figura 3.10 – Circuito de aquisição de dados com um conversor A/D compartilhado.....	15
Figura 3.11 – Circuito de aquisição de dados conversores A/D independentes para cada entrada.....	16
Figura 3.12 – Diagrama do processo de treinamento do classificador.....	17
Figura 3.13 – Diagrama do processo de classificação. A entrada do classificador é alimentada por vetores de características, e em sua saída temos as classes estimadas.....	18
Figura 3.14 – Exemplo bidimensional de classificação binária solucionada por meio de três modelos distintos de classificadores	18
Figura 3.15 – Representação de SVM com margens rígidas no espaço \mathbb{R}^2 . Os dados estão representados em duas classes (classificação binária): quadrado e círculo. O hiperplano ótimo está representado por linha pontilhada. Os vetores de suporte estão realçados em azul.....	20
Figura 3.16 – Representação de SVM com margens suaves no espaço \mathbb{R}^2 . Em (a) temos um dado “quadrado” dentro da região de separação e do lado correto da superfície de decisão. Em (b) temos um dado “círculo” no lado errado da superfície de decisão. O hiperplano ótimo está representado por linha pontilhada. Os vetores de suporte estão realçados em azul.....	21
Figura 3.17 – Representação da ideia de SVM não-linear de mapear os dados de treinamento do (a) espaço de entrada em \mathbb{R}^2 em um espaço de maior dimensão (b) – espaço de características – em \mathbb{R}^3 ; e construir um hiperplano de separação (b).....	22

Figura 3.18 – Arquitetura da máquina de vetor de suporte.....	23
Figura 3.19 – Exemplo de estrutura de decisão binária de SVM. A partir de uma entrada, o dado é classificado entre duas classes (saídas). Para um maior número de classes é necessário o uso de técnicas de binarização	23
Figura 3.20 – Exemplo de estrutura hierárquica de máquina de vetor de suporte (HSVM)....	24
Figura 3.21 – Modelo não-linear de um neurônio artificial (nodo computacional), onde k é o índice referente ao neurônio.....	25
Figura 3.22 – R Influência do <i>bias</i> no (a) campo local induzido; e na (b) fronteira de decisão para um problema de classificação binária a partir de duas entradas (x_1 e x_2).....	25
Figura 3.23 – Rede totalmente conectada de perceptrons de múltiplas camadas com uma camada oculta.....	26
Figura 3.24 – Gráfico do fluxo de sinal da aprendizagem por retropropagação para uma rede totalmente conectada 3-3-3-3 com bias unitário e positivo (+1). Fluxo de sinal em preto: passo para frente; fluxo de sinal em azul: passo para trás.....	28
Figura 3.25 – Representação da regra de parada antecipada baseada na validação cruzada ...	29
Figura 3.26 – Arranjo cinemático dos robôs (a) cartesiano (PPP) e (b) antropomórfico (RRR). Os robôs manipuladores são compostos por elos unidos por juntas em uma cadeia cinemática aberta ou fechada, onde P refere-se à junta prismática (de translação) e R à junta de rotação 30	
Figura 4.1 – Micrografia (400x) de amostra do estado de entrega do aço SAE 1006 utilizado nos experimentos.....	32
Figura 4.2 – Configuração do experimento.....	34
Figura 4.3 – Interface gráfica com o usuário em Matlab	34
Figura 4.4 – Gabinete com dispositivos eletrônicos para acionamento do robô. Em (a) vista interna com o acondicionamento da plataforma Arduino à esquerda e os módulos de potência à direita; em (b) posicionamento do gabinete na estação de soldagem.....	35
Figura 4.5 – Transdutor ultrassônico H2-SE-20/0° 2MHz Eddytronic.....	35
Figura 4.6 – Resposta típica em frequência do microfone G.R.A.S. 40PH. A curva contínua apresenta a resposta de campo livre e a curva pontilhada apresenta a resposta de pressão. Resposta em frequência: ± 3 dB (10Hz-50Hz); ± 1 dB (50Hz-5kHz); e ± 2 dB (5kHz- 20kHz) 36	
Figura 4.7 – Transdutor ultrassônico H2-SE-20/0° 2MHz Eddytronic.....	36
Figura 4.8 – Sistema de aquisição NI 9234.....	37
Figura 4.9 – Sistema de aquisição multifuncional NI USB-6351	37
Figura 4.10 – Interface gráfica com o usuário em LabVIEW	40
Figura 4.11 – Diagrama de blocos do método proposto para extração de características.....	41

Figura 4.12 – Metodologia proposta para a segmentação dos dados em quadros de curto termo	41
Figura 4.13 – Metodologia proposta para a segmentação dos dados a partir da morfologia do cordão	42
Figura 4.14 – Árvore de decomposição por Wavelet para uma dimensão, divide o sinal (s) em coeficientes de aproximação (a_i) e detalhe (d_i) para cada nível	43
Figura 4.15 – Diagrama do algoritmo de decomposição <i>Wavelet</i>	43
Figura 4.16 – Posicionamento utilizado nos experimentos de soldagem. Onde β é o ângulo do eletrodo	44
Figura 4.17 – Dimensões da chapa de aço. Sulcos transversais com 12x2mm na superfície inferior da chapa de aço	44
Figura 4.18 – Cordões de solda executados por meio da estação de soldagem SMAW robotizada: (a) efetuados para otimizar os parâmetros de soldagem; (b) utilizados nos classificadores	46
Figura 4.19 – Estrutura hierárquica proposta para classificação de descontinuidades no cordão de solda.....	49
Figura 4.20 – Geometria típica de um cordão de solda e suas principais medidas: largura (L); reforço (R) e penetração (P)	52
Figura 5.1 – Cordão de solda nº 30 com representantes das três classes: cordão normal, cratera e perfuração; e respectivo sinal audível amostrado.....	55
Figura 5.2 – Cordão de solda nº 31 com representantes das três classes e respectivo sinal audível amostrado	56
Figura 5.3 – Cordão de solda nº 32 com representantes das três classes e respectivo sinal audível amostrado	56
Figura 5.4 – Cordão de solda nº 34 com representantes das três classes e respectivo sinal audível amostrado	57
Figura 5.5 – Cordão de solda nº 26 com representantes das classes normal e cratera, bem como o respectivo sinal audível amostrado.....	57
Figura 5.6 – Cordão de solda nº 27 com representantes das classes normal e cratera, bem como o respectivo sinal audível amostrado.....	58
Figura 5.7 – Cordão de solda nº 24 efetuado com os parâmetros de soldagem de corrente de 75A, velocidade de translação de 2,5mm/s e velocidade de mergulho do eletrodo de 3,3mm/s	59
Figura 5.8 – Cordão de solda nº 25 efetuado com os parâmetros de soldagem de corrente de 75A, velocidade de translação de 2,5mm/s e velocidade de mergulho do eletrodo de 3,3mm/s	59

Figura 5.9 – Macrografia (10x) de cordão de solda da classe normal. Seção transversal C-C do cordão de solda nº 31 – Figura 5.2	60
Figura 5.10 – Macrografia (10x) de cordão de solda da classe normal. Seção transversal E-E do cordão de solda nº 32 – Figura 5.3	60
Figura 5.11 – Macrografia (10x) de cordão de solda da classe cratera. Seção transversal B-B do cordão de solda nº 31 – Figura 5.2	61
Figura 5.12 – Macrografia (10x) de cordão de solda da classe cratera. Seção transversal G-G do cordão de solda nº 34 – Figura 5.4	61
Figura 5.13 – Macrografia (10x) de cordão de solda da classe cratera. Seção transversal K-K do cordão de solda nº 27 – Figura 5.6	61
Figura 5.14 – Macrografia (10x) de cordão de solda da classe cratera. Seção transversal L-L do cordão de solda nº 27 – Figura 5.6	62
Figura 5.15 – Macrografia (10x) de cordão de solda da classe cratera. Seção transversal M-M do cordão de solda nº 24 – Figura 5.7	62
Figura 5.16 – Macrografia (10x) de cordão de solda. Seção transversal O-O do cordão de solda nº 25 – Figura 5.8.....	63
Figura 5.17 – Macrografia (10x) de cordão de solda da classe normal. Seção longitudinal H-H do cordão de solda nº 34 – Figura 5.4	63
Figura 5.18 – Macrografia (10x) de cordão de solda da classe normal. Seção longitudinal I-I do cordão de solda nº 34 – Figura 5.4	64
Figura 5.19 – Macrografia (10x) da seção longitudinal A-A do cordão de solda nº 30 (Figura 5.1) e seu correspondente sinal audível.....	65
Figura 5.20 – Macrografia (10x) da seção longitudinal D-D do cordão de solda nº 31 (Figura 5.2) e seu correspondente sinal audível.....	65
Figura 5.21 – Macrografia (10x) da seção longitudinal F-F do cordão de solda nº 32 (Figura 5.3) e seu correspondente sinal audível.....	66
Figura 5.22 – Macrografia (10x) da seção longitudinal J-J do cordão de solda nº 26 (Figura 5.5) e seu correspondente sinal audível.....	66
Figura 5.23 – Macrografia (10x) da seção longitudinal N-N do cordão de solda nº 24 (Figura 5.7).....	66
Figura 5.24 – Micrografia (50x) da seção transversal C-C do cordão de solda nº 31 com as três regiões básicas: ZF, ZTA e MB	68
Figura 5.25 – Micrografia (200x) de região de ZF referente a seção transversal C-C do cordão de solda nº 31	68

Figura 5.26 – Micrografia (200x) de região de ZF referente a seção transversal E-E do cordão de solda nº 32	69
Figura 5.27 – Micrografia (200x) de região de ZF referente a seção longitudinal I-I do cordão de solda nº 34	69
Figura 5.28 – Micrografia (200x) de região de ZF referente a seção transversal B-B do cordão de solda nº 31	70
Figura 5.29 – Micrografia (200x) de região de ZF referente a seção longitudinal F-F do cordão de solda nº 32.....	71
Figura 5.30 – Micrografia (200x) de região de ZF referente a seção transversal G-G do cordão de solda nº 34	71
Figura 5.31 – Micrografia (200x) de região de ZF referente a seção transversal M-M do cordão de solda nº 24.....	72
Figura 5.32 – Micrografia (50x) da região com micro trinca no cordão de solda nº 31 (Figura 5.20).....	73
Figura 5.33 – Micrografia (50x) da região com micro trinca no cordão de solda nº 31 após ataque químico (Figura 5.20)	73
Figura 5.34 – Micrografia (50x) da região com micro trinca no cordão de solda nº 32 (Figura 5.21).....	74
Figura 5.35 – Micrografia (50x) da região com micro trinca no cordão de solda nº 32 após ataque químico (Figura 5.21)	74
Figura 5.36 – Micrografia (50x) da região com trinca no cordão de solda nº 26 (Figura 5.22)	75
Figura 5.37 – Micrografia (50x) da região com trinca no cordão de solda nº 26 após ataque químico (Figura 5.22).....	75
Figura 5.38 – Micrografia (50x) da região com trinca no cordão de solda nº 24 (Figura 5.23)	76
Figura 5.39 – Micrografia (50x) da região com trinca no cordão de solda nº 24 após ataque químico (Figura 5.23).....	76
Figura 5.40 – Pré-processamento do sinal audível do cordão de solda nº 12: (a) espectro do sinal obtido por meio de DFT; (b) reamostragem do espectro de frequências. O sinal da classe perfuração é referente à segunda descontinuidade do cordão; o sinal da classe cratera é referente à primeira descontinuidade do cordão; o sinal da classe normal é referente ao segundo trecho do cordão.....	77
Figura 5.41 – Pré-processamento do sinal audível do cordão de solda nº 20: (a) espectro do sinal obtido por meio de DFT; (b) reamostragem do espectro de frequências. O sinal da classe perfuração é referente à segunda descontinuidade do cordão; o sinal da classe cratera é	

referente à primeira descontinuidade do cordão; o sinal da classe normal é referente ao primeiro trecho do cordão	78
Figura 5.42 – Pré-processamento do sinal audível do cordão de solda nº 22: (a) espectro do sinal obtido por meio de DFT; (b) reamostragem do espectro de frequências. O sinal da classe perfuração é referente à segunda descontinuidade do cordão; o sinal da classe cratera é referente à terceira descontinuidade do cordão; o sinal da classe normal é referente ao segundo trecho do cordão.....	78
Figura 5.43 – Pré-processamento do sinal audível do cordão de solda nº 23: (a) espectro do sinal obtido por meio de DFT; (b) reamostragem do espectro de frequências. O sinal da classe perfuração é referente à segunda descontinuidade do cordão; o sinal da classe cratera é referente à primeira descontinuidade do cordão; o sinal da classe normal é referente ao segundo trecho do cordão.....	79
Figura 5.44 – Decomposição por Wavelet do sinal do cristal piezoelétrico referente às descontinuidades de cratera (a) e de perfuração (b) do cordão de solda nº 12. Sendo s o sinal, \mathbf{a}_6 a aproximação e \mathbf{d}_6 o detalhe para o sexto nível de decomposição	80
Figura 5.45 – Decomposição por Wavelet do sinal do cristal piezoelétrico referente às descontinuidades de cratera (a) e de perfuração (b) do cordão de solda nº 20. Sendo s o sinal, \mathbf{a}_6 a aproximação e \mathbf{d}_6 o detalhe para o sexto nível de decomposição	81
Figura 5.46 – Decomposição por Wavelet do sinal do cristal piezoelétrico referente às descontinuidades de cratera (a) e de perfuração (b) do cordão de solda nº 22. Sendo s o sinal, \mathbf{a}_6 a aproximação e \mathbf{d}_6 o detalhe para o sexto nível de decomposição	81
Figura 5.47 – Decomposição por Wavelet do sinal do cristal piezoelétrico referente às descontinuidades de cratera (a) e de perfuração (b) do cordão de solda nº 23. Sendo s o sinal, \mathbf{a}_6 a aproximação e \mathbf{d}_6 o detalhe para o sexto nível de decomposição	82
Figura 5.48 – Figura 5.48 – Imagens da poça de fusão das três classes: (a) normal; (b) cratera; e (c) perfuração.....	83
Figura 5.49 – Imagens da vista lateral: (a) antes do início do processo de soldagem; (b) durante a execução do processo de soldagem	83
Figura 5.50 – Cordões com trechos em realce que foram classificados incorretamente pelos modelos SVM (cordões 7, 22 e 23), HSVM (cordões 6, 7 e 16) e RNA (cordão 21).....	107
Figura 5.51 – Pré-processamento do sinal audível do cordão de solda nº 22: (a) espectro do sinal obtido por meio de DFT; (b) reamostragem do espectro de frequências. O sinal da classe perfuração é referente à segunda descontinuidade do cordão; o sinal da classe cratera é referente à primeira descontinuidade do cordão; o sinal da classe normal é referente ao segundo trecho do cordão.....	108

Lista de Tabelas

Tabela 4.1 – Composição química do aço comum SAE utilizado nos experimentos. Valores médios de três amostras.....	32
Tabela 4.2 – Composição química do eletrodo E 6013.....	33
Tabela 4.3 – Características do módulo NI 9234.....	38
Tabela 4.4 – Características do sistema de aquisição multifuncional NI USB-6351.....	39
Tabela 4.5 – Informações dos trechos dos cordões de solda utilizados nos classificadores (* sem dados de trechos da classe normal, cratera ou perfuração).....	47
Tabela 4.6 – Descontinuidades e seus respectivos requisitos de qualidade (D – baixo; C – médio; B – alto). Sendo h a altura ou largura da descontinuidade; b a largura do cordão; s a espessura do cordão de solda; t a espessura da placa; e d o diâmetro do poro.....	52
Tabela 5.1 – Medidas geométricas dos cordões de solda normal das macrografias das Figuras 5.9 e 5.10.....	60
Tabela 5.2 – Medidas geométricas do cordão de solda da macrografia da Figura 5.16.....	63
Tabela 5.3 – Vetores de características por classes (* sem dados do piezo).....	84
Tabela 5.4 – Resultado da SVM para as 10 primeiras sementes.....	84
Tabela 5.5 – Desempenho de classificação do classificador por SVM.....	85
Tabela 5.6 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da SVM e da HSVM (1º estágio).....	85
Tabela 5.7 – Vetores de características do sinal de emissão acústica aérea utilizados no teste por meio da SVM e da HSVM (1º estágio).....	90
Tabela 5.8 – Resultado da HSVM para as 10 primeiras sementes.....	92
Tabela 5.9 – Desempenho de classificação do classificador por HSVM – 1º estágio (sem fusão sensorial).....	93
Tabela 5.10 – Desempenho de classificação do classificador por HSVM – 2º estágio (com fusão sensorial).....	93
Tabela 5.11 – Vetores de características do sinal de emissão acústica aérea e do sinal de emissão acústica sólida utilizados no treinamento da HSVM (2º estágio).....	93
Tabela 5.12 – Vetores de características do sinal de emissão acústica aérea e de emissão acústica sólida utilizados no teste por meio da HSVM (2º estágio).....	95
Tabela 5.13 – Resultado da RNA para as 10 primeiras sementes.....	97

Tabela 5.14 – Desempenho de classificação do classificador por RNA	97
Tabela 5.15 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da RNA.....	98
Tabela 5.16 – Vetores de características do sinal de emissão acústica aérea utilizados na validação cruzada do treinamento da RNA.....	102
Tabela 5.17 – Vetores de características do sinal de emissão acústica aérea utilizados no teste da RNA.....	103
Tabela 5.18 – Tempo de execução e acurácia global dos classificadores (* tempo de processamento de vetores de características de fusão sensorial). Cada segmento de dados corresponde a 1660ms de dados gravados	105

Lista de Notações

ANN – *Artificial Neural Network*

CA – Corrente Alternada

CC – Corrente Contínua

DAQ – Aquisição de Dados (*Data Acquisition*)

DECAT – Departamento de Engenharia de Controle e Automação e Técnicas Fundamentais

DEMET – Departamento de Engenharia Metalúrgica e de Materiais

DFT – Transformada de Fourier Discreta (*Discrete Fourier Transform*)

FET – Transistor de Efeito de Campo (*Field Effect Transistor*)

FFT – Transformada Rápida de Fourier (*Fast Fourier Transform*)

HSVM – Máquina de Vetor de Suporte Hierárquica (*Hierarchical Support Vector Machine*)

LESTA – Laboratório de Engenharia de Superfícies e Técnicas Afins

LTM – Laboratório de Tratamento Térmico e Microscopia Óptica

MB – Metal de Base

MLP – Perceptrons de Múltiplas Camadas (*MultiLayer Perceptron*)

PTZ – Titanato Zirconato de Chumbo

RMS – Raiz do Valor Quadrático Médio (*Root Mean Square*)

RNA – Rede Neural Artificial

SMAW – Soldagem por Eletrodos Revestidos (*Shielded Metal Arc Welding*)

SVM – Máquina de Vetor de Suporte (*Support Vector Machine*)

T_c – Temperatura Crítica

T_f – Temperatura de Fusão

TIG – Soldagem a Arco com Eletrodo de Tungstênio (*Tungsten Inert Gas*)

T_p – Temperatura de Pico

ZF – Zona Fundida

ZTA – Zona Termicamente Afetada

Resumo

Propõe-se neste trabalho uma nova metodologia para a detecção de descontinuidades no cordão de solda aplicado em processos de soldagem por eletrodos revestidos (SMAW). Para a execução dos experimentos e otimização de parâmetros do processo, foi desenvolvida uma estação de soldagem robotizada. O sistema de detecção baseia-se em dois sensores – um microfone e um cristal piezoelétrico – que adquirem as emissões acústicas geradas durante a soldagem. Os vetores de características extraídos do conjunto de dados dos sensores são usados para construir os modelos dos classificadores. As abordagens baseadas nos classificadores de Rede Neural Artificial (RNA) e de Máquina de Vetor de Suporte (SVM) são capazes de identificar com alta acurácia as três classes propostas de cordões de solda: cordão de solda normal, e descontinuidades de cratera e de perfuração. Os resultados experimentais ilustram a acurácia do sistema, superior a 83% para cada classe. Uma nova estrutura de máquinas de suporte hierárquico (HSVM) é proposta para viabilizar o uso deste sistema em ambientes industriais. Esta abordagem apresentou 96,6% de acurácia global. Este sistema pode ser aplicado nas indústrias metal-mecânicas.

Palavras-chave: eletrodos – soldagem; instrumentos de medição; emissão acústica; testes não-destrutivos; aprendizado do computador.

Abstract

One proposes in this work a new methodology for the detection of discontinuities in the weld bead applied in Shielded Metal Arc Welding (SMAW) processes. A robotized welding station was developed for the execution of the experiments and optimization of process parameters. The detection system is based on two sensors – a microphone and piezoelectric – that acquire acoustic emissions generated during the welding. The feature vectors extracted from the sensor dataset are used to construct classifier models. The approaches based on Artificial Neural Network (ANN) and Support Vector Machine (SVM) classifiers are able to identify with high accuracy the three proposed weld bead classes: desirable weld bead, shrinkage cavity and burn through discontinuities. Experimental results illustrate the system's accuracy, greater than 83% for each class. A novel Hierarchical Support Vector Machine (HSVM) structure is proposed to make feasible the use of this system in industrial environments. This approach presented 96.6% overall accuracy. This system can be applied in the metal-mechanical industries.

Keywords: shielded metal arc welding; instrumentation; acoustic emissions; non-destructive testing; machine learning.

1. Introdução

O processo de soldagem por eletrodos revestidos (SMAW) é uma forma simples, de baixo custo e adequada para unir a maioria dos metais e ligas comumente utilizados na indústria (O'Brien, 2004). Devido a essas características, o SMAW é o principal processo de união permanente utilizado nos países em desenvolvimento, como Índia, China e em toda a América Latina (Paul, 2016). Por outro lado, apresenta algumas desvantagens, tais como: ser um processo predominantemente manual, de baixa produtividade, de difícil repetibilidade e controle de qualidade.

A fim de aumentar a repetibilidade e melhorar a qualidade do cordão de solda, Lima II e Bracarense (2010) propuseram a robotização do processo, considerando a variação do centro da ferramenta durante a geração de trajetória. Ao substituir os dispositivos manuais por automáticos, é necessário implementar um controlador com base no conhecimento do processo. Para o processo SMAW, isso envolve uma abordagem multidisciplinar com emparelhamento complexo de variáveis entrada-saída (Paul, 2013). Portanto, instrumentação e modelagem são questões chave para a eficiente implementação desses controladores (Shi *et al.*, 2015).

Nessa linha, a quarta revolução industrial, conhecida por Indústria 4.0, destaca-se como propulsora de inovação tecnológica na indústria. Esse termo foi inicialmente utilizado em 2011 na Alemanha, como estratégia para desenvolvimento de tecnologia para a manufatura do país (Ogawa, 2017). Desde então, essa revolução recebeu diferentes nomes por todo mundo, e diferentes princípios foram agregados. Pode-se afirmar que a Indústria 4.0 tem como cerne a comunicação entre as máquinas, sistemas e ativos, propiciada pelo advento das redes digitais. A expectativa é que a tomada de decisões seja autônoma, tendo como base a transformação de informação em conhecimento. Esse cenário foi a motivação para o desenvolvimento do presente trabalho, que tem como base o uso de tecnologias para extrair informações do processo SMAW e a tomada de decisão autônoma na qualificação do cordão de solda.

Na indústria, as técnicas de controle de qualidade por meio de ensaios (testes) não destrutivos são predominantes. Krolczyk *et al.* (2015) discutiram algumas tendências em técnicas não destrutivas para diagnóstico de solda e avaliaram o uso de perfilômetro óptico 3D, raios X e tomografia computadorizada para inspeções topográficas. O monitoramento do processo de soldagem é hoje um dos mais importantes temas de pesquisa industrial. Atualmente, a maioria dos sistemas industriais usados para monitorar processos de soldagem adotam sensores com dinâmica rápida e custo relativamente baixo, como fotodiodos, pirômetros e microfones (You, Gao e Katayama, 2014). Os fotodiodos são associados com

filtros para limitar os sinais aos comprimentos de onda de luz de interesse. Sua principal desvantagem é a baixa eficiência na identificação de pequenos defeitos. Os pirômetros mostram a temperatura da poça de solda. No entanto, eles têm capacidade limitada para detecção de descontinuidades e necessitam de cuidados na calibração da emissividade. Já o microfone é muito sensível a ruídos em ambiente industrial. Em contrapartida, o som emitido por meio da interação do arco com a peça de trabalho é um sinal promissor para a qualificação do cordão de solda. Segundo Sansan *et al.* (2010), esse sinal pode ser filtrado usando a técnica de separação de fonte cega, ou pode-se realizar uma fusão sensorial, associando o sinal do microfone a outro sinal de processo (Alfaro e Cayo, 2012).

Uma pesquisa recente propôs o uso de transdutor ultrassônico para diagnosticar falhas de falta de fusão e formação de trincas em processos de soldagem a arco com eletrodo de tungstênio (TIG) (Apasov e Apasov, 2012). Esses transdutores em geral são constituídos de cristais piezoelétricos, que operam em altas frequências, sendo menos sensíveis a distúrbios. No entanto, sua aplicação em técnicas não destrutivas convencionais apresenta algumas restrições operacionais (Manjula *et al.*, 2012). Vale ressaltar, por sua vez, que o uso de sensores visuais está se tornando mais comum no monitoramento de processos de soldagem, em função da redução de seus custos. A precisão de detecção visual depende fortemente do algoritmo de reconhecimento de padrões (You, Gao e Katayama, 2014). Uma alternativa de baixo custo para a detecção de descontinuidades por meio de características ópticas é o uso de espectrômetro industrial (You, Gao e Katayama, 2015). Entretanto, em geral, espectrômetro e sensores visuais operam em baixas frequências de amostragem. Ademais, segundo Schmidt, Otto e Kägeler (2013), é necessária uma frequência de amostragem de 2kHz, para que as características ópticas de uma poça de fusão sejam preservadas.

Diferentes topologias de Redes Neurais Artificiais (RNA) foram extensivamente exploradas para prever a geometria do cordão de solda (largura, reforço e penetração). Andersen *et al.* (1990) conduziram um dos estudos pioneiros com RNA em processos de soldagem a arco. Seu trabalho foi realizado usando o algoritmo de treinamento supervisionado por retropropagação de erros da rede neural artificial, para prever as geometrias do cordão de solda a partir dos parâmetros do processo TIG. Mais tarde, esses pesquisadores exploraram a aplicação da RNA em soldagem a arco plasma com polaridade variável (Cook *et al.*, 1995). Eles propuseram o uso de algumas estruturas de RNA para localizar descontinuidades de mordeduras, bem como determinar parâmetros geométricos do cordão, a partir de informações do perfil transversal do cordão de solda. Nagesh e Datta (2002) empregaram o algoritmo de retropropagação para prever a geometria de cordões a partir de parâmetros SMAW.

Outras pesquisas relacionadas ao uso de RNA para a predição de imperfeições em cordões de solda obtidos por processo de soldagem a arco foram realizadas. Sterjovski *et al.* (2007) descreveram os resultados obtidos com dois modelos de RNA para assistir ao processo de soldagem a arco com arame tubular. Primeiro, implementaram uma estrutura de RNA por retropropagação para prever o hidrogênio difusível com base nos parâmetros do processo. Em seguida, propuseram uma RNA probabilística para prever a ocorrência de trinca a frio por hidrogênio em um cordão depositado transversalmente a uma ranhura em uma chapa de aço. Mirapeix *et al.* (2007) investigaram a classificação de diferentes casos de falta de fusão no processo de soldagem TIG por meio da análise espectroscópica dos espectros emitidos pelo plasma, utilizando o método de Análise de Componentes Principais, para a extração de características de medições do espectrômetro e a classificação dos cordões de solda por meio de RNA por retropropagação. Posteriormente, Garcia-Allende *et al.* (2008) relataram algumas vantagens de se usar algoritmo de busca sequencial flutuante para frente para a extração de características. Kumar *et al.* (2016) estudaram o uso de um osciloscópio de armazenamento digital para avaliar o desempenho de fontes de energia de SMAW e assistir o processo de treinamento de soldadores usando modelos de redes neurais de mapas auto-organizáveis. O principal desafio para o uso de osciloscópio digital é sua amostragem limitada, já que é inadequada para variáveis que requerem altas taxas de amostragem, como por exemplo sensor piezoelétrico. Para o mesmo processo, Paul (2016) propôs o uso do controlador de modo deslizante de segunda ordem para otimizar a corrente da fonte de energia, em função de variação do comprimento do arco que é inerente do processo e influencia na qualidade do cordão.

Ancona *et al.* (2002) apresentaram uma técnica de inteligência computacional, que tem como base um algoritmo que compara a temperatura do plasma do processo de soldagem a laser com uma faixa de valores definida durante o modo de auto-aprendizagem, e que, posteriormente, foi implementado para monitoramento em tempo real da qualidade do cordão de solda no processo TIG (Mirapeix *et al.*, 2009). Outra técnica que se destacou na última década para modelagem de classificadores foi, e é, a Máquina de Vetor de Suporte (SVM). Segundo Schölkopf e Smola (2002), a SVM apresenta um desempenho igual ou superior à da RNA em uma ampla variedade de aplicações. Huang *et al.* (2017) investigaram o uso de classificador SVM para detecção de porosidade em soldas do processo TIG. Eles relataram o emprego de decomposição de modo empírico para a extração de características do sinal de um espectrômetro, e o uso de algoritmo genético para selecionar os parâmetros do classificador.

No entanto, tem-se observado que, o estado da arte de monitoramento e tratamento de dados de processos de soldagem não está consolidado. Diversos trabalhos foram realizados nas

últimas décadas, e em sua maioria limitam a aplicações laboratoriais com condições de ambiente controlado. Além disso, apresentam restrições operacionais ou de processo.

No presente trabalho, propõe-se o uso de técnicas de aprendizagem de máquinas (computador) para detecção de descontinuidades no cordão de solda do processo SMAW, tendo como contribuições o uso de máquina de vetor de suporte e uma inovadora estrutura hierárquica desse classificador, que agrega robustez ao sistema e possibilita o seu emprego em ambiente industrial.

O texto desta tese encontra-se organizado da seguinte forma. No Capítulo 1 é apresentado o estado da arte do monitoramento de processos de soldagem. No Capítulo 2 são apresentados os objetivos deste trabalho. No Capítulo 3 é efetuada a revisão bibliográfica de temas relacionados ao trabalho, e.g., soldagem com eletrodos revestidos, aspectos metalúrgicos relacionados ao processo, instrumentação, aprendizado de máquinas e robotização do processo. No Capítulo 4 são apresentados os materiais utilizados e os métodos adotados para a realização dos experimentos e avaliação dos resultados. No Capítulo 5 são apresentados os resultados experimentais, os cordões de solda e suas descontinuidades são caracterizadas por meio de metalografia, os sinais amostrados e seus respectivos pré-processamentos são analisados, os resultados de classificação de padrões são apresentados e discutidos. No Capítulo 6 são apresentadas as conclusões, as contribuições originais ao conhecimento e a relevância dos resultados. No Capítulo 7 são propostas sugestões para trabalhos futuros.

2. Objetivos

Objetiva-se com este trabalho implementar uma nova metodologia, por meio de aprendizado de máquinas, para a qualificação de cordões de solda no processo de soldagem por eletrodos revestidos.

2.1 Objetivos Específicos

1. Desenvolver estação de soldagem robotizada que possibilite a otimização de parâmetros do processo SMAW;

2. Implementar um sistema de aquisição de dados para a amostragem de emissões acústicas aéreas e sólidas, respectivamente por meio de microfone e cristal piezoelétrico;

3. Extrair características dos sinais amostrados no processo SMAW;

4. Avaliar os experimentos e os sinais amostrados;

5. Determinar estrutura de classificador de padrões por máquina de vetor de suporte hierárquica (HSVM) com fusão sensorial para detecção de descontinuidades do tipo perfuração e cratera no cordão de solda;

6. Avaliar os resultados dos modelos SVM, HSVM e RNA para qualificação de cordões de solda.

3. Revisão Bibliográfica

Será apresentada neste capítulo a revisão de literatura relacionada às áreas de conhecimento do presente trabalho.

3.1 Soldagem com Eletrodos Revestidos

A soldagem com eletrodos revestidos (SMAW) é um dos processos de soldagem por fusão, cuja fonte de energia usada para união dos metais é o arco elétrico. Os processos de soldagem a arco são os de maior relevância na indústria (Marques; Modenesi e Bracarense, 2009). Durante o processo SMAW, o metal de adição é fornecido pelo eletrodo ao metal de base, por meio de fusão de ambos, para formar a poça de fusão (Figura 3.1).

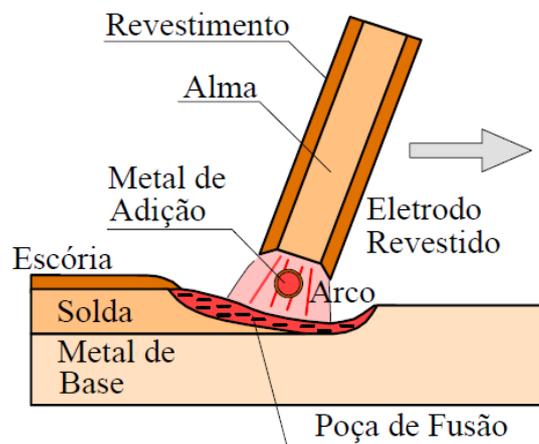


Figura 3.1 – Representação esquemática de soldagem com eletrodo revestido. Fonte: Marques; Modenesi e Bracarense, 2009.

O processo SMAW é efetuado por meio de uma fonte de energia conectada em um circuito com um eletrodo e o metal de base em série (Figura 3.2). Essa fonte de energia pode ser de Corrente Alternada (CA) ou de Corrente Contínua (CC), com saída de tensão ou corrente constante. Apresentam ciclo de trabalho de aproximadamente 60% em aplicações industriais, e de aproximadamente 20% em uso doméstico ou em pequenas empresas. O tempo ocioso do ciclo de trabalho é necessário para resfriamento da fonte. Outros elementos importantes no circuito são os cabos (alimentação e retorno), o porta-eletrodos e o elemento de fixação do metal de base ao cabo de retorno.

O eletrodo revestido é composto por um núcleo metálico (alma) coberto por um revestimento, tendo como principais funções na soldagem: (1) manter o arco estável; (2) adicionar elementos de liga; (3) eliminar impurezas; (4) proteger a poça de fusão por meio do

arco elétrico e da deposição de escória sobre o cordão; e (5) influenciar nas propriedades mecânicas da solda. Os eletrodos são classificados de acordo com seu revestimento, que podem ser do tipo oxidante, ácido, rútilico, básico ou celulósico. Cada tipo de revestimento promove uma ação predominante no processo (estabilidade do arco, ajuste da composição química do cordão, proteção da poça de fusão e penetração) e possui suas respectivas restrições de operação (fonte de energia e posição de soldagem).

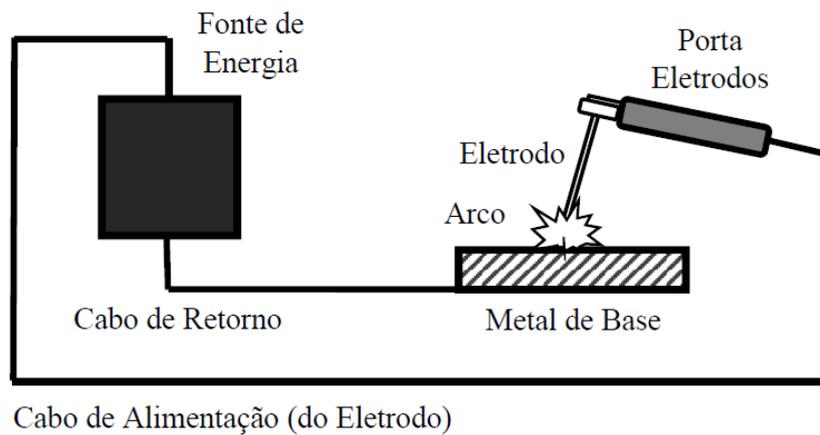


Figura 3.2 – Elementos típicos que compõem circuito do processo SMAW. Fonte: Autor.

A soldagem é predominantemente manual, com algumas automações do processo por dispositivo mecânico (soldagem por gravidade) e por robôs. As principais variáveis do processo são corrente, comprimento do arco e velocidade de soldagem.

3.1.1 Vantagens do Processo

Dentre as vantagens do processo SMAW podemos citar:

1. Capacidade de soldar ampla variedade de metais e ligas;
2. Equipamento relativamente simples;
3. Portabilidade do equipamento;
4. Custo relativamente baixo;
5. Menor sensibilidade à ação de ventos.

3.1.2 Limitações do Processo

Em contrapartida, o processo possui algumas limitações, cujas principais são:

1. Baixa produtividade;
2. Operação manual majoritária;

3. Restrições para soldagem de metais de baixo ponto de fusão, metais refratários ou muito reativos, bem como em chapas delgadas;
4. Necessidade de treinamento e destreza do operador (operação manual);
5. As chapas podem apresentar deformações em função do aquecimento durante o processo de soldagem.

3.2 Conceitos da Metalurgia da Soldagem

Nesta seção serão discutidos fenômenos metalúrgicos que influenciam nas propriedades do aço. O diagrama de equilíbrio ferro-carbono, bem como o tema referente ao fluxo de calor na soldagem serão apresentados para discussão da macro e microestrutura do material após o processo de soldagem.

3.2.1 Transformações de Fases em Aço de Baixo Carbono

Os aços são definidos como ligas de ferro contendo um teor inferior a 2,06% de carbono. Em geral, os aços de baixo carbono, que são comumente encontrados no mercado, possuem um teor de até 0,2% de carbono. Como exemplo, podemos citar as ligas SAE 1006, 1010, 1015, 1018 e 1020.

Neste trabalho, o diagrama de equilíbrio Fe-C é uma importante ferramenta para analisar a formação da microestrutura do cordão. Na Figura 3.3 tem-se representado as transformações de fases de um aço hipoeutetóide no diagrama de equilíbrio Fe-C. Aços hipoeutetóides possuem um teor de carbono no intervalo de 0,022% até 0,76% (Callister e Rethwisch, 2014) e, à temperatura ambiente, são constituídos basicamente por ferrita (α) e perlita (composta pelas fases de ferrita e de cementita – Fe_3C , dispostas em forma de lamelas alternadas).

Para os aços de baixo carbono, as transformações de fases podem ser descritas da seguinte forma: (1) acima da linha MO (ponto c) do diagrama Fe-C (Figura 3.3) tem-se a presença de austenita (γ), onde o ferro apresenta uma estrutura cristalina Cúbica de Face Centrada (CFC); (2) abaixo da linha MO (ponto d), com o resfriamento da liga, ocorre a formação de ferrita, com estrutura cristalina Cúbica de Corpo Centrado (CCC), a partir da austenita; (3) a ferrita cresce ao longo do resfriamento (ponto e); (4) abaixo da linha NO (e.g., ponto f) toda a austenita é convertida em perlita. A ferrita presente antes da temperatura de eutetóide (T_e) é denominada de proeutetóide e a formada a partir da austenita abaixo dessa temperatura é denominada de eutetóide.

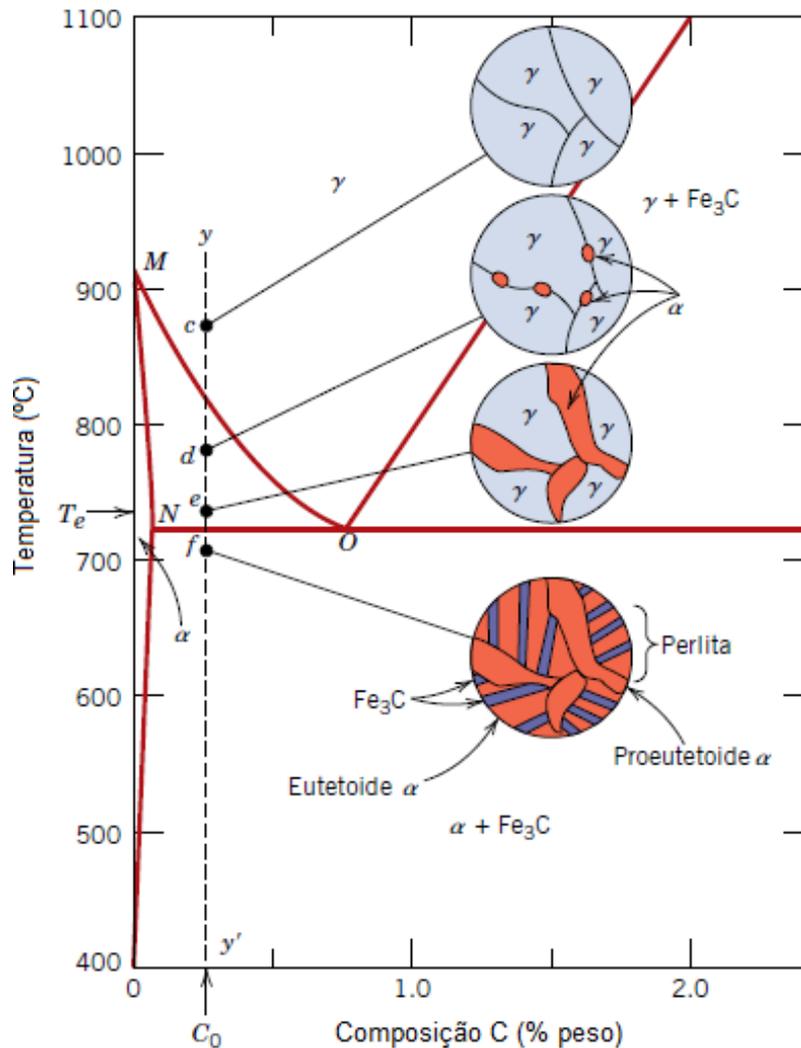


Figura 3.3 – Diagrama Fe-C com representação esquemática de microestruturas para uma liga de aço carbono hipoeutetóide. Fonte (adaptado): Callister e Rethwisch, 2014.

3.2.2 Fluxo de Calor

O fluxo de calor na soldagem possui relação direta com alterações nas estruturas do cordão de solda e de suas regiões adjacentes. Dois estágios estão relacionados ao fluxo de calor: (1) fornecimento de calor à junta; e (2) dissipação de calor no metal de base.

O primeiro estágio relaciona-se à energia de soldagem, que é definida como a quantidade de energia liberada pela fonte de calor por unidade de comprimento da solda (Scotti, Reis e Liskevych, 2012). Neste trabalho, o arco é a única fonte de calor, sendo sua energia líquida de soldagem expressa por:

$$H_L = \frac{\zeta VI}{v} \quad (3.1)$$

onde H_L é a energia líquida de soldagem, em J/mm , que considera o fator adimensional de rendimento ζ ; V é a tensão de soldagem, em Volts; I é a corrente de soldagem, em Ampères; e v é a velocidade de soldagem, em mm/s . Segundo Marques e Modenesi (2014) o fator adimensional de rendimento da energia líquida para o processo SMAW encontra-se no intervalo de 0,65 a 0,85. Vale ressaltar que diversos parâmetros operacionais influenciam no rendimento térmico do processo, e.g., ângulo do eletrodo, corrente de soldagem, comprimento do arco e polaridade do eletrodo.

No segundo estágio, a forma predominante de dissipação de calor no metal de base é por condução. Considere que seja traçada uma linha transversal ao cordão de solda. Para cada ponto nessa linha teremos associada uma curva térmica que representa o aquecimento pela passagem da fonte de calor e a dissipação de calor no metal de base. Essa curva é denominada ciclo térmico de soldagem, e possui informações importantes relacionadas à temperatura de pico, tempo de permanência acima da temperatura crítica e velocidade de resfriamento. Associando-se a temperatura máxima alcançada em cada ponto em função da distância do cordão de solda, obtêm-se a curva de repartição térmica, cujo diagrama esquemático encontra-se representado na Figura 3.4.

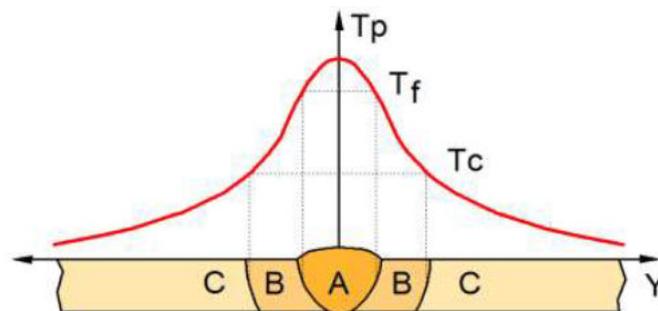


Figura 3.4 – Curva de repartição térmica e regiões de uma solda por fusão. A – Zona Fundida (ZF), B – Zona Termicamente Afetada (ZTA), C – Metal de Base (MB), T_p – Temperatura de Pico, T_f – Temperatura de Fusão e T_c – Temperatura Crítica. Fonte: Marques, Modenesi e Bracarense (2009).

A partir da representação esquemática da Figura 3.4 pode-se analisar as alterações estruturais em três regiões básicas: zona fundida (ZF); zona termicamente afetada (ZTA); e metal de base (MB). Na região da ZF, o material de base é fundido, pois as temperaturas de pico são superiores à temperatura de fusão. A interface da ZF com a ZTA é caracterizada pela presença de grãos colunares na raiz da ZF. Na região da ZTA, as temperaturas alcançadas estão no intervalo da temperatura crítica e da temperatura de fusão. Portanto, não há fusão. Entretanto,

ocorrem alterações em sua microestrutura caracterizadas pelo crescimento dos grãos. No MB, como as temperaturas máximas são inferiores à temperatura crítica do material, não ocorrem alterações estruturais em função do ciclo térmico.

O tipo e a espessura do metal de base, a geometria da junta, a energia de soldagem e a temperatura inicial do metal de base influenciam na repartição térmica (Marques; Modenesi e Bracarense, 2009).

3.3 Instrumentação

Nesta seção serão apresentados os transdutores, bem como o princípio de funcionamento de seus respectivos elementos sensitivos utilizados neste trabalho.

3.3.1 Transdutor Microfone

Na execução manual de soldagem a arco, o operador é dependente das emissões acústicas aéreas para o controle do processo (Tam e Huissoon, 2005). Segundo Alfaro e Cayo (2012), os soldadores prestam atenção no regime permanente do sinal audível durante a soldagem. Esse sinal pode ser medido por meio da pressão sonora gerada pelo processo. O transdutor comumente utilizado para medida desse sinal é o microfone capacitivo. Segundo Mathew (2017), esse microfone foi amplamente utilizado nos últimos cinquenta anos no campo da instrumentação em função de sua confiabilidade.

O microfone capacitivo consiste em um diafragma metálico, placa do capacitor que deforma quando submetido a pressão, e uma placa fixa. O deslocamento do diafragma varia a distância entre as duas placas do capacitor (Figura 3.5), que altera a saída do sinal desse sensor. O sensor capacitivo tem como característica elevada sensibilidade para pequenos deslocamentos.

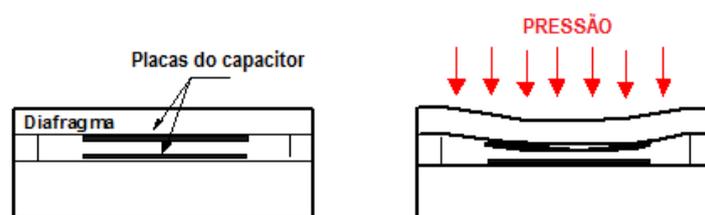


Figura 3.5 – Sensor de pressão capacitivo. Fonte (adaptado): García *et al.*, 2004.

Uma variação do microfone capacitivo é o microfone de eletreto, que dispensa a polarização externa. A cápsula (microfone) de eletreto é composta por um capacitor eletreto (elemento sensor) e um pré-amplificador integrado de baixa potência (Figura 3.6).

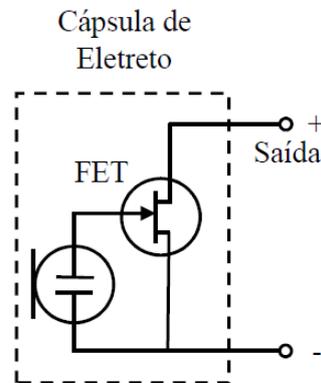


Figura 3.6 – Diagrama esquemático da cápsula de eletreto. Fonte: Autor.

O princípio de seu funcionamento pode ser descrito da seguinte maneira: a pressão sonora induz a vibração mecânica do diafragma; essa vibração altera a indução elétrica do capacitor formado pelo diafragma e o eletreto. Por sua vez, o sinal elétrico gerado é amplificado por meio de transistor de efeito de campo (FET).

3.3.2 Transdutor Ultrassônico

Transdutores ultrassônicos são comumente utilizados em ensaios não destrutivos tradicionais para detecção de discontinuidades em cordões de solda (Krolczyk *et al.*, 2015). Sua nomenclatura faz referência à capacidade de captação de frequências sonoras superiores ao espectro audível do ser humano, em um intervalo de 20kHz a 500MHz (García *et al.*, 2004), no qual o sinal é menos sujeito a perturbações do ambiente. Pesquisas relacionadas ao monitoramento de processo de soldagem a laser reportaram o uso de transdutores ultrassônicos para medir emissões acústicas sólidas nesse espectro de frequência (Hamann, Rosen e Labier, 1989; Wersborg *et al.*, 2009).

Tipicamente, os transdutores ultrassônicos utilizam cristais piezo elétricos como elemento sensor, que são obtidos por meio de elementos cerâmicos como o Titanato de Bário e Titanato Zirconato de Chumbo (PTZ).

O cristal piezo elétrico possui a propriedade de gerar carga elétrica quando submetido a algum tipo de deformação (Figura 3.7), sendo a corrente proporcional à frequência de variação da deformação (García *et al.*, 2004). Seu circuito elétrico equivalente consiste em um capacitor

ligado em série com uma fonte de tensão (Figura 3.8). Como consequência, ao conectar em sua saída um dispositivo de medida, cuja impedância real não é infinita, a carga gerada pelo cristal será dissipada nesse dispositivo em um curto período. Em função dessa característica, seu uso sem circuito de acondicionamento é limitado para medidas dinâmicas, i.e., medidas em que a força aplicada (pressão ou aceleração) sobre o cristal é variável.

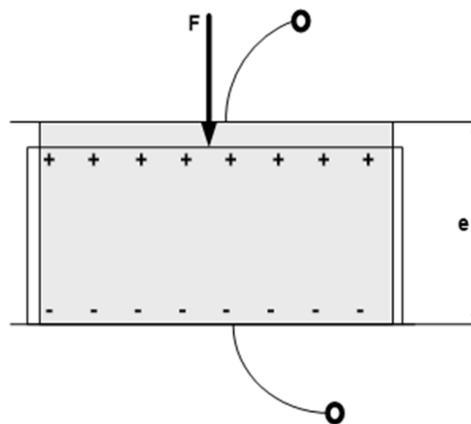


Figura 3.7 – A força aplicada sobre o cristal piezo elétrico provoca o surgimento de cargas.

Fonte: García *et al.*, 2004.

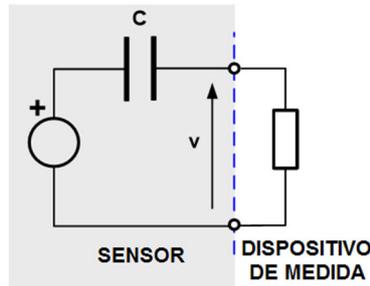


Figura 3.8 – Circuito equivalente simplificado de um sensor piezo elétrico. Fonte (adaptado):

García *et al.*, 2004.

De acordo com García *et al.* (2004), quando se utiliza o sensor piezo elétrico para amostragem de vibrações é recomendada a fixação do cabo, a fim de evitar a geração de ruídos na conexão (efeito triboelétrico). Também recomendam minimizar o comprimento do cabo, uma vez que a capacitância do cabo minimiza a sensibilidade do circuito de instrumentação. Na figura 3.9 ilustra-se uma fixação típica do cabo de um transdutor ultrassônico.

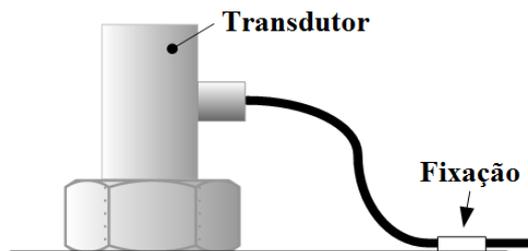


Figura 3.9 – Montagem recomendada de fixação de sensor piezo elétrico para medição de vibração. Fonte (adaptado): García *et al.*, 2004.

3.3.2.1 Emissão Acústica Sólida

A emissão acústica é um fenômeno de geração e propagação de ondas sonoras e ultrassônicas em materiais quando submetidos a processos de deformação e fratura. Segundo Beattie (2013), a emissão acústica sólida é resultante de uma rápida mudança no estado de tensão em uma região de um material. A energia é transmitida ao longo do material por meio do movimento cooperativo de uma série de átomos que o constituem. A propagação da onda de emissão acústica sólida depende de sua frequência, das propriedades do material, bem como da geometria da amostra. Elas propagam sob as mesmas regras que qualquer outra onda acústica (Beattie, 2013), diferenciando-se por propagar em meio sólido.

Por meio do monitoramento desse fenômeno, é possível detectar a formação de trincas, poros, falta de fusão e inclusão de materiais rígidos no cordão de solda. Segundo Wersborg *et al.* (2009), a amostragem desse sinal em frequências superiores a 375kHz permite identificar padrões de comportamentos associados à penetração do cordão. A formação de cada descontinuidade produz uma onda acústica transitória, e a sobreposição desses eventos transitórios pode resultar em um sinal de emissão acústica sólida quase contínuo (Beattie, 2013).

3.4 Sistema de Aquisição de Dados

Um sistema de aquisição de dados (DAQ) é o instrumento utilizado para obter informações de um determinado processo ou do estado de uma planta (García *et al.*, 2004). Ele pode ser baseado em microcomputador (com uma ou várias placas de aquisição de dados conectadas no barramento interno do microcomputador), baseado em sistemas de aquisição autônomos e independentes, e baseado em módulos de aquisição conectados em *rack*.

Os sistemas baseados em microcomputador não são adequados para trabalhar em ambiente industrial. Em aplicações onde a precisão e a confiabilidade são desejadas, recomenda-se o uso de sistemas de aquisição modulares ou autônomos e independentes.

Os circuitos de sistemas de aquisição de dados podem conter um conversor A/D compartilhado com mais de uma entrada (Figura 3.10) por meio de um multiplexador ou dispor de um conversor A/D para cada entrada analógica (Figura 3.11). No primeiro caso, as conversões dos sinais de entrada são executadas sequencialmente, o que restringe a velocidade máxima de aquisição de dados. Além desses componentes eletrônicos, circuitos de amostragem e retenção (S&H) e amplificadores de sinais estão presentes na placa de aquisição de dados. Dispositivos que incluem outras funcionalidades, e.g., saídas analógicas, entradas/saídas digitais, mecanismo de início de captura por evento externo (*trigger*), circuitos contadores e de temporização, são denominados por sistemas de aquisição multifuncionais.

Na seleção do dispositivo de aquisição de dados, é importante analisar sua velocidade de aquisição. De acordo com o teorema de Nyquist (Shannon, 1948), a frequência de amostragem deve ser pelo menos duas vezes a maior frequência do sinal a ser amostrado. Para evitar a superposição dos espectros do sinal amostrado (efeito *aliasing*), em função da sub-amostragem, alguns dispositivos dispõem de filtros *anti-aliasing* que podem ser configurados para uma determinada frequência de corte.

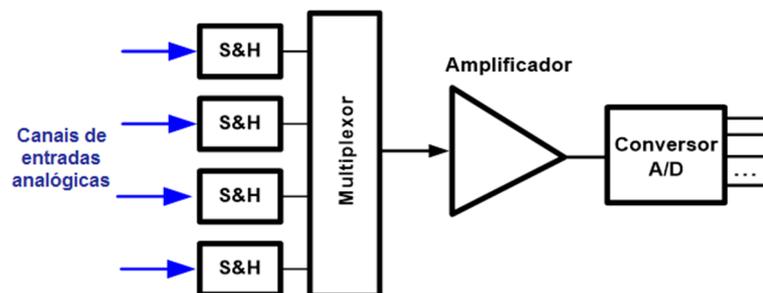


Figura 3.10 – Circuito de aquisição de dados com um conversor A/D compartilhado. Fonte (adaptado): García *et al.*, 2004.

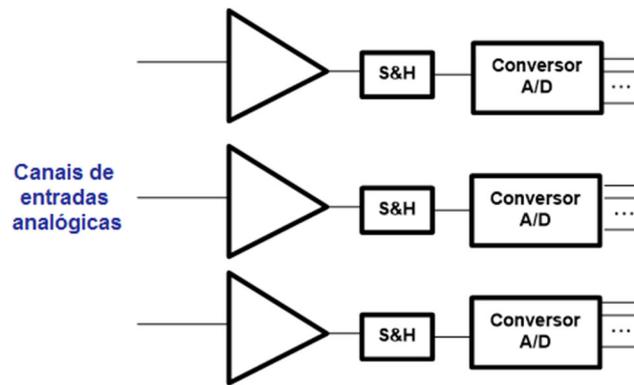


Figura 3.11 – Circuito de aquisição de dados conversores A/D independentes para cada entrada. Fonte (adaptado): García *et al.*, 2004.

3.5 Extração de Características

Segundo Kumar *et al.* (2014), uma característica é um valor que descreve um objeto na forma quantitativa, e a seleção das melhores representações de características é essencial para o sucesso de qualquer algoritmo de classificação. O processo de busca por características no conjunto de dados é denominado por extração de características, sendo uma etapa fundamental no reconhecimento de padrões no aprendizado de máquinas (Giannakopoulos e Pikrakis, 2014; Mitchell, 1997). Em geral, essas características possuem uma dimensão inferior ao do espaço de dados.

A primeira fase na extração de características consiste na segmentação dos dados, i.e., dividir o sinal em quadros de curto termo, de acordo com a seleção das características desejadas. A segunda etapa consiste em pré-processar os segmentos dos dados. Esse pré-processamento geralmente é efetuado por meio de transformadas que podem ou não ser associadas a outras funções. De acordo com Giannakopoulos e Pikrakis (2014), a maioria das características relevantes utilizadas para analisar o conteúdo de sinais de emissão acústica aérea são definidas no domínio da frequência. A Transformada de Fourier Discreta (DFT) possibilita essa análise no domínio da frequência, sendo considerada uma das ferramentas mais valiosas e frequentemente usadas no processamento e análise de sinais (Sibillano *et al.*, 2010). Na literatura tem-se o registro de uso da transformada *Wavelet* para a extração de características da emissão acústica sólida (Wersborg *et al.*, 2009). Segundo Sibillano *et al.* (2010), a transformada *Wavelet* é uma ferramenta promissora para o monitoramento de processos devido à sua capacidade fornecer informações no domínio do tempo e da frequência.

A partir de um conjunto inicial de características, procede-se para a etapa de seleção de características (discriminativas), que consiste no processo de escolha de características desejáveis. Essa tarefa é extremamente difícil e dependente do problema (Chang *et al.*, 1997).

3.6 Aprendizado de Máquina

O aprendizado de máquina possibilita a construção de modelos para predição de dados a partir de inferência por indução. Nele, o algoritmo retorna uma provável conclusão verdadeira a partir da observação de um padrão previamente conhecido de um conjunto de dados.

Neste trabalho foram usados classificadores que utilizam técnicas de aprendizado de máquinas supervisionado, que são baseadas na teoria de aprendizado estatístico. Em um primeiro estágio, a partir de um conjunto de dados de treinamento, que consiste em vetores de características cujos rótulos de suas classes são conhecidos, os parâmetros de um método de classificação são sintonizados para que o classificador “aprenda” esse conjunto de dados (Giannakopoulos e Pikrakis, 2014) – Figura 3.12.

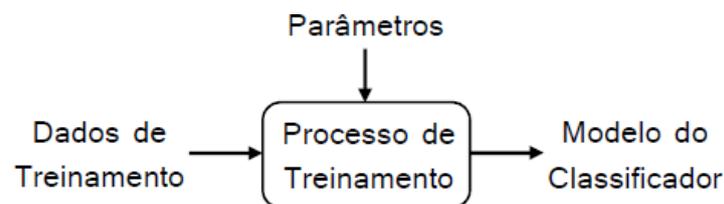


Figura 3.12 – Diagrama do processo de treinamento do classificador. Fonte: Autor.

Portanto, para o bom desempenho do classificador é importante que o conjunto de dados de treinamento seja representativo para cada uma das classes consideradas. A eficácia do treinamento pode ser mensurada pelo cálculo do erro de treinamento. Entretanto, vale ressaltar que um baixo erro de treinamento não garante um baixo erro de teste (Schölkopf e Smola, 2002). Mais importante do que ter um baixo erro de treinamento é o classificador ter capacidade de generalização, i.e., que o classificador tenha a habilidade de prever corretamente as classes de novos dados.

Uma vez obtido o modelo do classificador, pode-se utilizá-lo para classificar os padrões a partir do conjunto de dados de teste. Neste segundo estágio, os vetores de características são alimentados na entrada do classificador (Figura 3.13), e deseja-se que os resultados de classificação não sejam distantes de seus respectivos verdadeiros rótulos das classes. Os dados de treinamento e de teste devem ser distintos, para que o resultado do classificador seja confiável.

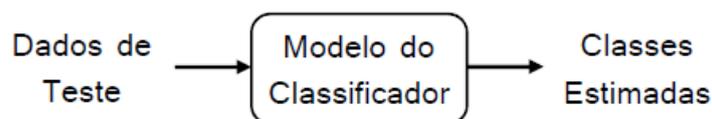


Figura 3.13 – Diagrama do processo de classificação. A entrada do classificador é alimentada por vetores de características e, em sua saída tem-se as classes estimadas. Fonte: Autor.

3.6.1 Conceitos Básicos de Aprendizado Estatístico

Nesta subseção serão apresentados conceitos básicos de aprendizado estatístico, que norteiam os algoritmos de reconhecimento de padrão.

Dado um conjunto de treinamento composto por duas classes ponto e círculo, o objetivo do processo de aprendizado é encontrar uma função que permita separar estas classes. Essa função também pode ser denominada de fronteira de decisão ou de classificador. Na Figura 3.14 tem-se ilustradas três propostas de traçado para a fronteira de decisão.

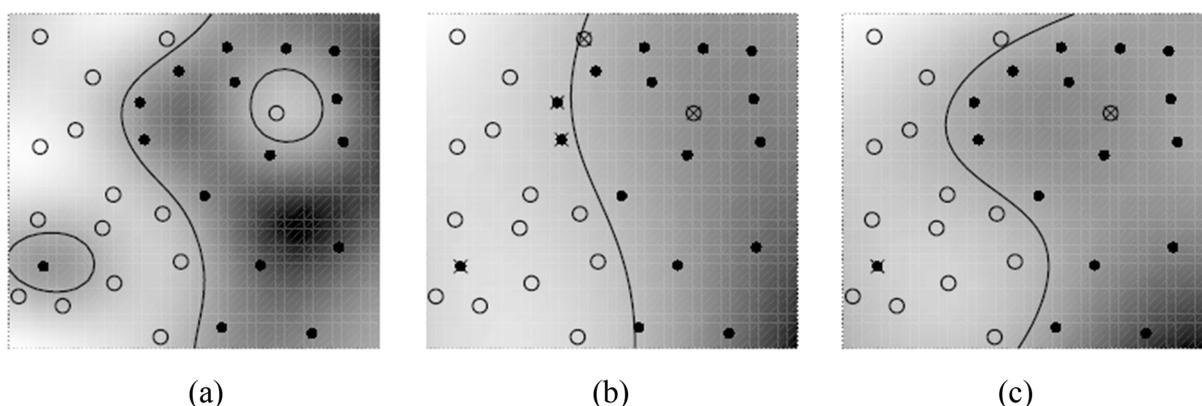


Figura 3.14 – Exemplo bidimensional de classificação binária solucionada por meio de três modelos distintos de classificadores. Fonte (adaptado): Schölkopf e Smola, 2002.

Na primeira proposta (Figura 3.14a) de traçado para a fronteira, tem-se um classificador que separa corretamente todos os dados do treinamento. Esse é o típico caso de super-ajuste do modelo aos dados de treinamento, no qual o erro de treinamento é nulo. Modelos excessivamente ajustados possuem elevada susceptibilidade de cometer erros na classificação dos dados de teste (Lorena e Carvalho, 2007). Para evitar essa situação, precisa-se optar por um modelo com maior capacidade de generalização.

A segunda proposta (Figura 3.14b) é uma fronteira de decisão quase linear. Entretanto, comete equívocos na classificação das duas classes, dentre eles, a classificação simples de pontos próximos à fronteira de decisão.

Com o intuito de evitar esses equívocos de classificação, a terceira proposta (Figura 3.14c) é mais atrativa. Nela, o modelo possui complexidade intermediária, classifica corretamente a maioria dos dados de treinamento e minimiza a influência de ruídos no processo de indução.

3.6.2 Classificação Binária e Multiclasse

Até o momento, abordamos conceitos relacionados à classificação de duas classes, conhecida como classificação binária. Para situações em que mais de duas classes são envolvidas, tem-se a tarefa de classificação multiclasse. Muitos métodos de classificação são projetados para operar com tarefas de classificação binária. A Máquina de Vetor de Suporte é um desses casos. Para lidar com cenário de multiclasse, a principal técnica é por meio de binarização, que consiste em treinar vários classificadores binários e posteriormente combiná-los, de modo que resultem em uma classificação multiclasse.

Os dois métodos de binarização mais relatados na literatura são (Giannakopoulos e Pikrakis, 2014):

- Um-contra-todos: um classificador binário é treinado por classe, tendo como objetivo que o classificador discrimine os dados de sua classe (exemplos positivos) em relação aos dados das demais classes (exemplos negativos). Desta forma, quando um dado de teste (dado desconhecido) é alimentado, ele é classificado na classe associada ao classificador binário que produzir a saída positiva.

- Um-contra-um: também conhecido como classificador em pares. Este método propõe a decomposição de multiclasse por meio do treinamento de classificadores que envolvem duas classes. Nesse estágio, uma classe recebe o rótulo positivo, e a outra, o negativo. O número de modelos é igual ao total de possíveis combinações de pares de classes. No estágio de classificação de um novo dado, a classe que acumular maior pontuação será a escolhida.

3.6.3 Máquinas de Vetor de Suporte

Este trabalho adota a Máquina de Vetor de Suporte (SVM), uma máquina linear proposta por Vapnik (1992), que corresponde a um dos classificadores mais bem-sucedidos em aplicações de aprendizado de máquinas (Giannakopoulos e Pikrakis, 2014). O princípio de funcionamento de SVM e suas estruturas de decisão serão apresentados nesta subseção.

Dado um conjunto de dados linearmente separáveis, o treinamento do classificador consiste na determinação de hiperplano (superfície de decisão) para separar os dados em

classes. Nesse caso, teremos três hiperplanos, o hiperplano separador e duas margens rígidas de separação das classes (hiperplanos paralelos ao primeiro) – Figura 3.15.

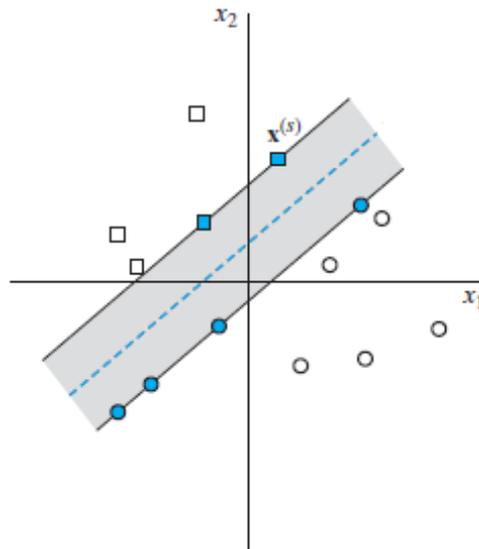


Figura 3.15 – Representação de SVM com margens rígidas no espaço \mathbb{R}^2 . Os dados estão representados em duas classes (classificação binária): quadrado e círculo. O hiperplano ótimo está representado por linha pontilhada. Os vetores de suporte estão realçados em azul. Fonte (adaptado): Haykin, 2009.

O método SVM busca por um hiperplano ótimo que maximiza a distância entre as margens de separação das classes dos dados de treinamento. Essa característica difere das redes neurais, cujo hiperplano de separação dos dados obtido pode não corresponder ao de maior margem de separação (Lorena e Carvalho, 2007). A principal restrição em uma SVM com margens rígidas é não haver dados entre as margens de separação das classes (Lorena e Carvalho, 2007). Os padrões mais próximos do hiperplano separador correspondem aos dados sobre as margens de separação das classes, que são denominados de vetores de suporte. Todos os demais dados de treinamento são irrelevantes na construção do modelo SVM, pois apenas os vetores de suporte contribuem na determinação do hiperplano separador (Schölkopf e Smola, 2002).

Na prática é difícil encontrar aplicações cujos padrões sejam linearmente separáveis, o que dificulta o uso de SVM com margens rígidas. Nesses casos, podem-se utilizar margens suaves de separação entre classes, que consiste em admitir dados entre as margens de separação, por meio da introdução de variáveis de folga e a ocorrência de alguns erros de classificação, por meio do parâmetro de regularização. Na Figura 3.16 tem-se a ilustração de duas situações

do emprego do SVM com margens suaves. Na primeira situação (Figura 3.16, a) tem-se uma classificação correta entre as margens de separação, e na segunda situação (Figura 3.16, b) tem-se uma classificação incorreta dos dados.

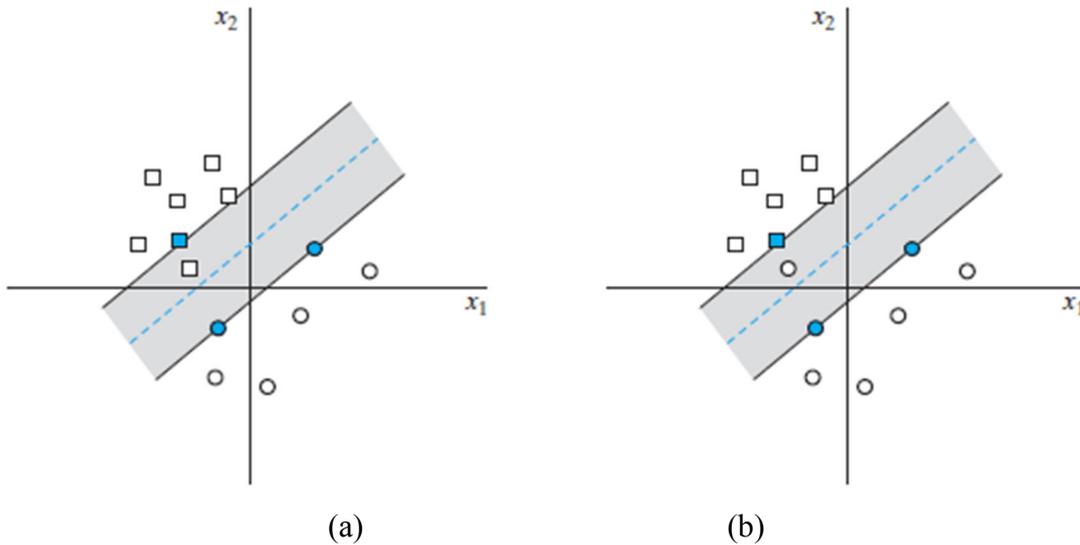


Figura 3.16 – Representação de SVM com margens suaves no espaço \mathbb{R}^2 . Em (a) tem-se um dado “quadrado” dentro da região de separação e do lado correto da superfície de decisão. Em (b) tem-se um dado “círculo” no lado errado da superfície de decisão. O hiperplano ótimo está representado por linha pontilhada. Os vetores de suporte estão realçados em azul. Fonte (adaptado): Haykin, 2009.

Nota-se que se os dados entre as margens não forem utilizados no conjunto de dados para o treinamento do classificador, a superfície de decisão não altera. O parâmetro de regularização, também conhecido como parâmetro de restrição C , relaciona o compromisso entre maximizar a distância entre as margens de separação das classes e minimizar o erro de treinamento. Esse parâmetro pode ser determinado de forma empírica ou analítica (Schölkopf e Smola, 2002). Basicamente, o aumento do valor do parâmetro de regularização resulta em uma separação mais rígida entre as classes, e o decréscimo do parâmetro em direção de zero (0) admite a ocorrência de um maior número de erros na classificação (MathWorks, 2017).

Em muitos casos não é possível separar de forma satisfatória os dados de treinamento por um hiperplano (Figura 3.17a). Nestas situações recorre-se à ideia da SVM de mapear os dados de treinamento para um espaço de características, de maior dimensão, por meio de uma função denominada *Kernel*. Esta transformação é computada por meio do núcleo de produto interno de dados do espaço de entrada de acordo com o tipo de *Kernel*. Segundo o teorema de

Cover, nesse novo espaço (de características) os padrões não-linearmente separáveis no espaço de entrada passam a ser linearmente separáveis (alta probabilidade), por meio de um hiperplano definido por uma função linear de vetores retirados do espaço de características, em vez do espaço de entrada original (Haykin, 2009).

Teoria de Cover: um problema de classificação de padrões não linear em um espaço de alta dimensão tem maior probabilidade de ser linearmente separável do que em um espaço de baixa dimensionalidade.

Na Figura 3.17 tem-se a ilustração do mapeamento dos dados no espaço de características, bem como a separação deles por um hiperplano.

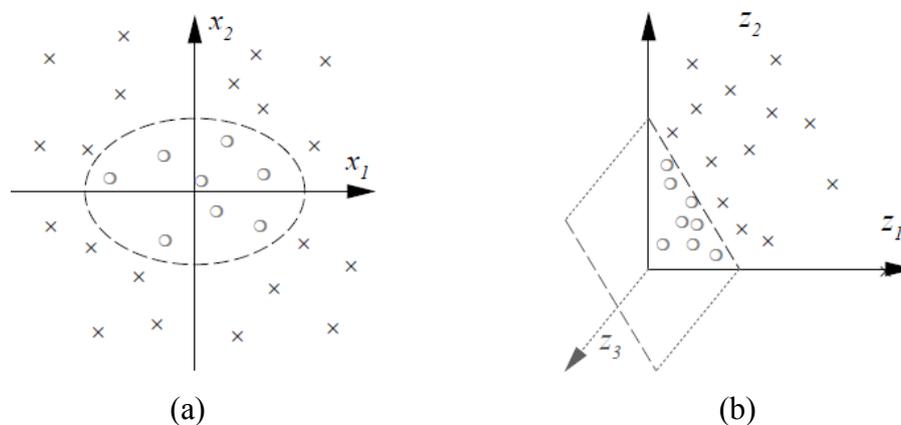


Figura 3.17 – Representação da ideia de SVM não-linear de mapear os dados de treinamento do (a) espaço de entrada em \mathbb{R}^2 em um espaço de maior dimensão (b) – espaço de características – em \mathbb{R}^3 ; e construir um hiperplano de separação (b). Fonte: Schölkopf e Smola (2002).

A arquitetura de uma máquina de vetor de suporte consiste em uma rede alimentada adiante com uma camada oculta de unidades não lineares – Figura 3.18 (Haykin, 2009). Essas unidades são núcleos de produto interno que mapeiam os dados de entrada no espaço de características, e solucionam a otimização numérica nesse espaço de acordo com o teorema de Mercer (Boser, Guyon e Vapnik, 1992).

Teorema de Mercer: seja k um núcleo de produto interno simétrico e contínuo. Então, existe uma base ortonormal (φ_i) e um conjunto de coeficientes positivos $(\lambda_i > 0)$, tal que a soma $\sum_{i=1}^{\infty} \lambda_i \varphi_i(x) \varphi_i(x')$, onde $x, y \in [a, b]$, converge absoluta e uniformemente para $k(x, x')$.

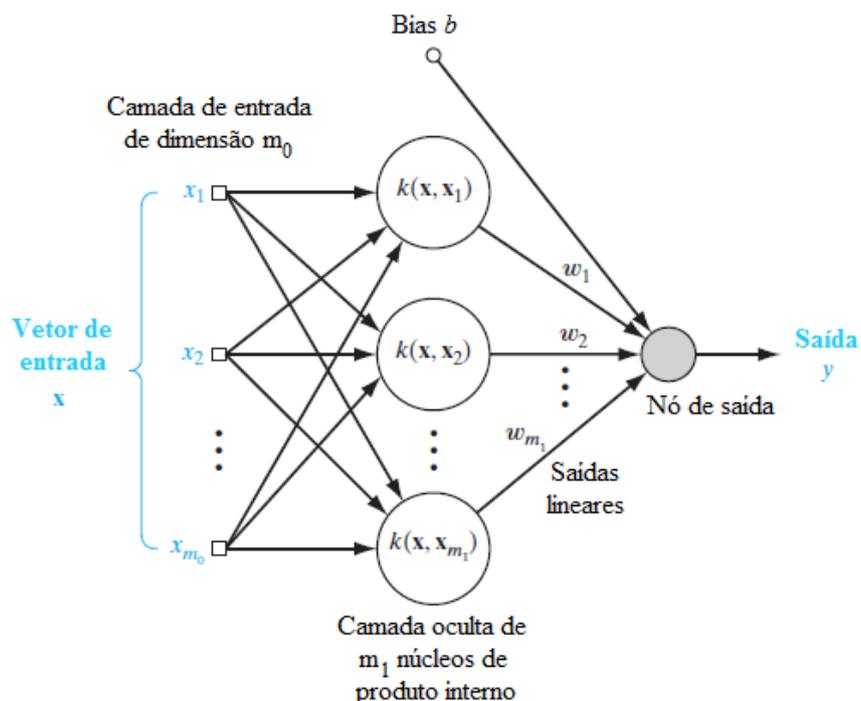


Figura 3.18 – Arquitetura da máquina de vetor de suporte. Fonte (adaptado): Haykin, 2009.

Outro ponto importante a ser abordado refere-se às estruturas de decisão de SVM. Dentre as estruturas presentes na literatura, destacam-se a convencional e a hierárquica. A convencional (Figura 3.19) é utilizada para a classificação binária ou multiclasse por meio de técnicas de binarização (subseção 3.6.2). Para lidar com classificações multiclasse, em especial para elevado número de classes, foi proposta a estrutura hierárquica (HSVM) ilustrada na Figura 3.20, que baseia em classificar dados a partir de duas meta-classes (Chen *et al.*, 2004).

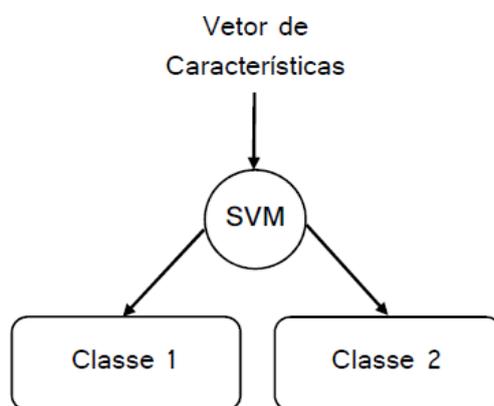


Figura 3.19 – Exemplo de estrutura de decisão binária de SVM. A partir de uma entrada, o dado é classificado entre duas classes (saídas). Para um maior número de classes é necessário o uso de técnicas de binarização. Fonte: Autor.

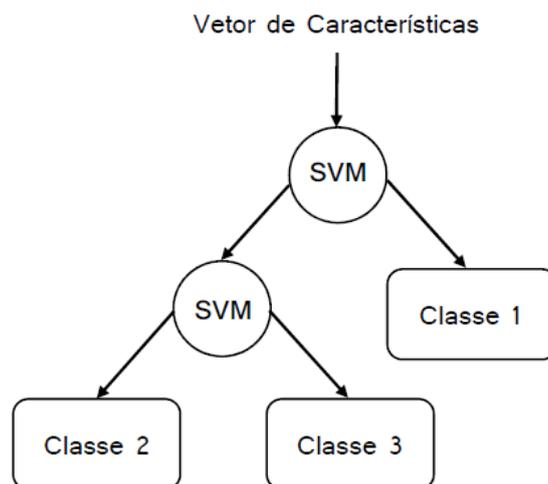


Figura 3.20 – Exemplo de estrutura hierárquica de máquina de vetor de suporte (HSVM).

Fonte: Autor.

3.6.4 Redes Neurais Artificiais

Para comparação de resultados da SVM, foi implementado um classificador por meio de Rede Neural Artificial (RNA), cujo modelo foi obtido pela técnica de aprendizagem por retropropagação de erros.

A unidade básica de processamento em RNA é o neurônio artificial (Figura 3.21) que tem como base o modelo proposto por McCulloch e Pitts (1943). As entradas representam os dendritos do neurônio biológico. Elas recebem os m sinais de entrada (x_1, x_2, \dots, x_m) . As sinapses (ou elos de conexão) são emuladas por meio de pesos (w_{kj}) , que podem assumir valores positivos ou negativos, e que são multiplicados por suas respectivas entradas $(j = [1, m])$. O corpo do neurônio biológico é representado por um combinador linear que realiza a soma ponderada dos sinais de entrada. Caso essa soma ultrapasse um limiar de excitação, ocorre o disparo de sinal pelo neurônio artificial, cuja condição está representada no diagrama de blocos pela função de ativação. Em geral, essa função é não-linear e limita o intervalo de amplitude do sinal de saída, sendo tipicamente representada por um intervalo unitário fechado $[0,1]$ ou $[-1,1]$ (Haykin, 2009). Na Figura 3.21, b_k representa um *bias*, que tem como função possibilitar o deslocamento do campo local induzido (potencial de ativação) v_k do neurônio k (Figura 3.22a). De forma análoga, em aplicações de classificação por meio de *perceptron*, o *bias* possibilita deslocar a fronteira de decisão em relação à origem (Figura 3.22b).

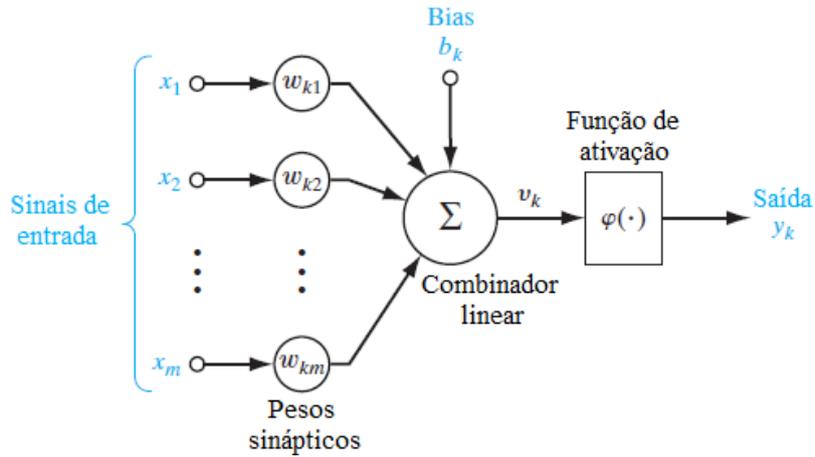


Figura 3.21 – Modelo não-linear de um neurônio artificial (nodo computacional), onde k é o índice referente ao neurônio. Fonte (adaptado): Haykin, 2009.

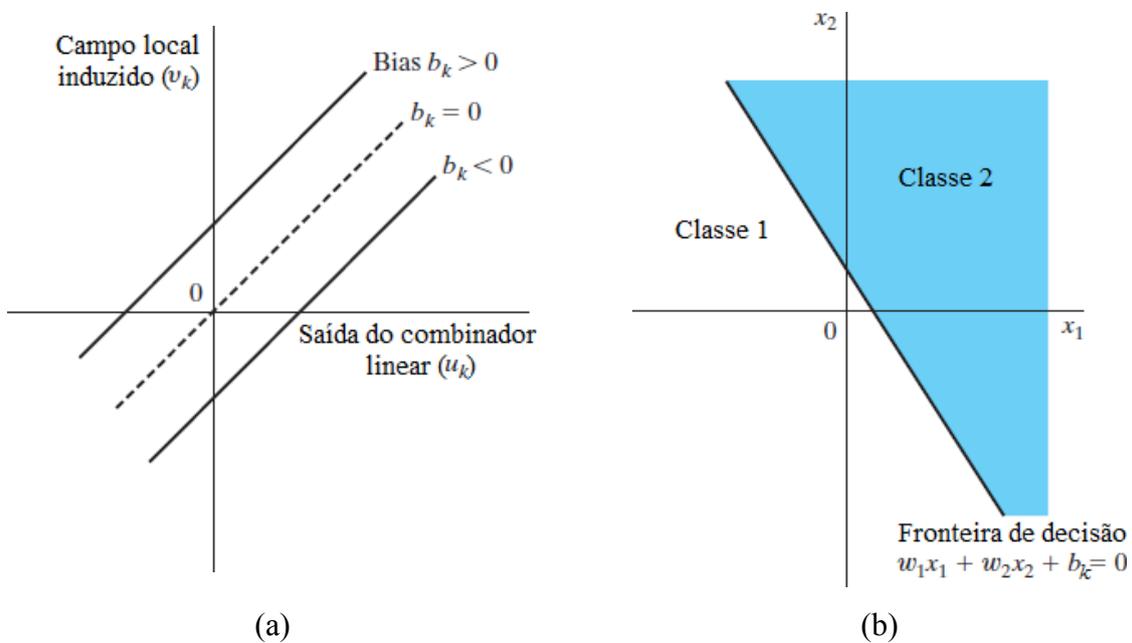


Figura 3.22 – Influência do *bias* no (a) campo local induzido; e na (b) fronteira de decisão para um problema de classificação binária a partir de duas entradas (x_1 e x_2). Fonte (adaptado): Haykin, 2009.

O *perceptron* de uma única camada foi proposto por Rosenblatt (1958) como o primeiro modelo para aprendizagem RNA supervisionada. Esse modelo consiste em um único neurônio com pesos sinápticos ajustáveis por meio de um algoritmo de treinamento (convergência do *perceptron*) e *bias*. Basicamente, o algoritmo proposto atualiza o vetor de peso do *perceptron*, com o auxílio de um parâmetro denominado de taxa de aprendizado (η), toda vez em que um dado do conjunto de treinamento é classificado incorretamente em uma iteração. A aplicação

de redes de uma só camada é limitada à classificação de padrões linearmente separáveis. Essa limitação foi uma das razões que restringiu o avanço de pesquisas para aplicação de RNA, até que o algoritmo de aprendizagem por retropropagação (Rumelhart, Hinton e Williams, 1986) fosse proposto para redes neurais de *perceptrons* de múltiplas camadas (MLP).

As redes neurais de *perceptrons* de múltiplas camadas diferenciam-se do *perceptron* de camada única por possuírem pelo menos uma camada oculta. Na Figura 3.23 tem-se uma típica rede MLP alimentada adiante, em que o sinal de entrada se propaga ao longo da rede, camada por camada. Na camada de entrada, responsável por receber o sinal de entrada, não há a presença de neurônios, apenas de nós de fonte. A camada seguinte é a camada oculta, constituída por neurônios (nós computacionais) que fazem o elo de ligação da camada anterior com a camada posterior, que neste caso é a camada de saída. A camada oculta capacita a rede a aprender tarefas complexas por meio de extração de características mais significativas dos vetores de entrada (Haykin, 2009). Por sua vez, a camada de saída combina as saídas produzidas pela camada anterior e gera a classificação final da rede.

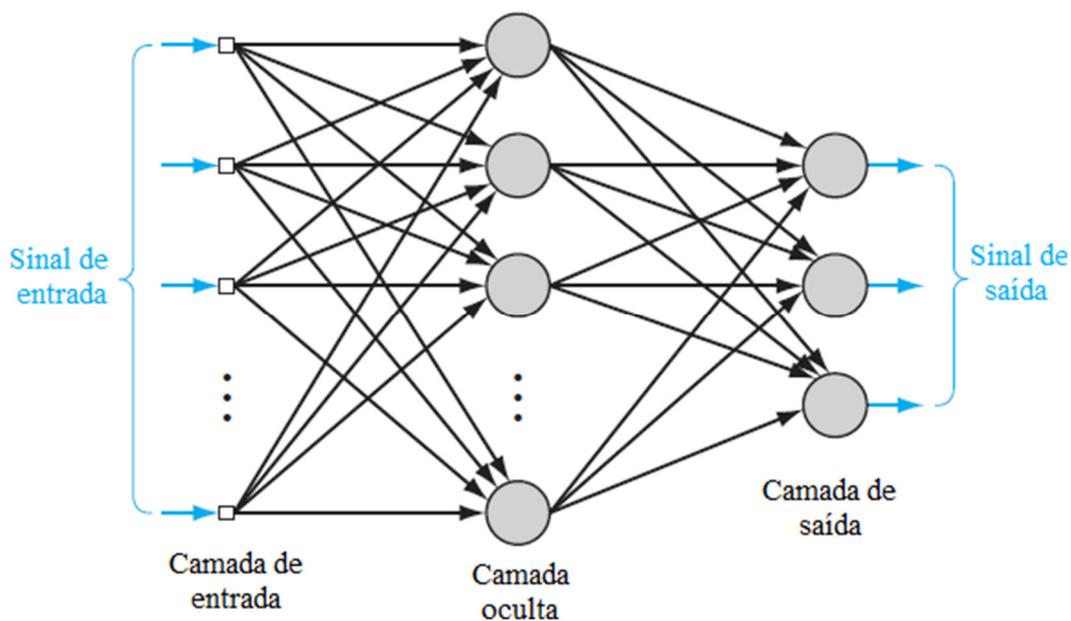


Figura 3.23 – Rede totalmente conectada de *perceptrons* de múltiplas camadas com uma camada oculta. Fonte (adaptado): Haykin, 2009.

Segundo Braga, Carvalho e Ludermir (2000), a contribuição dos nodos no processo de aprendizagem de uma RNA pode ser contextualizada da seguinte forma: (a) os nodos da primeira camada oculta traçam retas no espaço de padrões de treinamento; (b) na existência de uma camada oculta posterior, seus nodos combinam as retas traçadas pelos neurônios da

camada anterior, gerando regiões convexas nesse espaço; (c) na camada de saída os nodos definem regiões com formatos abstratos a partir de combinações das regiões definidas pelos nodos da camada anterior.

De acordo com Cybenko (1989), uma rede MLP com uma camada oculta pode implementar qualquer função contínua. Ele afirma que para implementar uma função descontínua é suficiente o uso de duas camadas ocultas. Com relação ao número de camadas ocultas, é importante salientar que não é recomendado o uso de um grande número delas (Braga; Carvalho e Ludermir, 2000).

O algoritmo de aprendizagem por retropropagação de erros baseia-se na regra de aprendizado por correção de erro e consiste em dois passos: a propagação do sinal de entrada, que corresponde ao passo para frente; e a retropropagação de erro, que corresponde ao passo para trás (Haykin, 2009). Na iteração para frente é computada a saída de cada nodo computacional, sendo que na última camada (de saída) calcula-se o sinal de erro. Na execução do passo para trás ocorre a atualização dos pesos sinápticos a cada iteração, de acordo com a regra de correção de erro. O ajuste dos pesos (ganhos) de sinapse tem como finalidade induzir que a resposta da rede tenda para a resposta desejada.

Na Figura 3.24 tem-se um gráfico do fluxo de sinal da aprendizagem por retropropagação para uma rede neural 3-3-3-3, ou seja, uma rede com três entradas, duas camadas ocultas (com três nodos cada) e três saídas. A parte superior do gráfico (fluxo de sinal em preto) corresponde ao passo para a frente. A parte inferior do gráfico (fluxo de sinal em azul) corresponde ao passo para trás (retropropagação). A atualização dos pesos ocorre em cada camada oculta l por meio da seguinte regra:

$$w_{kj}^{(l)}(n+1) = w_{kj}^{(l)}(n) + \alpha \left[w_{kj}^{(l)}(n-1) \right] + \eta \delta_k^{(l)}(n) y_j^{(l-1)}(n) \quad (3.4)$$

onde o valor futuro do peso é função do valor atual, da constante de momento (α) e do valor passado, bem como da regra delta (Widrow e Hoff, 1960) presente no terceiro termo. A constante de momento tem como finalidade aumentar a velocidade do treinamento em regiões planas da superfície de erro para evitar mínimos locais (Braga, Carvalho e Ludermir, 2000). A regra delta é função da taxa de aprendizagem (η), do gradiente local (δ_k) da superfície de erro e do sinal de saída (y) do neurônio j na camada anterior ($l-1$), na iteração n .

As iterações de passos para frente e de passos para trás são efetuadas a cada ciclo de treinamento até que seja satisfeito um critério de parada. Um método eficaz é a regra de parada

antecipada baseada na validação cruzada (Figura 3.25). Nele, após cada iteração de aprendizagem, a rede é testada pelo seu desempenho de generalização.

Para execução desse método necessitamos de dois conjuntos de dados: um para o treinamento e outro para a validação. O erro da curva de treinamento decresce com o acréscimo de conjuntos de dados (épocas) empregados na aprendizagem em cada iteração. Em contrapartida, o erro da curva de aprendizagem de validação decresce até um ponto mínimo e depois tende a crescer com a continuidade do treinamento. Esse ponto de mínimo da curva de validação determina o momento em que o processo de aprendizagem deve ser encerrado. A continuação da aprendizagem por retropropagação após esse ponto poderá resultar no superajustamento do modelo do classificador, que não é desejado conforme discutido na seção 3.6. Após esse ponto, a rede essencialmente aprende os ruídos contidos nas épocas (Haykin, 2009).

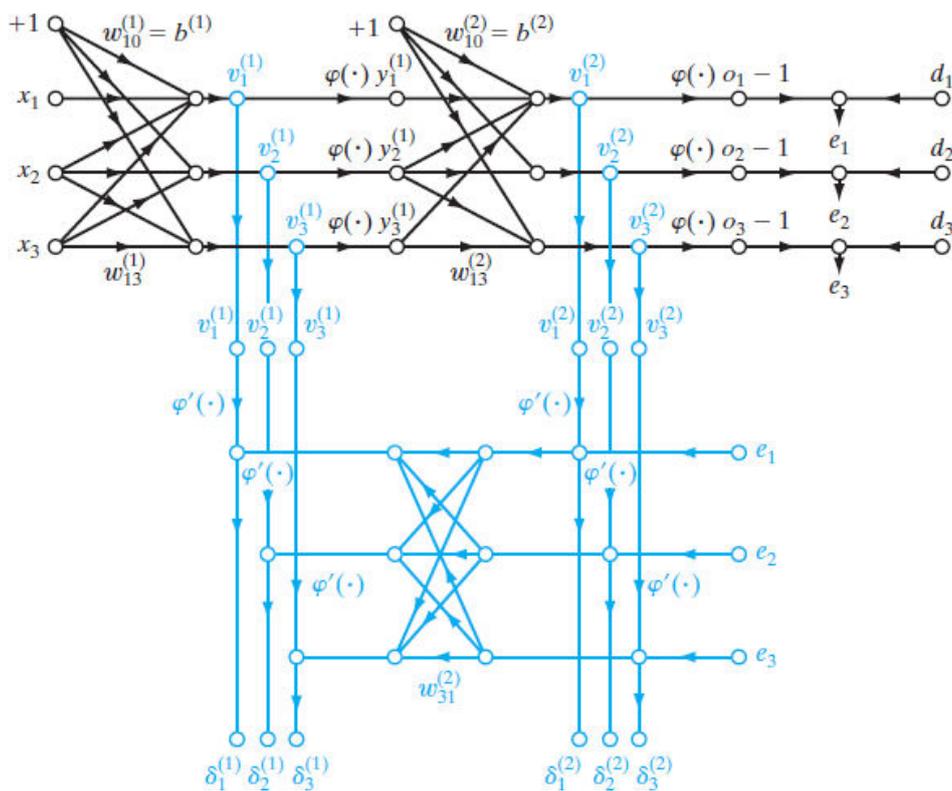


Figura 3.24 – Gráfico do fluxo de sinal da aprendizagem por retropropagação para uma rede totalmente conectada 3-3-3-3 com *bias* unitário e positivo (+1). Fluxo de sinal em preto: passo para frente; fluxo de sinal em azul: passo para trás. Fonte: Haykin, 2009.

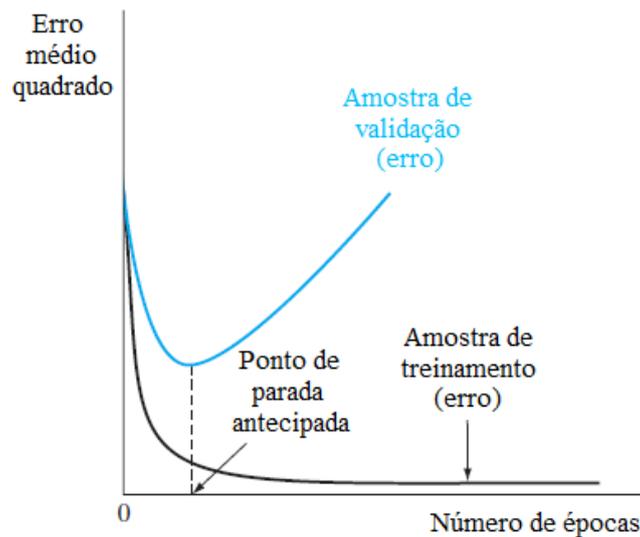


Figura 3.25 – Representação da regra de parada antecipada baseada na validação cruzada.

Fonte (adaptado): Haykin, 2009.

3.6.5 Observações Finais

Redes neurais artificiais incorporam o conhecimento do problema, que pode ser descrito pela relação entre entradas-saídas por meio do ajuste de pesos da rede. Essa sintonia tem como referência a minimização do erro de treinamento, que leva a um mínimo que pode não ser global. Portanto, o hiperplano de separação das classes determinado por meio da RNA, com base nos seus respectivos pesos, pode não ser ótimo.

Para a SVM não importa o conhecimento do domínio do problema e sim, onde traçar um hiperplano ótimo que maximize a distância entre as fronteiras das classes. Como discutido, apenas um grupo restrito de dados do treinamento (vetores suporte) são relevantes para o modelo do classificador. Essa característica é única das máquinas de vetor de suporte (Haykin, 2009), e a construção do modelo não está sujeita a sobrecarga em função dos dados de treinamento (Chen et al., 2004).

Outro ponto importante é que pode-se considerar que os neurônios ocultos em RNA desempenham papel similar ao *Kernel* da SVM. Eles são responsáveis por mapear classes não linearmente separáveis no espaço de entrada original na camada oculta, onde é mais provável que sejam linearmente separáveis (Haykin, 2009).

Na seção (3.6) referente a Aprendizado de Máquinas abordam-se conceitos básicos relativos ao Aprendizado Estatístico, SVM e RNA. Mais detalhes podem ser consultados nas obras de Schölkopf e Smola (2002), Giannakopoulos e Pikrakis (2014), Braga, Carvalho e Ludermir (2000) e Haykin (2009).

3.7 Robotização do Processo de Soldagem com Eletrodos Revestidos

Segundo Siciliano *et al.* (2009), a automação de processos de soldagem foi responsável pela segunda maior parcela de vendas de robôs na Europa no período de 2005 a 2006. A automação de processo de soldagem envolve o controle de diversas operações, e.g., abertura e manutenção do arco, aporte térmico e penetração, deslocamento e orientação do arco, alimentação de material e seguimento de junta. Em geral, o emprego de robôs em processo de soldagem está mais associado à tarefa de deslocamento e orientação do arco (controle de trajetória), sendo as demais atividades realizadas de forma integrada com outros dispositivos.

Os robôs mais utilizados em operações de soldagem são do tipo cartesiano e antropomórfico. Seus respectivos arranjos cinemáticos estão ilustrados na Figura 3.26. Os robôs cartesianos são mais utilizados nos processos de soldagem de cordões de solda lineares (Marques; Modenesi e Bracarense, 2009), em função da simplicidade de controle de trajetórias lineares por esses robôs. Os robôs antropomórficos (ou articulados) recebem este nome por emularem as características do braço humano e possuem grande liberdade de movimento dentro de seu espaço de trabalho, sendo atualmente o mais utilizado em operações de soldagem (Marques; Modenesi e Bracarense, 2009).

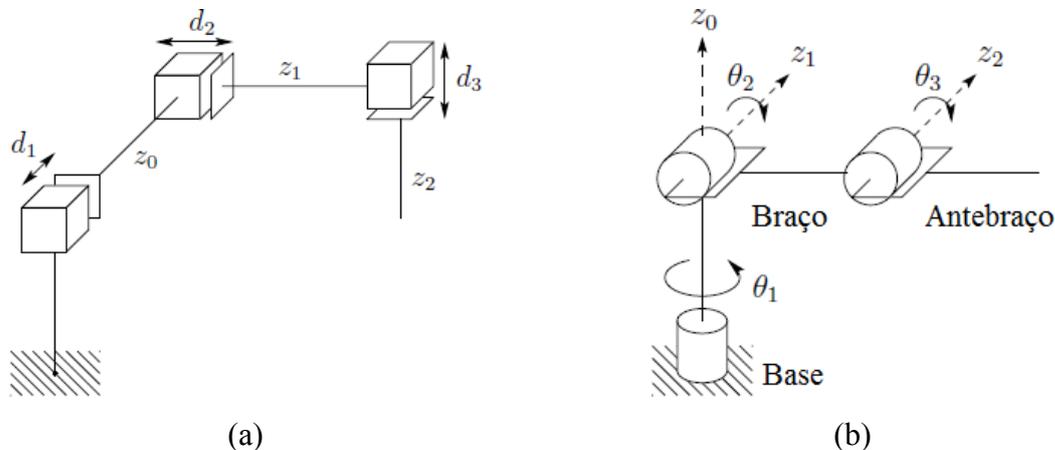


Figura 3.26 – Arranjo cinemático dos robôs (a) cartesiano (PPP) e (b) antropomórfico (RRR). Os robôs manipuladores são compostos por elos unidos por juntas em uma cadeia cinemática aberta ou fechada, onde P refere-se à junta prismática (de translação) e R à junta de rotação.

Fonte (adaptado): Spong, 2005.

Embora o processo de soldagem com eletrodos revestidos seja tipicamente manual, alguns trabalhos que utilizaram dispositivos mecânicos por gravidade (Silva, Bracarense e Pessoa, 2012) ou robotizados (Lima II e Bracarense, 2010) para deslocamento e orientação do

arco foram relatados na literatura. Em função do baixo ciclo de trabalho e de taxa de deposição de material, não é comum a automação do processo SMAW. Neste trabalho foi utilizado um robô planar com duas juntas prismáticas para o controle de trajetória do arco na estação de soldagem SMAW, com o objetivo de manter constante a velocidade de soldagem para a repetibilidade do cordão de solda.

4. Materiais e Métodos

Neste capítulo são descritos os materiais utilizados, bem como as metodologias adotadas para a realização dos experimentos, extração de características, treinamento dos modelos de classificadores, preparação das amostras para metalografia e avaliação dos resultados.

4.1 Aço de Baixo Carbono

Neste trabalho foi utilizado o aço SAE 1006, com baixo teor de carbono, como metal de base nos experimentos de soldagem. Esse aço foi escolhido em função da predominância de ferrita em sua microestrutura. Os principais elementos que compõem o aço utilizado estão elencados na Tabela 4.1. Essa composição química foi identificada por meio do espectrômetro FOUNDRY-MASTER Xpert da Oxford Instruments, pertencente ao Laboratório de Fundição do Departamento de Engenharia Metalúrgica e de Materiais (DEMET) – Escola de Minas.

Tabela 4.1 – Composição química do aço comum SAE utilizado nos experimentos. Valores médios de três amostras (% peso).

%C	%Mn	%P	%S	%Si
0,0628	0,341	0,0176	0,0070	0,0315

Na Figura 4.1 tem-se a micrografia do estado de entrega do aço utilizado. Como esperado, sua microestrutura predominante é formada por ferrita. Esta imagem foi adquirida por meio do microscópio Olympus CX31 e câmera Panambra, pertencentes ao Laboratório de Tratamento Térmico e Microscopia Óptica (LTM) do DEMET – Escola de Minas.



Figura 4.1 – Micrografia (400x) de amostra do estado de entrega do aço SAE 1006 utilizado nos experimentos. Fonte: Autor.

4.2 Eletrodo Revestido E 6013

Para a execução de cordões de solda por um passe foi utilizado o eletrodo AWS E 6013, com diâmetro de 2,5mm. Esse eletrodo foi escolhido em função da estabilidade de seu arco. A composição química típica desse eletrodo está apresentada na Tabela 4.2. É um eletrodo com revestimento rutilico com ligante à base de silicato de potássio, de fácil manipulação, que pode ser usado em fontes de Corrente Alternada (CA) ou de Corrente Contínua (CC), em qualquer posição de soldagem. Produzem cordões com bom aspecto e com média ou baixa penetração (Marques; Modenesi e Bracarense, 2009).

Os eletrodos utilizados foram adequadamente armazenados em estufa, após a remoção de sua respectiva embalagem, a fim de evitar o acúmulo excessivo de umidade, que prejudica a abertura e estabilidade do arco. De acordo com o fabricante, a faixa de corrente de operação recomendada desse eletrodo é de 60 a 100A (Fortes, 2005).

Tabela 4.2 – Composição química do eletrodo E 6013. Fonte: ESAB, 2017.

%C	%Mn	%Si
0,07	0,35	0,20

4.3 Estação de Soldagem

A estação de soldagem SMAW que foi desenvolvida para este trabalho é composta por um sistema de aquisição de dados, um porta-eletrodo acoplado a um robô planar (PP) e uma fonte convencional CA com ciclo de trabalho de 20% e controle de corrente por meio de núcleo móvel que permite a operação até 150A. A estação está instalada no Laboratório de Engenharia de Superfícies e Técnicas Afins (LESTA) do DEMET – Escola de Minas. Na Figura 4.2 tem-se um diagrama dessa estação de soldagem. Duas câmeras foram posicionadas para a gravação do arco elétrico e da poça de fusão durante a realização dos ensaios.

Para o acionamento do robô, foi desenvolvido um *script* em Matlab 2016a. Uma interface gráfica possibilita ao usuário iniciar e encerrar o movimento do robô, aproximar o eletrodo da superfície da chapa de aço, configurar as velocidades de deslocamento das juntas prismáticas, determinar o comprimento do cordão, bem como definir os intervalos para disparo (*trigger*) de sinal para captura de dados do sensor ultrassônico (Figura 4.3). O robô é acionado por meio da placa microcontrolada Arduino MEGA 2560 e a comunicação dela com o Matlab é efetuada por meio de uma porta USB de um microcomputador.

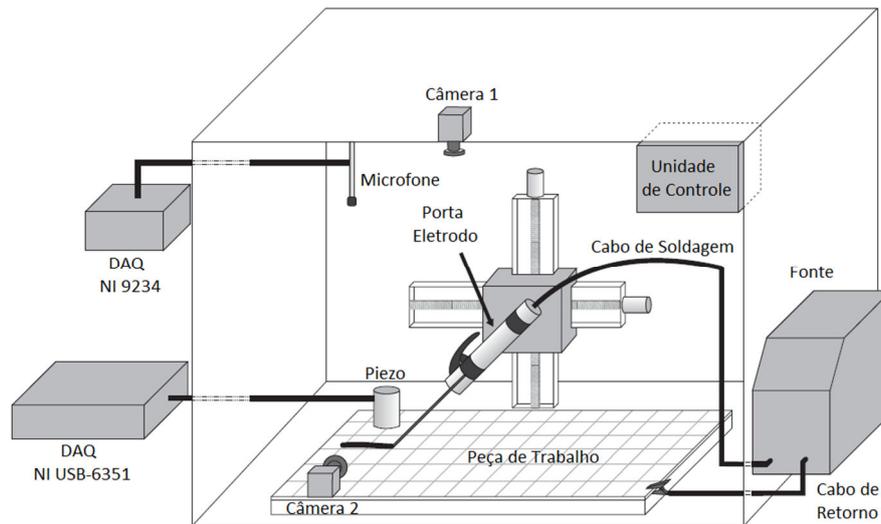
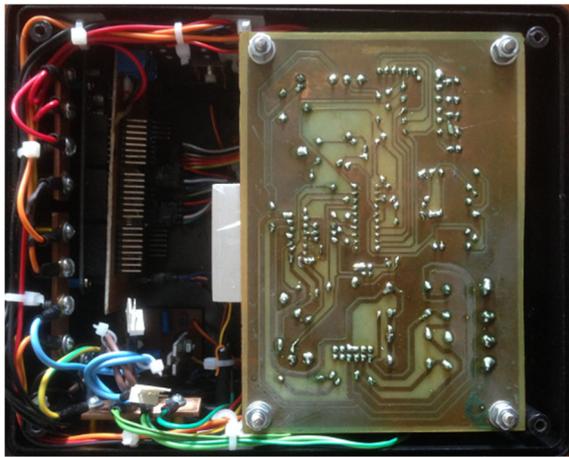


Figura 4.2 – Configuração do experimento. Fonte (adaptado): Cocota *et al.* (2017).

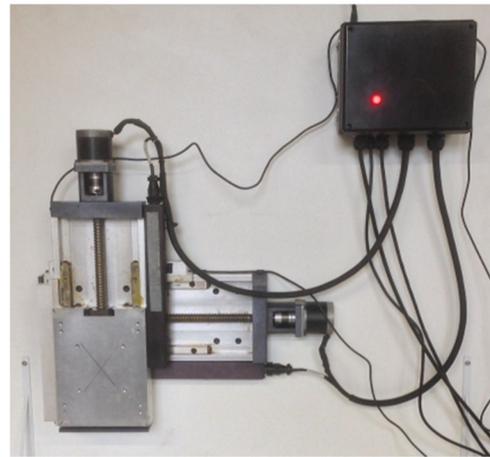
Para o controle do robô foi utilizado um microcomputador com processador Intel Core i5, de 2,7 GHz, 8 GB de memória RAM com S.O. macOS Sierra. Na Figura 4.4, tem-se os circuitos eletrônicos do robô acondicionados em um gabinete plástico, com o intuito de proteger esses componentes durante a execução do processo de soldagem. Maiores informações sobre o circuito de acionamento, bem como sobre a lógica de programação do Arduino, podem ser consultadas no trabalho referente ao *retrofitting* do robô para sua operacionalização (Rocha *et al.*, 2015).



Figura 4.3 – Interface gráfica com o usuário em Matlab. Fonte: Autor.



(a)



(b)

Figura 4.4 – Gabinete com dispositivos eletrônicos para acionamento do robô. Em (a) vista interna com o acondicionamento da plataforma Arduino à esquerda e os módulos de potência à direita; em (b) posicionamento do gabinete na estação de soldagem. Fonte: Autor.

4.4 Instrumentação

4.4.1 Transdutor Microfone

Para amostragem do som audível emitido pela interação do arco elétrico com a poça de fusão, optou-se pelo transdutor G.R.A.S. 40PH (Figura 4.5), pertencente ao Departamento de Engenharia de Controle e Automação e Técnicas Fundamentais (DECAT) – Escola de Minas. Trata-se de um microfone de eletreto onidirecional, localizado na placa traseira da sua cápsula, para medições de precisão. Esse microfone, com diafragma de ¼ pol., pode amostrar frequências de até 20kHz, com sensibilidade de 50mV/Pa e com resposta em frequência aproximadamente plana (Figura 4.6). Esse é um requisito importante na escolha de um microfone para medição, para que a amplitude dos sinais amostrados não seja prejudicada.



Figura 4.5 – Microfone G.R.A.S. Sound & Vibration 40PH. Fonte: G.R.A.S. (2017).

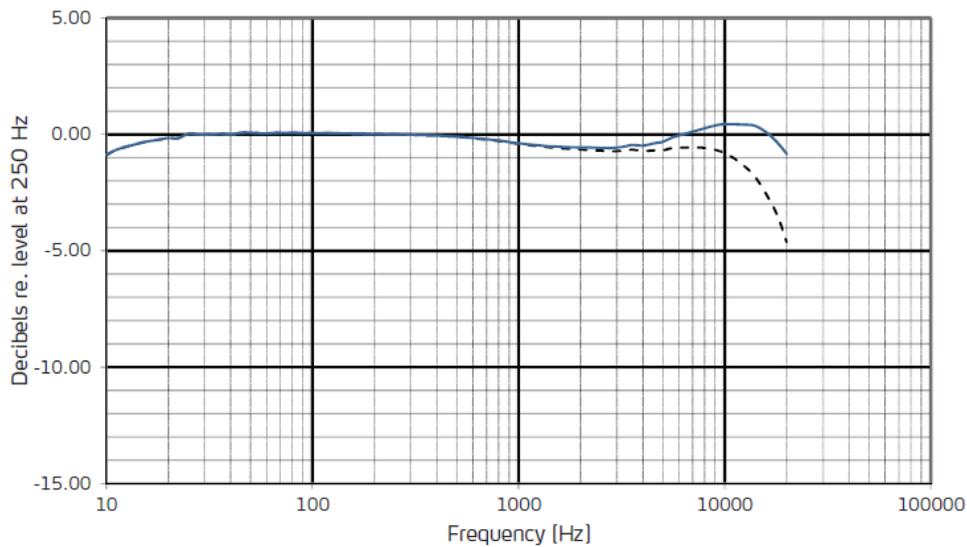


Figura 4.6 – Resposta típica em frequência do microfone G.R.A.S. 40PH. A curva contínua apresenta a resposta de campo livre e a curva pontilhada apresenta a resposta de pressão. Resposta em frequência: ± 3 dB (10Hz-50Hz); ± 1 dB (50Hz-5kHz); e ± 2 dB (5kHz- 20kHz).

Fonte: G.R.A.S. (2017).

4.4.2 Transdutor Ultrassônico

Neste trabalho foi utilizado o transdutor ultrassônico H2-SE-20/0° de 2MHz da Eddytronic (Figura 4.7), disponível no LESTA, para a amostragem da emissão acústica sólida propagada na chapa de aço durante a execução do processo de soldagem.



Figura 4.7 – Transdutor ultrassônico H2-SE-20/0° 2MHz Eddytronic. Fonte: Autor.

Esse transdutor possui dois cristais, que possibilitam o uso de um cristal como emissor e o outro como receptor, configuração comumente utilizada em ensaios não destrutivos tradicionais. Como neste trabalho o transdutor ultrassônico foi utilizado para a amostragem de emissões acústicas, apenas o cristal receptor (elemento sensor) foi empregado. Embora a técnica de amostragem de emissões acústicas não seja tradicional em soldagem, a norma ASTM E749

define os padrões de prática para o monitoramento da emissão acústica durante o processo de soldagem contínua.

4.5 Sistema de Aquisição de Dados

O sistema consiste na aquisição de dados de um transdutor microfone (G.R.A.S. 40PH) e um transdutor ultrassônico (cristal piezoelétrico de 2MHz da Eddytronic). O sinal audível (propagado no ar) é amostrado por meio do microfone por meio do dispositivo de aquisição de dados NI 9234 (Figura 4.8). O microfone onidirecional é posicionado dentro da estação de trabalho a uma distância de 550 mm da superfície da peça a ser soldada (chapa de aço SAE 1006). Essa distância foi escolhida para evitar a inclusão de respingos no microfone.



Figura 4.8 – Sistema de aquisição NI 9234. Fonte: National Instruments, 2017.

O monitoramento de emissão acústica (propagada na chapa de aço – meio sólido) é realizado de acordo com o padrão ASTM E749, empregando o sensor piezoelétrico que está rigidamente fixado à placa de aço por meio de sargento, usando o sistema de aquisição multifuncional NI USB-6351 (Figura 4.9). Em atendimento a esse padrão o sensor piezoelétrico foi posicionado a uma distância mínima de 150 mm da ZTA do cordão de solda. O sensor piezoelétrico foi fixado sem o uso de acoplante, conforme previsto na referência ASTM E650.



Figura 4.9 – Sistema de aquisição multifuncional NI USB-6351. Fonte: National Instruments, 2017.

Ambos dispositivos de aquisição de dados pertencem ao DECAT – Escola de Minas. Para a transmissão dos sinais analógicos foram utilizados cabos do tipo coaxial, com 3m de comprimento, de 4mm (0,4x2,5) com impedância de 75ohms e 80% de blindagem.

O dispositivo de aquisição de dados NI 9234 foi utilizado neste trabalho como um sistema de aquisição autônomo e independente, por meio do chassi cDAQ-9171 da National Instruments. Suas principais características estão apresentadas na Tabela 4.3.

Tabela 4.3 – Características do módulo NI 9234.

Número de entradas:	4 entradas analógicas com conversores A/D independentes.
Configuração das entradas analógicas:	Podem ser configuradas para sinais referenciados ao terra ou para sinais diferenciais.
<i>Trigger:</i>	Não dispõe de mecanismo para captura de dados por evento externo.
Velocidade de aquisição:	51,2kS/s/canal e incorpora filtros <i>antialiasing</i> .
Resolução:	24 bits.
Acurácia:	7,1mV.
Margem de entrada:	±5V
Tipo de conversor A/D:	Delta-sigma
Transferência de dados:	Por meio de porta USB (serial).

Nos experimentos, utilizou-se o canal AI0 (do módulo NI 9234) com conexão BNC para amostragem do som audível com a velocidade de aquisição de 50kS/s. Como a velocidade de aquisição desse dispositivo é limitada a 51,2kS/s, e Wersborg *et al.* (2009) sugerem velocidades de aquisição superiores para amostrar as emissões acústicas sólidas, foi necessário o uso do sistema de aquisição multifuncional NI USB-6351. Suas principais características estão apresentadas na Tabela 4.4.

Tabela 4.4 – Características do sistema de aquisição multifuncional NI USB-6351.

Número de entradas:	16 entradas analógicas com conversores A/D independentes ou sequenciais.
Configuração das entradas analógicas:	Podem ser configuradas para sinais referenciados ao terra ou para sinais diferenciais. No caso de sinais diferenciais o número de entradas reduz para a metade.
<i>Trigger</i> :	Possui mecanismo para captura de dados por evento externo.
Velocidade de aquisição:	1,25MS/s para um canal ou 1MS/s para múltiplos canais.
Resolução:	16 bits.
Acurácia:	0,8mV para a entrada nominal de $\pm 5V$ que foi utilizada.
Margem de entrada:	$\pm 0,1V$; $\pm 0,2V$; $\pm 0,5V$; $\pm 1V$; $\pm 2V$; $\pm 5V$; ou $\pm 10V$.
Tipo de conversor A/D:	Não informado pelo fabricante.
Transferência de dados:	Por meio de porta USB (serial).

Nos experimentos, utilizaram-se o canal AI0 (da placa multifuncional NI USB-6351) para amostragem da emissão acústica com a velocidade de aquisição de 1,2MS/s, e a entrada de *trigger* para comandar o intervalo de captura destes dados por evento externo. Devido ao elevado volume de dados, o sinal de emissão acústica sólida é amostrado apenas nos períodos de descontinuidades.

A programação dos dispositivos para aquisição de dados foi efetuada em LabVIEW 2013 por meio de diagramas de blocos (Anexo A). Uma interface gráfica com o usuário em LabVIEW possibilita iniciar e encerrar o processo de aquisição de dados, visualizar o histórico dos dados amostrados por meio de gráficos, bem como configurar parâmetros das DAQs (Figura 4.10). Para a aquisição de dados, foi utilizado um microcomputador com processador Intel Core i5, de 1,7 GHz, 4 GB de memória RAM com S.O. Windows 8.

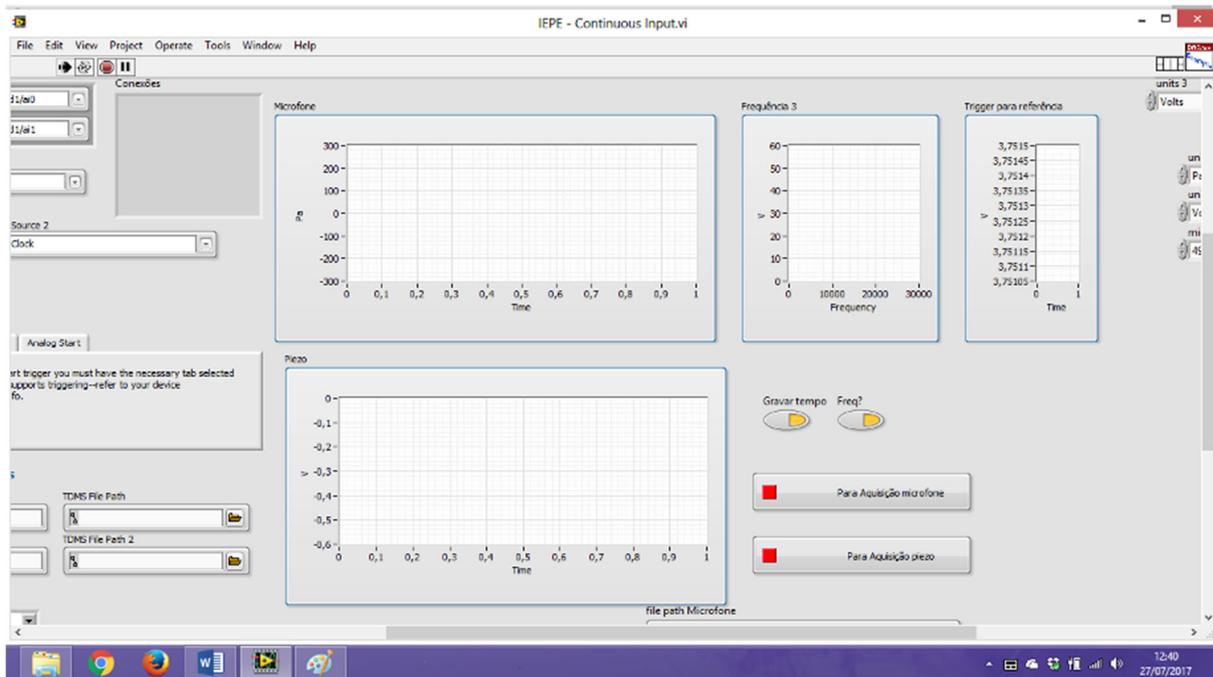


Figura 4.10 – Interface gráfica com o usuário em LabVIEW. Fonte: Autor.

4.6 Extração de Características

Neste trabalho, a extração de características da emissão acústica aérea (sinal audível) ocorre em duas etapas: (1) o conjunto de dados segmentados no domínio do tempo é transformado para o domínio da frequência, por meio da Transformada de Fourier Discreta (DFT); e (2) em seguida é aplicado um algoritmo de reamostragem por decimação por média (*average downsampling*).

Na literatura relacionada a monitoramento de processos de soldagem, não há registro do uso de reamostragem por decimação por média para o processamento de sinais de emissão acústica aérea. O uso dessa técnica permitiu obter resultados de classificação superiores aos alcançados por meio de vetores de características processados exclusivamente por DFT.

Para a extração de características da emissão acústica sólida foi utilizada a transformada *Wavelet*. Essas técnicas possibilitaram distinguir padrões de comportamento entre as classes de estudo neste trabalho.

A metodologia adotada neste trabalho encontra-se ilustrada na Figura 4.11. A fusão dos vetores de características somente é efetuada na estrutura hierárquica de máquina de vetor de suporte (HSVM) proposta neste trabalho (Seção 4.8).

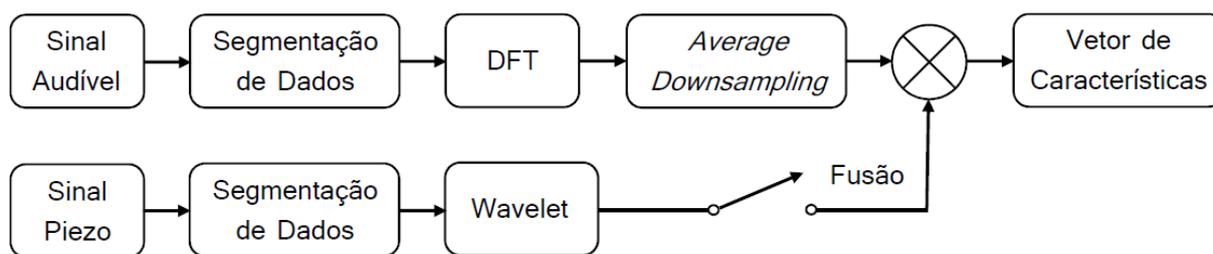


Figura 4.11 – Diagrama de blocos do método proposto para extração de características. Fonte (adaptado): Cocota *et al.*, 2017.

4.6.1 Segmentação dos Dados

Neste trabalho, os dados amostrados foram segmentados em intervalos de 2,5s. Este intervalo corresponde ao período de ocorrência das discontinuidades de cratera e de perfuração em função de redução da espessura da chapa (subseção 4.7.1). A partir destes segmentos, os dados foram novamente segmentados em dois conjuntos, que serão denominados como quadros de curto termo do sinal. Esses correspondem a 2/3 do intervalo inicial e compartilham dados da região central do segmento original. A segunda segmentação foi necessária para aumentar o número de representantes de cada classe (normal, cratera e perfuração). Na Figura 4.12 tem-se a ilustração da metodologia adotada.

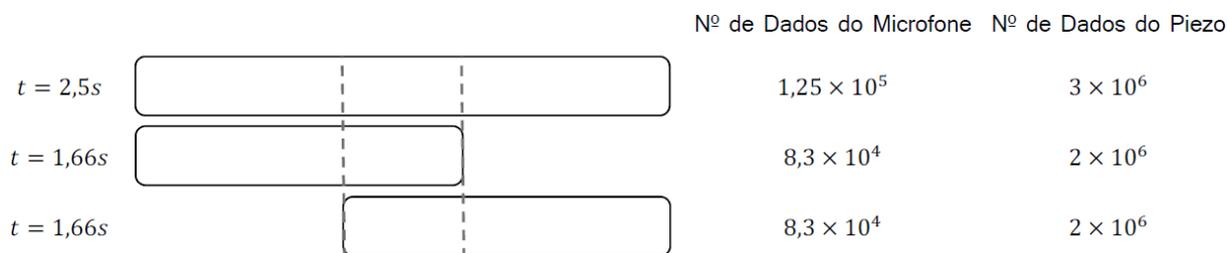


Figura 4.12 – Metodologia proposta para a segmentação dos dados em quadros de curto termo. Fonte: Autor.

Os intervalos para segmentação dos dados foram escolhidos de acordo com a classe de interesse. O trecho classificado como normal sempre foi escolhido entre duas discontinuidades (falhas), nunca no início ou no final do cordão, para minimizar o risco de segmentação de dados durante a fase de transitório do arco elétrico, ou seja, nos períodos de instabilidade do arco. Os trechos de segmentação de dados das crateras e das perfurações foram escolhidos tendo como referência o centro de suas respectivas discontinuidades. Essa metodologia está ilustrada na Figura 4.13.

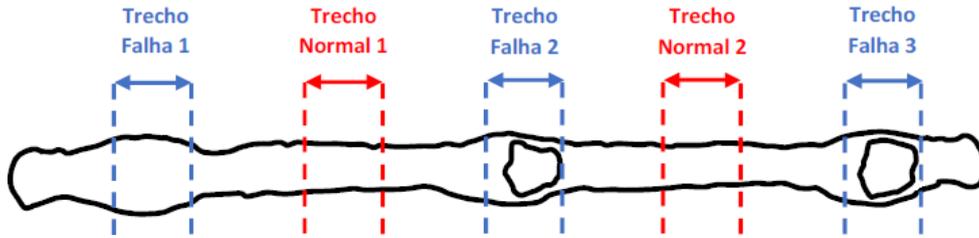


Figura 4.13 – Metodologia proposta para a segmentação dos dados a partir da morfologia do cordão. Fonte: Autor.

4.6.2 Transformada de Fourier Discreta

A DFT é computada por meio de um algoritmo da Transformada Rápida de Fourier (FFT). A principal vantagem da FFT é a velocidade de processamento.

Dado um sinal em tempo discreto, $x(n)$, $n = 0, \dots, N - 1$, sendo N o número de amostras temporais, igualmente espaçadas pelo intervalo de amostragem, sua DFT é definida por:

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j\frac{2\pi}{N}kn}, \quad k = 0, \dots, N - 1 \quad (4.1)$$

sendo $j = \sqrt{-1}$ e k a ordem harmônica. Nota-se que, com exceção de $X(0)$, a saída da Equação 4.1 é uma sequência de números complexos.

4.6.3 Decimação por Média

Após a conversão do sinal audível para o domínio da frequência (Equação 4.1), aplica-se um algoritmo de reamostragem por meio de decimação média. Esse algoritmo permite reduzir as 80.000 primeiras amostras de cada quadro de curto termo do sinal para 5.000 médias, de acordo com a seguinte expressão:

$$\mu(i) = \frac{W}{N} \left[\sum_{(k) \left(\frac{N}{W}\right) + 1}^{(k+1) \left(\frac{N}{W}\right)} X(k) \right]_k^{W-1} \quad (4.2)$$

onde $\mu(i)$ é o vetor com 5.000 médias de janelas deslizantes do espectro do sinal, $X(k)$ é a DFT (Equação 4.1) do sinal, N é o número de amostras do quadro de curto termo e W é o

número de janelas deslizantes. A reamostragem suaviza o espectro do sinal audível e reduz sua dimensionalidade.

4.6.4 Transformada *Wavelet*

Cada quadro de curto termo do sinal amostrado por meio do cristal piezoelétrico possui 2×10^6 amostras (Figura 4.12). O pré-processamento desse sinal é efetuado por meio da transformada *Wavelet*. Ela divide o sinal em coeficientes de aproximação e detalhe em cada nível de decomposição, em uma dimensão de forma hierárquica, conforme apresentado na Figura 4.14. Para cada decomposição, os subsinais (coeficientes) gerados possuem a metade do comprimento do sinal anterior.

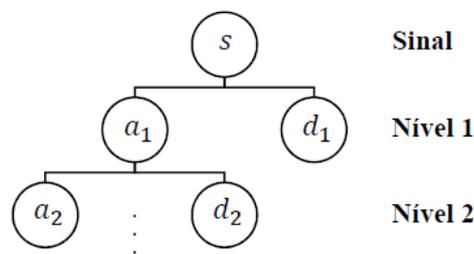


Figura 4.14 – Árvore de decomposição por *Wavelet* para uma dimensão, divide o sinal (s) em coeficientes de aproximação (a_i) e detalhe (d_i) para cada nível. Fonte: Autor.

Para computar a transformada *Wavelet* foi utilizada a função *dwt* do Matlab. A decomposição foi efetuada até o sexto nível por meio da *Wavelet*-mãe *Daubechies 4* (Daubechies, 1992). A escolha dessa *Wavelet*-mãe foi baseada no trabalho de Wersborg *et al.* (2009). O algoritmo dessa função consiste na convolução do sinal (s) com o filtro passa-baixa (Lo_D) para obter o coeficiente de aproximação, e o filtro passa-alta (Hi_D) para obter o coeficiente de detalhe, seguidos por decimação diádica (Figura 4.15). A técnica utilizada para lidar com o problema de distorção de borda do sinal (*padding*) foi a compensação simétrica.

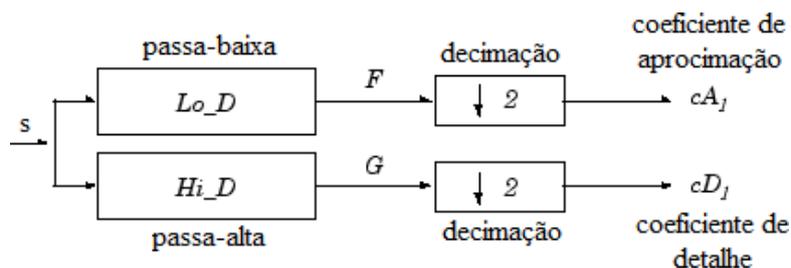


Figura 4.15 – Diagrama do algoritmo de decomposição *Wavelet*. Fonte (adaptado):

MathWorks, 2017.

4.7 Soldagem com Eletrodos Revestidos

Os cordões de solda foram executados na posição plana e o eletrodo posicionado com ângulo de 25° no modo puxando a poça de fusão (Figura 4.16). A técnica de soldagem puxando a poça de fusão proporciona um cordão de solda mais estreito, com reforço e penetração maiores (ESAB, 2014). O passe único foi efetuado sem movimento de tecimento, apenas o movimento de translação foi efetuado com velocidade de soldagem constante.

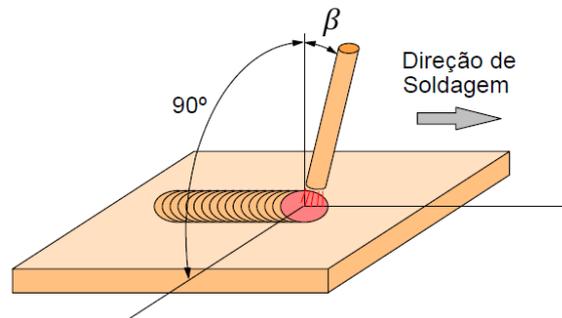


Figura 4.16 – Posicionamento utilizado nos experimentos de soldagem, em que β é o ângulo do eletrodo. Fonte (adaptado): Marques; Modenesi e Bracarense (2009).

4.7.1 Preparação das Amostras para Soldagem

Uma chapa do aço SAE 1006 de 1/8 pol. (3,175mm) de espessura com dimensão de 520x245mm foi utilizada nos experimentos de soldagem a arco por eletrodo revestido. Sulcos com dimensão de 12x2mm (Figura 4.17), transversais à direção de soldagem, foram usinados na face inferior da chapa com o intuito de induzir descontinuidades do tipo cratera e perfuração no cordão durante o processo de soldagem, conforme proposto em Sansan *et al.* (2010). Para a realização desses sulcos, foi utilizado o centro de usinagem CNC ROMI D 600, pertencente ao Laboratório de Elementos de Máquinas do DECAT – Escola de Minas.

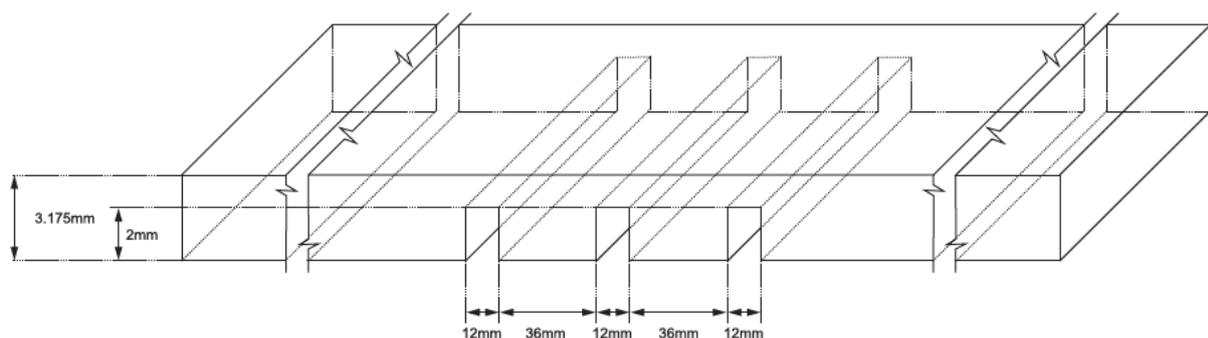


Figura 4.17 – Dimensões da chapa de aço. Sulcos transversais com 12x2mm na superfície inferior da chapa de aço. Fonte: Cocota *et al.* (2017).

Para evitar a contaminação, a superfície da chapa foi limpa antes da realização de cada cordão. Como procedimento de limpeza foi utilizada escova de cerdas de aço para remoção de escórias e película de óxido, seguida de algodão embebido em álcool etílico para eliminar pequenas partículas sobre o metal de base.

4.7.2 Configuração dos Parâmetros Operacionais

Para operação da estação de soldagem SMAW robotizada é necessário determinar algumas variáveis primárias do processo. Inicialmente, a corrente e a velocidade de soldagem foram determinadas empiricamente (em operação manual) por um técnico com experiência em soldagem. A partir desses parâmetros, foram realizados ensaios com o robô para a otimização dessas variáveis que resultasse em um melhor aspecto do cordão de solda. A maior dificuldade na execução do cordão de solda pelo robô foi a abertura do arco elétrico. Diferentes técnicas de movimento do eletrodo pelo robô foram testadas sem sucesso. A solução foi o uso de esponja de aço para auxiliar a abertura do arco, conforme reportado por Lima e Bracarense (2010).

Após a realização de uma série de ensaios com o robô, foi definido como referência o intervalo de corrente de 70 a 75A e velocidade de soldagem de 4,0mm/s, para deposição de cordão de solda em chapa de aço SAE 1006 com 1/8 pol. de espessura por meio de eletrodo E6013 com 2,5mm de diâmetro. Durante a realização desses ensaios, notou-se que para correntes superiores a 75A ocorreu maior incidência de respingos no processo. Para atender a velocidade de soldagem desejada, foram definidas as velocidades de 2,5mm/s de deslocamento no eixo horizontal (v_x , velocidade de translação do eletrodo) e de 3,7mm/s de deslocamento no eixo vertical (v_y , velocidade de mergulho do eletrodo) do robô. Essas velocidades, para o intervalo de corrente citado, resultaram em um comprimento médio do arco de 5mm. Esse valor foi estimado após a análise da gravação em vídeo do arco elétrico.

4.7.3 Experimentos de Soldagem

Um total de cinquenta cordões de solda foram executados pelo robô na chapa de aço descrita na subseção 4.7.1. Os dez primeiros cordões foram efetuados para otimizar os parâmetros de soldagem (Figura 4.18a). Os demais foram utilizados para treinar, validar e testar os classificadores propostos neste trabalho (Figura 4.18b). Os dados amostrados de trechos normais de cordões de solda curtos, i.e., com a presença de apenas uma descontinuidade

induzida pelos sulcos presentes na chapa de aço (cordões 13, 14, 15, 16, 17, 35, 36, 37, 38, 39 e 40 – Figura 4.18b), não foram utilizados nos classificadores.

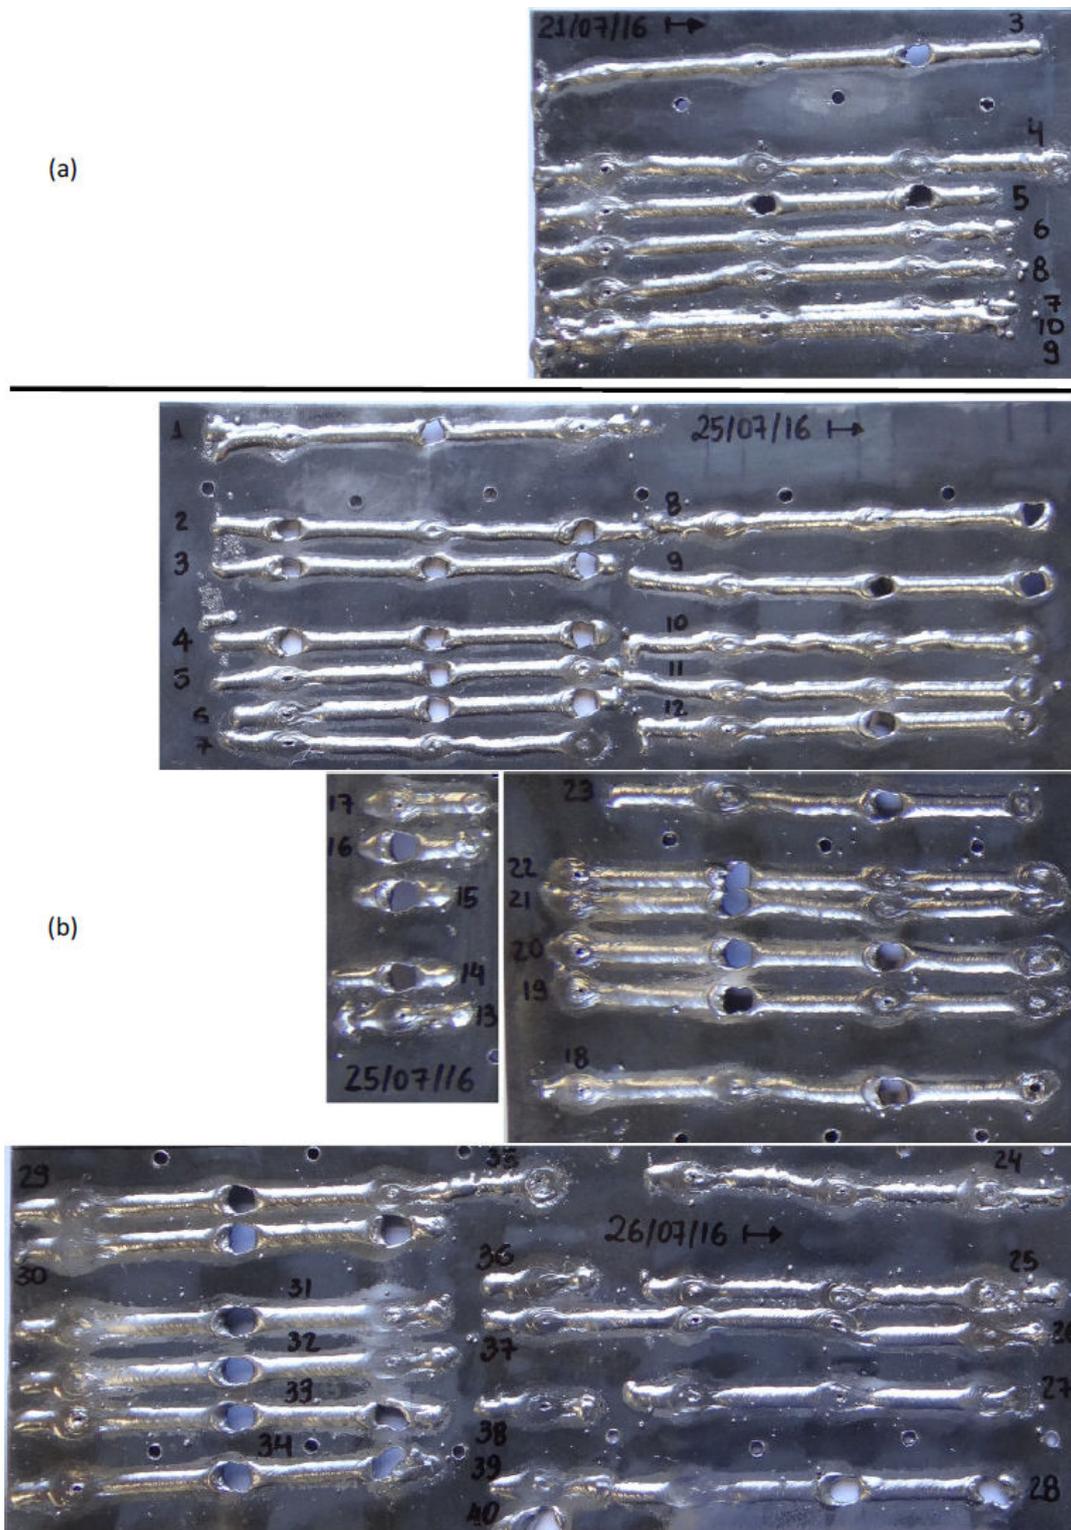


Figura 4.18 – Cordões de solda executados por meio da estação de soldagem SMAW robotizada: (a) efetuados para otimizar os parâmetros de soldagem; (b) utilizados nos classificadores. Fonte: Autor.

Na Tabela 4.5 tem-se a relação de 98 trechos dos cordões de solda que foram segmentados em 196 quadros de curto termo do sinal acústico aéreo, incluso os 43 trechos de descontinuidades que foram segmentados em 86 quadros de curto termo do sinal acústico sólido (conforme discutido nas seções 4.5 e 4.6), bem como outras informações relativas aos cordões de solda. Na penúltima coluna dessa matriz encontra-se identificado os trechos da classe normal de cada cordão de solda que foram utilizados nos classificadores. Na última coluna tem-se a identificação dos trechos das descontinuidades de cordões, agrupados por classe (perfuração ou cratera), que foram utilizados nos classificadores.

Tabela 4.5 – Informações dos trechos dos cordões de solda utilizados nos classificadores (* sem dados de trechos da classe normal, cratera ou perfuração). Fonte: Autor.

(continua)

Nº do Cordão	Comp. (mm)	Veloc. de Soldagem (mm/s)	Corrente (A)	Nº do Trecho Normal	Nº do Trecho de Descontinuidade (Classe)
4	123	3,8	70	1 e 2	1, 2 e 3 (Perfuração)
6	120	3,8	70	1 e 2	1 (Cratera)
7	119	4,0	70	1 e 2	1 e 2 (Cratera)
8	122	3,8	70	1 e 2	1 e 2 (Cratera)
9	128	4,1	70	1 e 2	2 (Perfuração)
10	122	3,9	70	1 e 2	1, 2 e 3 (Cratera)
11	126	4,0	70	1 e 2	2 (Cratera)
12	122	4,0	70	1 e 2	1 e 3 (Cratera); 2 (Perfuração)
14	33	4,1	70	*	1 (Perfuração)
15	23	3,9	70	*	1 (Perfuração)
16	27	3,8	70	*	1 (Perfuração)
17	31	3,9	70	*	1 (Cratera)
18	154	4,1	70	1, 2 e 3	1 (Cratera); 3 e 4 (Perfuração)
19	152	4,0	70	1, 2 e 3	1 e 4 (Cratera)
20	153	4,1	75	1, 2 e 3	1 e 4 (Cratera); 2 e 3 (Perfuração)
21	155	4,0	75	1, 2 e 3	2 (Perfuração)
22	154	4,0	75	1, 2 e 3	1, 3 e 4 (Cratera); 2 (Perfuração)
23	125	3,9	75	1 e 2	1 e 3 (Cratera); 2 (Perfuração)
24	130	3,8	75	1 e 2	1 e 3 (Cratera)

Tabela 4.5 – Informações dos trechos dos cordões de solda utilizados nos classificadores (* sem dados de trechos da classe normal, cratera ou perfuração). Fonte: Autor.

(conclusão)

Nº do Cordão	Comp. (mm)	Veloc. de Soldagem (mm/s)	Corrente (A)	Nº do Trecho Normal	Nº do Trecho de Descontinuidade (Classe)
25	120	3,8	75	1 e 2	3 (Cratera)
26	116	3,7	75	1 e 2	1 (Cratera)
27	125	3,9	75	1 e 2	1 e 3 (Cratera)
28	125	4,1	75	1 e 2	*
29	130	4,0	75	1 e 2	*
30	125	4,1	75	1 e 2	*
31	128	4,1	75	1 e 2	*
32	129	4,2	75	1 e 2	*
33	128	4,1	75	1 e 2	*
34	127	4,2	75	1 e 2	*

Nota-se na Tabela 4.5 que a velocidade de soldagem não foi constante nos ensaios. Isso era esperado, uma vez que o controle de velocidades das juntas do robô é efetuado em malha aberta. Assim, podemos afirmar que a velocidade de soldagem dos ensaios foi de $4,0\text{mm/s} \pm 0,2$.

A fim de minimizar a deformação da chapa em função do aquecimento durante o processo de soldagem, ela foi fixada por meio de parafusos sobre uma placa de madeira e em suas extremidades foram utilizados sargentos.

4.8 Classificadores de Padrões

Neste trabalho é proposto o uso de máquina de vetor de suporte (SVM) para qualificação de cordões de solda do processo SMAW. Um classificador por rede neural artificial (RNA) é implementado para comparação de resultados. Além disso, é proposta uma abordagem inovadora da estrutura hierárquica de máquina de vetor de suporte (HSVM).

A nova estrutura consiste no escalonamento de entrada de dados em dois estágios (Figura 4.19). Essa é a diferença em relação à estrutura HSVM original, na qual existe apenas uma entrada de dados. Nota-se que, na estrutura hierárquica proposta, só há fusão sensorial (de vetores de características) quando classificada uma descontinuidade do cordão de solda na SVM

do primeiro estágio. A principal vantagem da estratégia proposta é o acréscimo do custo computacional (execução do segundo estágio com o processamento dos dados do cristal piezoelétrico) ocorrer apenas quando for necessário. Outra diferença importante é a forma de classificação das três classes. No SVM tem-se o problema de classificação multiclasse solucionado pelo método de binarização um-contra-um (subseção 3.6.2). No HSVM tem-se a classificação binária em cada nível de decisão.

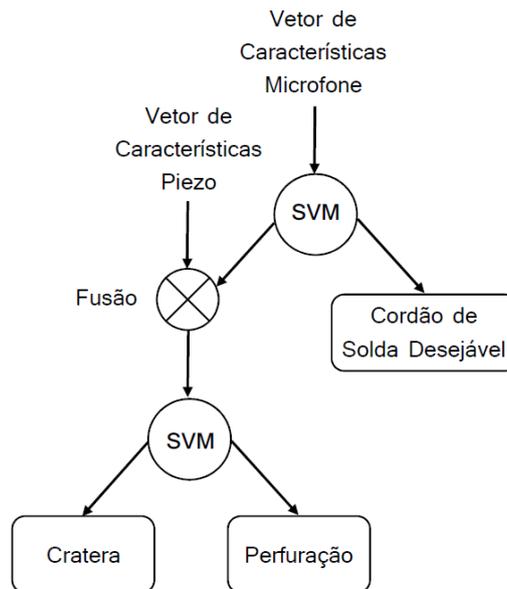


Figura 4.19 – Estrutura hierárquica proposta para classificação de descontinuidades no cordão de solda. Fonte (adaptado): Cocota *et al.*, 2017.

No Anexo B encontram-se fluxogramas simplificados dos *scripts* implementados em MATLAB para os classificadores SVM, HSVM e RNA.

4.8.1 Treinamento, Validação e Teste dos Classificadores

Para o treinamento da SVM e da HSVM propostas foram utilizados 69% dos dados pré-processados do sinal acústico aéreo (microfone) e os 31% restantes foram utilizados no teste do modelo. Os dados pré-processados do sinal acústico sólido (piezo) foram utilizados na mesma proporção para treinamento e teste do modelo SVM presente no segundo estágio da estrutura HSVM (Figura 4.19). No treinamento de ambas máquinas de vetor de suporte, aplicou-se uma função *Kernel* linear, com o parâmetro de restrição *C* unitário, em conjunto com o método de binarização um-contra-um. Em ambos classificadores a alimentação dos dados foi aleatória para treinamento e teste. Para assegurar a distribuição uniforme de probabilidade entre as classes no modelo do classificador foi utilizado o parâmetro *uniform* na função *fitcecoc*.

Para a rede neural artificial (RNA), utilizam-se 60% dos dados pré-processados do sinal acústico aéreo para treinar o modelo do classificador, 20% para validação cruzada do treinamento da rede e 20% restantes para teste do modelo. Os dados foram ordenados de forma aleatória para o treinamento, validação e teste. Na etapa de treinamento, os valores dos pesos e de *bias* foram atualizados de acordo com o método do gradiente conjugado escalonado. A arquitetura da RNA utilizada foi a de aprendizagem por retropropagação para uma rede totalmente conectada 5k-10-3, ou seja, uma rede com 5 mil entradas, uma camada oculta e três saídas, sendo uma para cada classe.

4.8.2 Avaliação dos Classificadores

Neste trabalho, para avaliação do desempenho dos classificadores SVM e RNA adotou-se a metodologia da acurácia global a partir da Matriz de Confusão (*MC*) quadrada com dimensão $N_c \times N_c$. Essa matriz associa as linhas (*m*) aos verdadeiros rótulos das classes e as colunas (*n*) aos resultados da classificação. A acurácia global (Equação 4.3) é computada pela razão da soma dos elementos da diagonal, que correspondem às classes estimadas corretamente, em relação ao total de elementos da matriz (Gannakopoulos e Pikrakis, 2014).

$$A_{CC} = \frac{\sum_{m=1}^{N_c} MC(m, m)}{\sum_{m=1}^{N_c} \sum_{n=1}^{N_c} MC(m, n)} \quad (4.3)$$

O erro de classificação é expresso por $e = 1 - A_{CC}$.

Para avaliar a capacidade de generalização do classificador HSVM, considerou-se os resultados de classificação dos dois estágios de SVM. Portanto, as duas matrizes de confusão (MC_1 e MC_2) foram utilizadas para computar a acurácia global do classificador HSVM proposto (Equação 4.4). Essa metodologia foi proposta, pois os vetores de características avaliados no segundo estágio do HSVM são distintos do primeiro estágio em função da fusão sensorial.

$$A_{CC} = \frac{\sum_{m=1}^{N_c} MC_1(m, m) + \sum_{m=1}^{N_c} MC_2(m, m)}{\sum_{m=1}^{N_c} \sum_{n=1}^{N_c} MC_1(m, n) + \sum_{m=1}^{N_c} \sum_{n=1}^{N_c} MC_2(m, n)} \quad (4.4)$$

4.9 Preparações Metalográficas

Um total de quinze amostras foram seccionadas de cordões de solda para avaliações metalográficas, sendo oito seções transversais e sete seções longitudinais. Essas amostras

tiveram suas superfícies de interesse seccionadas em um equipamento de corte a disco diamantado de precisão e de baixa rotação (da Materials Science – NW), tendo realizado um papel fundamental na execução de corte longitudinal no centro de cordões de solda. Para o uso desse equipamento, que se encontra no LESTA, no corte de seções longitudinais de aproximadamente 40mm de comprimento, foi necessário instalar um circuito fechado de água para o arrefecimento do disco e da amostra.

As amostras devidamente cortadas foram embutidas a frio em resina acrílica com agente de cura. Os embutimentos foram deixados nos moldes durante vinte e quatro horas para cura completa.

Posteriormente, as amostras foram devidamente preparadas a úmido com lixas do tipo SiC nas granulações 120, 180, 240, 320, 400, 600, 800 e 1200. Concluída a etapa de desbaste por lixa, foi efetuado o polimento das amostras em duas etapas: (1) polimento com alumina em suspensão de 1 μ m; e (2) polimento com pasta de diamante de 1 μ m. Após a etapa de polimento, as amostras foram submetidas à limpeza em banho de álcool etílico pró-análise (P.A), com posterior secagem por meio de jato de ar quente.

As amostras devidamente preparadas foram fotografadas por meio da lupa Olympus SZ61, com auxílio da câmera Leica MC170 HD, para posterior avaliação macroscópica dos cordões de solda. A lupa e a câmera pertencem ao LTM.

Em sequência, foram adquiridas imagens dessas amostras por meio do microscópio Leica DM 2700 M, também disponível no LTM, e da câmera Leica MC170 HD, com o objetivo de avaliar descontinuidades não visíveis por meio de lupa.

Por fim, as amostras foram submetidas à ataque químico por uma solução Nital 2% (composta por 2% de ácido nítrico e 98% de álcool P.A). O ataque possibilita realçar os contornos dos grãos das amostras, para posterior avaliação da microestrutura a partir de imagens adquiridas por meio do microscópio supracitado.

4.10 Análises Macro e Microscópicas

Para a qualificação das descontinuidades nos cordões de solda foi utilizada como referência a norma ISO 5817 (Soldagem – Juntas soldadas por fusão em aço, níquel, titânio e outras ligas – Níveis de qualidade para imperfeições). De acordo com ela, não é admissível a ocorrência de perfuração ou de trinca no cordão de solda e a avaliação macroscópica deve ser efetuada por meio de uma lupa com aumento de até 10 vezes. A presença das demais descontinuidades é tolerável desde que atendidos os requisitos de qualidade (Tabela 4.6). Nessa etapa, além da avaliação das descontinuidades, também foram identificadas as principais

medidas geométricas (largura, reforço e penetração) dos cordões (Figura 4.20). De acordo com a mesma norma, as micro trincas devem ser avaliadas por meio de microscópio com aumento de 50 vezes.

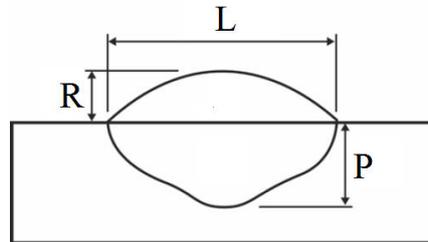


Figura 4.20 – Geometria típica de um cordão de solda e suas principais medidas: largura (L); reforço (R) e penetração (P). Fonte (adaptado): Ribeiro *et al.* (2015).

Tabela 4.6 – Descontinuidades e seus respectivos requisitos de qualidade (D – baixo; C – médio; B – alto). Sendo h a altura ou largura da descontinuidade; b a largura do cordão; s a espessura do cordão de solda; t a espessura da placa; e d o diâmetro do poro. Fonte (adaptado): ISO 5817.

(continua)

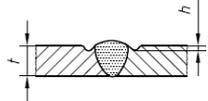
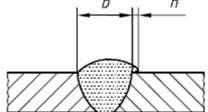
Tipo de descontinuidade	Observações	Limites para os níveis de qualidade		
		D	C	B
Cratera		Pequenas imperfeições são permitidas ($h \leq 0,4s$)	Não permitido	Não permitido
Mordedura		Pequenas imperfeições ($h \leq 0,2t$)	Pequenas imperfeições ($h \leq 0,1t$)	Não permitido
Sobreposição		$h \leq 0,2b$	Não permitido	Não permitido
Poros superficial	Dimensão máxima de um poro	$d \leq 0,3s$	Não permitido	Não permitido
Porosidade na raiz	Formação esponjosa na raiz da solda resultante do borbulhamento da poça de fusão no momento de solidificação	Permitido localmente	Não permitido	Não permitido

Tabela 4.6 – Descontinuidades e seus respectivos requisitos de qualidade (D – baixo; C – médio; B – alto). Sendo h a altura ou largura da descontinuidade; b a largura do cordão; s a espessura do cordão de solda; t a espessura da placa; e d o diâmetro do poro. Fonte (adaptado): ISO 5817.

(conclusão)

Tipo de descontinuidade	Observações	Limites para os níveis de qualidade		
		D	C	B
Porosidade (resultante de aprisionamento de gás no momento de solidificação)	Percentual máximo de poros em relação a área transversal do cordão	$\leq 2,5\%$	$\leq 1,5\%$	$\leq 1\%$
	Dimensão máxima de um poro	$d \leq 0,4s$, e máximo de 5mm	$d \leq 0,3s$, e máximo de 4mm	$d \leq 0,2s$, e máximo de 3mm
Micro trinca	Somente visível em microscópio (50x)	Permitido	A aceitação depende da susceptibilidade de formação de trinca no metal de base	
Respingos		A aceitação depende da aplicação		

5. Resultados e Discussões

Neste capítulo são apresentadas as discontinuidades observadas nos cordões, os parâmetros geométricos dos cordões, o pré-processamento de sinais e os resultados de classificação de padrões por meio de SVM e ANN.

5.1 Descontinuidades nos Cordões de Solda

Após a realização dos experimentos, foram identificados dois tipos de discontinuidades predominantes na superfície oposta aos sulcos transversais (Figura 4.17) no metal de base: cratera e perfuração.

Além dessas discontinuidades, outras foram observadas, e.g., respingo no metal de base, sobreposição, trinca na raiz dos cordões, mordedura e poro nas crateras. A presença de respingos não foi relevante nos experimentos. As discontinuidades de respingo, sobreposição, trinca, mordedura e poro nas crateras não são objeto de aprendizagem de máquinas neste trabalho. Serão apenas citadas as razões de suas ocorrências.

Nas Figuras 5.1 a 5.6 tem-se fotos da vista superior de cordões de solda, juntamente com a intensidade dos sinais audíveis, que foram obtidos nos experimentos, com representantes das três classes que são objeto de estudo deste trabalho: (1) normal; (2) cratera; e (3) perfuração.

Nessas figuras, a intensidade do sinal audível diminui ligeiramente no período de formação de cratera ou de perfuração da chapa. Esse comportamento era esperado, pois a quantidade de material na poça de fusão é menor na região do sulco transversal ao cordão, que resulta no decréscimo de emissão de sinais acústicos aéreos da interação do arco com a poça.

A atenuação do sinal audível associada a discontinuidade de cratera pode ser observada nas Figuras 5.2 (1ª e 3ª discontinuidade), 5.3 (1ª e 3ª discontinuidade), 5.5 (2ª e 3ª discontinuidade) e 5.6 (1ª e 2ª discontinuidade).

No caso da perfuração, quando ocorre essa discontinuidade, o arco é mantido mesmo com a ruptura da poça de fusão. Ele abre e o material passa a ser depositado no contorno original da poça. O instante dessa ocorrência é registrado por um acréscimo na intensidade (pico) do sinal audível que corresponde, aproximadamente, ao início da discontinuidade, sendo representado nas Figuras 5.1 (2ª discontinuidade em 15,28s e 3ª discontinuidade em 26,74s), 5.2 (2ª discontinuidade em 15,22s), 5.3 (2ª discontinuidade em 14,89) e 5.4 (2ª discontinuidade em 14,32s e 3ª discontinuidade em 25,41s).

É importante ressaltar que a atenuação do sinal audível no final dos registros dos cordões de solda corresponde ao fechamento do arco no término da execução dos cordões.

Embora os comportamentos temporais do sinal audível para as discontinuidades de cratera e perfuração, como descritos, sejam frequentes, não são unânimes. Nas Figuras 5.1 (1ª discontinuidade), 5.4 (1ª discontinuidade), 5.5 (1ª discontinuidade) e 5.6 (3ª discontinuidade) o comportamento do sinal audível no tempo é difícil de se distinguir em relação aos demais registros dos cordões. Essa foi a principal razão para o uso da transformada de Fourier no processo de extração de características do sinal audível. Assim, esse sinal passa a ser analisado no domínio da frequência (seção 5.4.1).

Na Figura 5.5 nota-se uma discontinuidade geométrica do cordão, falta de alinhamento, resultante de alteração da orientação do eletrodo. Neste caso, a extremidade do eletrodo fixada ao porta-eletrodo movimentou ao longo da execução do cordão de solda.

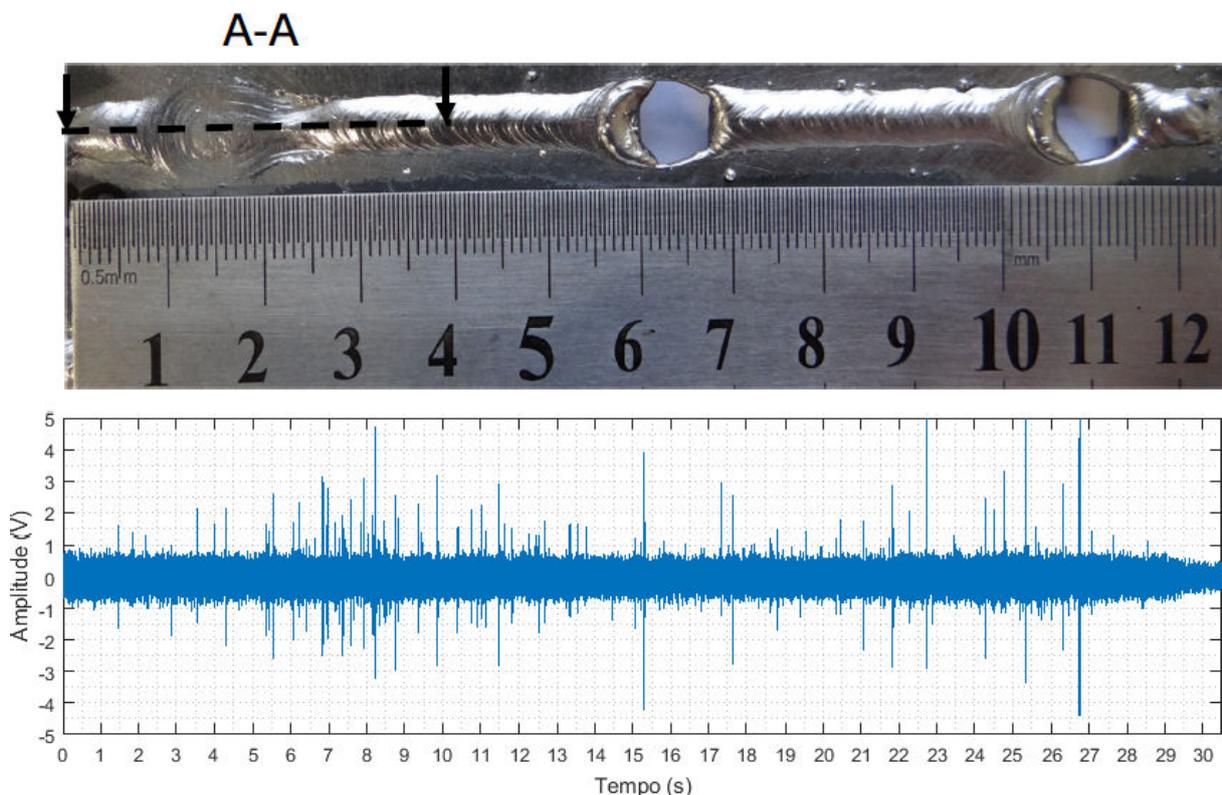


Figura 5.1 – Cordão de solda nº 30 com representantes das três classes: cordão normal, cratera e perfuração; e respectivo sinal audível amostrado. Fonte: Autor.

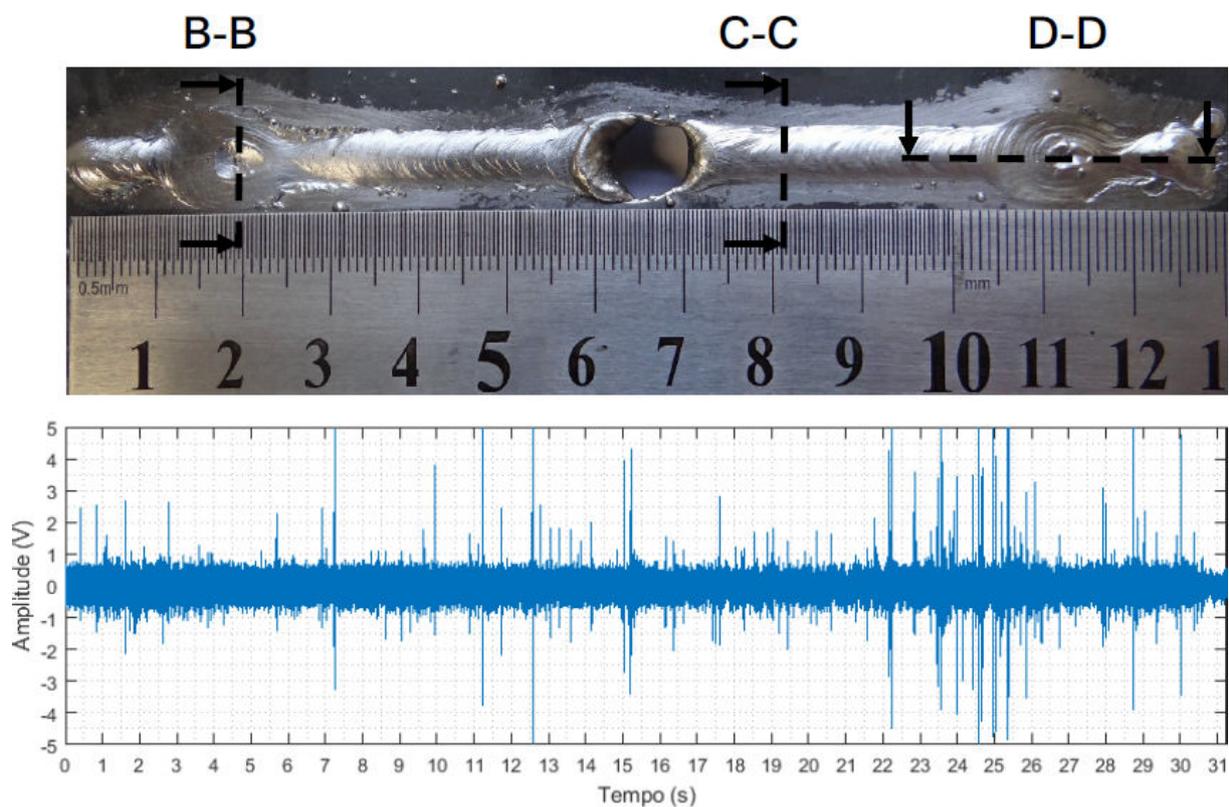


Figura 5.2 – Cordão de solda nº 31 com representantes das três classes e respectivo sinal audível amostrado. Fonte: Autor.

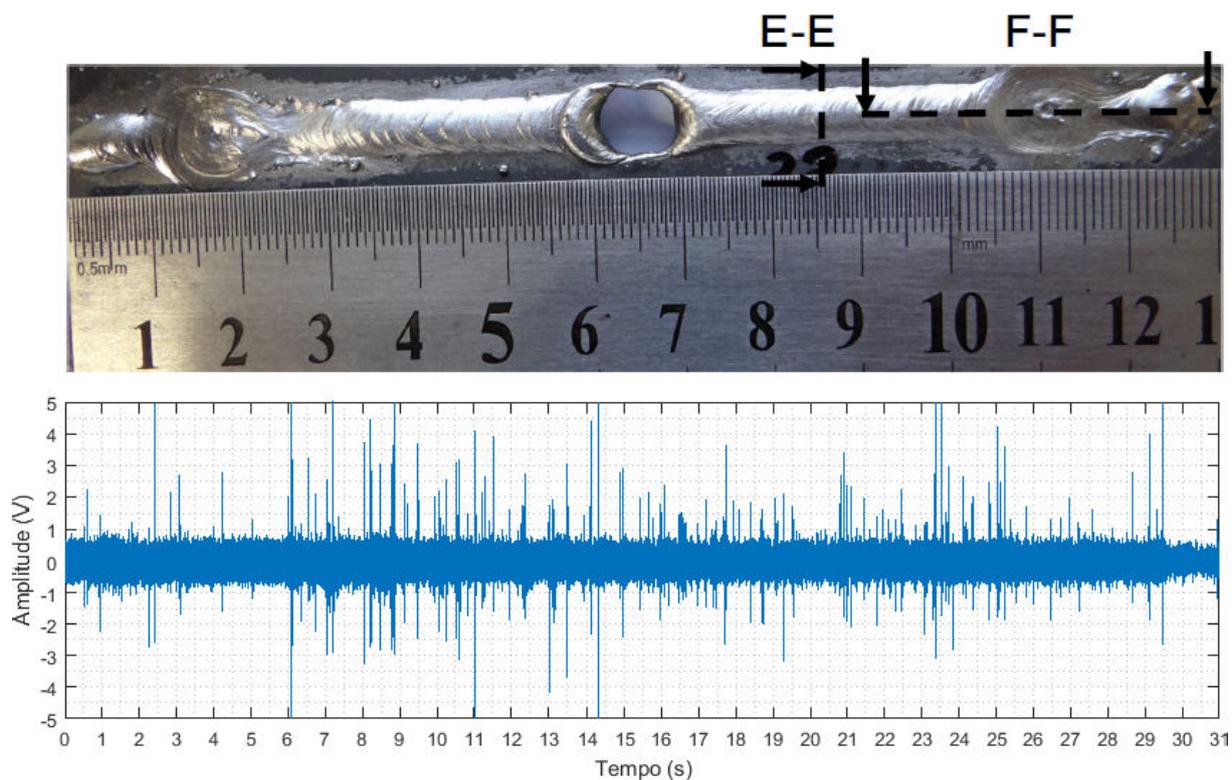


Figura 5.3 – Cordão de solda nº 32 com representantes das três classes e respectivo sinal audível amostrado. Fonte: Autor.

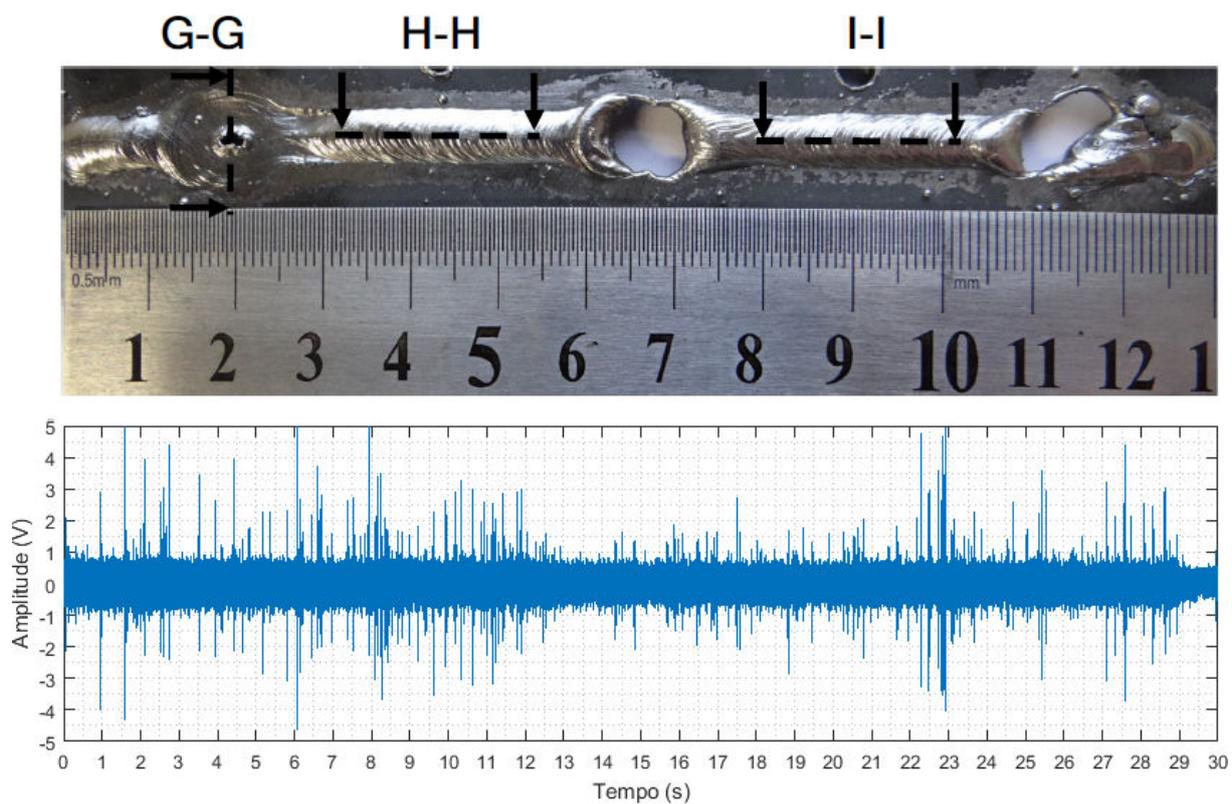


Figura 5.4 – Cordão de solda nº 34 com representantes das três classes e respectivo sinal audível amostrado. Fonte: Autor.

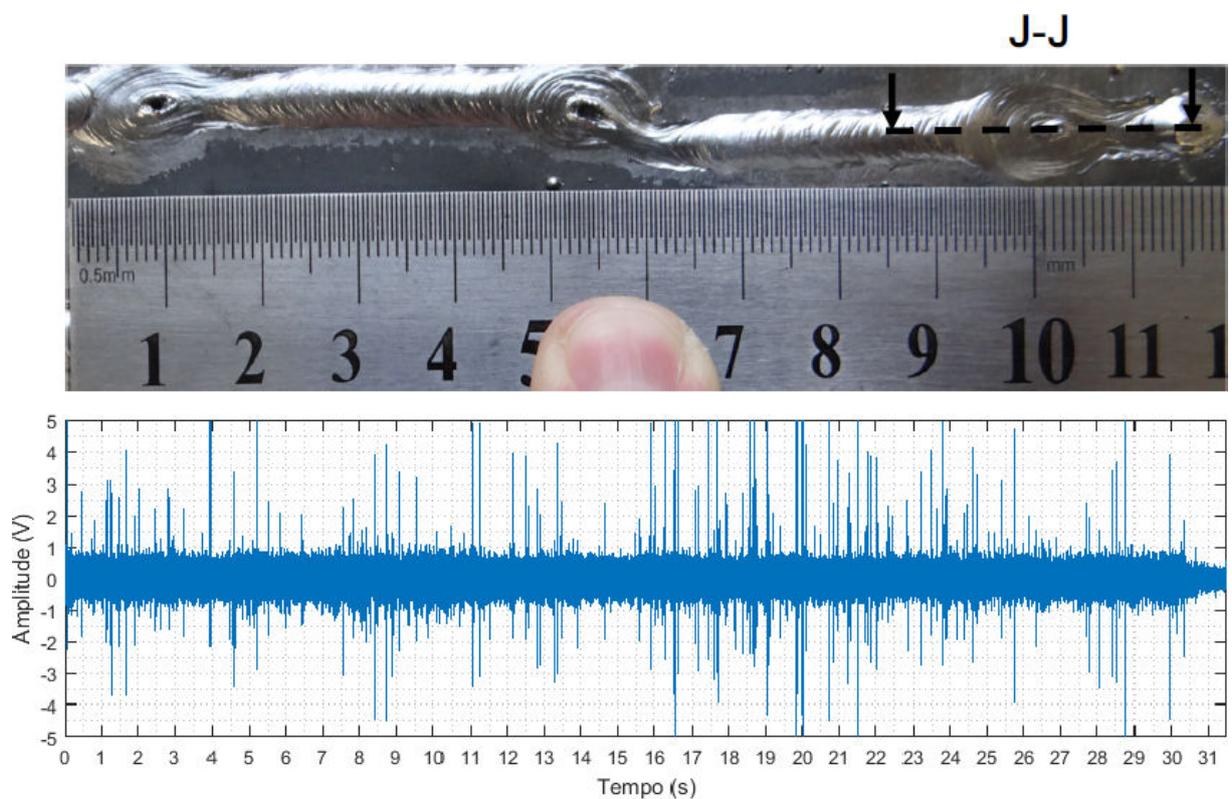


Figura 5.5 – Cordão de solda nº 26 com representantes das classes normal e cratera, bem como o respectivo sinal audível amostrado. Fonte: Autor.

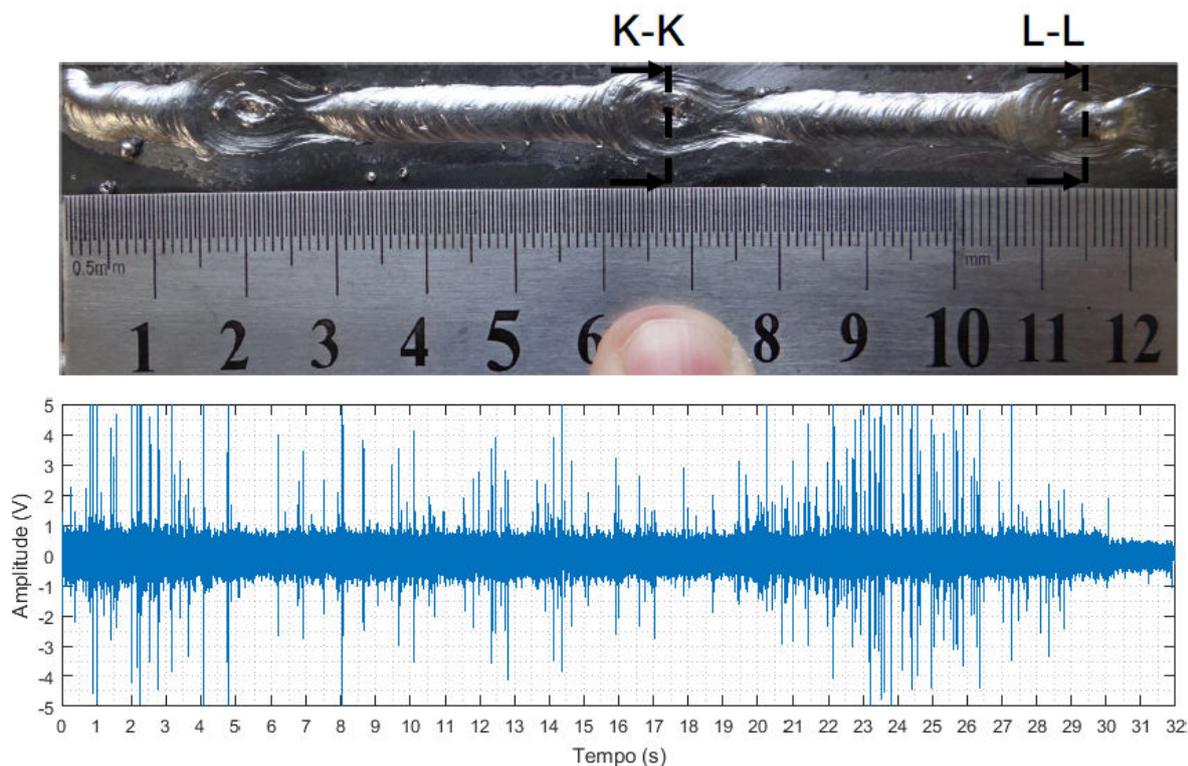


Figura 5.6 – Cordão de solda nº 27 com representantes das classes normal e cratera, bem como o respectivo sinal audível amostrado. Fonte: Autor.

Nas Figuras 5.1 a 5.6 são mostradas mordeduras no término das crateras, quando ocorre a transição da seção mais delgada (região do sulco transversal) para a mais espessa da chapa de aço. A causa está associada à falta de material do metal de base.

Nas Figuras 5.4, 5.5 e 5.6, tem-se a presença de poro superficial no centro da cratera. Essa descontinuidade está associada ao fluxo de calor. Em resumo, quando ocorre a formação da cratera, o comprimento do arco aumenta e o fornecimento de calor à junta é reduzido. Com menor energia de soldagem, a temperatura máxima (de pico) alcançada pelo cordão é reduzida. Consequentemente, como o período para solidificação do cordão é menor, gases gerados durante o processo SMAW podem não ter tempo hábil para serem expulsos da poça de fusão, resultando em poros internos, ao serem aprisionados no metal solidificado, ou em poros na superfície ou na raiz do cordão.

Para avaliar a influência de alteração de um parâmetro de soldagem, executou-se dois cordões de solda (Figuras 5.7 e 5.8) com velocidade de mergulho do eletrodo reduzida para 3,3mm/s. A corrente foi mantida em 75A e a velocidade de translação em 2,5mm/s. Além da ocorrência das crateras, a geometria do cordão deixou de ser uniforme nos trechos com maior espessura da chapa (3/8 pol.) e houve maior incidência de respingos. Nesses casos, como a

velocidade de alimentação do eletrodo foi menor, o comprimento do arco foi maior, aproximadamente 10mm, o que resultou na não uniformidade de deposição do metal de adição.

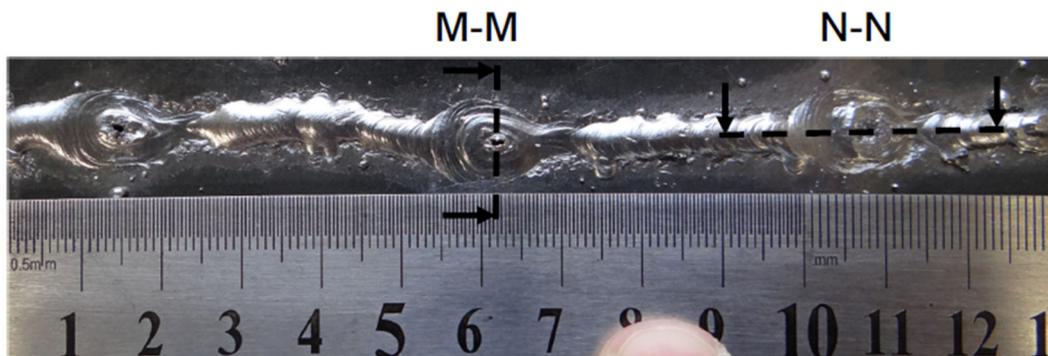


Figura 5.7 – Cordão de solda nº 24 efetuado com os parâmetros de soldagem de corrente de 75A, velocidade de translação de 2,5mm/s e velocidade de mergulho do eletrodo de 3,3mm/s.

Fonte: Autor.



Figura 5.8 – Cordão de solda nº 25 efetuado com os parâmetros de soldagem de corrente de 75A, velocidade de translação de 2,5mm/s e velocidade de mergulho do eletrodo de 3,3mm/s.

Fonte: Autor.

5.2 Análises Macroscópicas

5.2.1 Seções Transversais

Nas Figuras 5.9 e 5.10 tem-se macrografias de seções transversais de cordões de solda da classe normal. Observa-se que não houve penetração total do cordão, algo esperado pelo uso do eletrodo E 6013, caracterizado por baixa penetração e pelo curto comprimento do arco (Nagesh e Datta, 2002). Outra observação importante é que o metal de solda possui uma área total de poros inferior à do metal de base. Esse resultado reforça que os parâmetros adotados para deposição do cordão de solda na chapa com espessura de 1/8 pol. não influenciaram no surgimento de poros no metal de solda. Na Tabela 5.1 tem-se as principais medidas geométricas dos cordões da classe normal das Figuras 5.9 e 5.10.

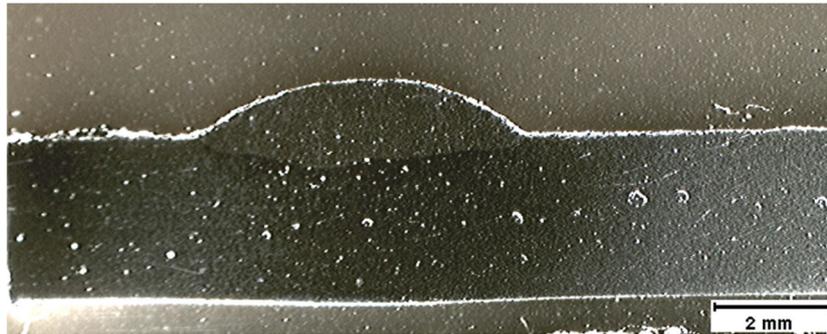


Figura 5.9 – Macrografia (10x) de cordão de solda da classe normal. Seção transversal C-C do cordão de solda nº 31 – Figura 5.2. Fonte: Autor.



Figura 5.10 – Macrografia (10x) de cordão de solda da classe normal. Seção transversal E-E do cordão de solda nº 32 – Figura 5.3. Fonte: Autor.

Tabela 5.1 – Medidas geométricas dos cordões de solda normal das macrografias das Figuras 5.9 e 5.10. Fonte: Autor.

Cordão (nº)	Seção Transversal	Medidas Geométricas		
		Largura	Reforço	Penetração
31	C-C (Figura 5.2)	5,7mm	1,1mm	0,5mm
32	E-E (Figura 5.3)	5,9mm	1,3mm	0,5mm

Esses cordões de solda foram executados com corrente de 75A. Os cordões executados com corrente de 70A diferem-se principalmente em sua topografia por apresentar menor largura do cordão.

As amostras de seções transversais de crateras estão apresentadas nas Figuras 5.11 a 5.15. Nessas figuras observa-se um coeficiente elevado de diluição, que não é desejável em cordões de solda, uma vez que altera significativamente o comportamento mecânico do material. A cratera ocorreu devido à penetração excessiva na seção mais delgada da chapa (região do sulco transversal) e corresponde ao estágio anterior à perfuração. Esse

comportamento é representado nas fotos pelo metal de solda que cede a um nível inferior ao do metal de base.



Figura 5.11 – Macrografia (10x) de cordão de solda da classe cratera. Seção transversal B-B do cordão de solda nº 31 – Figura 5.2. Fonte: Autor.

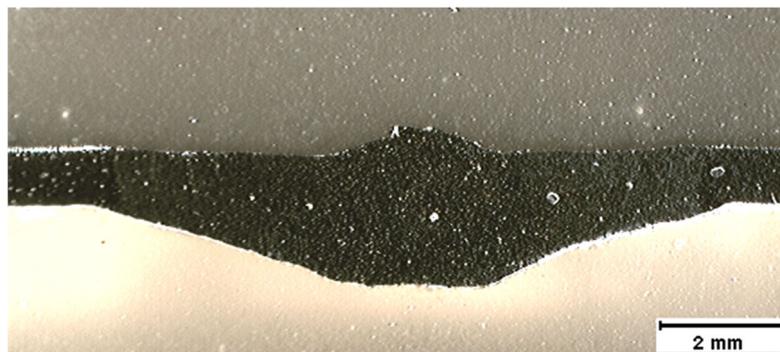


Figura 5.12 – Macrografia (10x) de cordão de solda da classe cratera. Seção transversal G-G do cordão de solda nº 34 – Figura 5.4. Fonte: Autor.



Figura 5.13 – Macrografia (10x) de cordão de solda da classe cratera. Seção transversal K-K do cordão de solda nº 27 – Figura 5.6. Fonte: Autor.

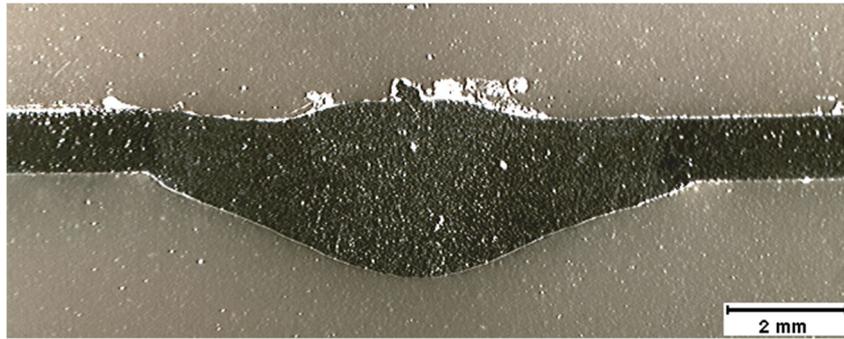


Figura 5.14 – Macrografia (10x) de cordão de solda da classe cratera. Seção transversal L-L do cordão de solda nº 27 – Figura 5.6. Fonte: Autor.

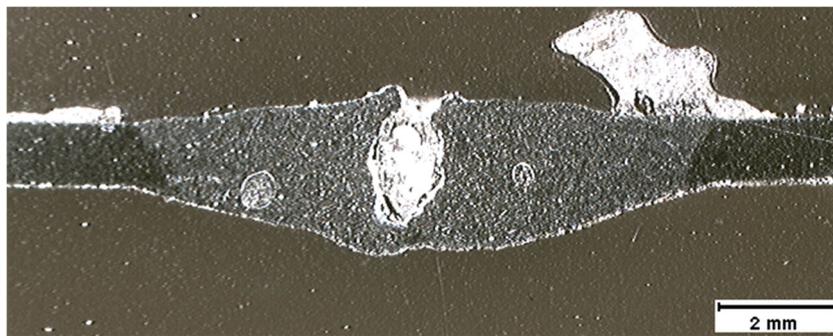


Figura 5.15 – Macrografia (10x) de cordão de solda da classe cratera. Seção transversal M-M do cordão de solda nº 24 – Figura 5.7. Fonte: Autor.

Nas Figuras 5.11 a 5.14 nota-se uma presença mais significativa de poros no metal de solda, em relação às amostras de cordão de solda da classe normal (Figuras 5.9 e 5.10). É possível verificar a presença de poros na superfície, na raiz e de porosidade resultante de aprisionamento de gás no metal de solda. Como discutido na seção 5.1, essas discontinuidades estão associadas ao menor fornecimento de calor à junta no período de formação da cratera, em função do acréscimo do comprimento do arco.

A macrografia da Figura 5.15 é referente ao experimento com velocidade de mergulho do eletrodo reduzida para 3,3mm/s. Nesse caso, vale recordar que o comprimento do arco foi maior, aproximadamente 10mm, o que resultou em uma queda acentuada do fluxo de calor. Como consequência, houve um acréscimo significativo de poros no metal de solda.

Na Figura 5.16, tem-se a macrografia da seção transversal “O-O” do cordão de solda nº 25 na região de maior espessura da chapa de aço. Esse cordão também foi efetuado com velocidade de mergulho do eletrodo reduzida para 3,3mm/s. Como esperado, não ocorreu penetração total. Nessa macrografia, à esquerda do cordão, tem-se a presença da discontinuidade de sobreposição. Essa discontinuidade ocorreu apenas nessa amostra. As

medidas geométricas desse cordão estão presentes na Tabela 5.2. Nota-se que, em função do maior comprimento do arco e do menor fluxo de calor, esse cordão apresentou maior largura e menor penetração.

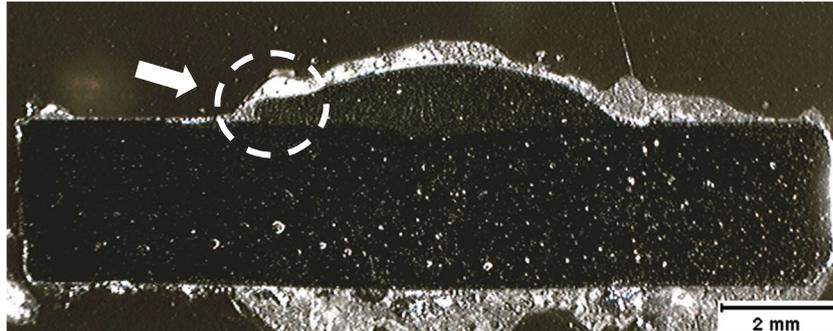


Figura 5.16 – Macrografia (10x) de cordão de solda. Seção transversal O-O do cordão de solda nº 25 – Figura 5.8. Fonte: Autor.

Tabela 5.2 – Medidas geométricas do cordão de solda da macrografia da Figura 5.16. Fonte: Autor.

Cordão (nº)	Seção Transversal	Medidas Geométricas		
		Largura	Reforço	Penetração
25	O-O (Figura 5.8)	6,2mm	1mm	0,3mm

5.2.2 Seções Longitudinais

Nas Figuras 5.17 e 5.18 tem-se macrografias de seções longitudinais de cordões de solda da classe normal. Essas seções foram efetuadas no centro do cordão de solda. As observações referentes a essas amostras são as mesmas que foram previamente discutidas: (1) não houve penetração total do cordão; (2) a área de poros no metal de solda é inferior à presente no metal de base; (3) a espessura do cordão foi de aproximadamente 1,7mm.

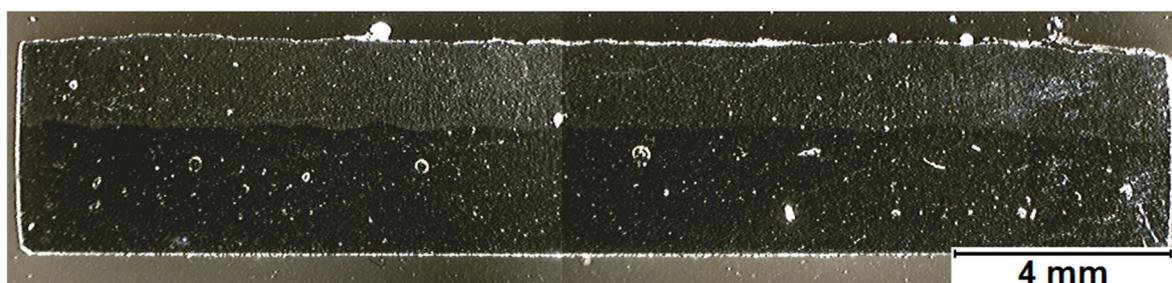


Figura 5.17 – Macrografia (10x) de cordão de solda da classe normal. Seção longitudinal H-H do cordão de solda nº 34 – Figura 5.4. Fonte: Autor.

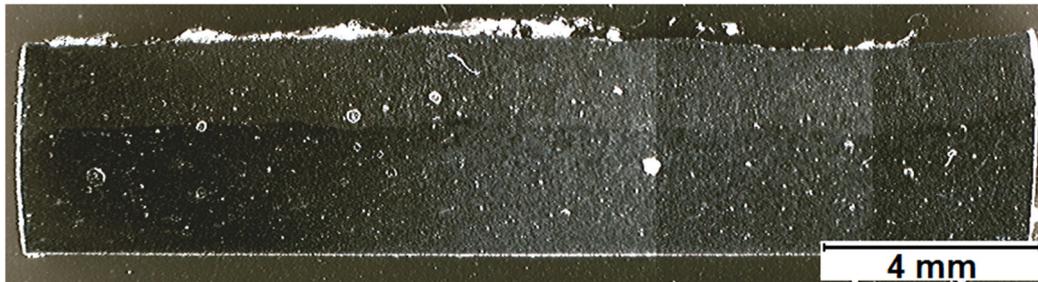


Figura 5.18 – Macrografia (10x) de cordão de solda da classe normal. Seção longitudinal I-I do cordão de solda nº 34 – Figura 5.4. Fonte: Autor.

Nas Figuras 5.19 a 5.22 tem-se macrografias de seções longitudinais de cordões de solda com representantes das classes normal e cratera. Nessas figuras, cada macrografia está associada ao seu respectivo sinal audível amostrado durante a execução do cordão de solda.

Uma observação importante é que esse sinal se altera com o formato da poça de fusão durante a formação da cratera, apresentando duas fases com características distintas. Na primeira fase, quando inicia a formação da poça de fusão na seção mais delgada da chapa, tem-se o comportamento de penetração total do cordão de solda. Segundo Li *et al.* (2013), no instante anterior à penetração total, o arco empurra a poça de fusão para um nível inferior ao do metal de base, e, como consequência, o comprimento do arco aumenta. Esse comportamento leva ao decréscimo da intensidade do sinal audível, que pode ser observado na região central da descontinuidade (em especial nas Figuras 5.20, 5.21 e 5.22). Na fase seguinte, à medida que o volume de material fundido reduz e o volume do metal de base cresce, a intensidade sonora gerada pela interação do arco com a poça de fusão aumenta.

Como discutido na seção 5.1, o sinal registrado da primeira descontinuidade do cordão de solda nº 30, que corresponde a cratera da Figura 5.19, é difícil de se distinguir em relação aos demais registros do cordão. Nota-se que o sinal do áudio no tempo da primeira seção longitudinal do cordão de solda da classe normal é similar a uma parcela significativa dos registros de áudio da descontinuidade.

Na Figura 5.20 é possível observar que o alinhamento de poros no centro da cratera resultou em uma trinca que atravessa a espessura da chapa de aço. Além disso, nota-se um pico no sinal audível no instante de ocorrência dessa descontinuidade.

Nas Figuras 5.20 e 5.21 tem-se a indicação de ocorrência de micro trincas na transição da espessura delgada para a mais espessa da chapa. Nas Figuras 5.22 e 5.23 tem-se a indicação de trincas nessa região. Nessas regiões de ocorrência de micro trincas e trincas, nota-se a

presença de picos na intensidade do sinal audível. Essas discontinuidades serão melhor discutidas na próxima seção.

A macrografia da Figura 5.23 é referente ao experimento com velocidade de mergulho do eletrodo reduzida para 3,3mm/s. Como houve um menor fluxo de calor para a junta, a presença de poros no metal de solda foi mais significativa, em especial na descontinuidade de cratera.

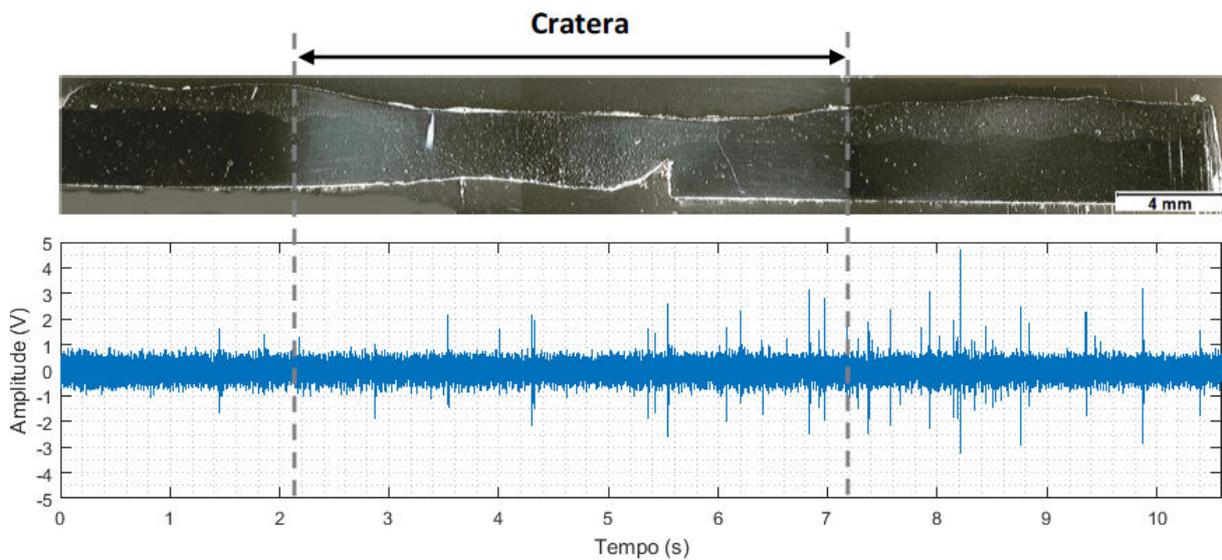


Figura 5.19 – Macrografia (10x) da seção longitudinal A-A do cordão de solda nº 30 (Figura 5.1) e seu correspondente sinal audível. Fonte: Autor.

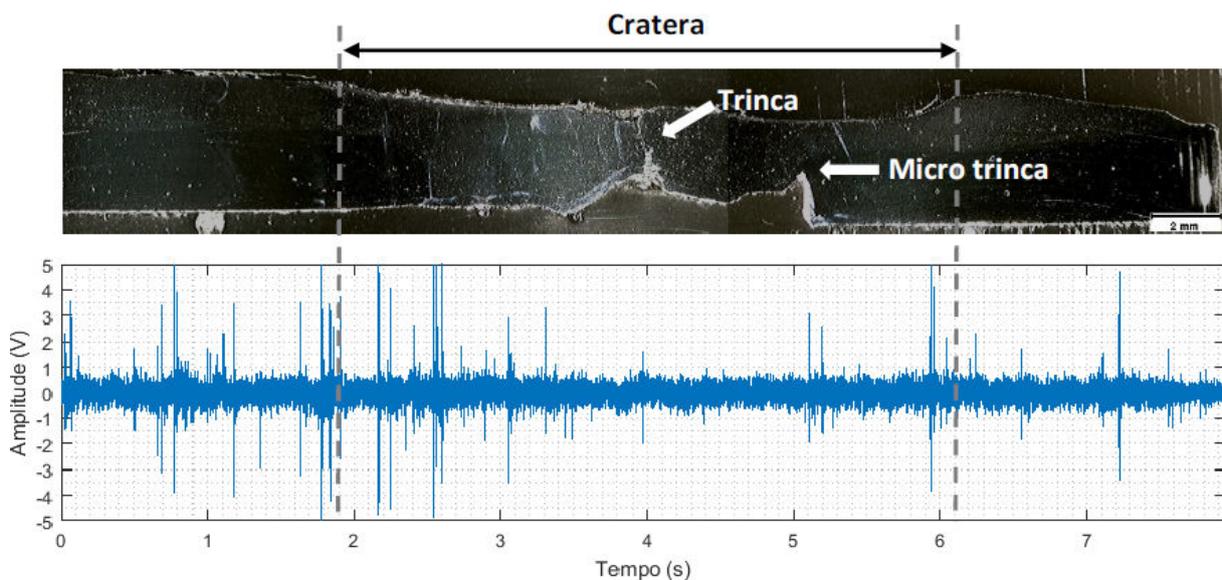


Figura 5.20 – Macrografia (10x) da seção longitudinal D-D do cordão de solda nº 31 (Figura 5.2) e seu correspondente sinal audível. Fonte: Autor.

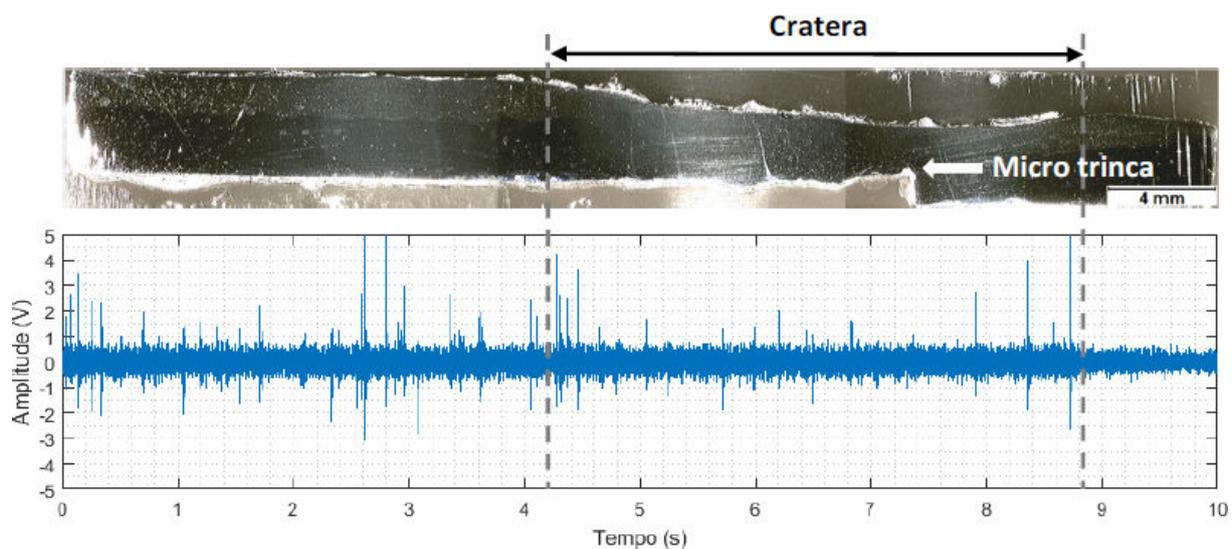


Figura 5.21 – Macrografia (10x) da seção longitudinal F-F do cordão de solda nº 32 (Figura 5.3) e seu correspondente sinal audível. Fonte: Autor.

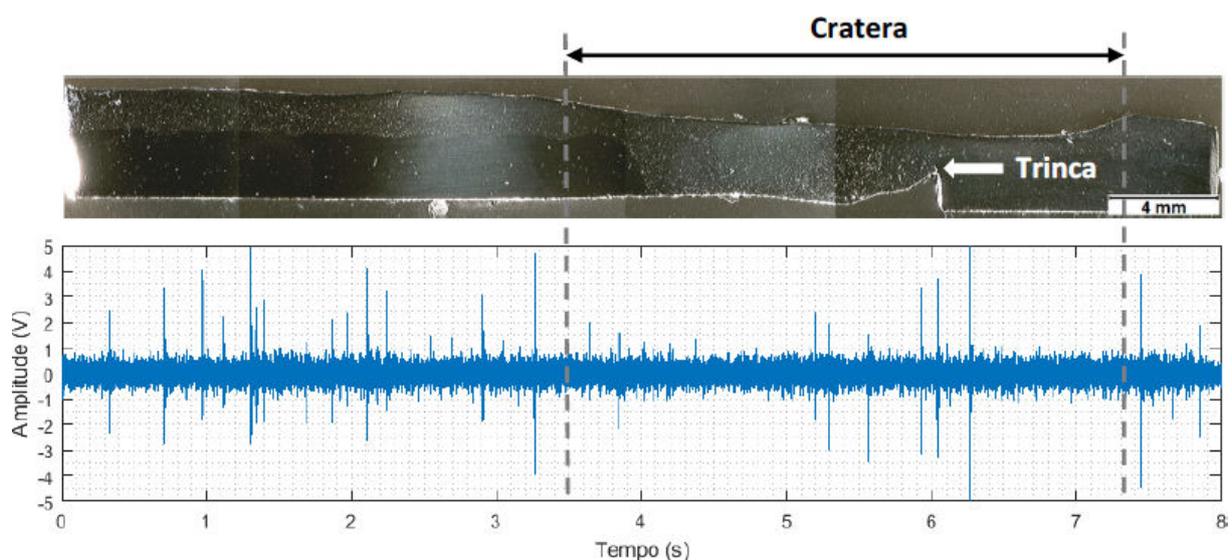


Figura 5.22 – Macrografia (10x) da seção longitudinal J-J do cordão de solda nº 26 (Figura 5.5) e seu correspondente sinal audível. Fonte: Autor.

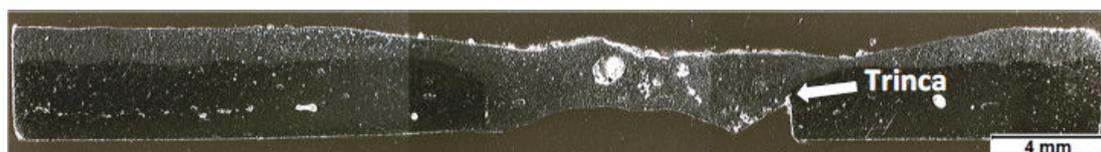


Figura 5.23 – Macrografia (10x) da seção longitudinal N-N do cordão de solda nº 24 (Figura 5.7). Fonte: Autor.

5.3 Análises Microscópicas

Aproximadamente 200 imagens foram capturadas por meio do microscópio óptico. Dentre essas, serão apresentadas as mais relevantes para caracterização da microestrutura dos cordões de solda das classes normal e cratera, bem como para exemplificar as descontinuidades de micro trinca e de trinca.

5.3.1 Cordão de Solda da Classe Normal

Na Figura 5.24 tem-se a micrografia parcial da seção transversal C-C do cordão de solda nº 31 da classe normal, com as três regiões básicas: zona fundida (ZF), zona termicamente afetada (ZTA) e metal de base (MB). Nela é possível observar a linha de fusão, que delimita a interface ZF e ZTA. A ZF é caracterizada por uma microestrutura de grãos colunares e grosseiros, com predominância de ferritas alotriomórfica e acicular. A ZTA pode ser subdividida em três regiões: região de crescimento de grãos, região de refino de grão e região intercrítica. A primeira, compreende a região do metal de base próxima a ZF, onde ocorre o crescimento significativo de grão. Nessa, há a presença significativa de microestrutura de ferritas poligonal e acicular. A segunda é caracterizada por uma estrutura fina de ferrita poligonal. Na região intercrítica ocorre a transformação parcial da estrutura original do metal de base. O MB corresponde à região com a microestrutura original do material, ou seja, mais refinada.

Nas Figuras 5.25, 5.26 e 5.27 tem-se micrografias de ZFs de amostras da classe normal dos cordões 31, 32 e 34. Além dos constituintes microestruturais predominantes, nota-se a presença de ferrita poligonal. Outra observação é que existe uma pequena incidência de poros.

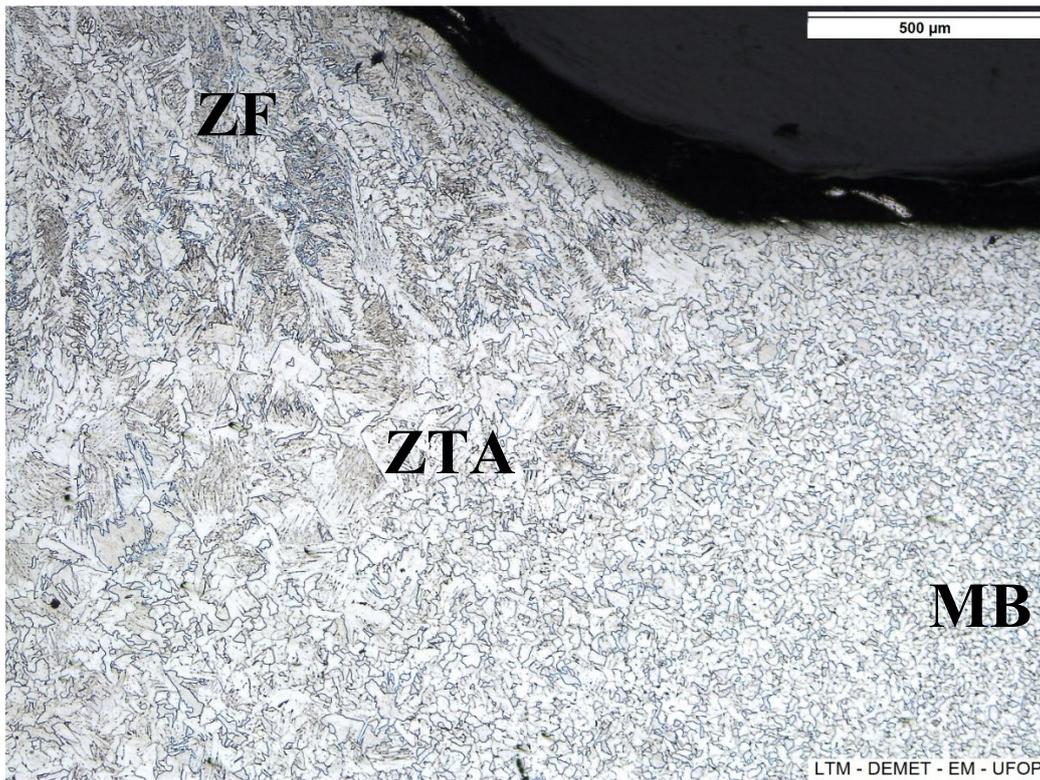


Figura 5.24 – Micrografia (50x) da seção transversal C-C do cordão de solda nº 31 com as três regiões básicas: ZF, ZTA e MB. Fonte: Autor.

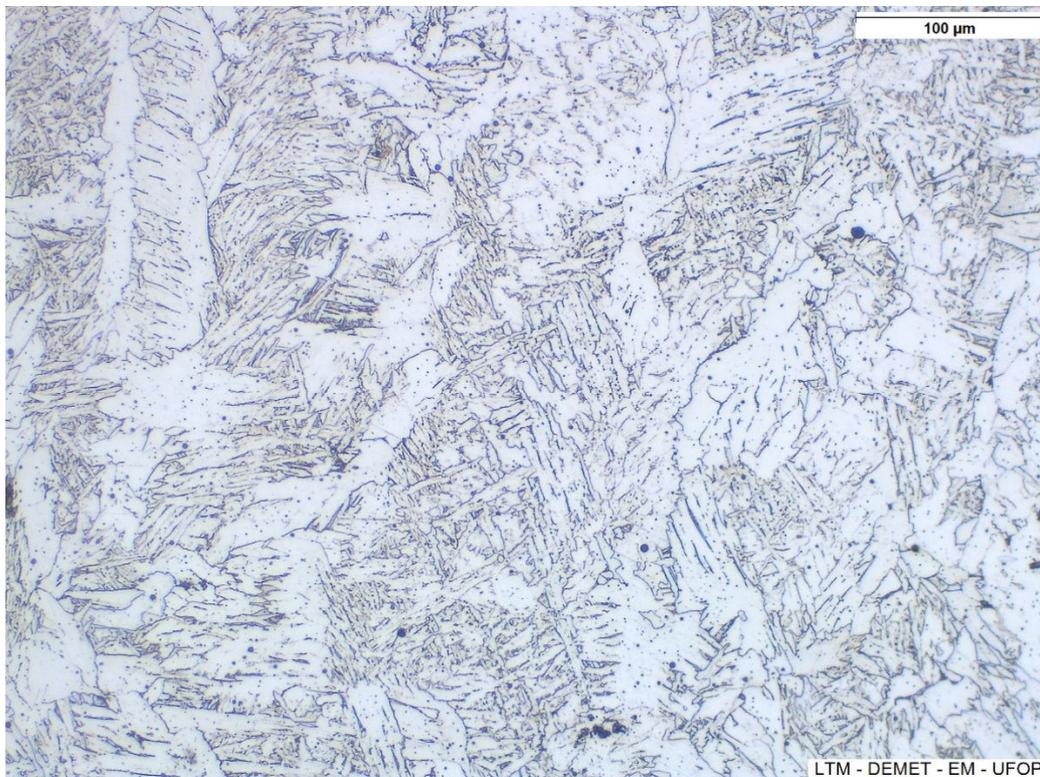


Figura 5.25 – Micrografia (200x) de região de ZF referente a seção transversal C-C do cordão de solda nº 31. Fonte: Autor.

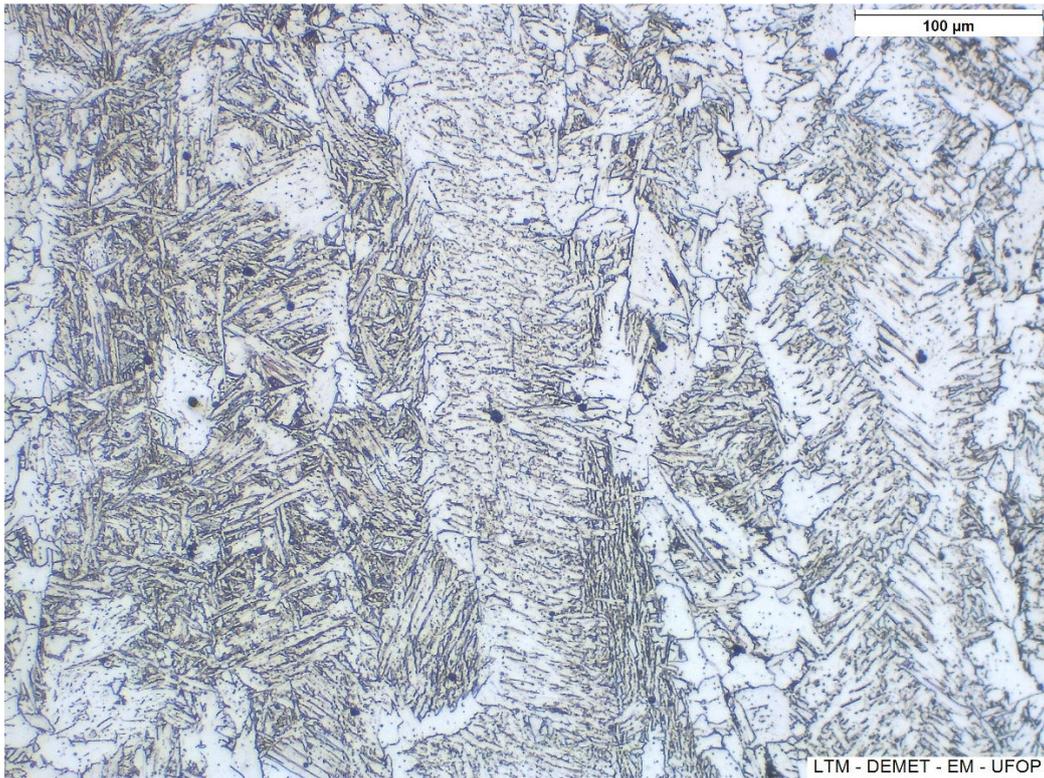


Figura 5.26 – Micrografia (200x) de região de ZF referente a seção transversal E-E do cordão de solda nº 32. Fonte: Autor.

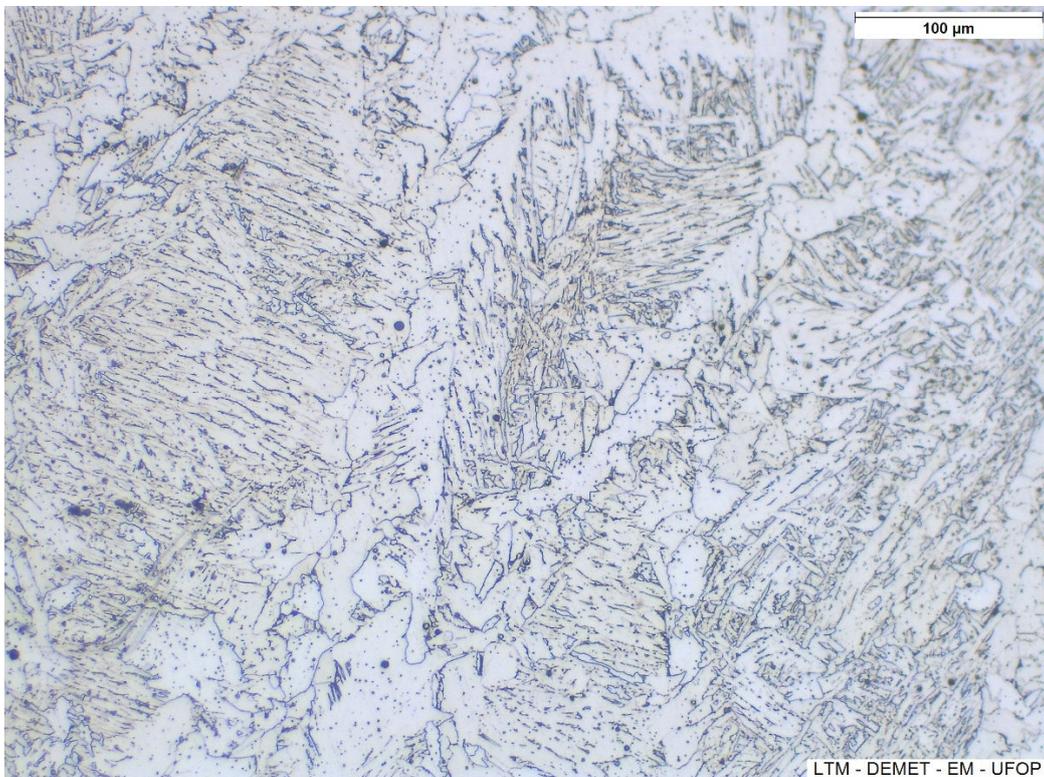


Figura 5.27 – Micrografia (200x) de região de ZF referente a seção longitudinal I-I do cordão de solda nº 34. Fonte: Autor.

5.3.2 Cordão de Solda da Classe Cratera

As micrografias das figuras 5.28, 5.29, 5.30 e 5.31, referentes às ZFs de amostras da classe cratera, revelam que seus microconstituintes são os mesmos presentes na classe normal. Diferenciam-se por possuírem grãos menos grosseiros e por apresentarem maior incidência de poros no metal de solda.

A presença de grãos menos grosseiros e a maior incidência de poros são resultado do menor fluxo de calor no período de formação da descontinuidade cratera no processo de soldagem. Quanto menor a energia, menor o crescimento dos grãos. Quanto menor a energia, menor é o tempo para que os gases sejam liberados da poça de fusão, resultando em maior aprisionamento deles no metal de solda, sob a forma de poros.

Na Figura 5.31 tem-se a amostra com os grãos menos grosseiros. Ela é referente à descontinuidade de cratera que ocorreu no experimento com menor velocidade de mergulho do eletrodo. Recorda-se que nesse experimento o comprimento do arco foi elevado, e resultou na queda acentuada do aporte térmico. Por consequência, essa amostra apresentou a menor dimensão dos grãos constituintes da solda.

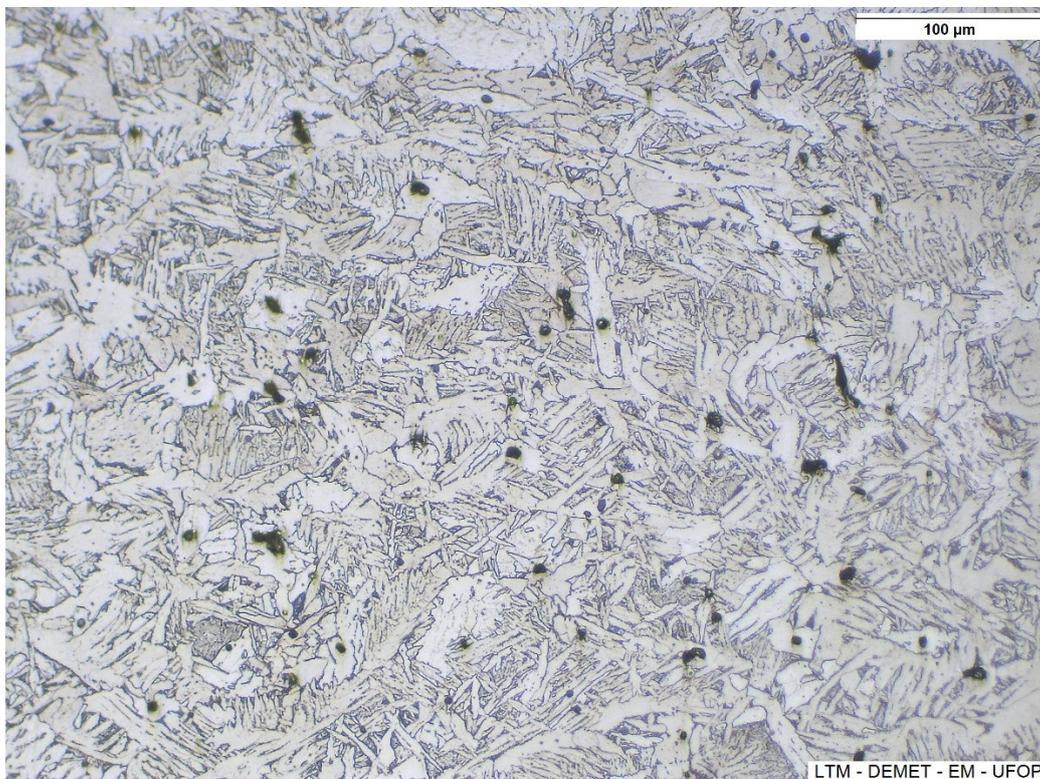


Figura 5.28 – Micrografia (200x) de região de ZF referente a seção transversal B-B do cordão de solda nº 31. Fonte: Autor.

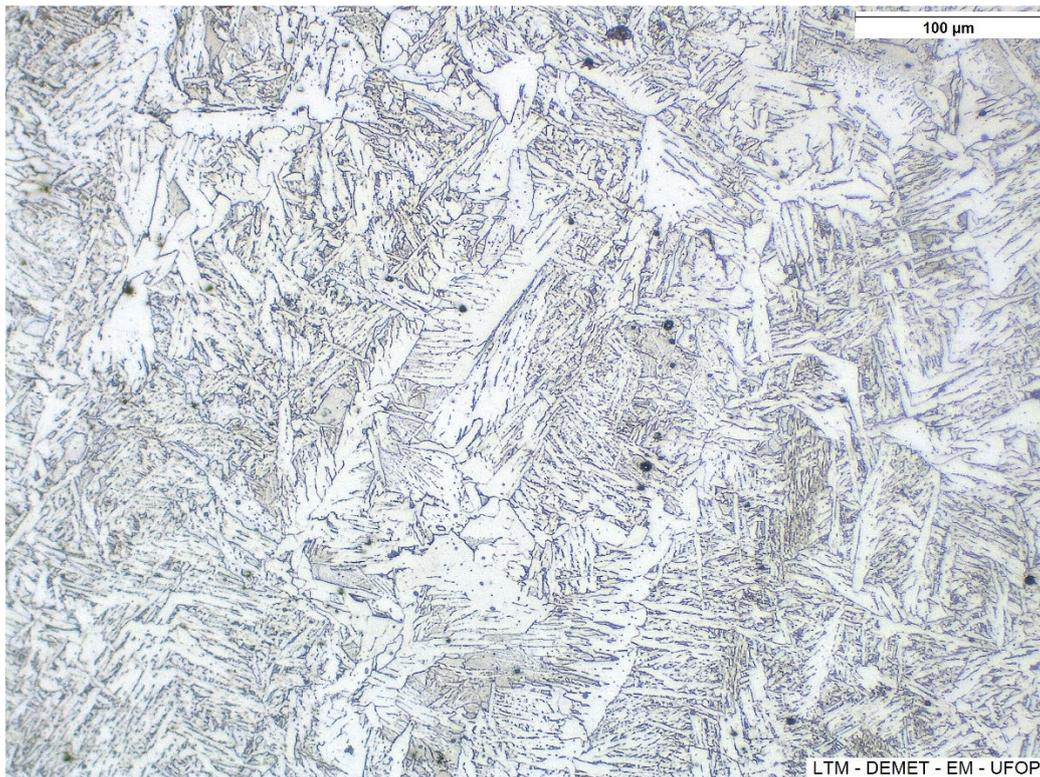


Figura 5.29 – Micrografia (200x) de região de ZF referente a seção longitudinal F-F do cordão de solda nº 32. Fonte: Autor.

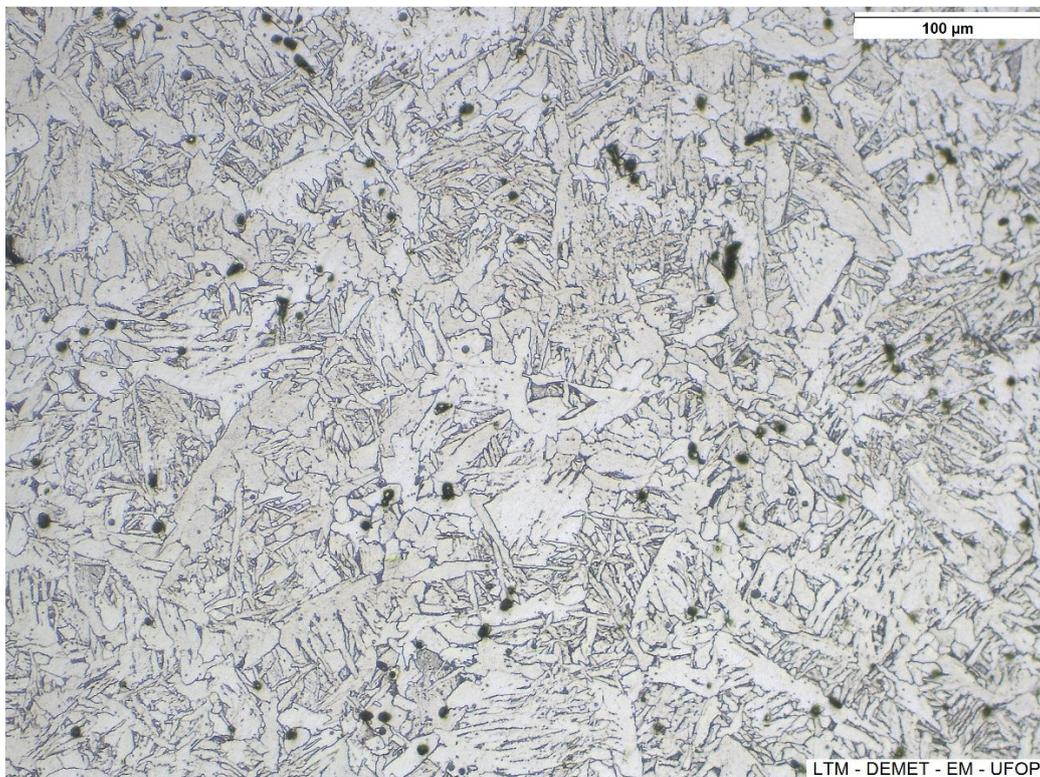


Figura 5.30 – Micrografia (200x) de região de ZF referente a seção transversal G-G do cordão de solda nº 34. Fonte: Autor.

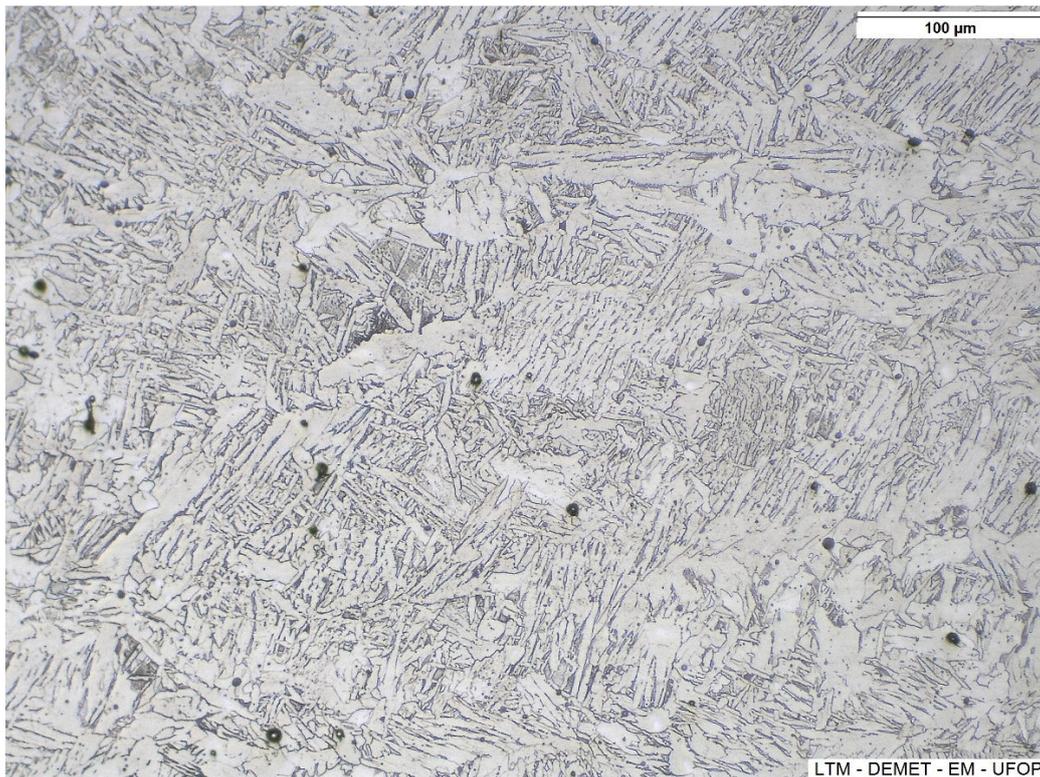


Figura 5.31 – Micrografia (200x) de região de ZF referente a seção transversal M-M do cordão de solda nº 24. Fonte: Autor.

5.3.3 Micro Trincas e Trincas

Nas Figuras 5.32 e 5.34 tem-se imagens de micro trincas que foram identificadas respectivamente nos cordões 31 e 32. Nas Figuras 5.36 e 5.38 tem-se imagens de trincas referentes aos cordões 26 e 24. Vale ressaltar que, para aquisição dessas imagens, as amostras não foram submetidas a ataque químico. Essas discontinuidades ocorreram em regiões de transição da menor para a maior espessura da chapa, na raiz do cordão, como identificado nas macrografias das Figuras 5.20 a 5.23.

A transição abrupta da espessura da chapa, em função da presença dos sulcos transversais (Figura 4.17), altera as direções de escoamento do calor da junta. Como consequência, existirão curvas de resfriamento distintas na vizinhança dessa transição, o que resultará no acréscimo de tensões residuais, que levam ao surgimento de micro trincas e de trincas durante a solidificação do cordão.

Essa afirmativa é reforçada após análise das amostras submetidas a ataque químico por solução Nital 2% (Figuras 5.33, 5.35, 5.37 e 5.39): as micro trincas e trincas propagam na vizinhança da linha de fusão; e não há formação de ZTA na região de menor espessura da chapa de aço (ou seja, todo o metal de base nessa região foi fundido).

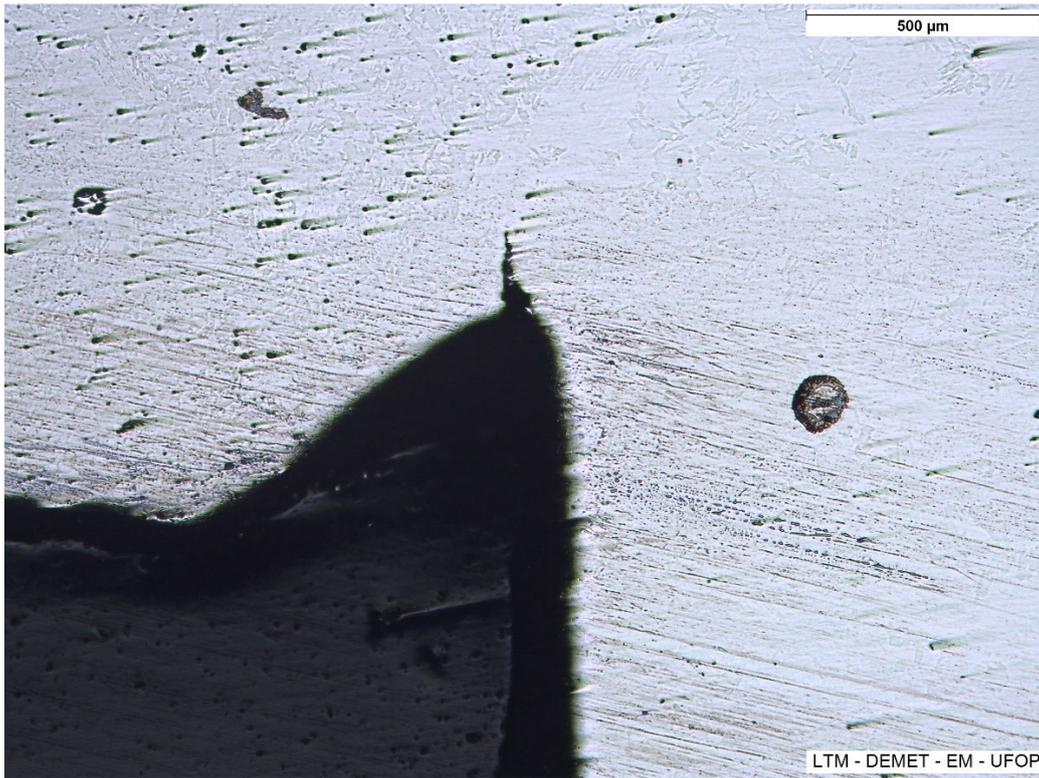


Figura 5.32 – Micrografia (50x) da região com micro trinca no cordão de solda nº 31 (Figura 5.20). Fonte: Autor.

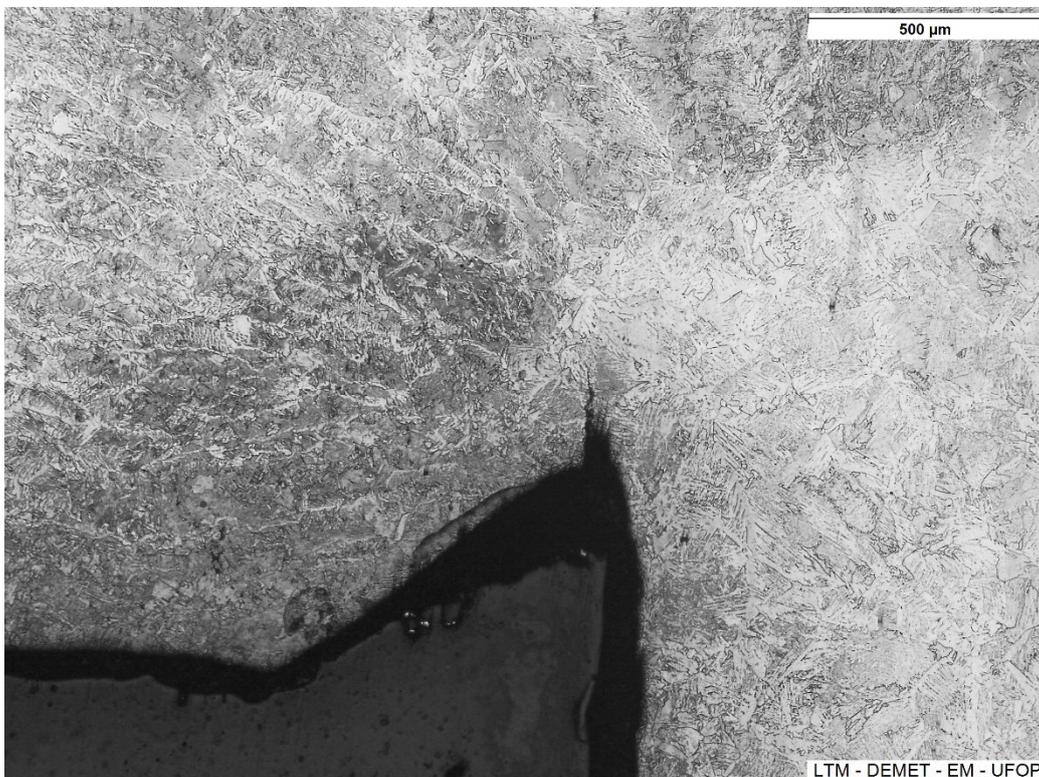


Figura 5.33 – Micrografia (50x) da região com micro trinca no cordão de solda nº 31 após ataque químico (Figura 5.20). Fonte: Autor.

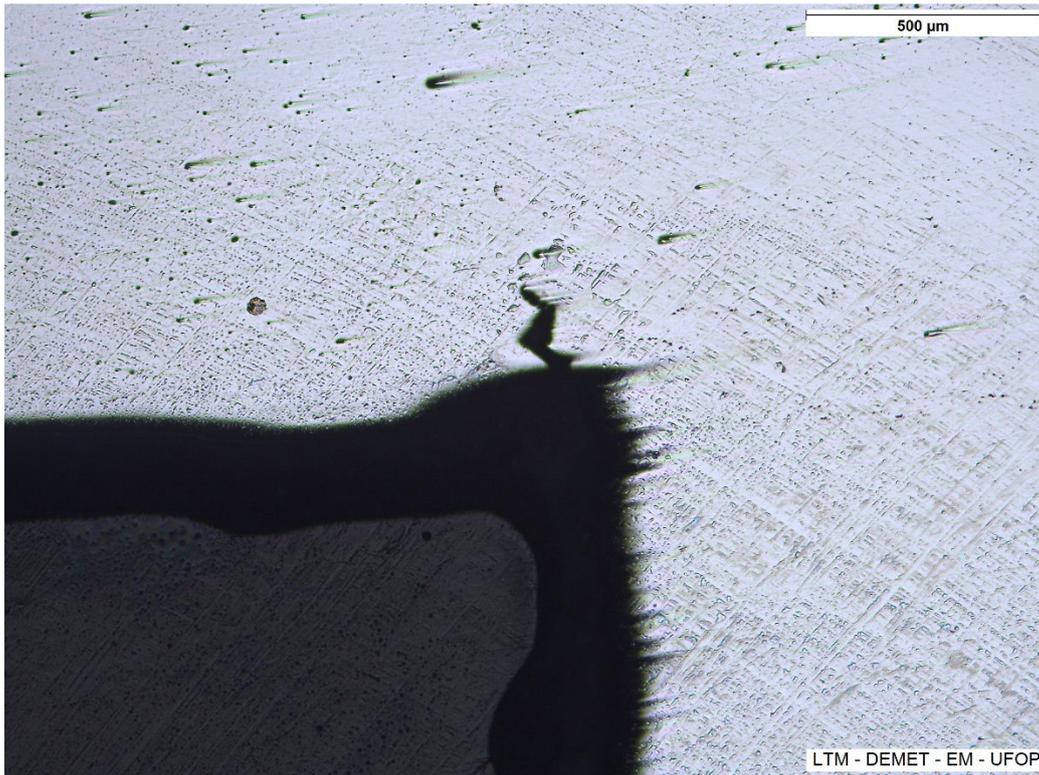


Figura 5.34 – Micrografia (50x) da região com micro trinca no cordão de solda nº 32 (Figura 5.21). Fonte: Autor.

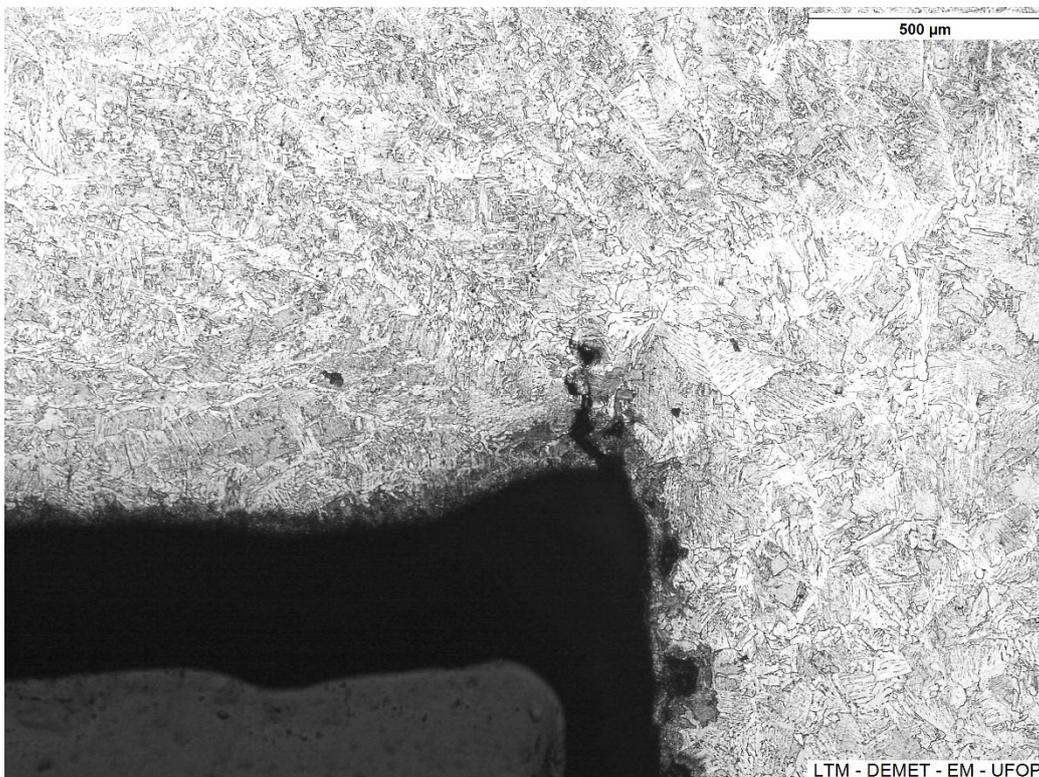


Figura 5.35 – Micrografia (50x) da região com micro trinca no cordão de solda nº 32 após ataque químico (Figura 5.21). Fonte: Autor.

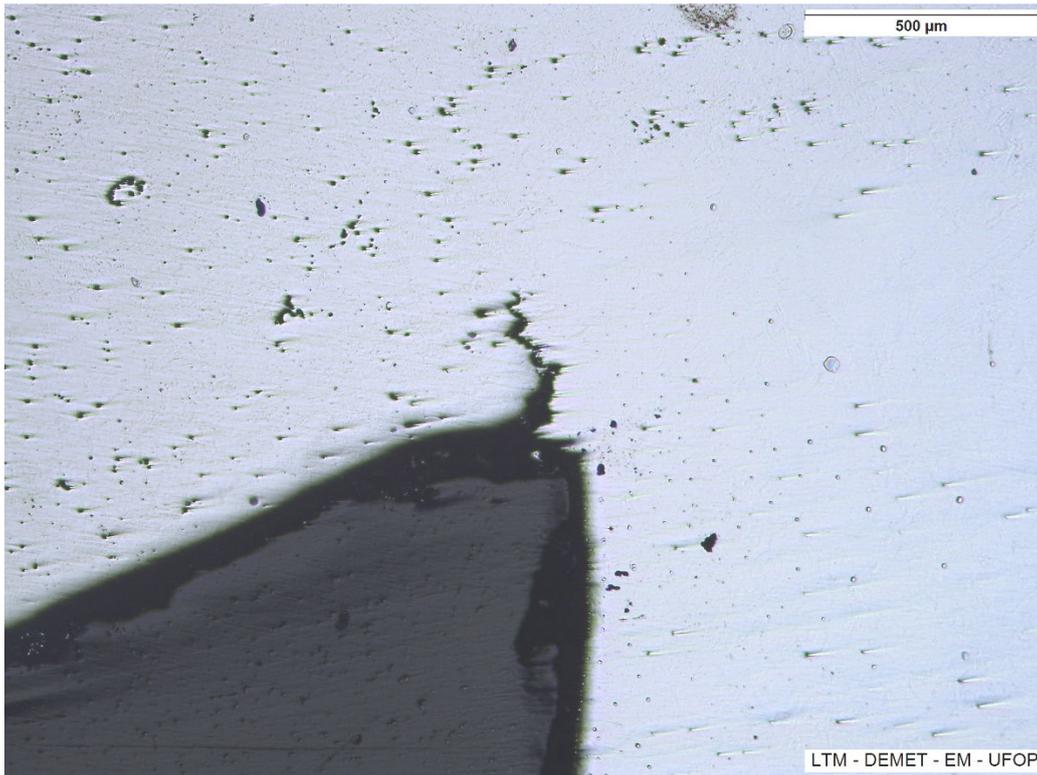


Figura 5.36 – Micrografia (50x) da região com trinca no cordão de solda nº 26 (Figura 5.22).

Fonte: Autor.

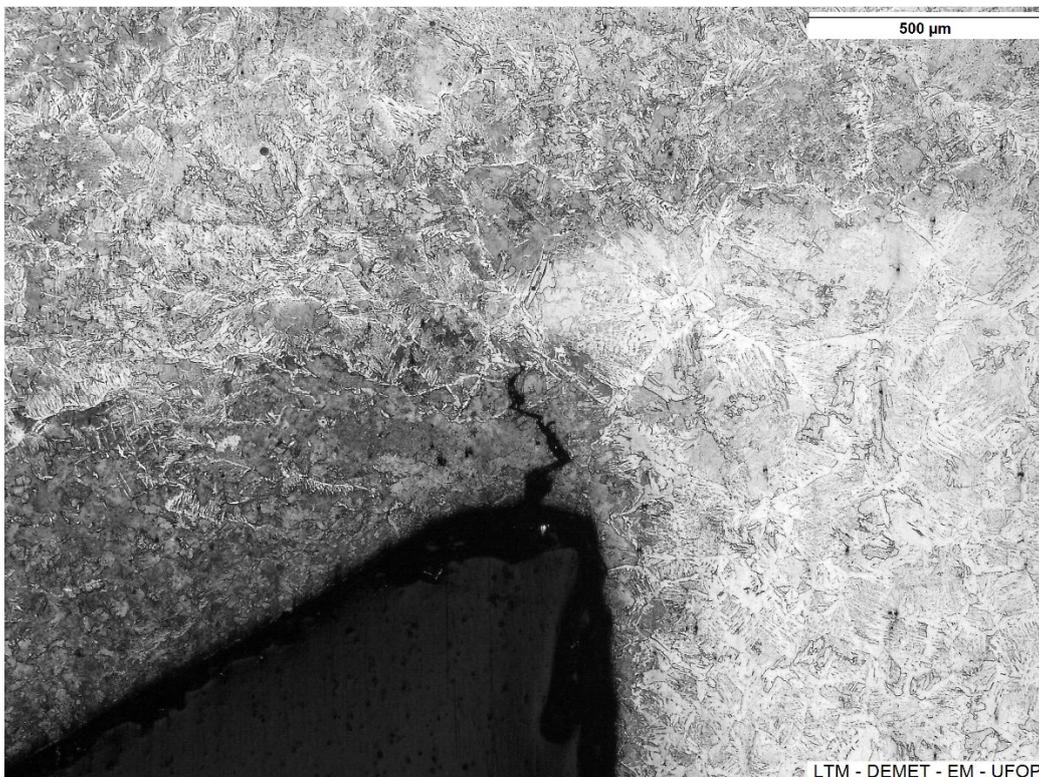


Figura 5.37 – Micrografia (50x) da região com trinca no cordão de solda nº 26 após ataque químico (Figura 5.22). Fonte: Autor.

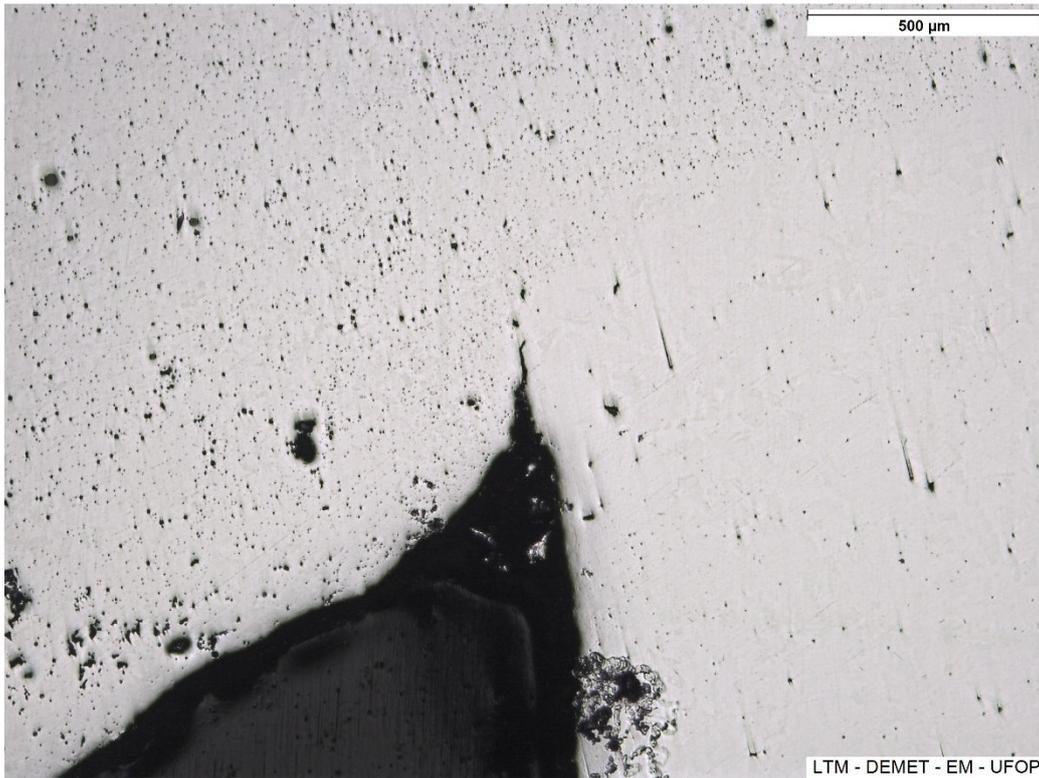


Figura 5.38 – Micrografia (50x) da região micro trinca no cordão de solda nº 24 (Figura 5.23).

Fonte: Autor.

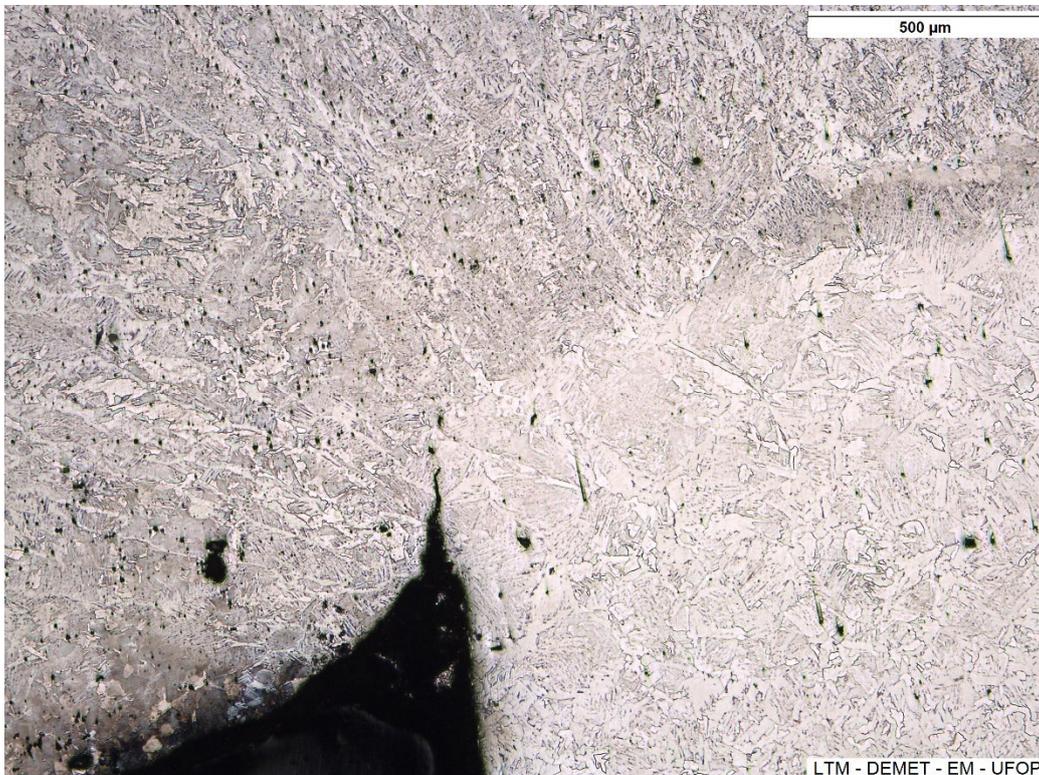


Figura 5.39 – Micrografia (50x) da região com trinca no cordão de solda nº 24 após ataque químico (Figura 5.23). Fonte: Autor.

5.4 Pré-processamento de Sinais

Para a apresentação de resultados do pré-processamento de sinais e discussão, escolheu-se os cordões de solda nº 12, 20, 22 e 23, por possuírem representantes de sinais da emissão acústica aérea e da emissão acústica sólida das três classes (normal, cratera e perfuração), conforme disposto na Tabela 4.5.

5.4.1 Emissões Acústicas Aéreas

Para a extração de características do sinal de emissões acústicas aéreas foi utilizada a Transformada de Fourier Discreta (DFT), seguida de reamostragem por meio de decimação por média, conforme descrito na seção 4.6.

Nas Figuras 5.40, 5.41, 5.42 e 5.43, tem-se o espectro do sinal audível e de reamostragem, de representantes das classes normal, cratera e perfuração, referentes aos cordões supracitados. A partir desses espectros, nota-se que, para frequências superiores a 6kHz, torna-se mais fácil diferenciar os representantes de cada classe.

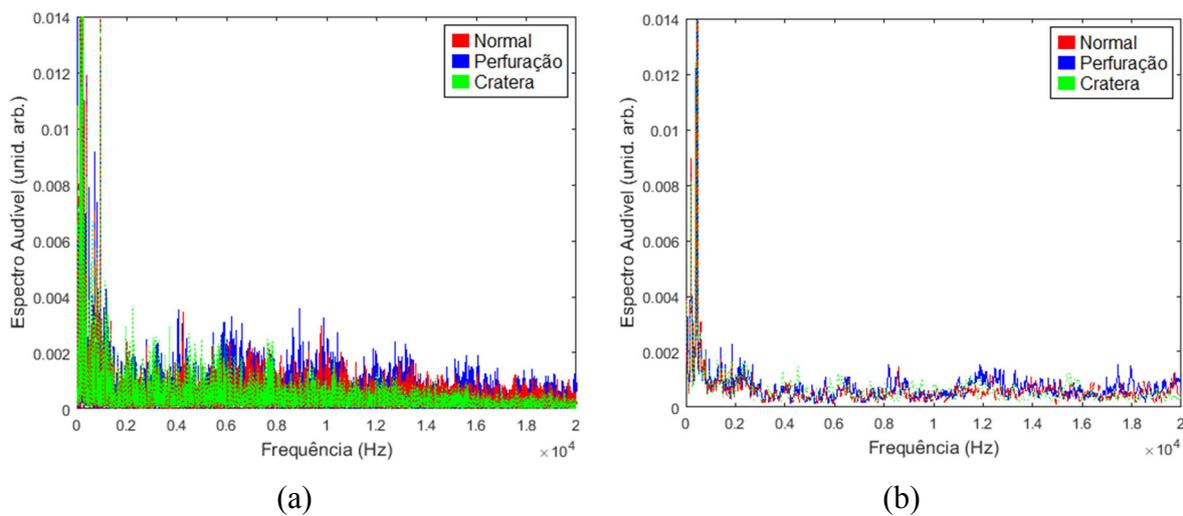


Figura 5.40 – Pré-processamento do sinal audível do cordão de solda nº 12: (a) espectro do sinal obtido por meio de DFT; (b) reamostragem do espectro de frequências. O sinal da classe perfuração é referente à segunda descontinuidade do cordão; o sinal da classe cratera é referente à primeira descontinuidade do cordão; o sinal da classe normal é referente ao segundo trecho do cordão. Fonte: Autor.

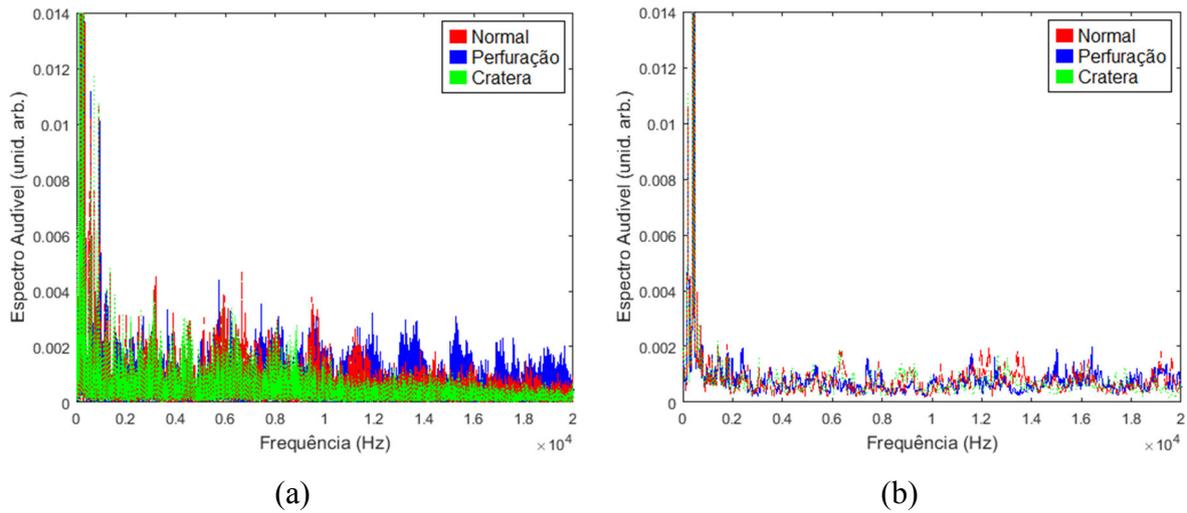


Figura 5.41 – Pré-processamento do sinal audível do cordão de solda nº 20: (a) espectro do sinal obtido por meio de DFT; (b) reamostragem do espectro de frequências. O sinal da classe perfuração é referente à segunda descontinuidade do cordão; o sinal da classe cratera é referente à primeira descontinuidade do cordão; o sinal da classe normal é referente ao primeiro trecho do cordão. Fonte: Autor.

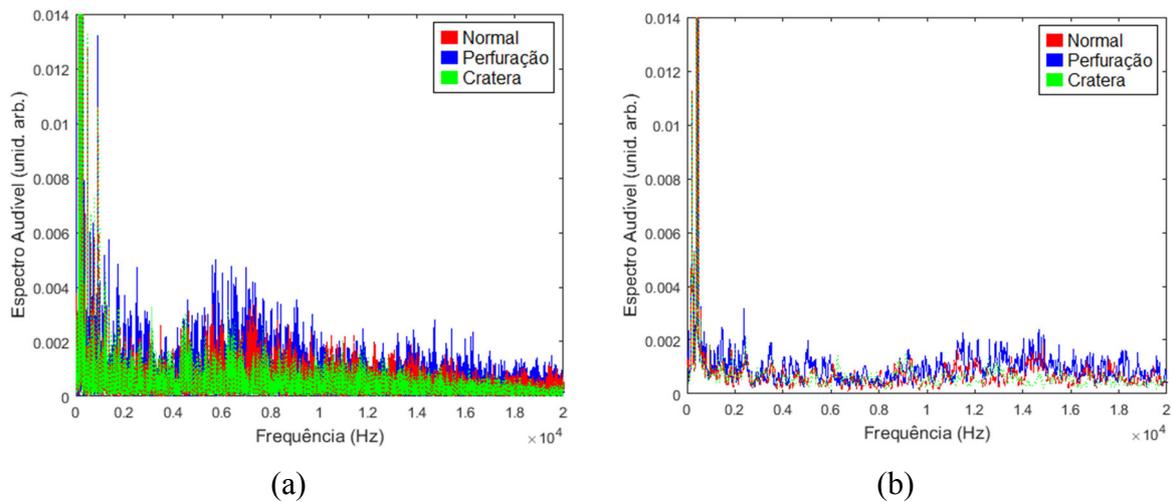


Figura 5.42 – Pré-processamento do sinal audível do cordão de solda nº 22: (a) espectro do sinal obtido por meio de DFT; (b) reamostragem do espectro de frequências. O sinal da classe perfuração é referente à segunda descontinuidade do cordão; o sinal da classe cratera é referente à terceira descontinuidade do cordão; o sinal da classe normal é referente ao segundo trecho do cordão. Fonte: Autor.

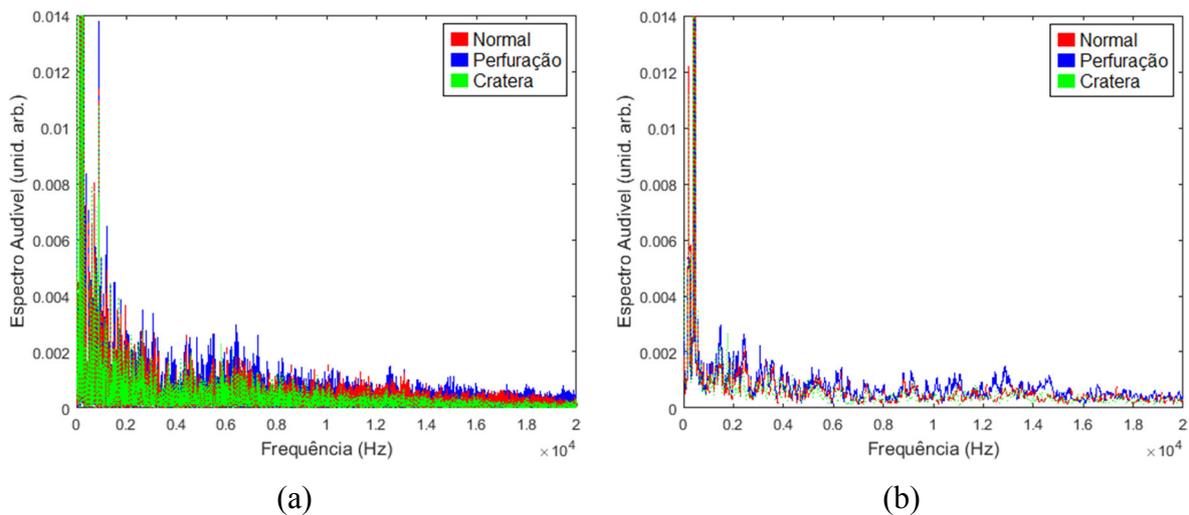


Figura 5.43 – Pré-processamento do sinal audível do cordão de solda nº 23: (a) espectro do sinal obtido por meio de DFT; (b) reamostragem do espectro de frequências. O sinal da classe perfuração é referente à segunda descontinuidade do cordão; o sinal da classe cratera é referente à primeira descontinuidade do cordão; o sinal da classe normal é referente ao segundo trecho do cordão. Fonte: Autor.

Os representantes da classe perfuração são os que apresentam maior incidência de harmônicos de alta ordem, seguidos por representantes da classe normal e da classe cratera. Esse resultado é o oposto do observado no processo de soldagem a laser (Sansan *et al.*, 2010). No processo a laser, quando ocorre a descontinuidade de perfuração, a quantidade de material fundido reduz, e a pressão sonora decresce. No caso do processo SMAW, quando ocorre a perfuração, o arco abre, e a deposição de material de adição passa a ser realizada nos contornos da descontinuidade, resultando na flutuação da pressão sonora no processo SMAW.

5.4.2 Emissões Acústicas Sólidas

Para a extração de características do sinal de emissões acústicas sólidas, foi utilizada a Transformada de *Wavelet*, conforme descrito na seção 4.6.

Nas Figuras 5.44, 5.45, 5.46 e 5.47, tem-se esses sinais das descontinuidades de cratera e de perfuração e suas respectivas decomposições por *Wavelet*, referente aos cordões e trechos discutidos no *caput* desse capítulo. Comparando os dois conjuntos de dados, é possível notar que as intensidades do sinal da descontinuidade cratera e de sua aproximação no sexto nível de decomposição são quase iguais às respectivas intensidades da descontinuidade perfuração. Por

meio da função de raiz do valor quadrático médio (RMS), não foi possível identificar uma característica que diferencie essas duas classes a partir do sinal de emissões acústicas sólidas ou a partir de suas respectivas aproximações.

Nota-se uma diferença entre as classes cratera e perfuração nos detalhes do sinal no sexto nível de decomposição. Predominantemente, a raiz do valor quadrático médio do detalhe da classe perfuração é superior à da classe cratera. No cordão nº 12 (Figura 5.44) a intensidade do detalhe de perfuração é 59% superior à de cratera. No cordão nº 20 (Figura 5.45) essa relação é de 23%, e no cordão nº 23 (Figura 5.47) é de 56%. Entretanto, no cordão nº 22 (Figura 5.46) a intensidade do detalhe de perfuração é 13% inferior à de cratera.

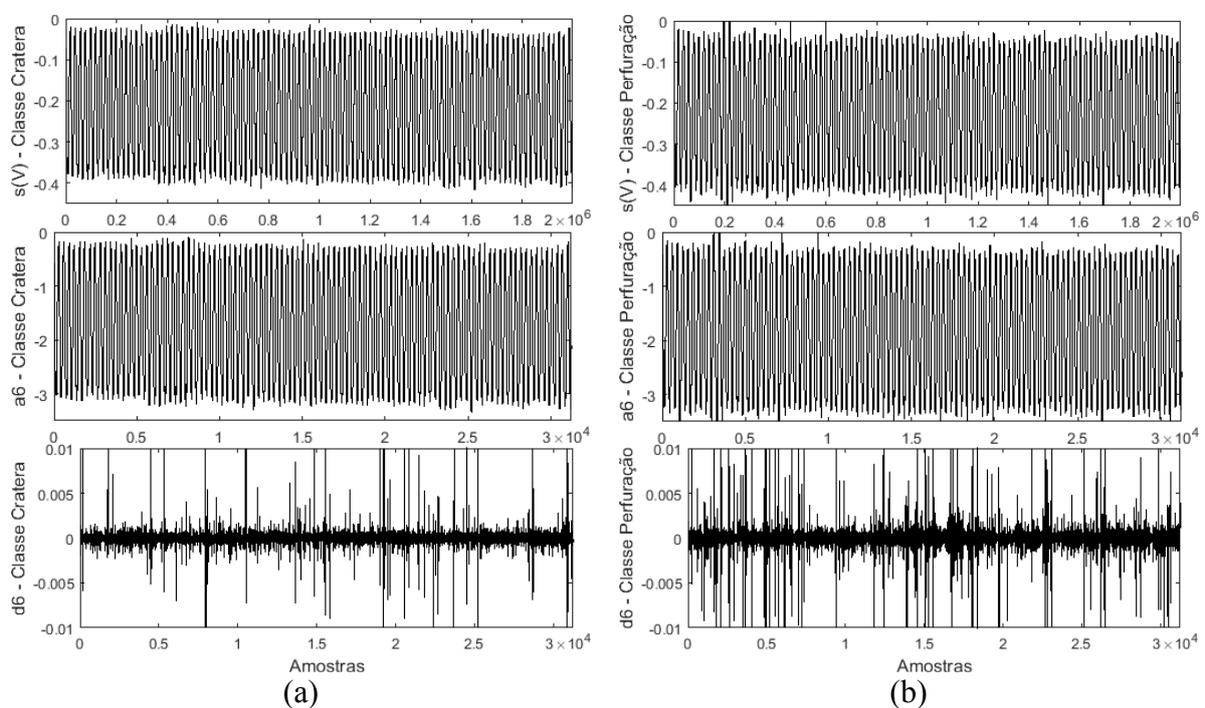


Figura 5.44 – Decomposição por *Wavelet* do sinal do cristal piezoelétrico referente às discontinuidades de cratera (a) e de perfuração (b) do cordão de solda nº 12. Sendo s o sinal, a_6 a aproximação e d_6 o detalhe para o sexto nível de decomposição. Fonte: Autor.

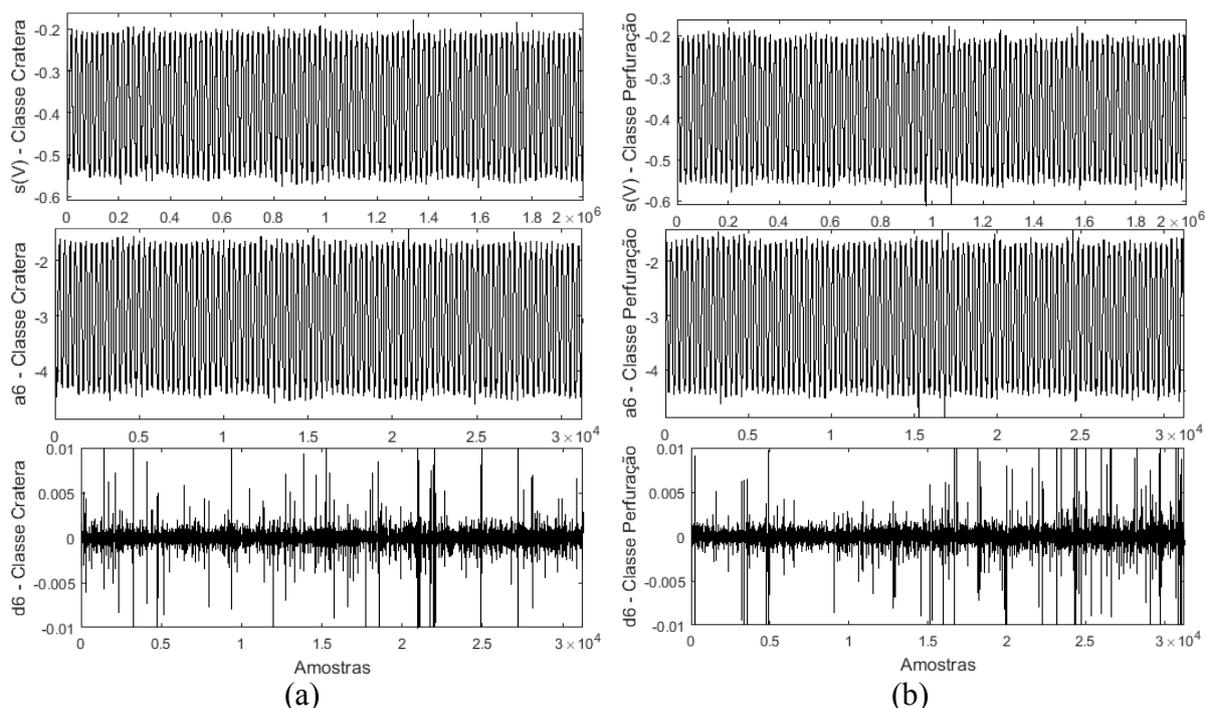


Figura 5.45 – Decomposição por *Wavelet* do sinal do cristal piezoelétrico referente às discontinuidades de cratera (a) e de perfuração (b) do cordão de solda nº 20. Sendo s o sinal, a_6 a aproximação e d_6 o detalhe para o sexto nível de decomposição. Fonte: Autor.

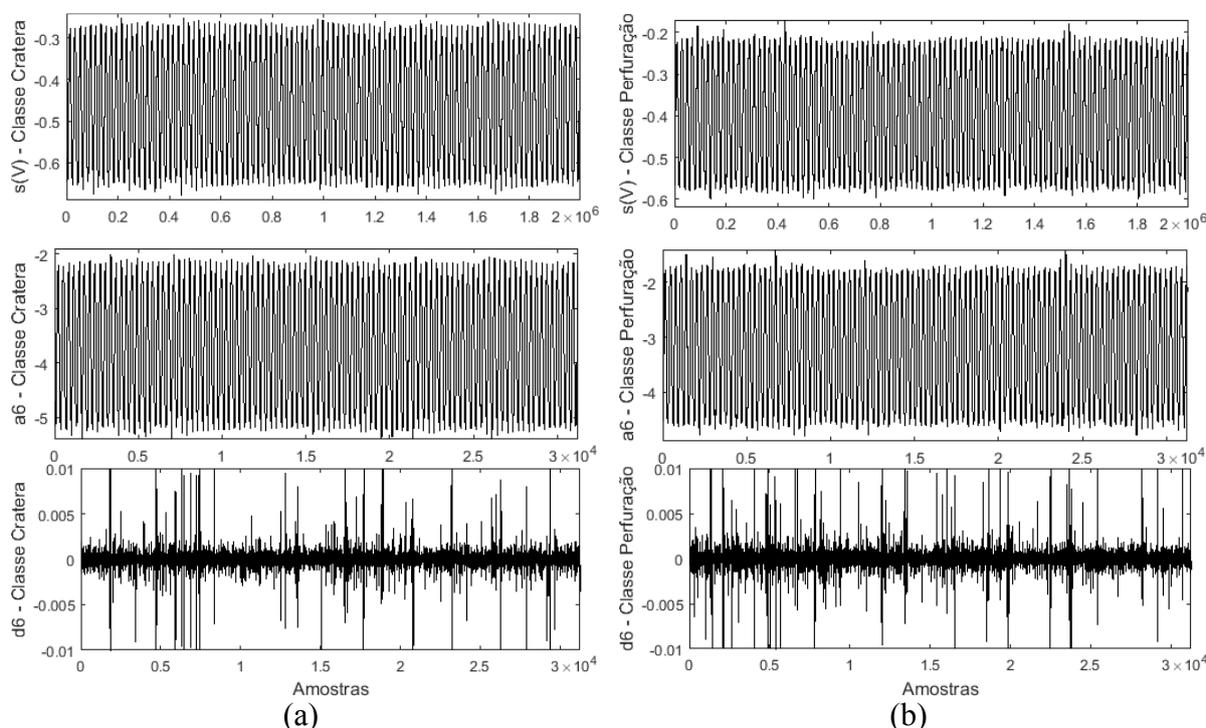


Figura 5.46 – Decomposição por *Wavelet* do sinal do cristal piezoelétrico referente às discontinuidades de cratera (a) e de perfuração (b) do cordão de solda nº 22. Sendo s o sinal, a_6 a aproximação e d_6 o detalhe para o sexto nível de decomposição. Fonte: Autor.

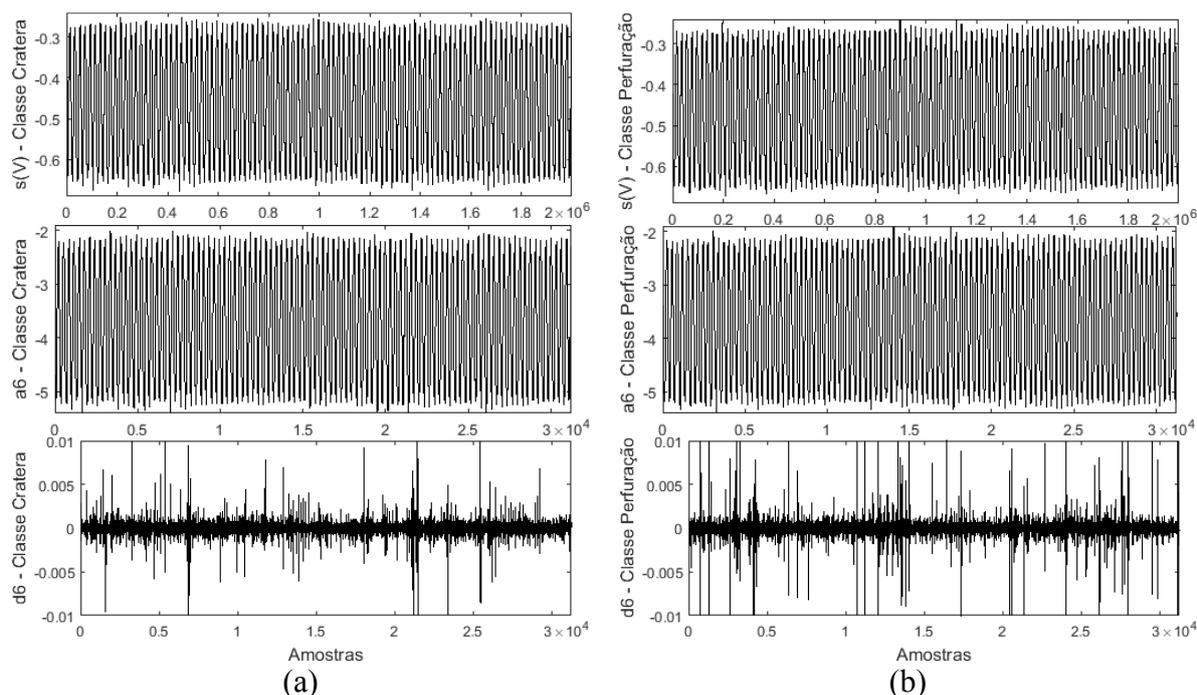


Figura 5.47 – Decomposição por *Wavelet* do sinal do cristal piezoelétrico referente às discontinuidades de cratera (a) e de perfuração (b) do cordão de solda nº 23. Sendo s o sinal, a_6 a aproximação e d_6 o detalhe para o sexto nível de decomposição. Fonte: Autor.

5.5 Imagens de Gravações em Vídeo

Para assistir a análise dos experimentos foi realizada a gravação em vídeo da poça de fusão e do arco elétrico (Figura 4.2). A maior dificuldade na gravação dos vídeos foi a seleção do foco. Entretanto, algumas gravações em vídeo são promissoras para o uso de técnicas de visão computacional para a detecção de falhas (Figura 5.48), e outras foram utilizadas para estimar o comprimento do arco elétrico (Figura 5.49)

5.5.1 Câmera 1 – Vista da Poça de Fusão

Na Figura 5.48 tem-se imagens da vista superior de representantes das três classes: normal, cratera e perfuração. Nota-se na Figura 5.48a a radiação do cordão de solda do tipo normal; na Figura 5.48b a reentrância característica na solidificação da cratera; e na Figura 5.48c a descontinuidade de radiação do cordão em função da perfuração.

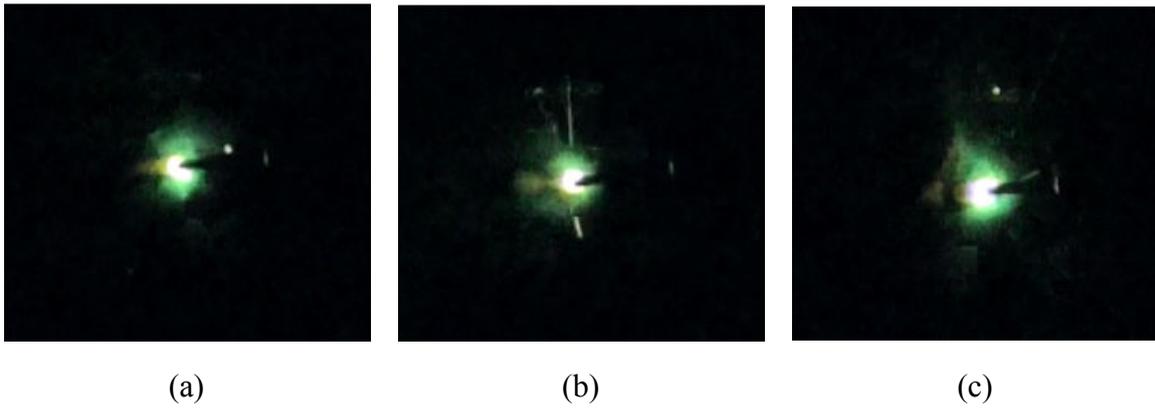


Figura 5.48 – Imagens da poça de fusão das três classes: (a) normal; (b) cratera; e (c) perfuração. Fonte: Autor.

5.5.2 Câmera 2 – Vista do Arco Elétrico

Na Figura 5.49 tem-se imagens da vista lateral, antes e após a abertura do arco elétrico. A partir da análise de imagens como das Figuras 5.49a e 5.49b foi possível estimar o comprimento do arco elétrico, conforme citado na subseção 4.7.2.



Figura 5.49 – Imagens da vista lateral: (a) antes do início do processo de soldagem; (b) durante a execução do processo de soldagem. Fonte: Autor.

5.6 Classificação de Padrões

Classificadores foram usados para reconhecimento de padrões cujos modelos foram obtidos por meio de aprendizado de máquinas, a partir de vetores de características e de seus respectivos rótulos de classes (ou estados). Os vetores de características dos sinais amostrados pelo microfone – emissão acústica aérea (total de 196 segmentos) e dos sinais amostrados pelo cristal piezoelétrico – emissão acústica sólida (total de 86 segmentos) foram rotulados em três classes (Tabela 5.3): (1) cordão normal; (2) descontinuidade cratera; e (3) descontinuidade perfuração.

Tabela 5.3 – Vetores de características por classes (* sem dados do piezo). Fonte: Autor.

Nº da Classe	Descrição	Nº de Vetores de Características	
		Microfone	Piezo
1	Normal	110	*
2	Cratera	56	56
3	Perfuração	30	30

Nas próximas subseções serão apresentados os dados utilizados para o treinamento dos classificadores, bem como os resultados obtidos na classificação dos dados de teste.

5.6.1 Máquinas de Vetor de Suporte

Conforme metodologia descrita na subseção 4.8, 135 vetores de características do sinal de emissão acústica aérea foram utilizados para treinamento das máquinas de vetor de suporte (SVM e HSVM proposto) e os 61 vetores restantes foram utilizados no teste. No caso da estrutura HSVM, além desses vetores de características, foram utilizados 59 vetores do sinal de emissão acústica sólida (piezo) no treinamento do modelo SVM presente no segundo estágio (ver Figura 4.19), e os 27 vetores restantes foram utilizados no teste.

Do total de vetores de características utilizados no teste do SVM, 34 correspondem a representantes da classe 1 (normal), 17 da classe 2 (cratera) e 10 da classe 3 (perfuração). Para esse classificador, a acurácia obtida está no intervalo de 80,3% a 95,1%, dependendo da escolha da semente no estágio de treinamento, com mediana de 86,9% para as 10 primeiras sementes (Tabela 5.4). O melhor resultado desse classificador está apresentado na Tabela 5.5. Para esse caso, foram utilizados os vetores de características para treinamento e teste que estão presentes respectivamente nas Tabelas 5.6 e 5.7.

Tabela 5.4 – Resultado da SVM para as 10 primeiras sementes. Fonte: Autor.

	Semente									
	1	2	3	4	5	6	7	8	9	10
Acurácia Global	90,2	80,3	82	88,5	95,1	85,2	95,1	83,6	83,6	91,8

Tabela 5.5 – Desempenho de classificação do classificador por SVM. Fonte: Autor.

Nº da Classe	Descrição	Classificado como #1	Classificado como #2	Classificado como #3	Correto (%)	Incorreto (%)
1	Normal	34	0	0	34 (100)	0 (0)
2	Cratera	1	15	1	15 (88,2)	2 (11,8)
3	Perfuração	1	0	9	9 (90)	1 (10)

Tabela 5.6 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da SVM e da HSVM (1º estágio). Fonte: Autor.

(continua)

Nº do Vetor	Nº do Cordão	Trecho	Classe
1	4	1	3
2	4	2	3
3	4	1	1
4	4	3	3
5	4	2	1
6	6	2	1
7	6	1	2
8	6	1	2
9	7	1	2
10	7	1	1
11	7	1	1
12	7	1	2
13	7	2	2
14	8	1	2
15	8	2	1
16	8	1	1
17	8	2	2
18	8	2	1
19	8	1	2
20	8	1	1
21	9	2	3
22	9	1	1

Tabela 5.6 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da SVM e da HSVM (1º estágio). Fonte: Autor.

(continuação)

Nº do Vetor	Nº do Cordão	Trecho	Classe
23	9	2	3
24	9	2	1
25	10	2	1
26	10	1	2
27	10	3	2
28	10	2	1
29	10	3	2
30	10	2	2
31	11	1	1
32	11	2	2
33	11	1	1
34	11	2	1
35	11	2	1
36	12	2	1
37	12	3	2
38	12	2	1
39	12	2	3
40	12	3	2
41	12	1	2
42	14	1	3
43	14	1	3
44	15	1	3
45	16	1	3
46	17	1	2
47	17	1	2
48	18	1	1
49	18	3	1
50	18	2	1
51	18	1	2

Tabela 5.6 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da SVM e da HSVM (1º estágio). Fonte: Autor.

(continuação)

Nº do Vetor	Nº do Cordão	Trecho	Classe
52	18	3	3
53	18	1	2
54	18	4	3
55	18	2	1
56	18	1	1
57	19	1	1
58	19	4	2
59	19	3	1
60	19	1	2
61	19	2	1
62	20	3	3
63	20	4	2
64	20	1	1
65	20	2	1
66	20	3	3
67	20	1	2
68	20	1	2
69	20	3	1
70	20	2	3
71	20	2	3
72	21	3	1
73	21	1	1
74	21	2	3
75	21	3	1
76	21	2	1
77	22	3	1
78	22	1	1
79	22	2	1
80	22	2	3

Tabela 5.6 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da SVM e da HSVM (1º estágio). Fonte: Autor.

(continuação)

Nº do Vetor	Nº do Cordão	Trecho	Classe
81	22	3	2
82	22	1	1
83	22	2	3
84	22	3	1
85	22	3	2
86	23	2	1
87	23	1	1
88	23	2	3
89	23	1	1
90	23	3	2
91	23	3	2
92	23	1	2
93	23	2	1
94	24	2	1
95	24	3	2
96	24	2	1
97	24	3	2
98	24	1	1
99	24	1	2
100	24	1	1
101	25	2	1
102	25	3	2
103	25	3	2
104	25	1	1
105	26	1	1
106	26	1	2
107	26	1	2
108	26	2	1
109	27	1	2

Tabela 5.6 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da SVM e da HSVM (1º estágio). Fonte: Autor.

(conclusão)

Nº do Vetor	Nº do Cordão	Trecho	Classe
110	27	3	2
111	27	2	1
112	28	1	1
113	28	2	1
114	28	1	1
115	28	2	1
116	29	1	1
117	29	2	1
118	29	2	1
119	30	2	1
120	30	1	1
121	30	1	1
122	30	2	1
123	31	2	1
124	31	1	1
125	31	1	1
126	32	1	1
127	32	2	1
128	32	1	1
129	32	2	1
130	33	2	1
131	33	2	1
132	34	1	1
133	34	2	1
134	34	1	1
135	34	2	1

Tabela 5.7 – Vetores de características do sinal de emissão acústica aérea utilizados no teste por meio da SVM e da HSVM (1º estágio). Fonte: Autor.

(continua)

Nº do Vetor	Nº do Cordão	Trecho	Classe
1	4	2	3
2	4	1	1
3	4	1	3
4	4	2	1
5	4	3	3
6	6	1	1
7	6	2	1
8	6	1	1
9	7	2	1
10	7	2	1
11	7	2	2
12	8	2	2
13	9	2	1
14	9	1	1
15	10	1	1
16	10	1	1
17	10	1	2
18	10	2	2
19	11	2	2
20	12	2	3
21	12	1	2
22	12	1	1
23	12	1	1
24	15	1	3
25	16	1	3
26	18	3	3
27	18	4	3
28	18	3	1
29	19	4	2

Tabela 5.7 – Vetores de características do sinal de emissão acústica aérea utilizados no teste por meio da SVM e da HSVM (1º estágio). Fonte: Autor.

(continuação)

Nº do Vetor	Nº do Cordão	Trecho	Classe
30	19	2	1
31	19	1	1
32	19	1	2
33	19	3	1
34	20	4	2
35	20	3	1
36	20	1	1
37	20	2	1
38	21	2	3
39	21	2	1
40	21	1	1
41	22	1	2
42	22	2	1
43	22	4	2
44	22	1	2
45	22	4	2
46	23	2	3
47	23	1	2
48	24	1	2
49	25	1	1
50	25	2	1
51	26	1	1
52	26	2	1
53	27	1	1
54	27	1	2
55	27	3	2
56	27	1	1
57	27	2	1
58	29	1	1

Tabela 5.7 – Vetores de características do sinal de emissão acústica aérea utilizados no teste por meio da SVM e da HSVM (1º estágio). Fonte: Autor.

(conclusão)

Nº do Vetor	Nº do Cordão	Trecho	Classe
59	31	2	1
60	33	1	1
61	33	1	1

A avaliação do segundo modelo de classificador por HSVM foi efetuada em dois estágios. No primeiro estágio, ocorre a classificação dos dados entre as classes normal e descontinuidade. No segundo estágio, para os vetores de características classificados como descontinuidade, ocorre a fusão dos dados da emissão acústica aérea e da emissão acústica sólida, seguido por posterior classificação entre as classes cratera e perfuração. A acurácia desse segundo modelo, que foi proposto no presente trabalho, está na faixa de 84,9% a 96,6%, dependendo da semente, com mediana de 91,8% para as 10 primeiras sementes (Tabela 5.8).

Tabela 5.8 – Resultado da HSVM para as 10 primeiras sementes. Fonte: Autor.

	Semente									
	1	2	3	4	5	6	7	8	9	10
Acurácia Global	93,1	84,9	86,6	92	96,6	91,7	92,8	87,2	89,7	95,4

O melhor resultado desse classificador está apresentado nas Tabelas 5.9 e 5.10. Para esse caso, foram utilizados os vetores de características para treinamento e teste que estão presentes respectivamente nas Tabelas 5.6 e 5.7 no primeiro estágio, e os vetores de características para treinamento e teste que estão presentes respectivamente nas Tabelas 5.11 e 5.12 no segundo estágio. Os vetores de características para treinamento e teste no HSVM no primeiro estágio são os mesmos utilizados no SVM, pois correspondem à escolha da semente em ambos classificadores com maior acurácia global (Tabelas 5.4 e 5.8).

Tabela 5.9 – Desempenho de classificação do classificador por HSVM – 1º estágio (sem fusão sensorial). Fonte: Autor.

Nº da Classe	Descrição	Classificado como #1	Classificado como #2 e 3	Correto (%)	Incorreto (%)
1	Normal	33	1	33 (97,1)	1 (2,9)
2 e 3	Descontinuidade	1	26	26 (96,3)	1 (3,7)

Tabela 5.10 – Desempenho de classificação do classificador por HSVM – 2º estágio (com fusão sensorial). Fonte: Autor.

Nº da Classe	Descrição	Classificado como #2	Classificado como #3	Correto (%)	Incorreto (%)
2	Cratera	16	0	16 (100)	0 (0)
3	Perfuração	1	9	9 (90)	1 (10)

Tabela 5.11 – Vetores de características do sinal de emissão acústica aérea e do sinal de emissão acústica sólida utilizados no treinamento da HSVM (2º estágio). Fonte: Autor.

(continua)

Nº do Vetor	Nº do Cordão	Trecho	Classe
1	4	1	3
2	4	2	3
3	4	3	3
4	6	1	2
5	6	1	2
6	7	1	2
7	7	1	2
8	7	2	2
9	8	1	2
10	8	2	2
11	8	1	2
12	9	2	3
13	9	2	3
14	10	1	2
15	10	3	2

Tabela 5.11 – Vetores de características do sinal de emissão acústica aérea e do sinal de emissão acústica sólida utilizados no treinamento da HSVM (2º estágio). Fonte: Autor.

(continuação)

Nº do Vetor	Nº do Cordão	Trecho	Classe
16	10	3	2
17	10	2	2
18	11	2	2
19	12	3	2
20	12	2	3
21	12	3	2
22	12	1	2
23	14	1	3
24	14	1	3
25	15	1	3
26	16	1	3
27	17	1	2
28	17	1	2
29	18	1	2
30	18	3	3
31	18	1	2
32	18	4	3
33	19	4	2
34	19	1	2
35	20	3	3
36	20	4	2
37	20	3	3
38	20	1	2
39	20	1	2
40	20	2	3
41	20	2	3
42	21	2	3
43	22	2	3
44	22	3	2

Tabela 5.11 – Vetores de características do sinal de emissão acústica aérea e do sinal de emissão acústica sólida utilizados no treinamento da HSVM (2º estágio). Fonte: Autor.

(conclusão)

Nº do Vetor	Nº do Cordão	Trecho	Classe
45	22	2	3
46	22	3	2
47	23	2	3
48	23	3	2
49	23	3	2
50	23	1	2
51	24	3	2
52	24	3	2
53	24	1	2
54	25	3	2
55	25	3	2
56	26	1	2
57	26	1	2
58	27	1	2
59	27	3	2

Tabela 5.12 – Vetores de características do sinal de emissão acústica aérea e de emissão acústica sólida utilizados no teste por meio da HSVM (2º estágio). Fonte: Autor.

(continua)

Nº do Vetor	Nº do Cordão	Trecho	Classe
1	4	2	3
2	4	1	3
3	4	3	3
4	8	2	2
5	10	1	2
6	10	2	2
7	11	2	2
8	12	2	3
9	12	1	2

Tabela 5.12 – Vetores de características do sinal de emissão acústica aérea e de emissão acústica sólida utilizados no teste por meio da HSVM (2º estágio). Fonte: Autor.

(conclusão)

Nº do Vetor	Nº do Cordão	Trecho	Classe
10	15	1	3
11	16	1	3
12	18	3	3
13	18	4	3
14	19	4	2
15	19	1	2
16	20	4	2
17	21	2	3
18	22	1	2
19	22	4	2
20	22	1	2
21	22	4	2
22	23	2	3
23	23	1	2
24	24	1	2
25	27	1	2
26	27	3	2

Todas as classes apresentaram alta acurácia de classificação, acima de 88%, para as estruturas de SVM e de HSVM propostas. Esse resultado reforça que essas estruturas podem ser utilizadas para identificar as três classes abordadas neste trabalho. Os modelos desses classificadores possuem características de sinais no tempo e na frequência, que foram amostrados por dois diferentes sensores. À medida que a quantidade de dados aumenta com o uso da fusão sensorial, a acurácia global aumenta de 95,1% para 96,6%. A mesma afirmação vale para a robustez, que aumentou com a fusão, como evidenciado no aumento expressivo da mediana da acurácia global de 86,9% para 91,8%.

5.6.2 Rede Neural Artificial

Para a rede neural artificial (RNA), utilizaram-se 117 vetores de características dos sinais de emissão acústica aérea para treinar o modelo do classificador, 39 vetores para validação cruzada do treinamento da rede, e 40 vetores para teste, conforme descrito a metodologia na subseção 4.8.

Dentre os vetores utilizados para teste, 22 correspondem a representantes da classe 1, 12 da classe 2 e 6 da classe 3. A representatividade de cada classe é similar à adotada nas máquinas de vetor de suporte. Para o classificador RNA, a acurácia está no intervalo de 75% a 97,5%, dependendo da escolha da semente no estágio de treinamento, com mediana de 83,8% para as 10 primeiras sementes (Tabela 5.13). O melhor resultado desse classificador está apresentado na Tabela 5.14. Para esse caso, foram utilizados os vetores de características para treinamento, validação e teste que estão presentes respectivamente nas Tabelas 5.15, 5.16 e 5.17.

Tabela 5.13 – Resultado da RNA para as 10 primeiras sementes. Fonte: Autor.

	Semente									
	1	2	3	4	5	6	7	8	9	10
Acurácia Global	90	85	85	80	75	87,5	80	82,5	97,5	82,5

Tabela 5.14 – Desempenho de classificação do classificador por RNA. Fonte: Autor.

Nº da Classe	Descrição	Classificado como #1	Classificado como #2	Classificado como #3	Correto (%)	Incorreto (%)
1	Normal	22	0	0	22 (100)	0 (0)
2	Cratera	0	12	0	12 (100)	0 (0)
3	Perfuração	0	1	5	5 (83,3)	1 (16,7)

Nesse modelo, 66 épocas minimizaram o erro para o melhor resultado dessa rede neural. Nota-se que todas as classes apresentaram acurácia acima de 83%, o que reforça a viabilidade do uso desse modelo para estimar as três classes propostas.

Tabela 5.15 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da RNA. Fonte: Autor.

(continua)

Nº do Vetor	Nº do Cordão	Trecho	Classe
1	4	2	3
2	4	1	3
3	4	3	3
4	4	3	3
5	4	1	1
6	6	1	2
7	6	1	2
8	6	2	1
9	6	1	1
10	7	1	2
11	7	1	1
12	7	1	1
13	7	1	2
14	7	2	1
15	7	2	2
16	7	2	1
17	8	2	2
18	8	2	1
19	8	1	1
20	9	2	3
21	9	2	3
22	9	1	1
23	10	1	1
24	10	2	2
25	10	1	2
26	10	2	1
27	10	2	1
28	10	1	1
29	11	2	1

Tabela 5.15 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da RNA. Fonte: Autor.

(continuação)

Nº do Vetor	Nº do Cordão	Trecho	Classe
30	11	1	1
31	11	2	1
32	11	2	2
33	11	2	2
34	12	3	2
35	12	1	2
36	12	3	2
37	12	2	3
38	12	2	1
39	12	2	1
40	14	1	3
41	14	1	3
42	15	1	3
43	16	1	3
44	17	1	2
45	18	3	3
46	18	4	3
47	18	3	1
48	18	2	1
49	18	1	1
50	19	2	1
51	19	1	2
52	19	1	1
53	19	2	1
54	19	1	1
55	19	4	2
56	19	4	2
57	19	3	1
58	19	3	1

Tabela 5.15 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da RNA. Fonte: Autor.

(continuação)

Nº do Vetor	Nº do Cordão	Trecho	Classe
59	20	3	3
60	20	2	3
61	20	1	1
62	20	4	2
63	20	2	1
64	21	2	3
65	21	2	1
66	21	1	1
67	21	1	1
68	21	3	1
69	21	3	1
70	22	4	2
71	22	3	2
72	22	2	1
73	22	1	2
74	22	2	3
75	22	1	2
76	22	4	2
77	22	1	1
78	22	3	1
79	23	1	1
80	23	2	3
81	23	1	2
82	23	2	1
83	23	3	2
84	23	1	1
85	23	2	1
86	24	1	1
87	24	1	2

Tabela 5.15 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da RNA. Fonte: Autor.

(continuação)

Nº do Vetor	Nº do Cordão	Trecho	Classe
88	24	2	1
89	24	3	2
90	24	2	1
91	25	3	2
92	25	1	1
93	25	2	1
94	26	2	1
95	26	1	2
96	26	1	2
97	26	2	1
98	27	1	2
99	27	2	1
100	27	2	1
101	27	1	1
102	27	1	1
103	27	3	2
104	27	1	2
105	28	2	1
106	28	1	1
107	29	1	1
108	30	1	1
109	30	1	1
110	31	1	1
111	31	2	1
112	32	1	1
113	33	2	1
114	33	1	1
115	33	2	1
116	34	1	1

Tabela 5.15 – Vetores de características do sinal de emissão acústica aérea utilizados no treinamento da RNA. Fonte: Autor.

(conclusão)

Nº do Vetor	Nº do Cordão	Trecho	Classe
117	34	1	1

Tabela 5.16 – Vetores de características do sinal de emissão acústica aérea utilizados na validação cruzada do treinamento da RNA. Fonte: Autor.

(continua)

Nº do Vetor	Nº do Cordão	Trecho	Classe
1	4	2	3
2	4	1	1
3	4	2	1
4	4	2	1
5	6	2	1
6	7	2	2
7	8	2	2
8	8	1	1
9	8	1	2
10	9	1	1
11	10	1	2
12	12	1	2
13	12	1	1
14	15	1	3
15	18	1	2
16	18	1	1
17	18	4	3
18	18	3	3
19	18	2	1
20	19	1	2
21	20	4	2
22	20	1	2
23	20	3	3

Tabela 5.16 – Vetores de características do sinal de emissão acústica aérea utilizados na validação cruzada do treinamento da RNA. Fonte: Autor.

(conclusão)

Nº do Vetor	Nº do Cordão	Trecho	Classe
24	20	1	1
25	21	2	1
26	22	2	1
27	22	3	1
28	23	2	3
29	23	3	2
30	24	1	1
31	25	1	1
32	25	2	1
33	26	1	1
34	26	1	1
35	27	3	2
36	29	2	1
37	31	1	1
38	32	1	1
39	34	2	1

Tabela 5.17 – Vetores de características do sinal de emissão acústica aérea utilizados no teste da RNA. Fonte: Autor.

(continua)

Nº do Vetor	Nº do Cordão	Trecho	Classe
1	4	1	3
2	6	1	1
3	8	1	2
4	8	2	1
5	9	2	1
6	9	2	1
7	10	3	2
8	10	2	2

Tabela 5.17 – Vetores de características do sinal de emissão acústica aérea utilizados no teste da RNA. Fonte: Autor.

(continuação)

Nº do Vetor	Nº do Cordão	Trecho	Classe
9	10	3	2
10	11	1	1
11	12	2	3
12	12	1	1
13	16	1	3
14	17	1	2
15	18	1	2
16	18	3	1
17	20	2	1
18	20	2	3
19	20	1	2
20	20	3	1
21	20	3	1
22	21	2	3
23	22	2	3
24	22	3	2
25	22	1	1
26	23	1	2
27	24	1	2
28	24	3	2
29	25	3	2
30	28	1	1
31	28	2	1
32	29	1	1
33	29	2	1
34	30	2	1
35	30	2	1
36	31	2	1
37	32	2	1

Tabela 5.17 – Vetores de características do sinal de emissão acústica aérea utilizados no teste da RNA. Fonte: Autor.

(conclusão)

Nº do Vetor	Nº do Cordão	Trecho	Classe
38	32	2	1
39	33	1	1
40	34	2	1

5.6.3 Discussão dos Resultados de Classificação

As máquinas de vetor de suporte resolvem problemas de classificação de padrões de forma próxima do ótimo por meio de seu algoritmo que minimiza o número de dados de treinamento que se encontram dentro da margem de separação das classes e as redes neurais artificiais, por meio do algoritmo de retropropagação de erro, minimizam o erro independente da tarefa de aprendizado (Haykin, 2009).

Na Tabela 5.18 tem-se a relação da melhor acurácia global, da mediana da acurácia global e dos tempos de execução de cada classificador. Como a mediana da acurácia global do classificador por RNA foi inferior à do classificador por SVM, a estrutura hierárquica de RNA com fusão sensorial não foi implementada.

Tabela 5.18 – Tempo de execução e acurácia global dos classificadores (* tempo de processamento de vetores de características de fusão sensorial). Cada segmento de dados corresponde a 1660ms de dados gravados. Fonte: Autor.

Classificador	Melhor Acurácia Global	Mediana da Acurácia Global	Tempo de Execução Médio para Cada Segmento de Dados (ms)		
			Extração de Características	Treinamento	Classificação
RNA	97,5%	83,8%	81	20,8	0,9
SVM	95,1%	86,9%	81	24,8	0,6
HSVM	96,6%	91,8%	297,6*	20,8*	2,2*

Molino et al. (2009) reportou em sua pesquisa que, para a detecção de descontinuidades de falta de penetração e de porosidade no processo de soldagem a laser em tempo real, é necessário o processamento dos dados (extração de características e classificação) em um

intervalo inferior a 125ms. Dessa forma, como apresentado na Tabela 5.18, os dados segmentados podem ser pré-processados e classificados em uma aplicação de tempo real por meio dos classificadores RNA e SVM. Os tempos de treinamento e de classificação da RNA são sensíveis a mudanças em sua estrutura (e.g., número de camadas ocultas e de neurônios em cada camada oculta). A SVM não apresenta essa sensibilidade. A estrutura HSVM proposta é viável em aplicações de tempo real. Ela é um sistema robusto para lidar com distúrbios e com sinais pré-processados de diferentes dimensões em dois diferentes estágios. No primeiro estágio do HSVM, seu período para extração de características é igual ao dos classificadores RNA e SVM. Nesse estágio o cordão de solda é monitorado para a detecção de discontinuidades. Se o classificador diagnostica uma falha, o segundo estágio do HSVM é acionado. Nesse caso, a extração de características da fusão sensorial ocorrerá. Essa é a principal vantagem da estratégia proposta, na qual ocorre o acréscimo do custo computacional somente quando necessário. Um classificador mais rápido pode ser implementado em outra linguagem de programação, e.g., C.

A transformada *Wavelet* utilizada no pré-processamento do sinal de emissão acústica sólida foi avaliada do primeiro ao décimo nível de decomposição no classificador HSVM para as dez primeiras sementes. Do primeiro ao nono nível de decomposição não há alteração na acurácia de classificação desse modelo. A partir do décimo nível, em função de perda de informações do sinal amostrado, a acurácia do classificador decresce. O sexto nível de decomposição por *Wavelet* foi escolhido, por ser o menor nível de decomposição no qual é possível diferenciar comportamentos dos detalhes de cratera e perfuração (como discutido na subseção 5.4.2). Para níveis inferiores de decomposição *Wavelet*, verificou-se acréscimo nos tempos de execução para extração de características e treinamento no HSVM.

Considerando-se os melhores resultados de acurácia global dos modelos SVM, HSVM e RNA, esses classificaram incorretamente seis vetores de características. Na Figura 5.50 tem-se, em realce, os trechos dos cordões referentes a esses vetores de características.

O modelo SVM classificou incorretamente trechos dos cordões de solda 7, 22 e 23 (Figura 5.50). No cordão de solda 7, o segundo trecho de discontinuidade referente a cratera foi classificado como pertencente a classe normal. Os sinais de emissão acústica aérea desse cordão foram analisados, e não foi encontrado um padrão no vetor de características que justifique essa falha de classificação. Como a vizinhança dessa cratera é caracterizada por discontinuidade geométrica do cordão, em função de alteração da orientação do eletrodo, é possível que dados dessa vizinhança estejam presentes no vetor de características e tenham contribuído nessa falha de classificação.

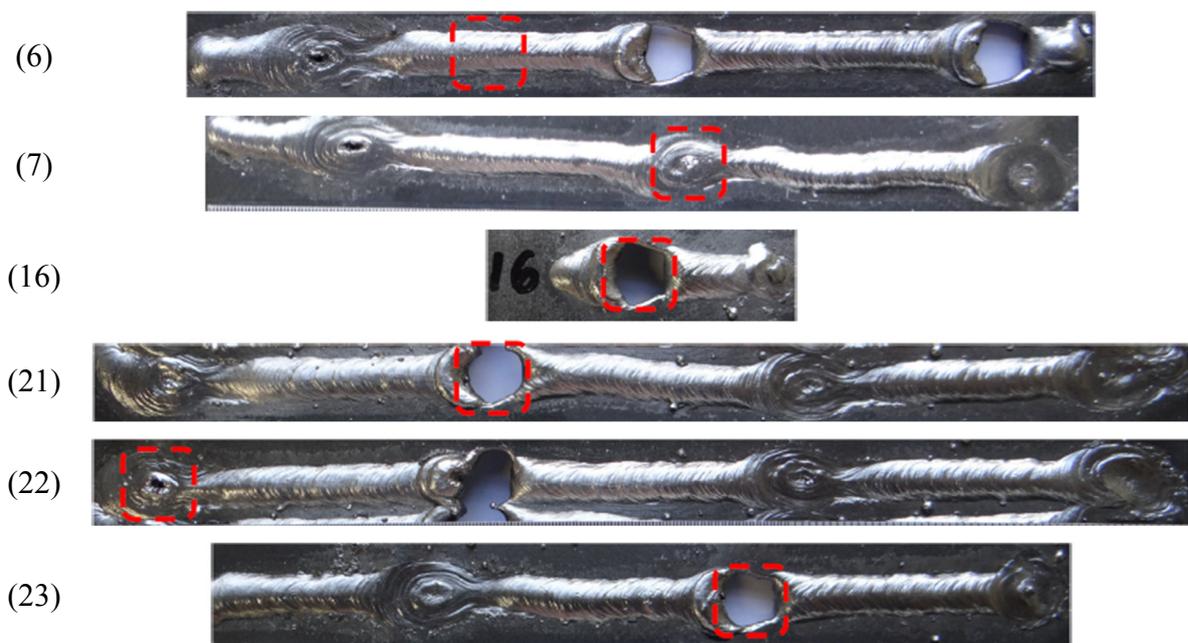


Figura 5.50 – Cordões com trechos em realce que foram classificados incorretamente pelos modelos SVM (cordões 7, 22 e 23), HSVM (cordões 6, 7 e 16) e RNA (cordão 21). Fonte: Autor.

No cordão de solda 22, o primeiro trecho de descontinuidade referente a cratera foi classificado como perfuração. Nota-se que essa descontinuidade ocorreu no início do cordão, que contempla um comportamento transitório de abertura do arco elétrico. Além disso, há a presença de um poro na superfície da cratera. Após análise do espectro do sinal audível e de reamostragem (Figura 5.51), observou a presença majoritária de harmônicos da classe cratera no intervalo de 6 a 10kHz do espectro do sinal reamostrado. Esse comportamento diferencia-se do padrão observado nessa classe, caracterizado por apresentar o menor espectro de sinal entre as três classes avaliadas neste trabalho.

Por fim, no cordão de solda 23, o segundo trecho de descontinuidade referente a perfuração foi classificado como pertencente a classe normal. Ao comparar o espectro do sinal audível e de reamostragem (Figura 5.43) desse cordão com outros, nota-se que os espectros das classes avaliadas são atenuados em relação a de outros cordões (Figuras 5.40 a 5.42). Portanto, é provável que essa atenuação desse espectro da classe perfuração tenha contribuído no erro de classificação.

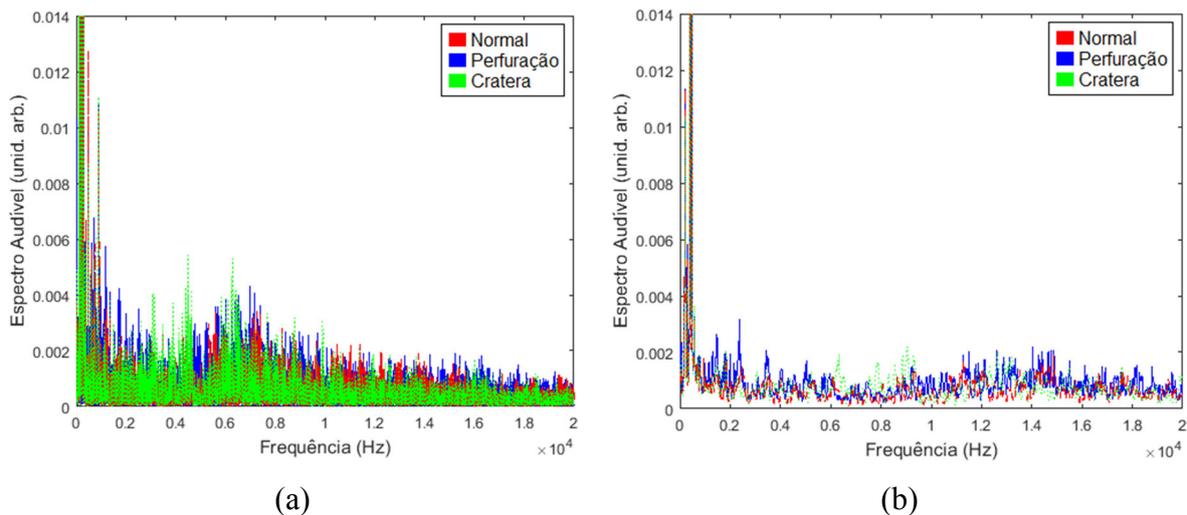


Figura 5.51 – Pré-processamento do sinal audível do cordão de solda nº 22: (a) espectro do sinal obtido por meio de DFT; (b) reamostragem do espectro de frequências. O sinal da classe perfuração é referente à segunda descontinuidade do cordão; o sinal da classe cratera é referente à primeira descontinuidade do cordão; o sinal da classe normal é referente ao segundo trecho do cordão. Fonte: Autor.

Já o modelo HSVM classificou incorretamente trechos dos cordões de solda 6, 7 e 16 (Figura 5.50). No cordão de solda 6, o segundo trecho normal foi classificado como descontinuidade. Os sinais de emissão acústica aérea desse cordão foram analisados, e não foi encontrado um padrão no vetor de características que justifique essa falha de classificação. É provável que as características do sinal de emissão acústica aérea desse trecho não foram contempladas na fronteira de decisão da HSVM. O segundo trecho de descontinuidade do cordão de solda 7 apresentou o mesmo erro de classificação observado no modelo SVM. O cordão de solda 16, que possui apenas dados referente a descontinuidade perfuração foi classificado como pertencente a classe cratera. Como esse cordão de solda é curto, é provável que contenha dados referente a abertura do arco elétrico e tenha contribuído no erro de classificação.

O modelo RNA classificou incorretamente apenas o segundo trecho de descontinuidade do cordão 21. A descontinuidade de perfuração foi classificada como de cratera. Os sinais de emissão acústica aérea desse cordão foram analisados, e não foi encontrado um padrão no vetor de características que justifique essa falha de classificação. É provável que as características do sinal de emissão acústica aérea desse trecho não foram contempladas na fronteira de decisão da RNA.

Vale ressaltar que o conjunto de vetores de características testado pela RNA é inferior ao conjunto avaliado pela SVM e HSVM, embora mantenha a mesma proporção de representantes de cada classe. Além disso, os trechos dos cordões 7, 22 e 23 classificados incorretamente pela SVM e HSVM não foram testados pela RNA. Os cordões de solda que apresentaram erros de classificação pelos modelos SVM, HSVM e RNA foram executados com a mesma corrente de soldagem (70A, Tabela 4.5).

6. Conclusões

No presente trabalho apresentou-se o desenvolvimento da primeira estação de soldagem robotizada do processo SMAW da Escola de Minas – UFOP (a partir do trabalho de Rocha *et al.*, 2015). Atualmente, é a única estação de soldagem robotizada em operação na universidade e pode ser utilizada para otimização de parâmetros do processo, assistir à capacitação de soldadores, bem como a execução de cordões de solda por meio de outros processos de soldagem.

Neste trabalho agregou-se conhecimentos na área de Engenharia de Materiais, em especial na Engenharia de Superfícies, que abrange as áreas de conhecimento relacionadas a topografia de cordões de solda e a ensaios não destrutivos. Um dos principais interesses foi aplicar técnicas de aprendizagem de máquinas para a qualificação de cordões de solda no processo de soldagem por eletrodos revestidos (SMAW).

Essas técnicas foram aplicadas com sucesso na detecção de descontinuidades no processo SMAW. As estruturas de máquina de vetor de suporte (SVM) e de redes neurais artificiais (RNA) foram configuradas para classificar os cordões de solda, com base nos vetores de características de dados amostrados por meio de microfone. Após o treinamento, ambas estruturas podem ser usadas para identificar as três classes propostas, que são o cordão de solda normal, descontinuidades de cratera e de perfuração. A acurácia de inspeção de cada classe é superior a 83%. Os resultados alcançados sugerem que ambos os classificadores podem ser utilizados em aplicações de tempo real. Para viabilizar o uso das técnicas propostas em ambiente industrial, foi realizada a fusão sensorial dos sinais amostrados por meio de microfone e por meio de cristal piezoelétrico. Para avaliar a contribuição dessa fusão, propõe-se uma inovação na estrutura hierárquica de máquina de vetor de suporte (HSVM) com escalonamento de entrada de dados em dois estágios (Cocota *et al.*, 2017). Essa abordagem apresentou acurácia global de 96,6% na classificação dos dados amostrados. O sistema desenvolvido pode ser utilizado no controle de qualidade de cordões de solda, bem como na análise de admissão de ocorrência da descontinuidade de cratera de acordo com os requisitos de qualidade.

Neste trabalho os sinais da emissão acústica sólida apresentados foram amostrados por meio de cristal piezoelétrico fixado ao metal de base sem o uso de acoplante. Posteriormente, ensaios com o uso de graxa como acoplante foram efetuados, e não observou-se diferença na amplitude do sinal amostrado.

Nos experimentos de execução de cordões de solda pelo processo SMAW, foram observadas as descontinuidades perfuração, cratera, mordedura, porosidade, trinca, micro

trinca, respingos e sobreposição. Com exceção da primeira, as demais descontinuidades estão relacionadas ao menor aporte térmico em função do acréscimo do comprimento do arco, que foi observado nos experimentos, conforme discutido nas análises metalográficas. Essas foram importantes na caracterização da descontinuidade de cratera. A dinâmica do sinal audível no tempo foi relacionada às descontinuidades de perfuração e cratera. Salienta-se que os resultados experimentais são relativos à execução de cordão de solda no aço SAE 1006, com eletrodo E 6013 para um dado conjunto de parâmetros de soldagem.

Verificou-se que a emissão acústica aérea da interação do arco com a poça de fusão, embora seja sujeita a distúrbios, é uma importante fonte de informação do processo. Vale ressaltar que, neste trabalho, identificou-se, pela primeira vez, que o espectro do sinal audível da descontinuidade perfuração apresenta, em sua distribuição de frequências, harmônicos de ordem superiores aos observados nas classes normal e cratera (Cocota *et al.*, 2017).

Os resultados similares de classificação obtidos neste trabalho com diferentes classificadores (RNA: 97,5%; SVM: 95,1%; e HSVM: 96,6%) reforçam que as metodologias de extração de características adotadas são adequadas para esta aplicação. O uso de transformada de Fourier (DFT) com reamostragem de decimação por média para extração de características do sinal audível é atrativo em função de sua relativa alta velocidade para execução desta tarefa. Os resultados de acurácia global alcançados para a detecção de descontinuidades estão em patamares equivalentes aos alcançados em trabalhos de monitoramento de outros processos de soldagem. Este diferencia-se por utilizar sensores com dinâmica rápida e custo relativamente baixo, que o torna atrativo para aplicação industrial.

Deve-se registrar que, embora seja viável o uso da estrutura HSVM proposta, o desempenho do sistema pode ser melhorado para sua aplicação em tempo real.

O trabalho realizado abre novas perspectivas para pesquisa na área de ensaios não destrutivos na instituição.

Finalmente, como o sistema é baseado em componentes amplamente disponíveis no mercado, pode-se estendê-lo, com a inclusão de outros sensores e aplicá-lo no reconhecimento de padrões em outros processos de soldagem a arco.

7. Sugestões para Trabalhos Futuros

Como sugestões para trabalhos futuros nesta linha de pesquisa, propõem-se:

- 1 – avaliar o uso da estação para identificação de condições ótimas de soldagem;
- 2 – avaliar o uso do sistema para assistir o processo de treinamento de soldadores;
- 3 – limitar a margem de entrada analógica da DAQ NI USB-6351 para $\pm 1V$, com o intuito de melhorar a acurácia de amostragem do sinal de emissão acústica sólida;
- 4 – utilizar peças de trabalho individuais para cada cordão de solda nos experimentos;
- 5 – executar ensaios com transdutores ultrassônico (piezoelétrico) e pré-amplicadores de diferentes frequências;
- 6 – executar novos ensaios, para que novos dados sejam utilizados no treinamento dos modelos de classificadores, aumentando assim a confiabilidade dos modelos propostos;
- 7 – alterar as dimensões dos sulcos transversais na superfície inferior da chapa de aço, para analisar se outras descontinuidades surgirão;
- 8 – analisar o sinal de emissão acústica aérea da descontinuidade do tipo perfuração para diferentes geometrias dos sulcos transversais na superfície inferior da chapa de aço;
- 9 – classificar por meio de reconhecimento de padrões as demais descontinuidades observadas (mordedura, porosidade, trinca, micro trinca e respingos);
- 10 – agregar à fusão sensorial a visão computacional;
- 11 – controlar o aporte térmico para evitar a ocorrência de descontinuidades no cordão de solda.

Referências Bibliográficas

ALFARO, S.C.A. e CAYO, E.H. Sensoring Fusion Data from the Optic and Acoustic Emissions of Electric Arcs in the GMAW-S Process for Welding Quality Assessment. *Sensors*, Basel, Switzerland, 12, p. 6953–6966, 2012.

ANCONA, A.; MAGGIPINTO, T.; SPAGNOLO, V.; FERRARA, M. e LUGARA, P.M. Optical Sensor for Real Time Weld Defects Detection. In: *SENSORS AND CAMERA SYSTEMS FOR SCIENTIFIC, INDUSTRIAL, AND DIGITAL PHOTOGRAPHY APPLICATIONS III*, 2002. Anais. Bellingham, WA, USA: SPIE, 2002. p. 217–226.

ANDERSEN, K.; COOK, G.E.; KARSAI, G. e RAMASWAMY, K. Artificial Neural Networks Applied to Arc Welding Process Modeling and Control. *IEEE Trans. Ind. Appl.*, Danvers, MA, USA, 26, p. 824–830, 1990.

APASOV, A.M. e APASOV, A.A. Acoustic Emission Diagnostics of Fault Fusion in Welding. In: *INTERNATIONAL FORUM ON STRATEGIC TECHNOLOGY*, 2012, Tomsk, Russia. Anais. Danvers, MA, USA: IEEE, 2012. p. 1–5.

BRAGA, A.P.; CARVALHO, A.P.L.F. e LUDERMIR, T.B. *Redes Neurais Artificiais – Teoria e Aplicações*. 1ª ed. Rio de Janeiro: LTC, 2000.

BEATTIE, A.G. *Acoustic Emission Non-Destructive Testing of Structures using Source Location Techniques*. USA: Sandia National Laboratories, 2013.

BOSER, B.; GUYON, I.; VAPNIK, V.N. A Training Algorithm for Optimal Margin Classifiers. *Fifth Annual Workshop on Computer Learning Theory*, p. 144-152, 1992.

CALLISTER, W.D.Jr. e RETHWISCH, D.G. *Materials Science and Engineering: An Introduction*, 9ª ed. Danvers, MA, USA: Wiley, 2014.

CHANG, J.; HAN, G.; VALVERDE, J.M.; GRISWOLD, N.C.; DUQUE-CARRILLO, J.F. e SÁNCHEZ-SINENCIO, E. Cork Quality Classification System using a Unified Image

Processing and Fuzzy-Neural Network Methodology. IEEE Trans. Neural Networks., Danvers, MA, USA, 8, p. 964–974, 1997.

CHEN, Y, CRAWFORD, M. M. e GHOSH, J. Integrating Support Vector Machines in a Hierarchical Output Space Decomposition Framework. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, 2004, Anchorage, AK, USA. Anais. Danvers, MA, USA: IEEE, 2004. p. 949–952.

COCOTA, J.A.N.; GARCIA, G.C.; da COSTA, A.R.; de LIMA, M.S.F.; ROCHA, F.A.S. e FREITAS, G.M. Discontinuity Detection in the Shield Metal Arc Welding Process. Sensors, Basel, Switzerland, 17, p. 1–14, 2017.

COOK, G.E.; BARNETT, R.J.; ANDERSEN, K. e STRAUSS, A.M. Weld Modeling and Control Using Artificial Neural Networks. IEEE Trans. Ind. Appl., Danvers, MA, USA, 31, p. 1484–1491, 1995.

CYBENKO, G. Continuous valued neural networks with two hidden layers are sufficient. Nota técnica, Department of Computer Science, Tufts University, 1988.

CYBENKO, G. Approximation by superpositions of a sigmoid function. Mathematics of Control, Signals and Systems, 2, p. 303-314, 1989.

DAUBECHIES, I. Ten Lectures on Wavelets. In: Regional Conference Series in Applied Mathematics, CBMS-NSF, Philadelphia, USA, p. 1-341, 1992.

ESAB. Processo de Soldagem: MIG/MAG (GMAW). Centro de Conhecimento ESAB, 2014. Disponível em: http://www.esab.com.br/br/pt/education/blog/processo_soldagem_mig_mag_gmaw.cfm. Acesso em 25/07/17.

FORTES, C. Apostila de Eletrodos Revestidos. Belo Horizonte: ESAB, 2005.

GARCIA-ALLENDE, P.B.; MIRAPEIX, J.; CONDE, O.M.; COBO, A. e LOPEZ-HIGUERA, J.M. Arc-Welding Spectroscopic Monitoring based on Feature Selection and Neural Networks. Sensors, Basel, Switzerland, 8, p. 6496–6506, 2008.

GARCÍA, M. A. P.; ANTÓN, J. C. A.; RODRÍGUEZ, J. C. C.; MARTÍN, F. J. F. e ORTEGA G. J. G. Instrumentación Electrónica. 1ª ed. Madri, Espanha: Thomson, 2004.

GIANNAKOPOULOS, T. e PIKRAKIS, A. Introduction to Audio Analysis, 1ª ed. San Diego, CA, USA: Academic Press, 2014.

G.R.A.S. 40PH CCP Free-field Array Microphone. Disponível em: <http://www.gras.dk/40ph.html>. Acesso em: 08/06/2017.

HAMANN, C.; ROSEN, H.G. e LABIGER, B. Acoustic emission and its application to laser spot welding, SPIE high powers lasers and laser machining technology. In: Proceedings of the SPIE, 1989, vol. 1132, pp. 275–281

HAYKIN, S. Neural Networks and Learning Machines, 3ª ed. Hamilton, Ontario, Canada: McMaster University, 2009.

HUANG, Y.; WU, D.; ZHANG, Z.; CHEN, H. e CHEN, S. EMD-based pulsed TIG welding process porosity defect detection and defect diagnosis using GA-SVM. J. Mater. Proc. Tech., Gangtok, India, 239, p. 92–102, 2017.

KROLCZYK, G.M.; NIESLONY, P; KROLCZYK, J.B.; SAMARDZIC, I.; LEGUTKO, S. e HLOCH, S. Influence of Argon Pollution on the Weld Surface Morphology. Budapest, Hungary: Measurement, 2015, 70, p. 203–213.

KUMAR, V.; CHANDRASEKHAR, N.; ALBERT, S.K. e JAYAPANDIAN, J. Analysis of Arc Welding Process Using Digital Storage Oscilloscope. Budapest, Hungary: Measurement, 2016, 81, p. 1–12.

KUMAR, G.S.; NATARAJAN, U.; VEERARAJAN, T. e ANANTHAN, S.S. Quality Level Assessment for Imperfections in GMAW. Weld. J., Miami, FL, USA, 93 p. 85–97, 2014.

LI, X.R.; SHAO, Z; ZHANG, Y.M.; KVIDAHL, L. Monitoring and Control of Penetration in GTAW and Pipe Welding. Weld. J., Miami, FL, USA, 92, p. 190–196, 2013.

LIMA II, E.J. e BRACARENSE, A.Q. Robotic Shielded Metal Arc Welding. *Weld. J.*, Miami, FL, USA, 89, p. 166–171, 2010.

LORENA, A. C. e CARVALHO, A. C. P. L. F. Uma Introdução às Support Vector Machines. Porto Alegre, Brasil: *Revista de Informática Teórica e Aplicada (RITA)*, 2007, 14, p. 43-67.

MANJULA, K.; VIJAYAREKHA, K.; VENKATRAMAN, B. e KARTHIK, D. Ultrasonic Time of Flight Diffraction Technique for Weld Defects: A Review. *Res. J. Appl. Sci. Eng. Technol.*, NY, USA, 24, p. 5525–5533, 2012.

MARQUES, P.V. e MODENESI, P.J. Algumas Equações Úteis em Soldagem. *Soldag. Insp.*, SP, Brasil, 19, p. 91–102, 2014.

MARQUES, P.V.; MODENESI, P.J. e BRACARENSE, A.Q. *Soldagem – Fundamentos e Tecnologia*. 3ª ed. Belo Horizonte, Brasil: Editora UFMG, 2009.

MATHEW, D. Choosing The Right Microphones For Precision Measurements. *Sensors ONLINE*. USA, Newton, Maio 2017. Disponível em: <http://www.sensormag.com/components/choosing-right-microphones-for-precision-measurements>. Acesso em: 08/06/17.

MATHWORKS. Support Vector Machines for Binary Classification. Mathworks documentation. Disponível em: <https://www.mathworks.com/help/stats/support-vector-machines-for-binary-classification.html>. Acesso em: 09/07/17.

MATHWORKS. Discrete Wavelet Analysis. Mathworks documentation. Disponível em: <https://www.mathworks.com/help/wavelet/ref/dwt.html>. Acesso em: 19/11/17.

McCULLOCH, W.S. e PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, p. 115-133, 1943.

MICHELL, T. *Machine Learning*. New York: McGraw Hill, 1997.

MIRAPEIX, J.; COBO, A.; FUENTES, J.; DAVILA, M.; ETAYO, J.M. e LOPEZ-HIGUERA, J.M. Use of the Plasma Spectrum RMS Signal for Arc-Welding Diagnostics. *Sensors*, Basel, Switzerland, 9, p. 5263–5276, 2009.

MIRAPEIX, J.; GARCÍA-ALLENDE, P.B.; COBO, A.; CONDE, O.M. e LOPEZ-HIGUERA, J.M. Real-time Arc-welding Defect Detection and Classification with Principal Component Analysis and Artificial Neural Networks. *NDT E Int.*, Gangtok, India, 40, p. 315–323, 2017.

MOLINO, A.; MARTINA, M.; VACCA, F.; MASERA, G.; TERRENO, A.; PASQUETTAZ, G. e D'ANGELO, G. FPGA implementation of time-frequency analysis algorithms for laser welding monitoring. *J. Microprocess. Microsyst.* 33, p. 179–190, 2009.

NAGESH, D.S. e DATTA, G.L. Prediction of Weld Bead Geometry and Penetration in Shielded Metal-Arc Welding Using Artificial Neural Networks. *J. Mater. Proc. Tech.*, Gangtok, India, 123, p. 303–312, 2002.

NATIONAL INSTRUMENTS (NI 9234). Disponível em: <http://sine.ni.com/nips/cds/view/p/lang/pt/nid/208802#>. Acesso em: 18/06/2017.

NATIONAL INSTRUMENTS (USB NI 6351). Disponível em: <http://sine.ni.com/nips/cds/view/p/lang/pt/nid/209071>. Acesso em: 18/06/2017.

O'BRIEN, A. *AWS Welding Handbook*. 9ª ed. Doral, FL, USA: American Welding Society, 2004. Volume 2, p. 52.

OGAWA, M. *Graduação tecnológica em automação industrial. Controle & Instrumentação*, São Paulo, SP, Brasil, 228, p. 48–49, 2017.

PAUL, A.K. Robust Product Design Using SOSM for Control of Shielded Metal Arc-Welding (SMAW) Process. *IEEE Trans. Ind. Electron.*, Danvers, MA, USA, 63, p. 3717–3724, 2016.

PAUL, A.K. Sliding Surface in 1-Sliding Boosts Multi-objective Optimization Program of Shielded Metal Arc Welding Process. In: *INTERNATIONAL CONFERENCE ON*

ADVANCED ELECTRONIC SYSTEMS, 2013, Pilani, India. Anais. Danvers, MA, USA: IEEE, 2013. p. 39–44.

RIBEIRO, R.A.; SANTOS, E.B.F.; ASSUNÇÃO, P.D.C.; MACIEL, R.R. e BRAGA, E.M. Predicting Weld Bead Geometry in the Novel CW-GMAW Process. *Weld. J.*, Miami, FL, USA, 94, p. 301–311, 2015.

ROCHA, F.A.S.; SERRANTOLA, W.G.; LOPEZ, G.N.; TORGA, D.S.; de CARVALHO, M.A.; de SOUZA, G.P.; COCOTA JR., J.A.N. e RÊGO SEGUNDO, A.K. Retrofitting de uma Mesa XY. In: Simpósio Brasileiro de Automação Inteligente, 2015, Natal, Brasil. Anais. SBA, 2015, p. 1931–1936.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychol. Rev.*, 65, p. 386-408, 1958.

RUMELHART, D.E; HINTON, G.E. e WILLIAMS, R.J. Learning representations of back-propagation erros. *Nature*, London, 323, p.533-536, 1986.

SANSAN, A.; ZHEN, L.; NAN, Z. e RUI, W. Blind Source Separation based on Principal Component Analysis—Independent Component Analysis for Acoustic Signal during Laser Welding Process. In: INTERNATIONAL CONFERENCE ON DIGITAL MANUFACTURING AND AUTOMATION, 2010, ChangSha, China. Anais. Danvers, MA, USA: IEEE, 2010. p. 336–339.

SCHMIDT, M.; OTTO, A. e KÄGELER, C. Analysis of YAG laser lap-welding of zinc coated steel sheets. *CIRP Annals - Manufacturing Technology*, Gangtok, India, 57, p. 213-216, 2008.

SCHÖLKOPF, B. e SMOLA, A. J. *Learning with Kernels*. Cambridge: The MIT Press, 2002.

SCOTTI, A.; REIS, R. P. e LISKEVYCH, O. Modelo descritivo do fluxo de calor em soldagem a arco visando o conceito de calor imposto efetivo. *Soldag. Insp.*, SP, Brasil, 17, p. 166–172, 2012.

SHANNON, C.E. A Mathematical Theory of Communication. The Bell System Technical Journal, USA, 27, pp. 379-423, 1948.

SHI, Y.; ZHANG, G.; MA, X.J.; GU, Y.F.; HUANG, J.K. e FAN, D. Laser-Vision-Based Measurement and Analysis of Weld Pool Oscillation Frequency in GTAW-P. Weld. J., Miami, FL, USA, 94, p. 176–186, 2015.

SIBILLANO, T.; ANCONA, A.; RIZZI, D.; LUPO, V. e TRICARICO, L. Plasma Plume Oscillations Monitoring during Laser Welding of Stainless Steel by Discrete Wavelet Transform Application. Sensors, Basel, Switzerland, 10, p. 3549–3561, 2010.

SICILIANO, B.; SCIAVICCO, L.; VILLANI, L.; ORIOLO, G. Robotics - Modelling, Planning and Control, 1ª ed. London: Springer, 2009.

SILVA, W.C.D.; BRACARENSE, A.Q. e PESSOA, E.C.P. Efeito da Profundidade de Soldagem no Hidrogênio Difusível de Soldas Molhadas. Soldag. Insp., SP, Brasil, 17, p. 298–305, 2012.

SPONG, B.; SCIAVICCO, L.; VILLANI, L.; ORIOLO, G. SPONG, M.W.; HUTCHINSON, S.; VIDYASAGAR, M. Robot Modeling and Control, 1ª ed. New York: John Wiley & Sons, Inc., 2005.

STERJOVSKI, Z; PITRUN, M.; NOLAN, D.; DUNNE, D. e NORRISH, J. Artificial Neural Networks for Predicting Diffusible Hydrogen Content and Cracking Susceptibility in Rutile Flux-cored Arc Welds. J. Mater. Proc. Tech., Gangtok, India, 184, p. 420–427, 2007.

TAM, J.; HUISSOON, J. Developing Psycho-Acoustic Experiments in Gas Metal Arc Welding. Proceedings of International Conference on Mechatronics & Automation, Niagara Falls, ON, Canada, p. 1112–1117, 2005.

VAPNIK, V.N. Principles of Risk Minimization for Learning Theory. Advances in Neural Information Processing Systems, 4, p.831-838, 1992.

YOU, D.; GAO, X. e KATAYAMA, S. Multisensor Fusion System for Monitoring High-Power Disk Laser Welding Using Support Vector Machine. *IEEE Trans. Ind. Inform.*, Danvers, MA, USA, 10, p. 1285–1295, 2014.

YOU, D.; GAO, X. e KATAYAMA, S. WPD-PCA-Based Laser Welding Process Monitoring and Defects Diagnosis by Using FNN and SVM. *IEEE Trans. Ind. Electron.*, Danvers, MA, USA, 62, p. 628–636, 2015.

WERSBORG, I.S.G.; BAUTZE, T.; BORN, F. e DIEPOLD, K. A cognitive approach for a robotic welding system that can learn how to weld from acoustic data. In *Proceedings of the International Conference on Computational Intelligence in Robotics and Automation, 2009*, Daejeon, Korea. Anais. Danvers, MA, USA: IEEE, 2009. P. 1–6.

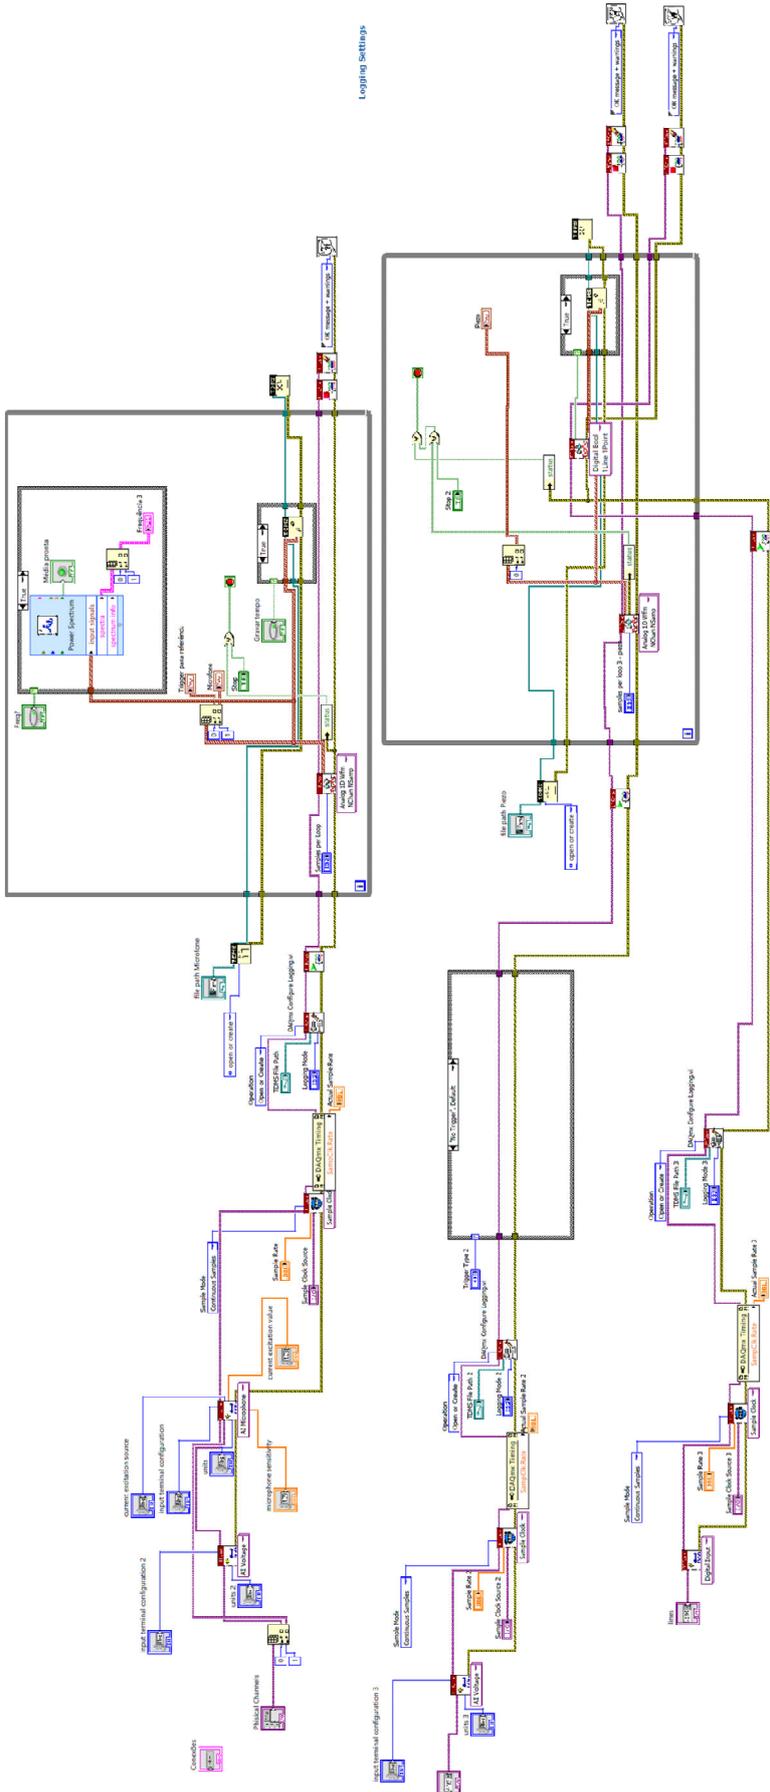
WIDROW, B. e HOFF, M.E. Adaptive switching circuits. Institute of Radio Engineers, Western Electronic Show and Convention, 1960, Los Angeles, California, USA.

Publicações do Autor Relacionadas com o Trabalho

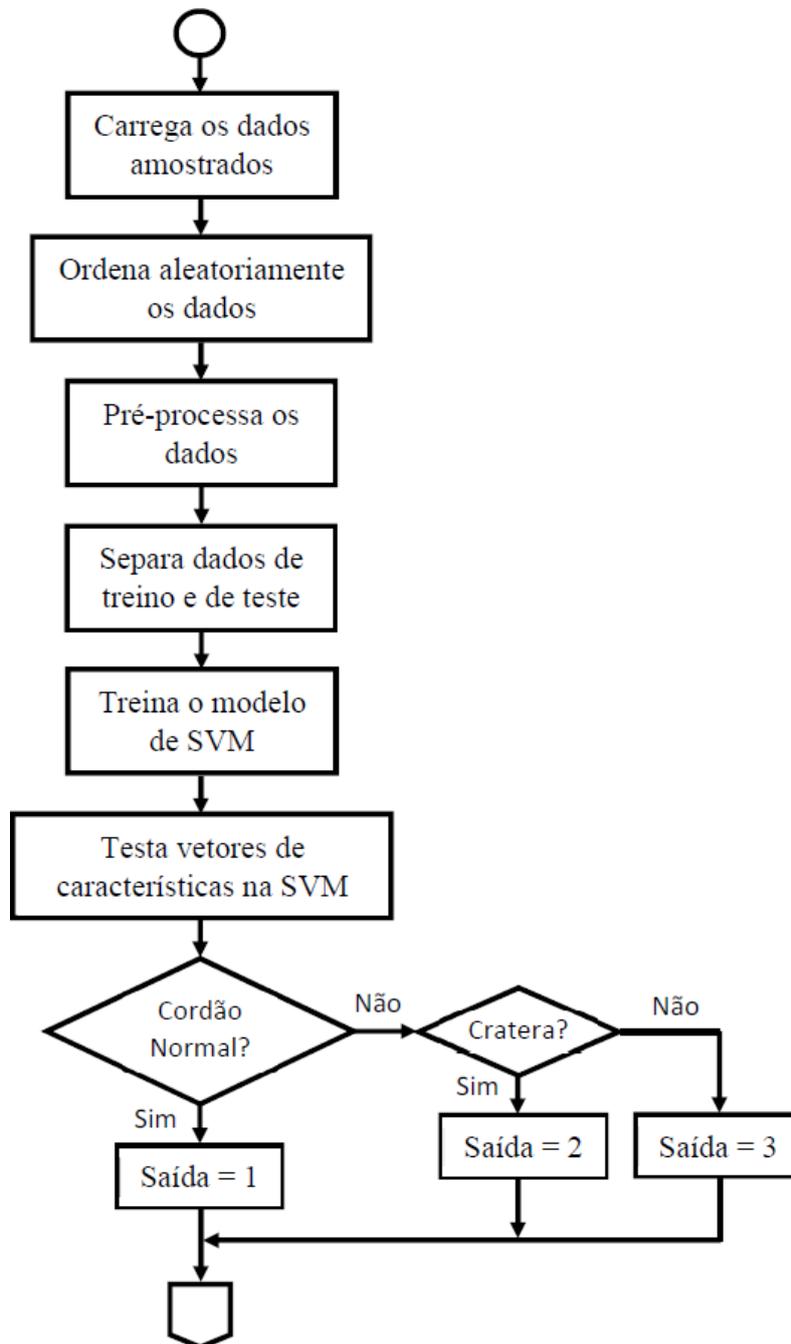
COCOTA, J.A.N.; GARCIA, G.C.; da COSTA, A.R.; de LIMA, M.S.F.; ROCHA, F.A.S. e FREITAS, G.M. Discontinuity Detection in the Shield Metal Arc Welding Process. *Sensors*, Basel, Switzerland, 17, p. 1–14, 2017.

ROCHA, F.A.S.; SERRANTOLA, W.G.; LOPEZ, G.N.; TORGA, D.S.; de CARVALHO, M.A.; de SOUZA, G.P.; COCOTA JR., J.A.N. e RÊGO SEGUNDO, A.K. Retrofitting de uma Mesa XY. In: *Simpósio Brasileiro de Automação Inteligente*, 2015, Natal, Brasil. *Anais. SBA*, 2015, p. 1931–1936.

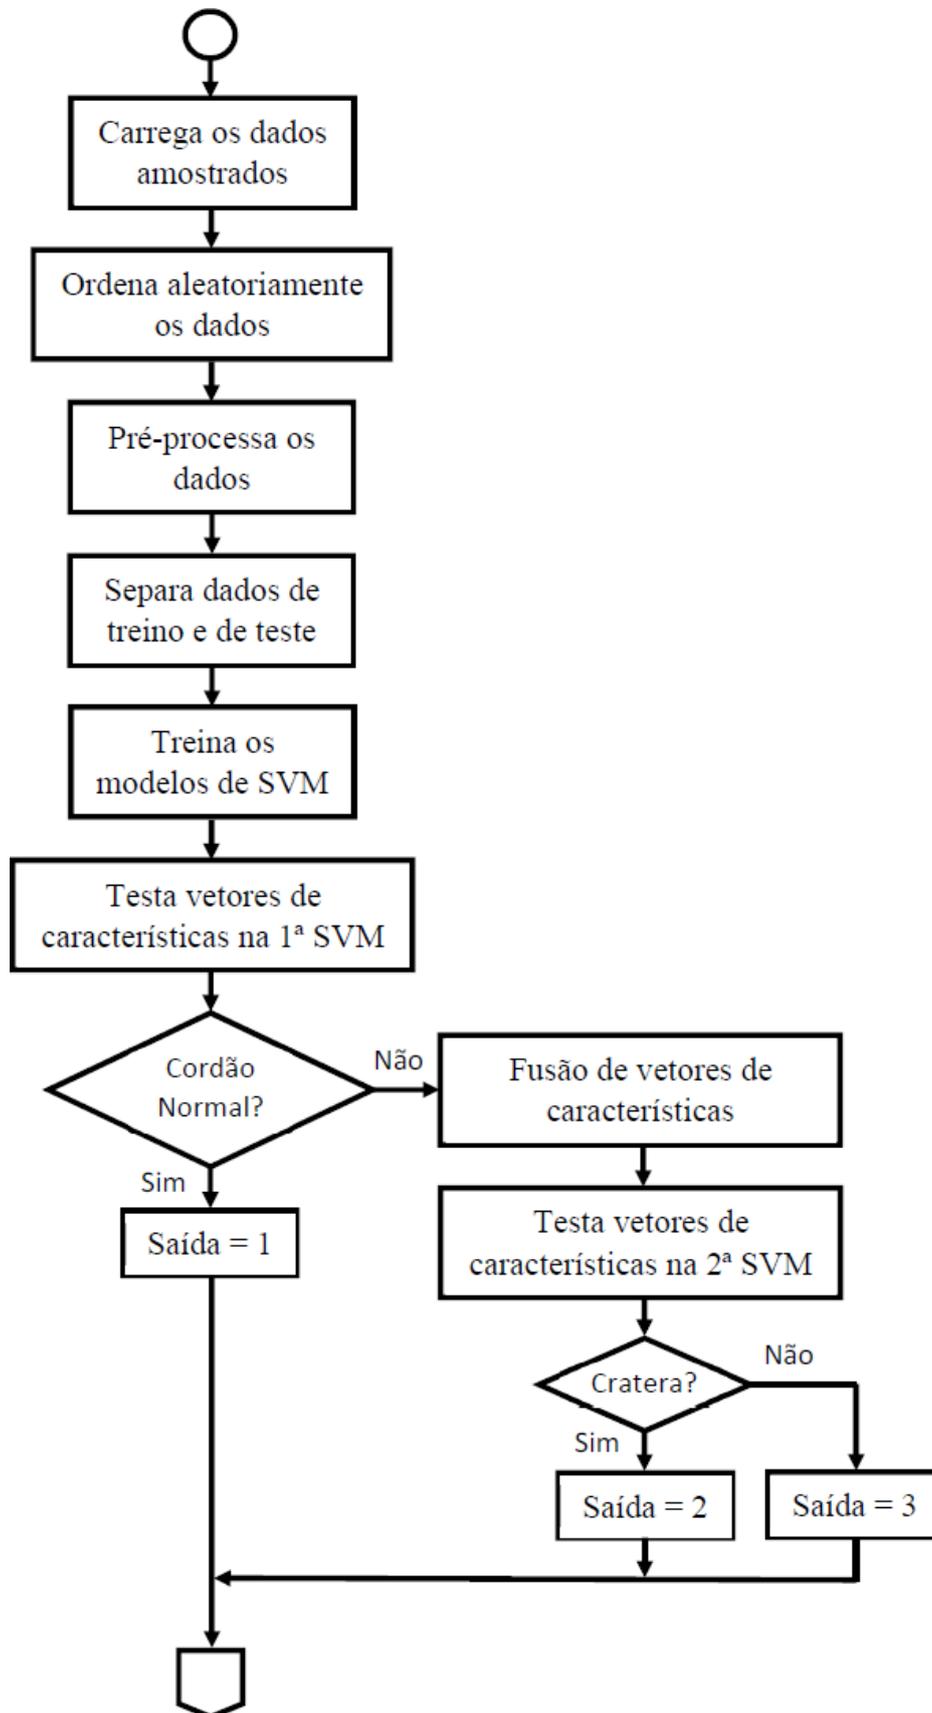
Anexo A – Diagrama de Blocos no LabVIEW



Anexo B – Fluxograma do *Script* em MATLAB – SVM



Anexo B – Fluxograma do *Script* em MATLAB – HSVM



Anexo B – Fluxograma do *Script* em MATLAB – RNA

