

FELIPE BAVAROSKI TOLEDO COSTA

FORMAÇÃO DE LIGA AI-Cu COM CONSTITUINTE EUTÉTICO POR ASP DISSIMILAR *IN SITU*, UMA ANÁLISE AUXILIADA POR MACHINE LEARNING



FELIPE BAVAROSKI TOLEDO COSTA

FORMAÇÃO DE LIGA AI-Cu COM CONSTITUINTE EUTÉTICO POR ASP DISSIMILAR *IN SITU*, UMA ANÁLISE AUXILIADA POR MACHINE LEARNING

Dissertação apresentada ao curso de Pós-Graduação em Engenharia Mecânica, Setor de Tecnologia, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr. Ramón Sigifredo Cortés Paredes

CURITIBA 2021

Catalogação na Fonte: Sistema de Bibliotecas, UFPR Biblioteca de Ciência e Tecnologia

C837f Costa, Felipe Bavaroski Toledo Formação de liga Al-Cu com constituinte eutético por ASP dissimilar *in situ*, uma análise auxiliada por machine learning [recurso eletrônico] / Felipe Bavaroski Toledo Costa – Curitiba, 2021.

> Dissertação - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Mecânica. Orientador: Prof. Dr. Ramón Sigifredo Cortés Paredes

> 1. Aspersão Térmica. 2. Aprendizado por máquina (Machine Learning). 3. Ligas (Metalurgia). I. Universidade Federal do Paraná. II. Paredes, Ramón Sigifredo Cortés. III. Título.

> > CDD: 671.734

Bibliotecária: Roseny Rivelini Morciani CRB-9/1585



MINISTÉRIO DA EDUCAÇÃO SETOR DE TECNOLOGIA UNIVERSIDADE FEDERAL DO PARANÁ PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA MECÂNICA - 40001016040P5

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA MECÂNICA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de FELIPE BAVAROSKI TOLEDO COSTA intitulada: FORMAÇÃO DE LIGA AI-Cu COM CONSTITUINTE EUTÉTICO POR ASP DISSIMILAR IN SITU, UMA ANÁLISE AUXILIADA POR MACHINE LEARNING, sob orientação do Prof. Dr. RAMON SIGIFREDO CORTES PAREDES, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua <u>APADO VADO</u> no rito de defesa. A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 23 de Julho de 2021.

RAMON SIGIÈREDO CORTES PARÈDES Presidente da Banca Examinadora

BAVARESCO SUCHARSKI GUSTA

Avaliador Externo (INSTITUTO DE TECNOLOGIA PARA O DESENVOLVIMENTO)

PSP

ANDERSON CERALDO MARENDA PUKASIEWICZ Avaliador Externo (UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ)

SIDNEI ANTONIO PIANARO

Avaliador Externo (UNIVERSIDADE ESTADUAL DE PONTA GROSSA)

Dedico esse trabalho aos meus pais e a todos que me ajudaram nesse caminho que chamamos de vida.

AGRADECIMENTOS

Agradeço primeiramente aos meus pais, por terem me criado e preparado para a esse mundo da melhor maneira que puderam, sacrificando tudo que podiam para me dar a melhor educação e condições a seu alcance.

À minha avó, pelo seu exemplo de vida e superação que me motivam e me guiam nesse mundo cheio de adversidades.

Ao Gabriel Santiago por acreditar em mim mais do que eu jamais pude, por sua amizade e suporte.

Ao Celso e a Ana por terem me aceitado em sua casa e tratado como um filho, me permitindo chegar onde estou hoje.

Ao Rafael Flaquer, pela sua amizade e companheirismo. Agradeço-lhe por todas nossas conversas e suporte durante os momentos mais difíceis da vida.

Ao Gustavo Padovany por todas as nossas conversas fora da caixa e divertidas que tivemos juntos.

À Patricia Tscheliski pela sua amizade, conversas loucas, suporte e por todas as músicas que ouvimos juntos durante a confecção deste trabalho.

Aos amigos e colegas de laboratório pelas discussões e conversas intrigantes, além de toda ajuda em meu trabalho.

Ao professor Ramon por todo seu apoio, tutoria e paciência através dos anos, que me levaram a esse caminho que hoje sigo em minha vida. Obrigado pela sua amizade, orientação e por ser o meu guia de onde pretendo chegar nessa vida.

A todos os professores que me guiaram nesse caminho com seus ensinamentos e suporte que permitiram chegar onde estou hoje. Muito obrigado por seu tempo e dedicação a essa incrível profissão.

Ao laboratório de Engenharia de Superfícies e ao Centro de Microscopia Eletrônica (CME) da UFPR pelo acesso e uso dos seus equipamentos na obtenção das imagens dos revestimentos usadas nesse estudo.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. E por tal sou grato.

RESUMO

A análise de revestimentos de aspersão térmica nem sempre é simples, em situações onde a microestrutura é complexa, como naquelas obtidas por ASP dissimilar, a presença de várias fases e misturas das mesmas dificulta o uso da técnica clássica de thresholding para avaliação das propriedades de revestimentos através de imagens. Dessa maneira esse estudo almeja avaliar a viabilidade do uso da técnica de machine learning para auxiliar a análise de revestimentos de aspersão térmica, visando melhorar a qualidade das análises obtidas e maior automação do processo. Para tal foram depositados revestimentos pelo ASP dissimilar utilizando um arame de alumínio e outro de cobre. A deposição de material foi feita em chapas de 50x75x1,5 mm de alumínio 5052. A análise da composição e morfologia das microestruturas dos revestimentos obtidos foi realizada por microscopia óptica, MEV e EDS. A análise quantitativa das imagens de MEV e microscopia ótica foi auxiliada por modelos de machine learning de árvore de decisão e floresta aleatória. Além disso, em paralelo às análises dos revestimentos, foi usado o equipamento DPV 2000 *particle diagnostics system™* para estudar os efeitos dos parâmetros do arco na zona de transferência. A metodologia experimental aplicada para análise dos revestimentos foi a do método robusto de Taguchi usando um arranjo ortogonal L8 adaptado. Os fatores de controle selecionados para avaliação foram a polaridade do arame de alumínio, corrente de aspersão, tensão, pré-aquecimento e distância de aspersão. Os fatores de resposta analisados foram a fração em área de porosidade, óxidos, mistura dos dois materiais para o revestimento e velocidade, temperatura e diâmetro das partículas para análise da zona de transferência. Com esses procedimentos, foi constatada a viabilidade do uso de machine learning para análises de revestimentos obtidos por aspersão térmica, sendo que o modelo de floresta aleatória obtido por Python™ apresentou uma pontuação f1 de classificação de 0,990. Através das técnicas aplicadas foi observado formação de liga, compostos intermetálicos e eutético nas interfaces de alumínio/cobre nos contornos das panquecas de material. Os revestimentos apresentaram porosidade, óxidos e mistura em fração de área de 8,06%, 11,53% e 16,46%, respectivamente. Entre os parâmetros analisados concluiu-se que a polaridade dos arames possuiu a maior influência sobre os fatores de resposta, sendo o mais influente sobre os valores de porosidade e óxidos dos revestimentos e sobre os valores de velocidade, temperatura e diâmetro das partículas. Enquanto a distância de aspersão se revelou o fator mais importante para a formação de mistura.

Palavras-chaves: Aspersão Térmica. *Machine Learning*. Formação de Liga. ASP dissimilar.

ABSTRACT

The analysis of thermal spray coatings is not always straightforward, in cases where the microstructure is complex, such as those obtained by dissimilar ASP, the presence of several phases and mixtures thereof makes it difficult to use the classical thresholding technique to evaluate the coating through images. Thus, this study aims to evaluate the feasibility of using machine learning techniques for the analysis of thermal spray coatings, seeking to improve the quality and automation of said analyses. For this purpose, coatings were deposited by dissimilar ASP using aluminum and a copper wires. The deposition of material was carried out on 50x75x1.5 mm aluminum sheets. The samples' microstructures composition and morphology analysis was performed by optical microscopy, SEM, and EDS. Quantitative analysis of MEV and optical microscopy images was aided by decision tree and random forest machine learning models. In addition, in parallel with the coatings' analysis, DPV 2000 particle diagnostics system™ equipment was used to study the arc parameter effects on the transfer zone. The experimental methodology applied was Taguchi's robust method using an adapted L8 orthogonal array. The selected control factors were the aluminum wire polarity, arc current and voltage, substrate preheating, and distance of deposition. The response factors analyzed were the content area of porosity, oxides, and a mixture of both materials for the coatings and velocity, temperature, and particle diameter for transfer zone analysis. With these procedures, it was verified the viability of using machine learning for analysis of coatings obtained by thermal spraying, with the random forest model obtained by Python[™] reaching an f1 classification score of 0.990. Through the applied techniques, alloy formation, intermetallic compounds, and eutectic were observed in the aluminum/copper interfaces in the materials lamellae contours. The coatings exhibited an area fraction of porosity, oxides, and a mixture of 8.06%, 11.53%, and 16.46%, respectively. Among the analyzed parameters, it was concluded that the polarity of the wires had the greatest influence on the response factors, being the most influential on the coating values of porosity and oxides on the particle values of velocity, temperature, and diameter. Meanwhile, the spray distance proved to be the most important factor in the mixture formation.

Key-words: Thermal Spray. Machine Learning. Alloy Formation. Dissimilar ASP.

LISTA DE ILUSTRAÇÕES

FIGURA	1 –	MICROESTRUTURA REQUERIDA PARA AUTO CURA	34
FIGURA	2 –	DIAGRAMA DE EQUILÍBRIO Al-Cu COM TODAS AS FASES	35
FIGURA	3 —	DIAGRAMA DE EQUILÍBRIO Al-Cu REGIÃO EUTÉTICA	36
FIGURA	4 —	DADOS DE DIFERENTES FASES PRESENTES EM LIGAS DE	
		Al-Cu	37
FIGURA	5 —	DIAGRAMA SIMPLIFICADO DO PROCESSO DE ASPERSÃO	
		ΤÉRMICA	38
FIGURA	6 —	CONCEITO DA PISTOLA USADA NO ASP	39
FIGURA	7 —	EFEITO DE CROSS-FIRE DO ASP NAS PROPRIEDADES DA	
		SEÇÃO DO REVESTIMENTO	40
FIGURA	8 -	MOVIMENTO DE CARGAS NOS ARAMES NO ASP	41
FIGURA	9 —	MECANISMO DE ADESÃO DO REVESTIMENTO POR ARPER-	
		SÃO TÉRMICA MECHANICAL INTERLOCKING	45
FIGURA	10 –	CARACTERÍSTICAS MORFOLOGICAS DE REVESTIMENTOS	
		POR ASPERSÃO TÉRMICA	46
FIGURA	11 –	MICROESTRUTURA OBSERVADA NA SEÇÃO DE REVESTI-	
		MENTO OBTIDO POR ASPERSÃO TÉRMICA	47
FIGURA	12 –	ZONAS DE FORMAÇÃO DE ÓXIDOS NO ASP	48
FIGURA	13 –	CICLO TÉRMICO NOS PROCESSOS DE ASPERSÃO TÉRMICA	49
FIGURA	14 –	REVESTIMENTO OBTIDO POR DEPOSIÇÃO DISSIMILAR AI-Cu	
		POR CHAMA PÓ DE LIGA EUTÉTICA(33,2% Cu) COM PANQUE-	
		CAS DE HIPO E HIPER-EUTÉTICO	50
FIGURA	15 —	REVESTIMENTO OBTIDO POR DEPOSIÇÃO DISSIMILAR DE AI-	
		Cu POR ARCO ELÉTRICO COM EUTÉTICO ENTRE PANQUECAS	51
FIGURA	16 —	DIAGRAMA SIMPLIFICADO DA METODOLOGIA DE TAGUCHI .	53
FIGURA	17 –	HISTOGRAMA DE TONS DE CINZA E FUNÇÃO DE DENSIDADE	
		DE PROBABILIDADE DE DIFERENTES FASES DO AÇO	55
FIGURA	18 –	HISTOGRAMAS DE TONS DE CINZA PARA IMAGENS DE MEV	
		PARA REVESTIMENTO DE AI-Cu POR ARCO ELÉTRICO DISSI-	
		MILAR	56
FIGURA	19 —	CLASSIFICAÇÃO POR MACHINE LEARNING POR MODELO	
		DE FLORESTA ALEATÓRIA COM 200 ÁRVORES DE REVESTI-	
		MENTO DE AI-Cu POR ASP DISSIMILAR	57
FIGURA	20 –	EXEMPLO SIMPLES DE ÁRVORE DE DECISÃO	59
FIGURA	21 –	EXEMPLO DE OVER-FITTING EM POLINÔMIOS	60

 FIGURA 23 – EXEMPLO DE EQUALIZAÇÃO DE HISTOGRAMA FIGURA 24 – DEMONSTRAÇÃO DO MÉTODO DE EQUALIZAÇÃO DE HISTOGRAMA PARA AUMENTO DE CONTRASTE EM UMA IMAGEI DE MEV DE UM REVESTIMENTO FIGURA 25 – EXEMPLO DE QUANTIFICAÇÃO DE IGUAL PROBABILIDADE FIGURA 26 – DEMONSTRAÇÃO DO MÉTODO DE QUANTIZAÇÃO DE UI REVESTIMENTO DE 256 PARA 32 NIVEIS FIGURA 27 – DEMONSTRAÇÃO DO MÉTODO DE <i>PADDING</i> POR REFLEXÃI PARA ANÁLISE DAS CARACTERÍSTICAS DE HARALICK FIGURA 28 – EQUIPAMENTO SULZER-METCO VALUE ARC 300E DE ASPEIS SÃO TÉRMICA ASP UTILIZADO FIGURA 29 – CONFIGURAÇÃO DPV™ E PISTOLA DE ASPERSÃO PARA MI DIÇÃO DAS PARTÍCULAS FIGURA 30 – PASES USADOS NO ASP DISSIMILAR FIGURA 31 – FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 – IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MORFOLOGIA FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFERENTES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRISENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OU TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGI TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGE 	. 67 . 68 . 71 . 72 . 73 . 73 . 79 . 80 . 84
 FIGURA 24 – DEMONSTRAÇÃO DO MÉTODO DE EQUALIZAÇÃO DE HISTO GRAMA PARA AUMENTO DE CONTRASTE EM UMA IMAGEI DE MEV DE UM REVESTIMENTO FIGURA 25 – EXEMPLO DE QUANTIFICAÇÃO DE IGUAL PROBABILIDADE FIGURA 26 – DEMONSTRAÇÃO DO MÉTODO DE QUANTIZAÇÃO DE UI REVESTIMENTO DE 256 PARA 32 NIVEIS FIGURA 27 – DEMONSTRAÇÃO DO MÉTODO DE <i>PADDING</i> POR REFLEXÃO PARA ANÁLISE DAS CARACTERÍSTICAS DE HARALICK FIGURA 28 – EQUIPAMENTO SULZER-METCO VALUE ARC 300E DE ASPEI SÃO TÉRMICA ASP UTILIZADO FIGURA 29 – CONFIGURAÇÃO DPV™ E PISTOLA DE ASPERSÃO PARA MI DIÇÃO DAS PARTÍCULAS FIGURA 30 – PASSES USADOS NO ASP DISSIMILAR FIGURA 31 – FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 – IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOF FOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREI TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OU TIDA PELO MODELO "<i>FAST RANDOM FOREST</i>" DO <i>PLUGI TRAINABLE WEKA SEGMENTATION</i> DO <i>SOFTWARE</i> IMAGE 	- 1 . 68 . 71 1 . 72 . 73 - . 79 - . 80 . 84
GRAMA PARA AUMENTO DE CONTRASTE EM UMA IMAGEI DE MEV DE UM REVESTIMENTO FIGURA 25 – EXEMPLO DE QUANTIFICAÇÃO DE IGUAL PROBABILIDADE FIGURA 26 – DEMONSTRAÇÃO DO MÉTODO DE QUANTIZAÇÃO DE UI REVESTIMENTO DE 256 PARA 32 NIVEIS FIGURA 27 – DEMONSTRAÇÃO DO MÉTODO DE PADDING POR REFLEXÃU PARA ANÁLISE DAS CARACTERÍSTICAS DE HARALICK FIGURA 28 – EQUIPAMENTO SULZER-METCO VALUE ARC 300E DE ASPEI SÃO TÉRMICA ASP UTILIZADO FIGURA 29 – CONFIGURAÇÃO DPV™ E PISTOLA DE ASPERSÃO PARA MI DIÇÃO DAS PARTÍCULAS FIGURA 30 – PASSES USADOS NO ASP DISSIMILAR FIGURA 31 – FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 – IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOF FOLOGIA FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREN TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREN TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OU TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGI TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGE	1 . 68 . 71 1 . 72 . 73 - . 79 - . 80 . 84
 DE MEV DE UM REVESTIMENTO FIGURA 25 – EXEMPLO DE QUANTIFICAÇÃO DE IGUAL PROBABILIDADE FIGURA 26 – DEMONSTRAÇÃO DO MÉTODO DE QUANTIZAÇÃO DE UN REVESTIMENTO DE 256 PARA 32 NIVEIS FIGURA 27 – DEMONSTRAÇÃO DO MÉTODO DE <i>PADDING</i> POR REFLEXÃO PARA ANÁLISE DAS CARACTERÍSTICAS DE HARALICK FIGURA 28 – EQUIPAMENTO SULZER-METCO VALUE ARC 300E DE ASPEFI SÃO TÉRMICA ASP UTILIZADO FIGURA 29 – CONFIGURAÇÃO DPV™ E PISTOLA DE ASPERSÃO PARA MI DIÇÃO DAS PARTÍCULAS FIGURA 30 – PASSES USADOS NO ASP DISSIMILAR FIGURA 31 – FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 – IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOF FOLOGIA FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREN TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRI SENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OR TIDA PELO MODELO "<i>FAST RANDOM FOREST</i>" DO <i>PLUGI TRAINABLE WEKA SEGMENTATION</i> DO <i>SOFTWARE</i> IMAGEM 	. 68 . 71 . 72 . 73 . 73 . 79 . 80 . 84
 FIGURA 25 – EXEMPLO DE QUANTIFICAÇÃO DE IGUAL PROBABILIDADE FIGURA 26 – DEMONSTRAÇÃO DO MÉTODO DE QUANTIZAÇÃO DE UI REVESTIMENTO DE 256 PARA 32 NIVEIS FIGURA 27 – DEMONSTRAÇÃO DO MÉTODO DE <i>PADDING</i> POR REFLEXÃI PARA ANÁLISE DAS CARACTERÍSTICAS DE HARALICK FIGURA 28 – EQUIPAMENTO SULZER-METCO VALUE ARC 300E DE ASPEFI SÃO TÉRMICA ASP UTILIZADO FIGURA 29 – CONFIGURAÇÃO DPV™ E PISTOLA DE ASPERSÃO PARA MI DIÇÃO DAS PARTÍCULAS FIGURA 30 – PASSES USADOS NO ASP DISSIMILAR FIGURA 31 – FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 – IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOF FOLOGIA FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREN TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRI SENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OR TIDA PELO MODELO "<i>FAST RANDOM FOREST</i>" DO <i>PLUGI TRAINABLE WEKA SEGMENTATION</i> DO <i>SOFTWARE</i> IMAGEM 	. 71 1 . 72) . 73 - . 79 - . 80 . 84
 FIGURA 26 - DEMONSTRAÇÃO DO MÉTODO DE QUANTIZAÇÃO DE UN REVESTIMENTO DE 256 PARA 32 NIVEIS FIGURA 27 - DEMONSTRAÇÃO DO MÉTODO DE <i>PADDING</i> POR REFLEXÃO PARA ANÁLISE DAS CARACTERÍSTICAS DE HARALICK FIGURA 28 - EQUIPAMENTO SULZER-METCO VALUE ARC 300E DE ASPEFI SÃO TÉRMICA ASP UTILIZADO FIGURA 29 - CONFIGURAÇÃO DPV™ E PISTOLA DE ASPERSÃO PARA MI DIÇÃO DAS PARTÍCULAS FIGURA 30 - PASSES USADOS NO ASP DISSIMILAR FIGURA 31 - FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 - IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOF FOLOGIA FIGURA 33 - IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREN TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 - IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRI SENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 - MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 - EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 38 - CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OR TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGI TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGE 	1 72) 73 - 73 - 79 - 80 . 84
 REVESTIMENTO DE 256 PARA 32 NIVEIS FIGURA 27 - DEMONSTRAÇÃO DO MÉTODO DE <i>PADDING</i> POR REFLEXÃO PARA ANÁLISE DAS CARACTERÍSTICAS DE HARALICK FIGURA 28 - EQUIPAMENTO SULZER-METCO VALUE ARC 300E DE ASPER SÃO TÉRMICA ASP UTILIZADO FIGURA 29 - CONFIGURAÇÃO DPV™ E PISTOLA DE ASPERSÃO PARA MI DIÇÃO DAS PARTÍCULAS FIGURA 30 - PASSES USADOS NO ASP DISSIMILAR FIGURA 31 - FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 - IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOR FOLOGIA FIGURA 33 - IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREN TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 - IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRI SENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 - MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 37 - ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 - CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OI TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGI TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGE 	. 72 . 73 79 80 . 84
 FIGURA 27 – DEMONSTRAÇÃO DO MÉTODO DE <i>PADDING</i> POR REFLEXÃ PARA ANÁLISE DAS CARACTERÍSTICAS DE HARALICK FIGURA 28 – EQUIPAMENTO SULZER-METCO VALUE ARC 300E DE ASPEF SÃO TÉRMICA ASP UTILIZADO) - 73 - 79 - 80 . 84
 PARA ANÁLISE DAS CARACTERÍSTICAS DE HARALICK FIGURA 28 – EQUIPAMENTO SULZER-METCO VALUE ARC 300E DE ASPEF SÃO TÉRMICA ASP UTILIZADO	. 73 - 79 - 80 . 84
 FIGURA 28 – EQUIPAMENTO SULZER-METCO VALUE ARC 300E DE ASPEF SÃO TÉRMICA ASP UTILIZADO FIGURA 29 – CONFIGURAÇÃO DPV™ E PISTOLA DE ASPERSÃO PARA MI DIÇÃO DAS PARTÍCULAS FIGURA 30 – PASSES USADOS NO ASP DISSIMILAR FIGURA 31 – FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 – IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOF FOLOGIA FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREI TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRI SENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OF TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGI TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGE 	- . 79 - . 80 . 84
 SÃO TÉRMICA ASP UTILIZADO FIGURA 29 - CONFIGURAÇÃO DPV™ E PISTOLA DE ASPERSÃO PARA MI DIÇÃO DAS PARTÍCULAS FIGURA 30 - PASSES USADOS NO ASP DISSIMILAR FIGURA 31 - FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 - IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOR FOLOGIA FIGURA 33 - IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREN TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 - IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRI SENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 - MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 - EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 - ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 - CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OR TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGI TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGE 	. 79 - . 80 . 84
 FIGURA 29 – CONFIGURAÇÃO DPV™ E PISTOLA DE ASPERSÃO PARA MI DIÇÃO DAS PARTÍCULAS FIGURA 30 – PASSES USADOS NO ASP DISSIMILAR FIGURA 31 – FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 – IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOF FOLOGIA FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREN TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRI SENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OF TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGI TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGE 	- . 80 . 84
DIÇÃO DAS PARTÍCULAS	. 80 . 84
 FIGURA 30 – PASSES USADOS NO ASP DISSIMILAR FIGURA 31 – FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 – IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOF FOLOGIA FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREN TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRI SENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OF TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGI TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGE 	. 84
 FIGURA 31 – FLUXOGRAMA DOS EXPERIMENTOS FIGURA 32 – IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOR FOLOGIA FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFEREN TES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRI SENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OF TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGIA TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGEM 	
 FIGURA 32 – IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOS TRANDO AS DIFERENTES FASES PRESENTES E SUA MOR FOLOGIA FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFERENTES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRI SENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OR TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGIA TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGEM 	. 85
TRANDO AS DIFERENTES FASES PRESENTES E SUA MOR FOLOGIA	-
 FOLOGIA FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFERENTES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRESENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OB TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGI TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGE 	-
 FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFERENTES FASES PRESENTES E SUA MORFOLOGIA FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRESENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OB TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGINA TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGES 	. 95
TES FASES PRESENTES E SUA MORFOLOGIA	-
 FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRESENÇA E MORFOLOGIA DO EUTÉTICO	. 96
SENÇA E MORFOLOGIA DO EUTÉTICO FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5 FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OB TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGI TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGES	-
 FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5 FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5	. 97
FIGURA 36 – EDS EM LINHA OBTIDO DA AMOSTRA 5	. 98
FIGURA 37 – ESPECTRO EDS EM PONTO OBTIDO DA AMOSTRA 5 FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OB TIDA PELO MODELO " <i>FAST RANDOM FOREST</i> " DO <i>PLUGI</i> <i>TRAINABLE WEKA SEGMENTATION</i> DO <i>SOFTWARE</i> IMAGE	. 100
FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA O TIDA PELO MODELO " <i>FAST RANDOM FOREST</i> " DO <i>PLUGI</i> <i>TRAINABLE WEKA SEGMENTATION</i> DO <i>SOFTWARE</i> IMAGE	. 101
TIDA PELO MODELO "FAST RANDOM FOREST" DO PLUGI TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGE	-
TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGE	
	/
FIGURA 39 - VARIAÇÃO DO COEFICIENTE DE VARIAÇÃO EM RELAÇÃO	<i>I</i> 104
AO TAMANHO DE JANELA PARA AS CARACTERÍSTICAS D	/ 104)
HARALICK DE CONTRASTE E MOMENTO INVERSO	/ 104) :
FIGURA 40 – DESEMPENHO MÉDIO ENTRE AS 5 DOBRAS DA SEGUND	/ 104) : . 105
BUSCA EM GRADE COM VALIDAÇÃO CRUZADA DO MODEL	/ 104) : . 105
FLORESTA ALEATÓRIA PELA QUANTIDADE DE ÁRVORES AV	/ 104) : . 105 (
LIADAS	/ 104) . 105 \) -

FIGURA 41 – TEMPO DE TREINAMENTO DO MODELO FLORESTA ALEATÓ- BIA PELA QUANTIDADE DE ÁRVORES AVALIADAS	109
FIGURA 42 – CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 3 PELO	100
BLIOTECAS	112
FIGURA 43 – <i>BOXPLOT</i> DA FRAÇÃO EM ÁREA DE POROSIDADE(%) DOS REVESTIMENTOS	113
FIGURA 44 – <i>BOXPLOT</i> DA FRAÇÃO EM ÁREA DE ÓXIDOS(%) DOS REVES- TIMENTOS	113
FIGURA 45 – <i>BOXPLOT</i> DA FRAÇÃO EM ÁREA DE MISTURA(%) DOS RE-	112
FIGURA 46 – TESTE DE NORMALIDADE DA FRAÇÃO EM ÁREA DE POROSI- DADE(%) DOS REVESTIMENTOS OBTIDOS PARA TODAS AS	110
FIGURA 47 – TESTE DE NORMALIDADE DA FRAÇÃO EM ÁREA DE ÓXI- DOS(%) DOS REVESTIMENTOS OBTIDOS PARA TODAS AS	114
MEDIÇÕES	115
MEDIÇÕES	115
FIGURA 49 – GRAFICOS DE EFEITOS PRINCIPAIS SOBRE A FRAÇAO EM ÁREA MÉDIA DE POROSIDADE(%) DOS REVESTIMENTOS	118
FIGURA 50 – GRÁFICOS DE EFEITOS PRINCIPAIS SOBRE A FRAÇÃO EM ÁREA MÉDIA DE ÓXIDOS(%) DOS REVESTIMENTOS	121
FIGURA 51 – GRÁFICOS DE EFEITOS PRINCIPAIS SOBRE A FRAÇÃO EM ÁREA MÉDIA DE MISTURA(%) DOS REVESTIMENTOS	123
FIGURA 52 – HISTOGRAMA DA VELOCIDADE(m/s) AVALIADA PELO DPV	106
FIGURA 53 – HISTOGRAMA DA TEMPERATURA(℃) AVALIADA POR DPV	120
FIGURA 54 – HISTOGRAMA DO DIÂMETRO(μm) AVALIADO PELO DPV DAS	126
PARTICULAS OBTIDAS NO EXPERIMENTO 8	127
PARTÍCULAS OBTIDAS EM TODOS OS EXPERIMENTOS FIGURA 56 – <i>BOXPLOT</i> DA TEMPERATURA(℃) AVALIADA PELO DPV DAS	128
PARTÍCULAS OBTIDAS EM TODOS OS EXPERIMENTOS	128
TÍCULAS OBTIDAS EM TODOS OS EXPERIMENTOS	129

FIGURA	58 –	TESTE DE NORMALIDADE DA VELOCIDADE(m/s) AVALIADA	
		PELO DPV DAS PARTÍCULAS OBTIDAS EM TODOS OS EXPE-	
		RIMENTOS	129
FIGURA	59 –	TESTE DE NORMALIDADE DA TEMPERATURA(°C) AVALIADA	
		PELO DPV DAS PARTÍCULAS OBTIDAS EM TODOS OS EXPE-	
		RIMENTOS	130
FIGURA	60 -	TESTE DE NORMALIDADE DO DIÂMETRO(µm) AVALIADO	
		PELO DPV DAS PARTÍCULAS OBTIDAS EM TODOS OS EXPE-	
		RIMENTOS	130
FIGURA	61 –	GRÁFICOS DE EFEITOS PRINCIPAIS SOBRE A VELOCIDADE	
		MÉDIA DAS PARTÍCULAS	133
FIGURA	62 –	GRÁFICOS DE EFEITOS PRINCIPAIS SOBRE A TEMPERATURA	
		MÉDIA DAS PARTÍCULAS	136
FIGURA	63 –	GRÁFICOS DE EFEITOS PRINCIPAIS SOBRE O DIÂMETRO	
		MÉDIO DAS PARTÍCULAS	139
	64		
FIGURA	64 –	TIDO NA AMOSTRA 1	160
	65		100
FIGUNA	05 -		160
	66		100
IIGUNA	00 -	TIDO NA AMOSTRA 3	160
FIGURA	67 -		100
IIGUIIA	07		160
FIGURA	68 -		100
	00		161
FIGURA	69 -		101
	00	TIDO NA AMOSTRA 6	161
FIGURA	70 –	IMAGEM DE MICROSCÓPIO ÓTICO DO REVESTIMENTO OB-	
			161
FIGURA	71 –	IMAGEM DE MICROSCÓPIO ÓTICO DO REVESTIMENTO OB-	
			162
FIGURA	72 –	IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 1	163
FIGURA	73 –	IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 2	163
FIGURA	74 –	IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 3	164
FIGURA	75 –	IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 4	164
FIGURA	76 –	IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 5	165
FIGURA	77 –	IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 6	165
FIGURA	78 –	IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 7	166

FIGURA 79 – IMAGEM MEV-BSE DO REVESTIMENTO DA	AMOSTRA 8	166
FIGURA 80 – CLASSIFICAÇÃO DA IMAGEM DE MICROS AMOSTRA 1 OBTIDA PELO MODELO "FA REST" DO PLUGIN TRAINABLE WEKA SEC	COPIA OTICA DA <i>ST RANDOM FO-</i> <i>GMENTATION</i> DO	167
FIGURA 81 – CLASSIFICAÇÃO DA IMAGEM DE MICROS AMOSTRA 2 OBTIDA PELO MODELO "FA REST" DO PLUGIN TRAINABLE WEKA SEC SOFTWARE IMAGEJ	COPIA OTICA DA ST RANDOM FO- GMENTATION DO	167
FIGURA 82 – CLASSIFICAÇÃO DA IMAGEM DE MICROS AMOSTRA 3 OBTIDA PELO MODELO "FA REST" DO PLUGIN TRAINABLE WEKA SEC	COPIA OTICA DA ST RANDOM FO- GMENTATION DO	100
FIGURA 83 – CLASSIFICAÇÃO DA IMAGEM DE MICROS AMOSTRA 4 OBTIDA PELO MODELO "FA REST" DO PLUGIN TRAINABLE WEKA SEG SOFTWARE IMAGE.I	COPIA OTICA DA ST RANDOM FO- GMENTATION DO	168
FIGURA 84 – CLASSIFICAÇÃO DA IMAGEM DE MICROS AMOSTRA 5 OBTIDA PELO MODELO "FA REST" DO PLUGIN TRAINABLE WEKA SEG	COPIA OTICA DA ST RANDOM FO- GMENTATION DO	
FIGURA 85 – CLASSIFICAÇÃO DA IMAGEM DE MICROS AMOSTRA 6 OBTIDA PELO MODELO "FA REST" DO PLUGIN TRAINABLE WEKA SEC SOFTWARE IMAGE.	COPIA OTICA DA ST RANDOM FO- GMENTATION DO	169
FIGURA 86 – CLASSIFICAÇÃO DA IMAGEM DE MICROS AMOSTRA 7 OBTIDA PELO MODELO "FA REST" DO PLUGIN TRAINABLE WEKA SEG	COPIA OTICA DA ST RANDOM FO- GMENTATION DO	170
FIGURA 87 – CLASSIFICAÇÃO DA IMAGEM DE MICROS AMOSTRA 8 OBTIDA PELO MODELO "FA REST" DO PLUGIN TRAINABLE WEKA SEC SOFTWARE IMAGEJ	COPIA OTICA DA ST RANDOM FO- GMENTATION DO	170
FIGURA 88 – CLASSIFICAÇÃO DA IMAGEM DE MEV DA A MODELO FLORESTA ALEATÓRIA POR PYTH BLIOTECAS	MOSTRA 1 PELO HON™ E SUAS BI-	171

FIGURA 89	– CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 2 PELO	
	MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BI-	
	BLIOTECAS	172
FIGURA 90	- CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 3 PELO	
	MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BI-	
	BLIOTECAS	172
FIGURA 91	- CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 4 PELO	
	MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BI-	
	BLIOTECAS	173
FIGURA 92	- CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 5 PELO	
	MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BI-	
	BLIOTECAS	173
FIGURA 93	- CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 6 PELO	
	MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BI-	
	BLIOTECAS	174
FIGURA 94	– CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 7 PELO	
	MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BI-	
	BLIOTECAS	174
FIGURA 95	- CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 8 PELO	
	MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BI-	
	BLIOTECAS	175

LISTA DE QUADROS

QUADRO 1 -	EXEMPLO DE MATRIZ DE CONFUSÃO PARA DUAS CLASSES	64
QUADRO 2 -	CARACTERÍSTICAS ESTATÍSTICAS TEXTURAIS DE SEGUNDO	
	GRAU DE HARALICK	75
QUADRO 3 –	FATORES DE CONTROLE PARA ANÁLISE DE TAGUCHI	81
QUADRO 4 -	FATORES DE RESPOSTA PARA ANÁLISE DE TAGUCHI	81
QUADRO 5 –	VALORES DOS NÍVEIS DOS FATORES DE CONTROLE OBTI-	
	DOS EXPERIMENTALMENTE DO ARRANJO ORTOGONAL DE	
	TAGUCHI L8 ADAPTADO	82
QUADRO 6 -	SEPARAÇÃO EM CATEGORIAS DOS FILTROS E CARACTE-	
	RÍSTICAS USADAS PARA TREINO DO MODELO DE MACHINE	
	LEARNING	89
QUADRO 7 -	PARÂMETROS USADOS PARA CÁLCULO DOS DIFERENTES	
	FILTROS USADOS PARA TREINO DO MODELO DE MACHINE	
	LEARNING	90
QUADRO 8 -	RESUMO DOS HIPER-PARÂMETROS AVALIADOS PARA O MO-	
	DELO DE ÁRVORE DE DECISÃO PELA TÉCNICA DE BUSCA	
	EM GRADE COM VALIDAÇÃO CRUZADA COM 5 DOBRAS	91
QUADRO 9 -	RESUMO DOS HIPER-PARÂMETROS AVALIADOS PARA O	
	MODELO DE FLORESTA ALEATÓRIA PELA PELA PRIMEIRA	
	BUSCA EM GRADE COM VALIDAÇÃO CRUZADA COM 5 DOBRAS	91
QUADRO 10-	-RESUMO DOS HIPER-PARÂMETROS AVALIADOS PARA O	
	MODELO DE FLORESTA ALEATÓRIA PELA PELA PRIMEIRA	
	BUSCA EM GRADE COM VALIDAÇÃO CRUZADA COM 5 DOBRAS	92
QUADRO 11 -	- HIPER-PARÂMETROS SELECIONADOS PARA O MODELO DE	
	ÁRVORE DE DECISÃO PELA TÉCNICA DE BUSCA EM GRADE	
	COM VALIDAÇÃO CRUZADA COM 5 DOBRAS	107
QUADRO 12-	- HIPER-PARÂMETROS SELECIONADOS PARA O MODELO DE	
	FLORESTA ALEATÓRIA PELA PRIMEIRA BUSCA EM GRADE	
	COM VALIDAÇÃO CRUZADA COM 5 DOBRAS	107
QUADRO 13-	- HIPER-PARÂMETROS SELECIONADOS PARA O MODELO DE	
	FLORESTA ALEATÓRIA PELA SEGUNDA BUSCA EM GRADE	
	COM VALIDAÇÃO CRUZADA COM 5 DOBRAS	109
QUADRO 14-	- HIPÓTESES PARA O EFEITO DE CADA FATOR DE CONTROLE	
	DO ARRANJO ORTOGONAL L8 DE TAGUCHI ADAPTADO PARA	
	6 FATORES	116

QUADRO 15-HIPÓTESES PARA O EFEITO DE CADA FATOR DE CONTROLE	
DO ARRANJO ORTOGONAL L8 DE TAGUCHI ADAPTADO PARA	
4 FATORES	131

LISTA DE TABELAS

TABELA 1 – I TABELA 2 – I	DADOS DA LIGA DO SUBSTRATO DOS CORPOS DE PROVA . EXPERIMENTOS DO ARRANJO ORTOGONAL L8 DE TAGUCHI ADAPTADO PARA 6 PARÂMETROS PARA ANÁLISE DOS RE-	78
TABELA 3 – I	VESTIMENTOS	82
/	ADAPTADO PARA 4 PARÂMETROS PARA ANÁLISE POR DPV™	83
TABELA 4 – I	RUGOSIDADE OBTIDA NOS SUBSTRATOS POR JATEAMENTO DE ABRASIVO DE ALUMINA RECLICLADO DE 30 MESH	94
TABELA 5 – 1	NÚMERO DE INSTÂNCIAS USADAS NO TREINO E TESTE DO MODELO <i>FAST RANDOM FOREST</i> USANDO O <i>PLUGIN TRAI</i> -	100
TABELA 6 – I	MABLE WERA SEGMENTATION DO SOFTWARE IMAGEJ MEDIDAS DE AVALIAÇÃO E PONTUAÇÃO DO MODELO "FAST	102
TABELA 7 – M	RANDOM FOREST" NOS DADOS DE TREINOMEDIDAS DE AVALIAÇÃO E PONTUAÇÃO DO MODELO "FAST	102
TABELA 8 – I	RANDOM FOREST" NOS DADOS DE TESTE	103
(TARELA 9 - 1	CONSIDERADAS PARA TREINO	106
	MODELOS DE ÁRVORE DE DECISÃO E FLORESTA ALEATÓRIA	
TABELA 10 – I	USANDO PYTHON™ E SUAS BIBLIOTECAS	110
		110
IABELA 11 – ľ	ÁRVORE DE DECISÃO DA BIBLIOTACA <i>SCIKIT-LEARN</i> NOS	
TABELA 12-1	DADOS DE TESTE	111
F	RESTA ALEATÓRIA DA BIBLIOTACA <i>SCIKIT-LEARN</i> NOS DA- DOS DE TREINO	111
TABELA 13 – I	MEDIDAS DE AVALIAÇÃO E PONTUAÇÃO DO MODELO FLO- RESTA ALEATÓRIA DA BIBLIOTACA <i>SCIKIT-LEARN</i> NOS DA-	
[111
IABELA 14 – /	ANALISE DE VARIANCIA DA FRAÇAO EM AREA DE POROSI- DADE DOS REVESTIMENTOS EM RELAÇÃO AOS PARÂME-	
7	TROS DE DEPOSIÇÃO	117

TABELA 15 – ANÁLISE DE VARIÂNCIA POR PERMUTAÇÃO DA FRAÇÃO EM ÁREA DA POROSIDADE DOS REVESTIMENTOS EM RELAÇÃO	
	117
TABELA 16 – BANQUE DE INFLUÊNCIA DOS FATORES PARA A ERAÇÃO EM	
ÁREA MÉDIA DE POROSIDADE(%) NOS REVESTIMENTOS	118
TABELA 17 – TESTE DE COMPABAÇÃO TUKEY COM 90% DE CONFIANÇA	
PARA POROSIDADE	119
TABELA 18 – ANÁLISE DE VARIÂNCIA DA FRAÇÃO EM ÁREA DE ÓXIDOS	
DOS REVESTIMENTOS EM RELAÇÃO AOS PARÂMETROS DE	
	119
TABELA 19 – ANÁLISE DE VARIÂNCIA POR PERMUTAÇÃO DA FRAÇÃO EM	
ÁREA DE ÓXIDOS DOS REVESTIMENTOS EM RELAÇÃO AOS	
PARÂMETROS DE DEPOSIÇÃO	120
TABELA 20 - RANQUE DE INFLUÊNCIA DOS FATORES PARA A FRAÇÃO EM	
ÁREA MÉDIA DE ÓXIDOS(%) NOS REVESTIMENTOS	120
TABELA 21 – TESTE DE COMPARAÇÃO TUKEY COM 90% DE CONFIANÇA	
PARA ÓXIDOS	121
TABELA 22 – ANÁLISE DE VARIÂNCIA DA FRAÇÃO EM ÁREA DA MISTURA	
DOS REVESTIMENTOS EM RELAÇÃO AOS PARÂMETROS DE	
DEPOSIÇÃO	122
TABELA 23 – ANÁLISE DE VARIÂNCIA POR PERMUTAÇÃO DA FRAÇÃO EM	
ÁREA DA MISTURA NOS REVESTIMENTOS EM RELAÇÃO AOS	
PARÂMETROS DE DEPOSIÇÃO	122
TABELA 24 – RANQUE DE INFLUÊNCIA DOS FATORES PARA A FRAÇÃO EM	
ÁREA MÉDIA DE MISTURA(%) NOS REVESTIMENTOS	123
TABELA 25 – TESTE DE COMPARAÇÃO TUKEY COM 90% DE CONFIANÇA	
	124
TABELA 26 – DADOS SELECIONADOS PARA OTIMIZAÇÃO DAS PROPRIEDA-	
	125
TABELA 27 – ANÁLISE DE VARIÁNCIA PARA VELOCIDADE DAS PARTÍCULAS	
	132
TABELA 28 – ANÁLISE DE VARIÁNCIA POR PERMUTAÇÃO PARA VELOCI-	
DADE DAS PARTÍCULAS EM RELAÇÃO AOS PARÂMETROS DE	
	132
TABELA 29 – RANQUE DE INFLUENCIA DOS FATORES PARA VELOCIDADE	
MEDIA DAS PARTICULAS (m/s)	132
TABELA 30 – TESTE DE COMPARAÇÃO TUKEY COM 95% DE CONFIANÇA	
PARA VELOCIDADE	134

TABELA 31 – ANÁLISE DE VARIÂNCIA DA TEMPERATURA DAS PARTÍCULAS	
EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO	135
TABELA 32 – ANÁLISE DE VARIÂNCIA POR PERMUTAÇÃO DA TEMPERA-	
TURA DAS PARTÍCULAS EM RELAÇÃO AOS PARÂMETROS DE	
DEPOSIÇÃO	135
TABELA 33 – RANQUE DE INFLUÊNCIA DOS FATORES PARA TEMPERA-	
TURA MÉDIA DAS PARTÍCULAS(℃)	135
TABELA 34 – TESTE DE COMPARAÇÃO TUKEY COM 95% DE CONFIANÇA	
PARA TEMPERATURA	137
TABELA 35 – ANÁLISE DE VARIÁNCIA DO DIÁMETRO DAS PARTÍCULAS EM	
	138
TABELA 36 – ANALISE DE VARIANCIA POR PERMUTAÇÃO DO DIAMETRO	
DAS PARTICULAS EM RELAÇÃO AOS PARAMETROS DE DE-	
	138
TABELA 37 – RANQUE DE INFLUENCIA DOS FATORES PARA DIAMETRO	
	139
TABELA 38 – TESTE DE COMPARAÇÃO TUKEY COM 95% DE CONFIANÇA	
PARA DIAMETRO DAS PARTICULAS	140

LISTA DE ABREVIATURAS E DE SIGLAS

AD	A estatística de Anderson-Darling de qualidade de ajuste
ANOVA	Analysis of Variance
ASP	Arc Spray Process
AT	Aspersão Térmica
Aj.	Ajustado
BSE	Backscattered Electron
CART	Classification And Regression Tree
CME	Centro de Microscopia Eletrônica
DPV	DPV 2000 particle diagnostics system™
DRX	Difratometria de Raios-X
DesvPad	Desvio Padrão
EDS	Espectroscopia de Energia Dispersiva
GL	Graus de liberdade
GLCM	Gray Level Co-occurrence Matrix
LABATS	Laboratório de Aspersão Térmica e Soldagens Especiais
LE	Limite de Escoamento
LR	Limite de Resistência
MEV	Microscópio Eletrônico de Varredura
MQ	Média Quadrática
N°	Número
Р	Método de pontuação Precisão
PERMANOVA	Permutational Analysis of Variance
Pré.Aq	Pré-Aquecimento
R	Método de pontuação Recall

SMA	Shape Memory Alloy
SQ	Soma dos Quadrados
T.Amb	Temperatura Ambiente
UFPR	Universidade Federal do Paraná
f1	Método de pontuação f1

LISTA DE SÍMBOLOS

Θ	Ângulo de orientação para o filtro de Gabor
Al	Alumínio
A	Ampere
C	Carbono
cm	Centímetro
cm^3	Centímetro cúbico
Cu	Cobre
κ	Coeficiente de condutividade do filtro de difusão anisotrópica
α	Coeficiente de dilatação linear
cps/eV	Contagens por segundo por elétron-volt
γ	Controle da velocidade de difusão do filtro de difusão anisotrópica
$ ho_{Al}$	Densidade do alumínio
$ ho_{Cu}$	Densidade do cobre
ρ_{arame}	Densidade do material do arame
$ ho_l$	Densidade linear
$\sigma_{inferior}$	Desvio padrão inferior para cálculo do filtro de diferença de Gauss
σ_x	Desvio padrão na direção horizontal para cálculo do filtro de Gabor
σ_y	Desvio padrão na direção vertical para cálculo do filtro de Gabor
$\sigma_{espacial}$	Desvio padrão no espaço de coordenadas do filtro bilateral
σ_{cor}	Desvio padrão no espaço de cores do filtro bilateral
d_{arame}	Diâmetro do arame
d_{Al}	Diâmetro do arame de alumínio
d_{Cu}	Diâmetro do arame de cobre
ξ	Frequência espacial da função harmônica do filtro de Gabor

g	Gramas
$^{\circ}C$	Grau Celsius
1/°C	Grau Celsius reciproco
М	Grau do polinômio de ajuste
θ	Intermetálico de alumínio e cobre Al ₂ Cu
δ	Intermetálico de alumínio e cobre Al ₂ Cu ₃
ε_1	Intermetálico de alumínio e cobre Al ₂ Cu ₉
β_0	Intermetálico de alumínio e cobre Al ₃ Cu ₇
γ_0	Intermetálico de alumínio e cobre Al ₄ Cu ₉
γ_1	Intermetálico de alumínio e cobre Al ₄ Cu ₉
ζ_1	Intermetálico de alumínio e cobre Al ₉ Cu ₁₁
ζ_2	Intermetálico de alumínio e cobre Al ₉ Cu ₁₁
η_1	Intermetálico de alumínio e cobre AlCu
η_2	Intermetálico de alumínio e cobre AlCu
ε_2	Intermetálico de alumínio e cobre AlCu ₁₅
eta	Intermetálico de alumínio e cobre AlCu ₃
α_2	Intermetálico de alumínio e cobre AlCu ₄
θ'	Intermetálico metaestável de alumínio e cobre Al ₂ Cu
$\theta^{\prime\prime}$	Intermetálico metaestável de alumínio e cobre Al ₂ Cu
$Al_x Cu_y$	Intermetálicos de alumínio e cobre
K	Kelvin
psi	Libras por polegada quadrada
log_2	Logaritmo de base 2
Mg	Magnésio
±	Mais ou menos
TM	Marca registrada

I_G	Medida de impureza de Gini
I_E	Medida de impureza de entropia ou informação
MPa	Megapascal
m/s	Metros por segundo
H_{μ}	Micro dureza
μm	Micrômetros
mA	Miliamperes
mm	Milímetros
N_2	Nitrogênio gasoso
N_g	Número de níveis de cinza da imagem avaliada
m	Número total de classes
$\Omega \cdot mm^2/m$	Ohm milímetro quadrado por metro
0	Oxigênio
%	Porcentagem
R_t	Profundidade total da rugosidade
p_i	Proporção de dados da classe i
keV	Quilo elétron-volt
kcal/mol	Quilocaloria por mol
kg/mm^2	Quilograma força por metro quadrado
kg/h	Quilograma por hora
kV	Quilovolt
r_{kernel}	Raio do <i>Kernel</i> do filtro
sqrt	Raiz quadrada
σ_B	Resistência a tração
ρ	Resistividade elétrica
R_y	Rugosidade máxima

R_a	Rugosidade média
S	Segundos
c_{ij}	Valor da célula de posição i,j da matriz de confusão
π	Valor de pi
R^2	Valor de qui-quadrado
V	Volt
Zn	Zinco

SUMÁRIO

1	INTRODUÇÃO	28
2	JUSTIFICATIVA	30
3 3.1 3.2	OBJETIVOS	31 31 31
4	REVISÃO DE LITERATURA	33
4.1	Propriedade de auto-cura	33
4.2		34
4.2.1		35
4.2.1.1	Aspersão térmica	36 37
4.3.1	Processo por arco elétrico (ASP)	38
4.3.1.1	Deposição bimodal, híbrida ou dissimilar	39
4.3.1.2	Produção de partículas no ASP	40
4.3.1.3	Distribuição de partículas na zona de transferência no ASP	41
4.3.1.4	Parâmetros de controle para o ASP dissimilar	42
4.3.2	Processo de jateamento	44
4.3.3	Microestrutura de revestimentos de aspersão térmica	45
4.3.3.1	Porosidade	47
4.3.3.2	Óxidos	47
4.3.4	Ciclo térmico no revestimento durante o processo de aspersão	49
4.4	Estudos prévios na deposição de ligas de Al-Cu <i>in Situ</i>	50
4.5	l ecnicas de analise de formação de particulas em aspersão termica .	52
4.0 4.7	Avaliação de imagens por <i>machine learning</i>	52 54
4.7.1	Técnicas de segmentação de imagens	54
4.7.1.1	Técnica de threshold	55
4.7.1.2	Avaliação por <i>machine learning</i>	56
4.7.2	Modelo matemático e treino	58
4.7.2.1	O problema de <i>over-fitting</i>	59
4.7.2.2	Método de busca em grade	60
4.7.2.3	Método de validação cruzada com k dobras	62
4.7.3	Avaliação da capacidade do modelo	64
4.7.3.1	Matriz de confusão	64
4.7.3.2	Método de pontuação f1	64
4.7.4	Coleta de características para análise	66
4.7.4.1	Equalização de histograma	66
4.7.5	Avaliação de textura por características de Haralick	68

4.7.5.1	GLCM	68
4.7.5.2	Seleção de tamanho de janela	72
4.7.5.3	Características de Haralick	74
4.7.6	Seleção de características para treino	76
5	MATERIAIS E MÉTODOS	78
5.1	Materiais	78
5.2	Equipamentos usados na aspersão	78
5.3	Avaliação das condições de deposição	79
5.3.1	Análise auxiliada pelo DPV 2000 particle diagnostics system [™]	80
5.4		80
5.4.1		80
5.4.2 5.5	Preparo dos corpos de prova	84 85
5.51	Obtonção do imagons por microscónio ático	85
5.5.2		85
5.6	Análise de microestrutura e fases por <i>machine learning</i>	86
5.6.1	Análise de viabilidade da técnica de <i>machine learning</i> através do <i>plugin</i>	
	Trainable Classification Weka do software ImageJ	86
5.6.2	Análise por <i>machine learning</i> através da linguagem Pvthon™ e suas	
	bibliotecas	87
5.6.3	Pré-tratamento das imagens para treino	87
5.6.3.1	Cálculo das características de Haralick	87
5.6.4	Escolha de características para treino por ReliefF	88
5.6.5	Treino e aplicação do modelo matemático	90
6	RESULTADOS E DISCUSSÃO	93
6.1	Avaliação das condições de deposição e adaptação do equipamento	93
6.2	Rugosidade dos substratos	94
6.3	Análise morfológica dos revestimentos	94
6.3.1	Imagens de microscópio ótico	94
6.3.2	Imagens de MEV	95
6.3.3	Análise por EDS	98
6.3.3.1	Mapeamento EDS	98
6.3.3.2	EDS em Linha	99
6.3.3.3	EDS em ponto	100
6.4	Análise quantitativa dos revestimentos por <i>machine learning</i>	101
6.4.1	Análise de viabilidade do uso de machine learning usando o plugin	
	Trainable Weka Segmentation do software ImageJ	102
6.4.2	Análise usando Python™ e suas bibliotecas	104
6.4.2.1	Tamanho de janela selecionado para cálculo da GLCM	104
6.4.2.2	Características selecionadas para o treino	105
6.4.2.3	Hiper-parâmetros selecionados para o modelo	106

6.4.2.4 6.5	Desemp Análise o	enho dos modelos finais	109
	software	ImageJ sobre as imagens de microscópio ótico	112
6.5.1	Análise estatística dos dados		
6.5.1.1	Análise estatística da porosidade		
6.5.1.2	Análise estatística dos óxidos		
6.5.1.3	Análise estatística da mistura		
6.5.1.4 6.6	Escolhas dos parâmetros para otimização		
6.6.1	Análise e	estatística dos dados obtidos por DPV	129
6.6.1.1	Análise e	estatística da velocidade	131
6.6.1.2	Análise e	estatística da temperatura	134
6.6.2	Análise e	estatística do diâmetro	138
7	CONCLUSÕES		
8	RECOM	ENDAÇÕES PARA TRABALHOS FUTUROS	143
	REFERÉ	ÈNCIAS	145
ANEXO	S		151
ANEXO	Α	ADAPTAÇÃO DA ROLDANA DE ALIMENTAÇÃO	152
ANEXO	В	CÓDIGO QUANTIZADOR DE IGUAL PROBABILIDADE	154
ANEXO	С	CÓDIGO WRAPPER CLASS RELIEFF	156
ANEXO	D	IMAGENS DOS REVESTIMENTOS POR MICROSCOPIA	
		ÓTICA	160
ANEXO	E	IMAGENS DOS REVESTIMENTOS POR MEV	163
ANEXO	F	CLASSIFICAÇÕES DOS REVESTIMENTOS USANDO O	
		SOFTWARE IMAGEJ	167
ANEXO	G	CLASSIFICAÇÕES DOS REVESTIMENTOS USANDO PYTHO	N™
		E SUAS BIBLIOTECAS	171

1 INTRODUÇÃO

A aplicação de revestimentos aumenta consoante à crescente necessidade da engenharia de melhorar as propriedades de materiais. O desenvolvimento de pesquisas na área de Aspersão Térmica(AT) tem permitido diversificar as áreas de aplicação de revestimentos, sendo estes utilizados para aumentar resistência ao desgaste, à corrosão, entre outros. Esse trabalho faz parte de uma linha de pesquisa maior do Laboratório de Aspersão Térmica e Soldagens Especiais(LABATS) da Universidade Federal do Paraná(UFPR) cujo objetivo é avaliar a viabilidade do uso de aspersão térmica para a obtenção da propriedade de autocura em revestimentos através do uso de uma liga de Al-Cu com presença de constituinte eutético.

Nesse estudo o processo de AT selecionado para produção dos revestimentos foi o *Arc Spraying Process* (ASP). Esse se baseia na aplicação de um potencial elétrico entre dois arames, de forma a abrir um arco elétrico entre eles. O calor então produzido pelo arco é usado para fundir esses arames. Ar comprimido é então usado para cisalhar, atomizar e transportar o material fundido dos arames e depositá-lo sobre um substrato.

Nesse processo geralmente são aplicados dois arames com mesmo diâmetro e composição, porém é possível o uso de arames dissimilares no processo. Segundo Pawlowski (2008) através do uso de dois arames de composições diferentes é possível a obtenção de um revestimento com uma pseudoliga da composição desejada, apesar disso, o ASP dissimilar é pouco aplicado para a produção de revestimentos.

Adicionalmente, segundo Pormousa (2007), o ASP tem visto seu uso crescer na indústria, sendo cada vez mais aplicado devido às suas vantagens em relação a outros processos de AT, entre elas sua maior eficiência energética, maior produtividade com deposição de material podendo chegar a 50 kg/h e menor custo de operação e de investimento inicial possuindo uma das máquinas de menor custo dentre os processos de AT. Essa premissa incentiva mais estudos sobre o ASP, com o objetivo de melhor entender a influência de seus parâmetros e ampliar a suas aplicações.

Nos estudos anteriores dessa linha de pesquisa feitos por Costa (2018) e Moreira (2019) foram encontrados problemas para avaliar as propriedades dos revestimentos obtidos pela técnica clássica de análise de imagens por *thresholding*, devido a complexidade, falta de contraste e similaridade de tons observados em diferentes fases presentes nos revestimentos tanto em imagens de microscopia ótica quanto por MEV. Esse resultado se agrava com o problema recorrente observado no campo de aspersão térmica onde a comparação dos valores medidos de porosidade e óxidos entre diferentes estudos geralmente é complexa, visto que não existe uma técnica que dê o valor preciso de porosidade e óxidos dos revestimentos, devido ao problema da subjetividade na medição pela técnica de *thresholding*, como descrito por Kang, Yoo e Jang (2007).

Dessa maneira esse trabalho foca em avaliar a viabilidade do uso de *machine learning* como uma ferramenta de análise que permita uma avaliação mais robusta, automatizada e menos subjetiva dos revestimentos. Para esse fim foram utilizadas duas abordagens. A primeira mais simples usando o *software* ImageJ e a segunda mais complexa usando a linguagem Python[™] e suas bibliotecas. Esta segunda abordagem permitiu o uso das técnicas de procura em grade, validação cruzada e uso de mais características para treino, como as de Haralick, visando a obtenção de modelos com melhor poder de classificação.

Assim sendo, um segundo foco desse estudo é avaliar a viabilidade do uso de ASP dissimilar, usando um arame de cobre e outro de alumínio, como um novo método para obtenção de ligas Al-Cu com presença de constituinte eutético, bem como avaliar a presença de outros microconstituintes, demais fases intermetálicas, zonas de não-mistura (metais puros), óxidos, porosidades e vazios através usando dos modelos de *machine learning*. Juntamente a uma análise de como os diferentes parâmetros de aspersão influenciam nas características observadas nos revestimentos obtidos por tal processo.

Adicionalmente, em estudos anteriores um interesse surgiu sobre o efeito da polaridade dos arames no ASP dissimilar. Esse interesse se dá, pois, em aplicações normais a polaridade não afeta o revestimento, visto que ambos arames possuem a mesma composição, mas no caso do ASP dissimilar com arames de espessuras e materiais diferentes esse parâmetro pode influenciar nos resultados.

Para avaliar esses fatores foram usadas imagens por microscopia ótica, MEV, EDS por mapeamento, em linha e em ponto para melhor compreender as fases obtidas nos revestimentos e sua morfologia. Juntamente de análises por DPV com o objetivo de melhor compreender a formação de partículas no ASP dissimilar. Juntamente foi aplicado o planejamento robusto de Taguchi como metodologia experimental, visando a obtenção de melhores revestimentos e dados mais estatisticamente significativos em relação a estudos anteriores.

Assim, esse estudo almeja ampliar o conhecimento sobre o ASP dissimilar e sua viabilidade como um novo método para obtenção de ligas Al-Cu, através do uso de *machine learning* e abordagens mais robustas de análise.

2 JUSTIFICATIVA

Nos estudos anteriores dessa linha de pesquisa foram encontrados problemas para avaliar as propriedades dos revestimentos por *thresholding*, devido a sua complexidade visual e abundância de fases de coloração semelhante em imagens tanto de microscopia ótica quanto por MEV. Adicionalmente a técnica de *thresholding* é considerada subjetiva, devido a sua dependência da pessoa realizando a análise. Fato que dificulta a comparação de resultados entre diferentes estudos. Dessa forma, esse estudo visa contribuir para o campo de aspersão térmica e revestimentos pela avaliação da técnica de *machine learning* para análise dos revestimentos, almejando uma análise mais automatizada e na obtenção de melhores dados para avaliação dos mesmos.

Adicionalmente esse estudo visa expandir o conhecimento sobre o uso do ASP dissimilar para a produção de ligas. O ASP tem visto seu uso crescer na indústria devido a seu baixo custo de operação e de maquinário somado a sua alta produtividade, porém a maioria dos estudos sobre o processo dissimilar focam no estudo dos mecanismos de produção de partículas sem focar na liga obtida no revestimento. Adicionalmente a influência da polaridade nas propriedades dos revestimentos não é estudada nas aplicações clássicas do processo de arco elétrico, devido a ambos os arames empregados serem da mesma liga e assim a própria ideia de influência da polaridade não existir, visto que trocar a posição dos arames não muda nada no processo. Sendo assim necessário um estudo maior sobre a formação de liga no ASP dissimilar e sobre os efeitos da polaridade nas propriedades do revestimento.

Dessa forma esse estudo visa não somente a obtenção de uma microstrutura que possua a mistura dos materiais utilizados na forma de uma pseudo liga pelo ASP dissimilar, mas também auxiliar em um maior entendimento do processo de modo geral e consequentemente permitir um maior controle da morfologia obtida pelo processo.

3 OBJETIVOS

3.1 OBJETIVOS GERAIS

Objetiva-se avaliar a viabilidade do uso de modelos de *machine learning* para análise de revestimentos mais complexos de maneira mais automatizada e menos dependente da pessoa realizando a análise, de forma a permitir uma avaliação mais objetiva e que contribua para o campo de aspersão térmica em sua integridade.

Adicionalmente, esse trabalho objetiva avaliar a viabilidade do uso do processo de aspersão térmica por ASP dissimilar para obtenção de revestimentos de Al-Cu, com a formação de liga e constituinte eutético.

Além disso, objetiva-se através de análise das propriedades das partículas como tamanho, velocidade e temperatura durante o processo de deposição para melhor compreender o ASP dissimilar e de como o controle dos parâmetros de máquina influenciam nas propriedades observadas nos revestimentos e nas partículas da zona de transferência. Com um foco principalmente nos efeitos da polaridade dos arames nas propriedades observadas.

3.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos do trabalho são:

- Avaliar a viabilidade do uso de técnicas de machine learning para avaliar revestimentos de aspersão térmica, visando obter uma técnica mais objetiva e automatizada para análises de revestimentos de aspersão térmica.
- Avaliar a influência dos parâmetros de aspersão na microestrutura do revestimento. Avaliando-se:
 - Teor de Óxidos;
 - Porosidade;
 - Formação de mistura de Al e Cu durante a aspersão;
- Avaliar a influência dos parâmetros de aspersão nas propriedades das partículas produzidas por ASP. Avaliando sua:
 - Velocidade;
 - Temperatura;
 - Diâmetro.

• Avaliar a morfologia obtida nos revestimentos, analisando a distribuição das diferentes fases, tal como a do constituinte eutético.

4 REVISÃO DE LITERATURA

Nesse capítulo são discutidos os assuntos pertinentes a propriedade de autocura, ligas de alumínio e cobre, o processo de aspersão térmica por arco elétrico, ciclo térmico presente durante a deposição, estudos prévios feitos na deposição de ligas Al-Cu *in situ*, planejamento experimental de Taguchi e as técnicas de *machine learning* considerados durante a confecção desse estudo.

4.1 PROPRIEDADE DE AUTO-CURA

Um dos grandes custos da área aeronáutica é o custo de manutenção de sistemas e peças de aeronaves. Dessa forma existe um esforço constante em produzir peças com maior vida. Uma abordagem mais recente tem se focado no desenvolvimento de peças com a propriedade de se curar de trincas de fadiga.

Um dos métodos empregados para dar a um material essa propriedade é o uso de uma liga metálica, que possua um campo eutético, como matriz reforçada com um material de memória ativado termicamente. O processo se baseia na obtenção de uma microestrutura eutética nos contornos de grão da matriz metálica, visto que os contornos de grão são uma região preferencial para a nucleação de trincas. (WRIGHT; MANUEL; WALLACE, 2013).

Com o aquecimento do material, a estrutura eutética se funde de forma a preencher as trincas juntamente ao uso de pressão aplicada pelo material de memória, que quando aquecido procura retornar a sua forma original, de maneira a auxiliar a peça a obter seu formato original, e assim, o preenchimento da trinca e cura da trinca. (WRIGHT; MANUEL; WALLACE, 2013).

No trabalho feito Wright, Manuel e Wallace (2013), esse efeito foi atingido com o uso de ligas Al-Si e liga Al-Cu reforçadas com arames de SMA. Um exemplo de estrutura obtida no trabalho, que permite essa propriedade pode ser vista na FIGURA 1.



FIGURA 1 – MICROESTRUTURA REQUERIDA PARA AUTO CURA

FONTE: Traduzido de Wright, Manuel e Wallace (2013).

4.2 LIGAS ALUMÍNIO COBRE

Ligas de alumínio cobre, ou ligas 2xxx, são aplicadas na indústria aeronáutica devido a sua alta resistência e baixa densidade. Sua alta resistência mecânica advêm da precipitação coerente do intermetálico $AI_2Cu(\theta)$, durante o processo chamado de envelhecimento, conforme Mondolfo (1976).

A precipitação do intermetálico θ ocorre em diferentes etapas, formas e regiões no sistema Al-Cu, essa ocorre primeiramente em planos específicos no caso das fases de transição Guinier–Preston e θ ", resultando em um precipitado altamente coerente no plano {100} da estrutura cristalina. Dentro dos grãos de alumínio, nas incoerências e discordâncias do material, é gerado um precipitado semi-coerente, como é o caso das fases θ' , e a partir desse precipitado se forma a fase θ . Por fim tem-se a precipitação de compostos intermetálicos nos contornos de grão, na forma estável θ . Todas essas configurações são obtidas a partir da liga em solução sólida através de envelhecimento natural ou artificial da liga, conforme descrito por Mondolfo (1976).

Devido a esses eventos, somente sobre condições de resfriamento lento o intermetálico pode ser encontrado precipitado dentro e nos contornos dos grãos na forma de constituinte eutético. Em condições de rápido resfriamento, tal como as encontradas em processos de soldagem, o cobre se mantêm em solução sólida na matriz de alumínio e posteriormente sofre envelhecimento passando pelas diferentes etapas do processo de precipitação resultando em uma estrutura diferente daquela do constituinte eutético. (DAVID A. PORTER, 1992).

Um fato evidenciado por Rabkin et al. (1970) é a característica exotérmica da mistura de cobre a alumínio fundidos, de forma que durante a mistura dos dois materiais é liberada energia na forma de calor, o que facilita a produção da liga. Na aspersão térmica esse efeito pode ser benéfico, visto que pode acarretar a liberação de calor durante o impacto das partículas no substrato, efeito que auxiliaria na difusão e mistura das partículas e, consequentemente, poderia influenciar na maior formação de liga, compostos intermetálicos e em uma taxa de resfriamento mais lenta com o maior aquecimento do substrato durante a aspersão.

4.2.1 Diagrama de fases sistema Al-Cu

No diagrama binário de alumínio-cobre na FIGURA 2 é observável a presença de diversas fases intermetálicas. Na FIGURA 3 vê-se o diagrama com uma ampliação na região de formação do constituinte eutético. Este é composto por duas fases: alumínio(α), que é uma fase com estrutura corpo de face centrada, e pelo intermetálico Al₂Cu(θ), que é uma fase com estrutura tetragonal. O constituinte eutético tem a composição de 33,2 % Cu em peso, sendo caracterizado pela sua temperatura de fusão de 548 °C em contraste com a temperatura de fusão de 660 °C do alumínio e 1085 °C do cobre.



FONTE: Traduzido de Xia et al. (2008).


FONTE: Adaptado de Ch, Reddy e Rao (2015).

Essas propriedades são o que suscitam o uso de ligas 2xxx nos estudos de materiais com propriedades de auto cura, dado que o material possuí regiões com distintas temperaturas de fusão permitindo que material líquido flua para as trincas e as preencha durante o aquecimento no processo de auto-cura.

4.2.1.1 Compostos intermetálicos do sistema Al-Cu

Propriedades físicas e visuais dos intermetálicos de Al-Cu foram avaliadas por Rabkin et al. (1970). Em seu estudo foi revelada a fragilidade de boa parte dos compostos intermetálicos de Al-Cu, além de sua aparência lisa e reflexiva. A análise da fase θ revelou uma dureza Vickers na faixa de 700kg/mm². Os dados levantados das diferentes fases das ligas Al-Cu podem ser vistos na FIGURA 4.

A formação de intermetálicos é normal em processos de soldagem e aspersão térmica devido à alta temperatura atingida. Para o processo de arco elétrico uma temperatura média de 5500 °C é atingida no bico da pistola segundo Marques (2003), dessa maneira espera-se que ambos os materiais entrem em estado de fusão e se misturem em proporções, que durante a solidificação, estejam nas diversas regiões do diagrama de equilíbrio, de forma que diferentes intermetálicos e morfologias sejam observados.



FIGURA 4 – DADOS DE DIFERENTES FASES PRESENTES EM LIGAS DE AI-Cu

FONTE: Traduzido de Rabkin et al. (1970).

LEGENDA: a: Microdureza Vickers, b: Resistência a Tração, c: Resistividade Elétrica, d: Coeficiente de dilatação linear.

4.3 ASPERSÃO TÉRMICA

Aspersão térmica é um conjunto de processos e técnicas para obtenção de um revestimento com o objetivo de conferir à superfície do substrato diversas propriedades como proteção contra corrosão, oxidação, erosão, desgaste, entre outras.

Essas técnicas se caracterizam pelo seu princípio de funcionamento que pode ser observado na FIGURA 5.

Na aspersão térmica um material na forma de pó, arame, barra, etc. é aquecido por uma fonte de calor até seu estado fundido ou semi-fundido. Esse material na forma de partículas é então acelerado e transportado até o substrato moldando-se a este durante o impacto. Assim a adesão da partícula ao substrato se dá de maneira mecânica sem haver a fusão do material do substrato.

A aderência das partículas no substrato decorre, então, de tensões residuais originadas da contração do material ao resfriar. (PAREDES, 2012; PAWLOWSKI, 2008; DAVIS, 2004).

Devido a essas características os processos de AT tem sido usados em aplicações onde é desejável manter a estrutura metalúrgica do material do substrato, sem que a deposição de um revestimento interfira em suas propriedades.



FIGURA 5 – DIAGRAMA SIMPLIFICADO DO PROCESSO DE ASPERSÃO TÉRMICA

FONTE: Adaptado de Paredes (2012).

4.3.1 Processo por arco elétrico (ASP)

No processo por arco elétrico dois arames são continuamente alimentados e fundidos através de um arco formado na ponta dos arames devido à diferença de potencial elétrico entre eles. Nesse processo são produzidas partículas de material fundido que ficam sobre os arames, essas são então cisalhadas pelo gás de transporte, usualmente gás comprimido nesse processo. Essas partículas então entram na chamada zona de transferência onde são atomizadas e resfriadas pelo gás de transporte até o momento de impacto com o substrato. O arranjo clássico de uma pistola para esse processo pode ser visto na FIGURA 6.

O uso do processo de arco elétrico viu seu uso aumentar constantemente na indústria nos últimos anos devido as suas vantagens em relação aos outros processos de aspersão. Entre essas seus maiores atrativos estão seu menor custo inicial de investimento, baixo custo de operação e qualidade de revestimento obtido.

Segundo Pormousa (2007) e Davis (2004) o processo ainda se destaca em aplicações onde se pretende conservar as propriedades metalúrgicas do substrato, ao contrário do processo a chama. Dado que, nesta técnica a chama usada para aquecer o pó acaba, também, esquentando o substrato podendo mudar suas propriedades metalúrgicas. Já no ASP o único calor transmitido ao substrato vem das partículas depositadas, visto que não há chama durante o transporte.



FIGURA 6 – CONCEITO DA PISTOLA USADA NO ASP

FONTE: Adaptado de Davis (2004).

A maior desvantagem do ASP é a falta de controle do tamanho das partículas depositadas. Nos processos que usam pós como material de aporte o controle do tamanho das partículas é feito através da seleção da granulometria do pó. Já no ASP o tamanho das partículas depositadas é definido pelos parâmetros de aspersão, o que limita as aplicações do processo. (PORMOUSA, 2007).

4.3.1.1 Deposição bimodal, híbrida ou dissimilar

Segundo Pawlowski (2008), uma pseudo liga pode ser obtida por ASP, pela aplicação de arames de diferentes ligas, ou materiais.

Zhu et al. (2003) usaram arames de cobre e aço para observar a distribuição de partículas no revestimento pelo ASP dissimilar. Em seu estudo, a pistola foi mantida parada. Dentre seus resultados foi possível observar uma deposição assimétrica de partículas de cobre e aço com conteúdo de cobre e aço variando na seção do revestimento, caracterizando assim um efeito de *cross-fire* na deposição. Esse efeito pode ser visto na FIGURA 7.

FIGURA 7 – EFEITO DE *CROSS-FIRE* DO ASP NAS PROPRIEDADES DA SEÇÃO DO REVESTIMENTO



FONTE: Adaptado de Zhu et al. (2003).

4.3.1.2 Produção de partículas no ASP

A influência da polaridade nas propriedades dos revestimentos não é estudada nas aplicações clássicas do processo de arco elétrico, devido à ambos os arames empregados serem da mesma liga e assim a ideia de influência da polaridade não existir, visto que trocar a posição dos arames não muda nada no processo. Assim os poucos estudos sobre efeito da polaridade no ASP tem por objetivo analisar os diferentes mecanismos de produção de partículas pelo arco elétrico.

Watanabe et al. (1996) observaram em seu estudo, através de imagens de alta velocidade, uma fusão dissimilar dos eletrodos, sendo a fusão no cátodo localizada produzindo pequenas partículas imediatamente lançadas pelo gás de transporte, em contraste, no ânodo foi observada uma fusão mais uniforme do arame com a formação de um filme superficial sobre o arame, tal filme é então cisalhado produzindo partículas de maior tamanho do que aquelas observadas no cátodo.

Estudos sobre mecanismos de fundição dos arames, cisalhamento, tamanho das partículas cisalhadas e influência da polaridade dos arames foi feita por Pormousa (2007) através de experimentos e simulações do processo de produção, transporte e deposição de partícula. Em seu trabalho as partículas formadas no ânodo tiveram aproximadamente o dobro de tamanho das partículas formadas no cátodo. Esse efeito foi atribuído a um superaquecimento localizado do cátodo, em contraste ao aquecimento mais homogêneo do ânodo devido ao efeito *arc-anode attachment*, onde o arco tem uma preferência pelo ânodo e se localiza mais próximo do mesmo devido à polaridade de ambos.

Outro efeito que explica a assimetria na formação de partículas nos arames são os processos de limpeza catódica e o calor extra gerado pelo impacto de elétrons no arame conectado ao polo positivo da máquina. Um efeito semelhante é observado nas soldagens por arco elétrico com gás de proteção, e é explicado por Kou (2003). Os elétrons emitidos pelo polo negativo da fonte são acelerados pelo arco em direção ao polo positivo e se chocam com ele, de forma que a energia do impacto é convertida em calor. Esse efeito está ilustrado na FIGURA 8.



FONTE: O autor(2021).

Geralmente todos esses efeitos são desconsiderados no ASP, pois são utilizados arames de mesmo diâmetro e composição no processo. Contudo, neste estudo com arames dissimilares, estes efeitos podem resultar em diferentes condições de fundição, mistura e tamanho das partículas de ambos materiais e, assim, interferir diretamente na microestrutura dos revestimentos obtidos.

4.3.1.3 Distribuição de partículas na zona de transferência no ASP

Horner, Hall e McCloskey (2015) avaliaram os efeitos dos parâmetros de tensão, corrente e pressão na dispersão do jato de transferência. Em seu trabalho foi percebido que uma menor tensão resulta em um arco menos disperso, o que leva, consequentemente, a menor perda de material. Para a pressão concluiu-se que um valor maior gera menor dispersão, a esse efeito foi atribuído a maior velocidade das partículas, o que resulta em menor tempo na zona de transporte e assim menor

influência da gravidade, arrasto e outros fatores que atuam na formação de um jato mais disperso.

Pormousa (2007) percebeu que na aspersão dissimilar as partículas do ânodo e cátodo tem tamanho diferente, o que acaba também afetando o seu comportamento na região de transferência. Em seu trabalho foi constatada a menor velocidade das partículas produzidas no ânodo devido a seu maior tamanho e consequentemente maior arrasto durante a transferência. Esse efeito indica que distribuições diferentes dos dois materiais podem ocorrer na área de transferência resultando em diferentes taxas de deposição dos dois materiais e, consequentemente, suceder na obtenção de uma relação diferente dos materiais do ânodo e cátodo presente nas diferentes regiões do revestimento.

Além disso, devido às diferentes velocidades na área de transferência entre as partículas produzidas pelo ânodo e pelo cátodo, esperasse a presença durante a deposição de um efeito similar ao de *cross-fire* observado por Zhu et al. (2003), onde uma distribuição dos dois materiais poderá ser encontrada não somente na horizontal mas também na vertical na zona de transferência.

4.3.1.4 Parâmetros de controle para o ASP dissimilar

No ASP existem vários parâmetros que podem ser definidos e controlados, resultando em diferentes propriedades e características nos revestimentos aspergidos.

Tensão

Segundo Davis (2004) a tensão está diretamente relacionada ao tamanho das partículas desprendidas dos arames durante a sua fusão, de forma que quanto maior a tensão do arco menor o tamanho das partículas. Além disso, a tensão influi diretamente no comprimento e estabilidade do arco, onde uma tensão menor resulta em um arco menor e mais estável, mas com menos energia e, consequentemente, menor transferência de calor para as partículas fundidas.

Corrente

Segundo Pormousa (2007) a corrente de aspersão é uma consequência das variáveis do processo, tal como o material dos arames e o fluxo do gás de transporte. Este, através do resfriamento da região do arco, diminui a condutividade elétrica do arco elétrico e consequentemente a capacidade dos elétrons de passar por ele.

Nos equipamentos de ASP, duas categorias de sistemas de controle de corrente são encontrados. Segundo Pormousa (2007) sistemas do tipo 1 se baseiam no controle da taxa de alimentação e sistemas do tipo 2 na seleção da corrente. A

pistola da Sulzer Metco utilizada nesse estudo se baseia no controle da taxa de alimentação de material, nesse sistema com um aumento da taxa de alimentação de material um aumento respectivo na corrente é observado.

O efeito da corrente sobre o processo de aspersão se dá sobre a dispersão do arco, com maiores valores resultando em arco mais dispersos como foi observado por Horner, Hall e McCloskey (2015). A corrente tem um efeito menor sobre a energia do arco do que a tensão, visto que, o seu aumento acarreta aumento direto na quantidade de material a ser fundido e assim a energia por material fundido é menos sensível do que a observada na alteração da tensão.

Pressão

No processo por arco-elétrico a pressão define o fluxo de gases na pistola, sendo que o fluxo é uma função linear da pressão conforme avaliado por Pormousa (2007). Geralmente é aplicado ar comprimido como gás de transporte, mas também é possível a aplicação de gases inertes ou N₂.

O fluxo de gases na pistola controla o cisalhamento de partículas dos arames e a atomização dessas durante o seu transporte. Sendo assim, a pressão influencia no tamanho das panquecas do revestimento. (DAVIS, 2004).

Os gases da pistola ainda são responsáveis pelo resfriamento de partículas durante o seu transporte. Segundo Davis (2004), esse processo diminui a plasticidade das partículas, que durante o impacto se moldam menos ao substrato e resultam, assim, em menor adesão do revestimento.

Por fim o fluxo de gases está diretamente correlacionado com a velocidade de impacto das partículas no substrato, sendo que geralmente maiores velocidades de impacto resultam em revestimentos de maior adesão segundo Pawlowski (2008).

• Polaridade

A polaridade de cada arame define o mecanismo de produção de partículas sobre o qual o arame irá trabalhar. (WATANABE et al., 1996). E consequentemente no tamanho das partículas observadas. (PORMOUSA, 2007).

O tamanho e temperatura das partículas produzidas está diretamente relacionado com a polaridade empregada, dessa forma, com a troca da polaridade esperasse observar uma mudança no tamanho das partículas de alumínio e cobre tal como uma mudança na sua proporção no revestimento final.

Distância

A distância de deposição é historicamente um dos parâmetros mais importantes para os processos de aspersão térmica, devido à sua influência imediata na

energia cinética das partículas no momento do impacto com o substrato. Dessa forma a distância de aspersão está diretamente correlacionada com a porosidade e aderência observada no revestimento.

Além disso, a distância de aspersão define o tempo de contato entre as partículas e o gás de transporte definindo assim a dispersão do arco, tempo de oxidação das partículas e consequentemente a quantidade de óxidos presentes no revestimento, conforme Pawlowski (2008).

• Pré-Aquecimento

O pré-aquecimento do substrato afeta a molhabilidade das partículas durante a deposição, conforme descrito por Paredes e Oliveira (2001). Em seu trabalho foi observado que as partículas se deformam melhor ao perfil de rugosidade do substrato e, assim, obtêm uma maior aderência ao mesmo quando há a aplicação de pré-aquecimento. Além disso, foi observado que o pré-aquecimento evita que as partículas se rompam durante o impacto, diminuindo o efeito de respingo e consequentemente a porosidade e oxidação do revestimento.

Outro efeito do pré-aquecimento é sua influência na taxa de resfriamento do material. Esse efeito é bem conhecido nos processos de soldagem, onde um maior pré-aquecimento acarreta uma menor taxa de resfriamento e assim permite ao material maior tempo para crescimento de grãos e precipitação de fases resultando em uma estrutura mais grosseira e com menos elementos em solução sólida conforme descrito por Kou (2003) e David A. Porter (1992). Dessa maneira na aspersão térmica de Al-Cu, esperasse que o pré-aquecimento permita uma menor taxa de resfriamento e assim maior tempo para que uma estrutura eutética seja atingida ao invés de uma com a precipitação coerente de intermetálicos na matriz de alumínio.

4.3.2 Processo de jateamento

Como já abordado a adesão dos revestimentos de aspersão térmica ao substrato se dá de maneira mecânica, sem a formação de liga metalúrgica na interface revestimento/substrato. Por esse motivo a limpeza da superfície do material base está diretamente correlacionada com a aderência do revestimento.

Dessa forma o processo de limpeza é necessário para se garantir adesão mecânica do revestimento sem que a presença de óxidos, óleos e impurezas na superfície atrapalhem a adesão das partículas no substrato. (DAVIS, 2004). Várias técnicas de limpeza podem ser empregadas como o uso de solventes, jato de água ou jateamento abrasivo. Essas técnicas e sua aplicação são descritas por Pawlowski (2008).

O processo de jateamento abrasivo é o mais aplicado nos casos de aspersão térmica, pois, além de limpeza, confere ao substrato maior rugosidade em um processo chamado de ativação. Este se baseia em aumentar a área superficial do substrato e fornecer vales para que às partículas aspergidas possam preencher e consequentemente aderir ao substrato, a essa configuração dá se o nome de *mechanical interlocking*. Esse processo é descrito por Davis (2004) e é considerado historicamente o mecanismo principal de adesão nos processos de aspersão térmica. Um exemplo dessa configuração pode ser visto na FIGURA 9.

FIGURA 9 – MECANISMO DE ADESÃO DO REVESTIMENTO POR ARPERSÃO TÉRMICA MECHANICAL INTERLOCKING



FONTE: Traduzido de Davis (2004).

Segundo Paredes e Oliveira (2001), a variação na rugosidade Ry da faixa 50-60 μ m para 70-80 μ m, obteve pouca influência na propriedade de aderência do revestimento, havendo uma diferença de apenas \pm 5 MPa, pelo ASP usando substrato de carbono 1020 e material de aporte arame de alumínio de 3,2 mm sem o uso de pré-aquecimento.

4.3.3 Microestrutura de revestimentos de aspersão térmica

Microestrutura obtida e problemas encontrados durante a preparação metalográfica de revestimentos por aspersão térmica são abordados por Lima, Camargo e Lima. (2004). Dentre suas observações está a forma da microestrutura obtida na aspersão térmica pelo processo de arco elétrico.

A configuração clássica do revestimento obtida pelo processo de aspersão pode ser vista na FIGURA 10.

FIGURA 10 – CARACTERÍSTICAS MORFOLOGICAS DE REVESTIMENTOS POR ASPER-SÃO TÉRMICA



FONTE: Adaptado de Thorpe (1993).

Na FIGURA 11, pode ser visto a seção de um revestimento obtido pelo processo de arco elétrico com as diferentes regiões do revestimento destacadas. Nela nota-se a presença de lamelas de material empilhadas, com a formação de óxidos nos contornos dessas, esses são formados durante a aspersão e se mantém como uma casca nas partículas depositadas, além da presença de porosidade em diferentes regiões do revestimento.

FIGURA 11 – MICROESTRUTURA OBSERVADA NA SEÇÃO DE REVESTIMENTO OBTIDO POR ASPERSÃO TÉRMICA



FONTE: Adaptado de Lima, Camargo e Lima. (2004). NOTA: Revestimento de aço carbono 1080 atacado com Nital 2%.

4.3.3.1 Porosidade

Durante a aspersão ocorre a formação de vazios nos revestimentos. Essa pode se dar por diferentes mecanismos entre eles: através da formação de respingos durante o impacto das partículas, pelo aprisionamento de bolhas do gás de transporte nas partículas depositadas, além falta de molhamento e consequente falta de conformação da partícula ao substrato.

Esses vazios influem diretamente na adesão e coesão de revestimento de forma que a estimativa de seus valores é uma análise recorrente em estudos na área de aspersão térmica como um indicativo da qualidade do revestimento.

Lima, Camargo e Lima. (2004) discutem em seu trabalho sobre a dificuldade de se estimar corretamente a fração de vazios em revestimentos de alumínio, dado que o material é muito sensível ao processo de lixamento e polimento da preparação metalográfica. Esse efeito acarreta uma "falsa porosidade" gerada durante à preparação metalográfica, onde pode ocorrer a retirada de lamelas inteiras ou de óxidos do revestimento resultando em grandes vazios observados nas micrografias.

4.3.3.2 Óxidos

A presença de óxidos nos revestimentos por aspersão térmica é inerente aos processos. As altas temperaturas atingidas, o uso de ar comprimido como gás de

transporte e o resfriamento das partículas depositadas durante os passes resultam na distribuição de óxidos nos contornos das panquecas de material similar a uma casca. Sendo que essa configuração evita a coesão entre as lamelas do revestimento.

Os diferentes mecanismos e tipos de óxidos de alumínio formados durante o ASP foram estudados por Rodriguez (2003). Em seu trabalho foi constatado que a maior fonte de óxidos no ASP é o arco elétrico. Isso resulta das altas temperaturas atingidas no arco somado à ionização do oxigênio atmosférico pelo arco que favorecem a formação de óxidos, sendo esse mecanismo o mais relevante para o ASP. As diferentes regiões e fontes dos óxidos podem ser vistos na FIGURA 12.



FIGURA 12 – ZONAS DE FORMAÇÃO DE ÓXIDOS NO ASP

FONTE: Adaptado de Rodriguez (2003).

LEGENDA: Mecanismo 1 – Arco elétrico - contato das partículas com oxigênio ionizado (Exclusivo para o ASP). Mecanismo 2 – Zona de transferência - Oxidação entre as partículas e o gás de transporte. Mecanismo 3 – Meio que envolve a zona de transferência - Entrada de oxigênio na zona de transferência devido ao fluxo turbulento dos gases. Mecanismo 4 - Revestimento - Partículas já ancoradas ao substrato ficam expostas ao ar do meio conforme movimento da pistola.

A formação de óxidos na deposição de alumínio, porém, nem sempre é considerada prejudicial ao processo. Devido à rápida formação da camada oxida em torno das partículas, essa pode atuar como uma capa insulante diminuindo a perda de calor das partículas durante o seu transporte. Adicionalmente, no momento do impacto da partícula com o revestimento a camada oxida se rompe permitindo a formação de novos óxidos.

Devido à oxidação do alumínio ser um processo altamente exotérmico, esses efeitos podem auxiliar em um maior aquecimento das partículas durante o seu processo de produção, sua atomização e em segundo momento de maneira mais localizada durante o impacto das partículas com o substrato. Esses efeitos podem promover uma maior temperatura atingida no revestimento e esperasse que auxiliem na maior formação de liga no revestimento.

4.3.4 Ciclo térmico no revestimento durante o processo de aspersão

O processo de aspersão térmica se baseia na deposição de partículas em estado líquido ou semi-solido por passes compostos de sub-passes através da movimentação da pistola em frente ao substrato, esse processo então é repetido até atingir-se um número determinado de passes ou a espessura de revestimento desejada.

Esse processo resulta em um aquecimento do substrato de maneira descontinua. Fazendo com que partes diferentes do substrato passem por ciclos térmicos diferentes, conforme descrito por Bao, Zhang e Gawne (2005). Um exemplo de ciclo térmico sobre o qual o revestimento é submetido pode ser visto na FIGURA 13.



FIGURA 13 – CICLO TÉRMICO NOS PROCESSOS DE ASPERSÃO TÉRMICA

FONTE: Adaptado de Bao, Zhang e Gawne (2005).

Na espessura as lamelas depositadas pelos primeiros passes acabam passando por mais ciclos térmicos. Isso pode fazer com que essas camadas passem maior tempo acima da temperatura de precipitação do que àquelas depositadas em passes finais. Acarretando, assim, em um revestimento com um perfil de precipitação em sua espessura.

Ainda segundo Bao, Zhang e Gawne (2005), em seu trabalho pôde ser observado que pontos diferentes da superfície do revestimento passam por diferentes ciclos térmicos. A esse efeito foi atribuído a diferente taxa de resfriamento desses pontos devido à sua distância das bordas do substrato efeito que resultaria em um campo de temperatura. Assim, diferentes partes do revestimento experienciam temperaturas e taxas de resfriamento variadas, e consequentemente no revestimento pode ser um observado um perfil tri-dimensional de morfologias e precipitados.

4.4 ESTUDOS PRÉVIOS NA DEPOSIÇÃO DE LIGAS DE AI-Cu IN SITU

Nos trabalhos desenvolvidos por Moreira (2019) e Costa (2018) foi comprovada a possibilidade de se obter uma estrutura eutética por aspersão térmica tanto pelos processos de chama-pó quanto pelo processo de arco-elétrico. No processo de chamapó observou-se a formação de panquecas inteiras do constituinte eutético, conforme pode ser visto na FIGURA 14. Em contrapartida, no arco-elétrico por processo dissimilar com arames de alumínio e cobre, pôde ser observado a formação de eutético no contorno entre lamelas de alumínio e cobre, além da presença de lamelas de eutético, conforme pode ser visto na FIGURA 15.

FIGURA 14 – REVESTIMENTO OBTIDO POR DEPOSIÇÃO DISSIMILAR AI-Cu POR CHAMA PÓ DE LIGA EUTÉTICA(33,2% Cu) COM PANQUECAS DE HIPO E HIPER-EUTÉTICO



FONTE: Adaptado de Moreira (2019).

FIGURA 15 – REVESTIMENTO OBTIDO POR DEPOSIÇÃO DISSIMILAR DE AI-Cu POR ARCO ELÉTRICO COM EUTÉTICO ENTRE PANQUECAS





FONTE: Adaptado de Costa (2018).

A falha de revestimentos obtidos por aspersão térmica geralmente se dá nos contornos das lamelas, devido à presença nessas regiões de óxidos e pelo ligamento entre lamelas ser majoritariamente mecânico. Nos materiais utilizados para o processo de auto-cura deseja-se uma que a fase eutética se encontre entre os contornos de grãos, uma vez que, essa é a região mais suscetível a trincas de fadiga. Dessa forma, no caso da formação de uma trinca, a peça pode ser aquecida à temperatura de fusão do constituinte eutético que se liquefaz na região da trica e a preenche. Como na aspersão térmica o contorno de partículas é a região mais suscetível a trincas é de interesse da pesquisa que essas regiões sejam onde o constituinte eutético esteja presente. O que torna o ASP de maior interesse para esse estudo.

Ainda nos estudos por Costa (2018), foi observada a formação do intermetálico γ_1 . Esse intermetálico possui uma alta temperatura de formação. Segundo Pawlowski (2008) a temperatura atingida no arco elétrico pode chegar a 6000K, mas segundo Davis (2004) o processo por arco elétrico é o processo que menos transfere energia térmico para o substrato, devido à falta de aquecimento durante o transporte e consequente maior resfriamento das partículas pelo gás de transporte. Dessa forma no trabalho de Costa (2018) foi levantada a hipótese de que os intermetálicos poderiam estar sendo formados no jato com o choque entre partículas de alumínio e cobre durante a sua transferência.

4.5 TÉCNICAS DE ANÁLISE DE FORMAÇÃO DE PARTÍCULAS EM ASPERSÃO TÉRMICA

O tamanho de partículas na aspersão térmica influencia diretamente nas propriedades do revestimento com a definição da fração de porosidade e quantidade de óxidos no revestimento. Sendo assim, muitas vezes é de interesse o aumento do tamanho das partículas para minimização desses fatores. Esse interesse é ainda maior na aplicação dissimilar do ASP, visto que os mecanismos de produção de partícula mudam nos dois eletrodos resultando em partículas com diferentes inércia e velocidade no momento do impacto.

Para análise dos tamanhos de partículas produzidas pelo processo de arco elétrico, Pormousa (2007) aplicou duas técnicas. A primeira foi análise pela deposição de partículas em uma cortina da água permitindo a coleta individual das mesmas sem que elas tivessem tempo de impactar entre si com posterior uso de microscopia eletrônica de varredura para avaliação do tamanho das partículas.

A segunda técnica aplicada por Pormousa (2007) foi o uso do equipamento *DPV 2000 particle diagnostics system*[™]. Esse equipamento se baseia no uso de uma câmera térmica de alta velocidade associada a um computador com uma interface gráfica para o usuário. Esse sensor permite avaliar a temperatura, diâmetro e velocidade de partículas individuais permitindo uma análise mais robusta dos efeitos de parâmetros do processo na formação de partículas.

4.6 PLANEJAMENTO EXPERIMENTAL DE TAGUCHI

Taguchi e Konishi (1987) desenvolveram a metodologia Taguchi, em visão de criar um método de análise estatística que fosse robusto e permitisse, com poucos experimentos, avaliar a influência de diferentes parâmetros na qualidade de produtos manufaturados. A técnica foi bem aceita pela indústria e comunidade científica e hoje é usada em várias ramos fora da área da qualidade, vendo sua aplicação em estudos científicos que almejam avaliar a influência de parâmetros nas propriedades analisadas e então usar esses dados para otimizar as propriedades de uma amostra.

O método Taguchi já viu sua aplicação na aspersão térmica com sucesso por estudos feitos por Silva (2017), Sucharski (2016) e Paredes (1998). Nesses estudos a aplicação do método permitiu a otimização as propriedades dos revestimentos avaliados como porosidade, adesão, óxidos e outros.

Na FIGURA 16 um resumo da metodologia de Taguchi é apresentada.



FIGURA 16 – DIAGRAMA SIMPLIFICADO DA METODOLOGIA DE TAGUCHI

FONTE: O autor(2021).

Para avaliar se os níveis dos parâmetros usados no planejamento de Taguchi foram significantes uma análise de variância(ANOVA) pode ser realizada. Essa técnica tem, porém, uma complicação, o modelo presume que os dados obtidos seguem uma distribuição normal, o que nem sempre é verdade.

Assim um teste de normalidade deve ser usado. Nesse teste a hipótese nula é de que os dados seguem uma distribuição normal, enquanto a hipótese alternativa é de que os dados não seguem uma distribuição normal.

Um exemplo de não normalidade esperada nesse estudo é a distribuição de diâmetros das partículas produzidas por ASP, já conhecida por ter um formato lognormal conforme Lefebvre e McDonell (2017) e Pormousa (2007). Além disso, as partículas de materiais diferentes são produzidas com diferentes mecanismos nas pontas dos arames pelo arco elétrico e, consequentemente, é esperado que as curvas obtidas sejam, na verdade, a soma de duas curvas para todos os resultados de DPV.

Apesar de a ANOVA ter a suposição de normalidade esse método é geralmente considerado robusto para dados não normais, e já teve sua robustez testada por Blanca et al. (2017) que teve resultados positivos.

Ainda assim, esperasse que os dados coletados quebrem a suposição e, dessa forma, a análise ANOVA foi realizada juntamente a um teste de ANOVA por Permutação(PERMANOVA) considerada mais robusta para análises com dados não normais.

O método de ANOVA por permutação foi proposto originalmente por Anderson (2001) como um substituto não paramétrico para análise multivariada da variância. Para tanto o algoritmo se baseia no uso de uma propriedade de distância entre os dados para calcular a razão entre sinal e ruído ao invés da abordagem clássica de se usar a média da soma dos quadrados para avaliar o valor F, de forma que essa técnica é não paramétrica, ou seja, não supõe sobre a distribuição dos dados.

Esses testes são considerados mais robustos que a ANOVA gerando resultados competitivos, podendo ser aplicados em dados não normais e experimentos não balanceados conforme Pajouh e Renaud (2010, 2014).

Outro teste geralmente usado com a análise de Taguchi é o teste de Tukey. O teste de Tukey, é um teste *post hoc* que permite avaliar se existe diferença estatística entre níveis e assim os agrupar conforme sua significância.

4.7 AVALIAÇÃO DE IMAGENS POR MACHINE LEARNING

Machine learning é uma ciência que se baseia na criação de modelos matemáticos que permitam computadores a aprender padrões a partir de dados, e assim, consigam fazer previsões, decisões, classificar dados entre outros. Muitos algoritmos já foram criados que podem ser considerados parte da família de *machine learning*, esse estudo se foca nos algoritmos de árvore de decisão e floresta aleatória.

4.7.1 Técnicas de segmentação de imagens

O uso de computadores e imagens digitais permitiu avanço na segmentação e classificação de imagens. Atualmente várias técnicas, algorítimos e programas estão a disposição para se avaliar imagens.

Uma das técnicas mais clássicas para a segmentação de imagens é a de *threshold*, onde a imagem é avaliada conforme os tons presentes. Essa técnica foi usada com sucesso por Zhu et al. (2003) para a classificação de fases presentes em ligas de alumínio.

Recentemente, porém, com o desenvolvimento nas áreas de inteligência artificial e *machine learning* novos modelos permitem a classificação de imagens considerando não somente seus dados de tonalidade, mas também de textura e forma.

4.7.1.1 Técnica de threshold

A técnica de *threshold* se baseia, geralmente, na conversão da imagem para tons de cinza e na seleção de limites dos tons de cinza para identificar as diferentes fases presentes no revestimento. Segundo Weszka e Rosenfeld (1978) essa técnica geralmente tem o problema dos resultados medidos serem muito dependentes da pessoa que a esta aplicando e de suas decisões, sendo assim muito subjetiva, fato que dificulta a comparação de resultados entre diferentes autores.

Weszka e Rosenfeld (1978) descrevem diferentes técnicas e abordagens para diminuir a subjetividade do processo. Essas técnicas se baseiam no uso e análise do histograma de tons da imagem e sua forma, propriedades que podem ser usadas para segmentação manual ou automatizada da imagem conforme Kang, Yoo e Jang (2007).

Segundo Weszka e Rosenfeld (1978), as curvas observadas nos histogramas podem ser modeladas como curvas normais, visto que sua forma vem das diferentes formas de ruído presentes durante a aquisição de imagens advindas do equipamento e *softwares* empregados. A sobreposição dessas curvas normais dificulta a segmentação precisa da imagem, visto que pixeis de mesma tonalidade podem representar diferentes regiões, ou no caso de aspersão térmica fases. Kang, Yoo e Jang (2007) propuseram em seu trabalho o uso do modelamento normal das curvas para uma segmentação mais precisa. Um exemplo de sobreposição de curvas e o ajuste normal pode ser visto na FIGURA 17.

FIGURA 17 – HISTOGRAMA DE TONS DE CINZA E FUNÇÃO DE DENSIDADE DE PROBA-





FONTE: Traduzido de Naik, Sajid e Kiran (2019).

LEGENDA: a- Curvas de ferrita e perlita facilmente discriminadas; b- Curvas de ferrita, perlita e martensita sobrepostas.

A técnica de *thresholding* foi aplicada por Costa (2018) para análises de revestimento de Al-Cu pelo processo dissimilar. Em seu trabalho obteve-se sucesso na análise de imagens obtidas por microscópio ótico, mas observou-se maior dificuldade ao se tentar analisar imagens obtidas por MEV, devido ao baixo contraste das imagens(alto grau de superposição das curvas de cada fase no histograma). Isso fez com que não fosse possível a medição de óxidos na maior parte dos revestimentos por imagens de MEV. Um exemplo da análise por histogramas de 3 diferentes imagens e sua segmentação correspondente pode ser visto na FIGURA 18.

FIGURA 18 – HISTOGRAMAS DE TONS DE CINZA PARA IMAGENS DE MEV PARA REVES-TIMENTO DE AI-CU POR ARCO ELÉTRICO DISSIMILAR



FONTE: (COSTA, 2018).

LEGENDA: A- Curvas normais de AI e óxidos facilmente discriminadas sobrepondo a curva de AI₂Cu; B- Melhor visualização da curva de AI₂Cu; C - Menor sobreposição das curvas de alumínio e óxidos.

4.7.1.2 Avaliação por machine learning

Ao contrário da técnica de *threshold*, que somente permite a avaliação da quantidade de fases presentes, as diferentes técnicas de *machine-learning* permi-

tem também o reconhecimento de morfologias/estruturas e não somente das fases presentes nelas.

Esse reconhecimento de estruturas tem a vantagem especial de poder ajudar na identificação de morfologias que se destacam pela sua aparência característica, como estruturas eutéticas, eutetóides, martensíticas, bainíticas, etc. Naik, Sajid e Kiran (2019) usaram desse fato para identificar as regiões de perlita, ferrita e martensita de um aço ASTM A36, conseguindo através de 4 diferentes modelos um desempenho maior que 97% em sua identificação.

Infelizmente a comparação dos valores medidos de porosidade e óxidos entre diferentes estudos é complexa na aspersão térmica, visto que não existe uma técnica que dê o valor preciso de porosidade e óxidos dos revestimentos, devido ao problema da subjetividade na medição por técnica de *threshold*, descrito por Kang, Yoo e Jang (2007). Além disso, já foi constatado por Costa (2018) a dificuldade de se avaliar os revestimentos de Al-Cu por processo de arco elétrico dissimilar por MEV.

Sendo assim, uma abordagem por *machine learning* é proposta nesse estudo para permitir uma análise quantitativa dos resultados. Na FIGURA 19 pode ser visto um exemplo de classificação obtida *machine learning* pelo modelo de floresta aleatória utilizando 200 árvores.

FIGURA 19 – CLASSIFICAÇÃO POR *MACHINE LEARNING* POR MODELO DE FLORESTA ALEATÓRIA COM 200 ÁRVORES DE REVESTIMENTO DE AI-Cu POR ASP DISSIMILAR



FONTE: (COSTA, 2018). LEGENDA: Vermelho: Cu, Amarelo: Al, Lilás: Al_xCu_y, Verde: óxidos.

4.7.2 Modelo matemático e treino

O algoritmo de árvore de decisão é um modelo de segmentação supervisionado. Ou seja, um modelo onde são alimentados dados sobre os quais a resposta esperada é sabida, no caso do escopo desse trabalho a classificação individual de diferentes pixeis da imagem (chamada de classe), como porosidade, óxidos, etc. é dada além de dados como tonalidade de cinza, e outras características obtidas em cima das imagens.

Para tal aplicação uma classificação por píxel foi selecionada. Nessa abordagens diferentes propriedades são avaliadas para cada píxel de classificação conhecida, essas propriedades são passadas para o modelo de *machine learning* que então tenta mapear e descobrir correlações nos dados informados.

Um dos modelos que permite tal aplicação é conhecido como árvore de decisão. Nesse modelo, tem-se o que são chamados de nós, no topo da árvore têm-se os chamados nós raiz, então nós intermediários, e por fim os nós folha. Cada nó representa uma propriedade a ser analisada como critério de decisão para separação dos dados, esse processo então é seguido de nó em nó até que se chegue nas folhas que representam a classificação final.

A árvore de decisão é uma ideia simples. Onde através de várias pequenas decisões se pode atingir bons níveis de generalização do modelo. O maior trabalho do modelo é selecionar as decisões que levem a classificação correta dos dados. Para isso usasse uma medida de impureza, essa se baseia em avaliar qual decisão tomada em cima dos dados irá separar melhor as diferentes classes, ou seja, obter novos nós com menor impureza ou mistura de dados de cada classe avaliada.

Existem duas principais medidas de impureza comumente utilizadas a primeira é conhecida como Gini originalmente proposta por Variabilità (1912) e pode ser observada na EQUAÇÃO 4.1. Outra opção muito usada também é o ganho de informação ou entropia, sua fórmula pode ser vista na EQUAÇÃO 4.2.

$$I_G = 1 - \sum_{i=1}^m p_i^2$$
 (4.1)

$$I_E = -\sum_{i=1}^m p_i \cdot \log_2(p_i) \tag{4.2}$$

Nessas fórmulas o p_i representa a proporção de dados de cada classe no novo nó e m o número de classes. A partir do cálculo das informações de impureza a variação de impureza é avaliada e assim a decisão com a maior redução de impureza é selecionada para aquele nó. Esse processo pode ser feito de duas formas, a primeira se baseia no cálculo da redução de impureza usando todas as propriedades ofertadas ao modelo, e assim, fazer a melhor escolha possível para aquele nó. A outra se baseia

na escolha de propriedades aleatoriamente para serem avaliadas até que uma gere uma redução de impureza considerada suficientemente boa.

Mais informações sobre árvores de decisão podem ser encontradas em Patel e Prajapati (2018). Enquanto mais informações sobre as vantagens e desvantagens de cada método de avaliação de impureza podem ser vistas em Raileanu e Stoffel (2004).

Um exemplo simples de árvore de decisão pode ser visto na FIGURA 20.



FIGURA 20 – EXEMPLO SIMPLES DE ÁRVORE DE DECISÃO

FONTE: Traduzido de Patel e Prajapati (2018)

Por fim outro modelo existente é o de floresta aleatória, esse modelo se baseia no uso de várias árvores criadas através da seleção aleatória dos dados usado para tomar a decisão. Esse modelo tem a vantagem de que seu resultado se assemelha a daquele de um conselho, onde cada árvore oferece sua classificação e um consenso é tomado. Dessa forma, esse algoritmo tende a ter melhor desempenho que o algoritmo de árvore de decisão.

4.7.2.1 O problema de over-fitting

O problema de *over-fitting* ocorre quando o modelo aprende muito bem a classificar os dados de treino, mas usado em novos dados não apresenta poder de generalização. Uma boa comparação fornecida por Bishop (2006) é o ajuste de um

polinômio de grau N»3 sobre dados tirados de uma equação de terceiro grau, um ajuste muito bom pode ser obtido, com a curva passando perto de todos os pontos, mas o ajuste pouco revela sobre a curva estudada. Um exemplo pode ser visto na FIGURA 21, onde fica claro que um polinômio de terceiro grau é o que melhor generaliza os dados e, apesar de um polinômio de grau 9 passar por todos os pontos, ele pouco serve para generalizar o problema.



FIGURA 21 – EXEMPLO DE OVER-FITTING EM POLINÔMIOS

FONTE: (BISHOP, 2006) LEGENDA: Verde:Polinomio original; Vermelho polinomio ajustado de grau M

4.7.2.2 Método de busca em grade

Os modelos de *machine learning*, além de possuírem os parâmetros de ajuste interno que o algoritmo tem que aprender para melhor tentar classificar os dados informados, possuem também parâmetros próprios que definem sua capacidade de generalização, custo computacional e repetibilidade chamados de hiper-parâmetros.

A escolha de hiper-parâmetros pode ser feita de diversas formas, muitas delas baseadas em técnicas eurísticas. Para evitar o processo de experimentar combinações baseado em decisões arbitrárias, outra abordagem pode ser aplicada, onde são estabelecidas faixas de valores para cada parâmetro e assim todas as combinações possíveis são testadas n vezes e tirada assim uma média para avaliar qual combinação de parâmetros leva aos melhores resultados.

A implementação de segmentação por árvores de decisão do modelo CART(*Classification and Regression Tree*) possibilita a escolha de diversos hiper-parâmetros, os quais são apresentados a seguir.

• Estratégia de divisão

Essa opção define qual abordagem o algoritmo usará para selecionar a propriedade para fazer os novos nós. Esse parâmetro tem duas opções disponíveis, melhor e aleatório. Onde no aleatório uma propriedade é selecionada e então testasse se ela pode ser usada para fazer uma divisão satisfatória, que é definida pelos outros hiper-parâmetros, esse processo é repetido até uma divisão satisfatória ser encontrada. Enquanto no melhor todas as propriedades são avaliadas e a de melhor desempenho é a usada.

• Critério de divisão

Qual formula será usada para avaliar a medida de impureza. Duas opções são ofertadas: o critério de Gini e entropia, mais clássicas às árvores de decisão.

· Profundidade máxima da árvore

Quantos nós de profundidade a árvore deve ter no máximo. Esse parâmetro visa reduzir o problema de *over-fitting*, impedindo que o algoritmo faça novos nós até que ele se adapte perfeitamente aos dados de treino, situação que reduz a capacidade de generalização do modelo.

• N° máximo de propriedades

Define o número máximo de parâmetros usados para avaliação da melhor propriedade para divisão. Exemplos de opções ofertadas são: sqrt e log₂ do número total de propriedades dadas, além da opção *None*, que usa todas as propriedades.

Semente para aleatoriedade

Número usado para a geração da aleatoriedade no modelo. O uso de uma semente permite que haja aleatoriedade no modelo, mas que essa se repita entre testes.

• Diminuição de impureza mínima.

O valor mínimo de redução de impureza para que um novo nó seja criado. Esse parâmetro serve para que o algoritmo não faça *over-fitting*.

Peso das classes

Devido ao desbalanceamento do grupo de treino em relação às classes o algoritmo pode dar preferencia a minimizar o erro da classe mais predominante, desconsiderando a outras, ou realizando uma generalização pior para as mesmas, dessa forma uma solução é dar as classes com menor número de pontos um peso maior e assim compensar seu menor número de pontos.

• N° mínimo de pontos por divisão

Semelhante à diminuição de impureza mínima esse parâmetro ter por objetivo impedir o *over-fitting* ao interromper o algoritmo de criar nós que reduzam o poder de generalização do modelo.

• N° mínimo de pontos por folha

Esse hiper-parâmetro tem funcionalidade similar a do item anterior com a diferença de limitar quantos pontos no mínimo um nó deve ter.

Segundo Gomes Mantovani et al. (2018), os hiper-parâmetros de número de pontos mínimos para divisão e por folha são os que mais influenciam a capacidade de generalização das árvores de decisão para o modelo CART. Além disso, em seu trabalho observou-se que valores menores para esses parâmetros geralmente levam a árvores maiores e com melhor desempenho.

Por fim, para avaliação de cada combinação de parâmetros o modelo deve rodar num grupo separado de dados chamado de grupo de validação. Isso é feito, pois, se o teste fosse realizado diretamente nos dados para avaliação final, a busca pelos melhores parâmetros tenderia a escolher os parâmetros melhores àquele grupo, ao invés, de escolher os que resultariam em uma melhor generalização, conforme Nielsen (2015).

4.7.2.3 Método de validação cruzada com k dobras

O treino do modelo sobre o mesmos dados sobre o qual ele será testado é um erro metodológico e leva a problemas de *over-fitting*, conforme o guia de usuário por Scikit-Learn Developers (2020) da biblioteca *scikit-learn*[™], desenvolvida por Pedregosa et al. (2011). Para resolver esse problema, geralmente os dados são divididos em 3 sub grupos de treino, validação e teste. Sendo a função do grupo de validação permitir a comparação entre modelos treinados com diferentes hiper-parâmetros para avaliar a melhor combinação dos mesmos para se obter o melhor classificador. Essa abordagem, porém, reduz a quantidade de dados disponíveis para o treino.

Uma solução para tal problema é o método chamado de validação cruzada com k dobras. Outras soluções e abordagens existem, mas sua discussão se encontra fora do escopo desse trabalho.

A validação cruzada com k dobras se baseia em dividir todos os dados em apenas dois grupos, o de treino e o de teste. Os dados de treino então são dividos em k partes iguais. O modelo então é treinado em k-1 partes do grupo de dados, sendo a última parte utilizada para a validação. Esse processo então é repetido k vezes, sendo que em cada uma delas é trocado o grupo usado para a validação. O desempenho do modelo é então avaliado pela média de todas as iterações. Uma explicação mais visual desse algorítimo pode ser vista na FIGURA 22



FIGURA 22 – DIAGRAMA EXEMPLIFICANDO A VALIDAÇÃO CRUZADA COM 5 DOBRAS

FONTE: Adaptado do guia de usuário por Scikit-Learn Developers (2020), da biblioteca *scikit-learn*[™] desenvolvida por Pedregosa et al. (2011)

Dado que o modelo não teve acesso aos dados da última parte durante o seu treino o erro metodológico é removido e mais dados estão disponíveis para treino, resolvendo ambos os problemas para validação de modelos.

4.7.3 Avaliação da capacidade do modelo

A escolha do método de pontuação dos modelos é de extrema importância para a técnica de *machine learning*, dado seu controle sobre o poder de generalização dos modelos obtidos. Enquanto as medidas de avaliação permitem a compreensão e visualização da capacidade do modelo obtido.

4.7.3.1 Matriz de confusão

A matriz de confusão(C) é um jeito simples e visual de observar o desempenho do modelo no seu trabalho de classificar imagens. Ela é uma matriz quadrada nxn, onde n é o número de classes sendo analisadas. Nas linhas dessa matriz tem-se a classificação correta de cada classe, enquanto nas colunas tem-se a classificação do modelo. Dessa maneira, essa matriz funciona como uma síntese da capacidade de generalização do modelo. Um exemplo para melhor visualização do funcionamento de uma matriz de confusão pode ser visto no QUADRO 1.

	~	

		Classificado			
		Classe A	Classe B		
Real	Classe A Classe B	N° de elementos da classe A classificado como A N° de elementos da classe B classificado como A	N° de elementos da classe A classificado como B N° de elementos da classe B classificado como B		

FONTE: O autor(2021).

4.7.3.2 Método de pontuação f1

A escolha do método de pontuação dos modelos é de extrema importância para a técnica de *machine learning*, visto que controla o poder de generalização dos modelos obtidos.

Um exemplo que pode demonstrar bem isso é o uso do método de acuracidade simples do modelo, onde é avaliada somente a porcentagem de pixeis que o modelo acertou. Em um caso extremo, como, por exemplo, um revestimento de inox, onde tenha ocorrido pouca formação de óxidos e porosidade com um valor de pôr volta de 90% de fase metálica, um modelo poderia aprender que ao classificar todo o revestimento como inox ele teria uma nota de 90%. E, sendo particularmente difícil encontrar parâmetros que confiram uma classificação maior que essa, ele simplesmente tenderia a essa resposta e ficaria preso na mesma e apresentaria nenhum poder de generalização.

Então o modelo obtido teria uma nota de 90%, mas as imagens geradas pelo mesmo seriam inúteis para a avaliação do revestimento, pois elas indicariam 0% de presença das outras regiões. Esse problema é clássico de *machine learning* e acontece quando há um grande desbalanço entre as classes avaliadas, mais sobre os problemas dessa forma de pontuação podem ser vistos em Akosa (2017).

Como revestimentos de aspersão térmica tem valores bem contrastantes entre as regiões presentes em seu revestimento, onde porosidade e óxidos tendem a tomar uma região pequena em comparação a fase metálica, esperasse a existência de um grande desbalanceamento entre as classes nos dados de treino.

Dessa forma, um método de pontuação deve ser escolhido de maneira a incentivar o modelo a ficar longe de tais soluções e assim ampliar seu poder de generalização. Naik, Sajid e Kiran (2019) utilizaram com sucesso em seu trabalho o método conhecido por pontuação f1, pontuação balanceada f ou medida f para lidar com o desbalanceamento na presença de ferrita, perlita e martensita em seus corpos de prova.

Esse método de pontuação se baseia no uso de duas outras medidas chamadas de *recall*(R), ou revocação, e precisão(P). A precisão é avaliada como a proporção entre o número de pontos corretamente classificados de cada classe pelo número total de pontos que foram classificados como elas. Já o *recall* é avaliado como a razão entre os pontos pertencentes a cada classe que foram corretamente classificados como sendo da classe.

A precisão tem a vantagem de castigar os modelos pela detecção de falsos positivos, ou seja, quando vários membros de uma classe são classificados como sendo erroneamente de outra. Isso evita o cenário discutido acima, dado que o modelo que classificar todo o revestimento como inox estaria cheio de falsos negativos.

O *recall*, por outro lado, tem a vantagem de castigar o modelo pela fabricação de falsos negativos. Um caso clássico para aplicação dessa pontuação é na área médica, onde é preferível que um modelo acuse um paciente saudável como possivelmente doente do que classifique um paciente doente como saudável. Dessa forma, essa pontuação tenderia a fazer o modelo a ter uma tendência a classificar mais pessoas como doentes, visto que o oposto poderia ocasionar em perdas humanas.

A pontuação f1 é calculada pela média harmônica das duas pontuações, visando incentivar o modelo a ficar longe de ambas situações de falsos positivos e negativos. As equações para cálculo dessas diferentes pontuações pode ser vista na EQUAÇÃO 4.3, EQUAÇÃO 4.4 e EQUAÇÃO 4.5. Nessas equações o símbolo C_{ij}

representa o elemento i,j da matriz de confusão e m o número de classes.

$$P = \frac{1}{m} \sum_{i=1}^{m} \frac{C_{ii}}{\sum_{j=1}^{m} C_{ji}}$$
(4.3)

$$R = \frac{1}{m} \sum_{i=1}^{m} \frac{C_{ii}}{\sum_{j=1}^{m} C_{ij}}$$
(4.4)

$$f1 = \frac{2 \cdot P \cdot R}{P + R} \tag{4.5}$$

Várias outras técnicas de pontuação já foram desenvolvidas, suas vantagens e desvantagens podem ser encontradas em diversas referências, mas sua discussão se encontra fora do escopo desse trabalho.

4.7.4 Coleta de características para análise

Uma das partes mais importantes para o treino de modelos de *machine learning* é a coleta, preparação e seleção dos dados de treino. A segmentação por píxel não permite que o modelo tenha uma compreensão da imagem, sua textura, bordas, etc. De forma que diferentes características precisam ser providenciados para o modelo para garantir uma melhor generalização. Como exemplo, que podem ser passados ao modelo, estão características que caraterizam textura, bordas, etc.

4.7.4.1 Equalização de histograma

Imagens obtidas de diferentes áreas, distâncias, dias e equipamentos resultam em imagens que possuem diferentes contrastes. Essa diferença de contraste em *machine learning* pode acarretar erros de classificação. Dessa forma, existem técnicas que visam aumentar o contraste em imagens em um conjunto de imagens de forma que a diferença de contraste entre elas seja minimizada.

O histograma de uma imagem é uma distribuição de seus tons de intensidade discretos. Essa distribuição associa cada tom da imagem com o número de pixeis que o possuem.

A equalização de histograma é um método que visa aproveitar todo o espectro de tons da imagem de forma a ampliar seu contraste. Isso é feito pela redistribuição dos tons da imagem de forma que eles fiquem regularmente distribuídos por todo o espectro de tons, visando um histograma cumulativo mais linear o possível. A ideia, é que sendo a distribuição cumulativa linear, a sua derivada seria uma constante e, consequentemente, todos os níveis teriam sua probabilidade equalizada. Um exemplo do funcionamento do algoritmo de equalização pode ser visto na FIGURA 23 e seu resultado sobre uma imagem de MEV pode ser vista na FIGURA 24.

FIGURA 23 – EXEMPLO DE EQUALIZAÇÃO DE HISTOGRAMA



FIGURA 24 – DEMONSTRAÇÃO DO MÉTODO DE EQUALIZAÇÃO DE HISTOGRAMA PARA AUMENTO DE CONTRASTE EM UMA IMAGEM DE MEV DE UM REVESTI-MENTO



FONTE: O autor(2021).

4.7.5 Avaliação de textura por características de Haralick

A avaliação de textura pode revelar muito sobre uma estrutura ou fase em uma imagem sendo muito útil para sua classificação. Textura, porém, é um conceito humano complicado de se traduzir para computadores. Humanos percebem textura pela mudança coloração e brilho nas imagens que veem, além do próprio tato que permite a sensação dos picos e vales da superfície, permitindo a distinção entre texturas suaves ou mais grosseiras. (HARALICK; SHANMUGAM; DINSTEIN, 1973; NAIK; SAJID; KIRAN, 2019; HALL-BEYER, 2017).

Vários métodos existem para a caracterização de uma textura. (HALL-BEYER, 2017). Entre eles um dos sistemas mais usados é conhecido como as características de Haralick, originalmente proposto por Haralick, Shanmugam e Dinstein (1973). Essas características se baseiam na avaliação da Matriz de Coocorrência de Tons de Cinza(Gray Level Co-occurrence Matrix - GLCM) e em cima dessa o cálculo de várias propriedades.

4.7.5.1 GLCM

A GLCM é uma matriz que representa a coexistência de diferentes níveis de tom de cinza dentro de uma imagem ou área da mesma. A matriz possui dimensão $N_g x N_g$, onde N_g é o número de níveis de cinza da imagem analisada e seu tamanho

independente do tamanho da imagem utilizada.

Cada um de seus elementos representa a contagem da existência conjunta de cada par possível dos níveis de cor. Dessa forma, a posição i,j da matriz representa quantas vezes os níveis i e j ocorrem de forma adjacente na área analisada. Para tal avaliação é selecionada uma distância, que define qual o passo que será dado entre os pixeis da imagem, e um ângulo, no qual a coexistência será avaliada.

A GLCM após ser calculada é normalizada de forma que seus valores representem a matriz de probabilidade de coexistência dos diferentes níveis de cinza na região avaliada.

Devido ao jeito que a avaliação da GLCM funciona um fator de importância na análise de textura é a quantificação da imagem. A quantização é um processo de redução da quantidade de níveis de cores que uma imagem possui. Esse é um processo inerente da análise das características de Haralick, esse fato se dá por dois principais fatores.

O primeiro é o custo computacional, para cálculo das características é necessário antes calcular a GLCM, essa matriz possui tamanho $N_g x N_g$, onde N_g é o número de níveis de cor de imagem. Assim sendo, o número de cores presentes na imagem influenciam diretamente no tempo de processamento e memoria utilizada. (HARALICK; SHANMUGAM; DINSTEIN, 1973; NAIK; SAJID; KIRAN, 2019; CLAUSI, 2001; CLAUSI, 2002).

Dessa forma imagens de 16bits, como as coletadas de MEV, tem um custo computacional muito alto para a técnica. Visto que uma GLCM para representar tal imagem teria a dimensão 65.536x65.536 ou 4.294.967.296 itens e logo requereria uma quantia substancial de memória e de tempo de processamento para cálculo das características.

O segundo motivo é o processo pelo qual a GLCM é obtida. No caso de uma imagem de 16 bits com 65536 cores a GLCM teria 65536 x 65536 células, sendo que a maioria dessas teria valor igual a zero, visto que a combinação de muitos níveis não existiria na imagem. Com a redução dos níveis de cinza na imagem, menos células da matriz seriam 0 e assim a matriz é mais representativa da textura. (HALL-BEYER, 2017).

Em seu trabalho Clausi (2002) critica a falta de parâmetro para escolha do nível de quantização utilizado em trabalhos e analisa os efeitos de diferentes níveis de quantização na qualidade do cálculo das diferentes características de Haralick. Em seu estudo foi constatado que quantizações usando acima de 64 níveis já causam grave deterioração dos valores das características.

Além disso, Clausi (2002), recomenda um valor mínimo de 24 níveis para o

cálculo. Sendo que um valor menor também resulta na deterioração das propriedades avaliadas.

Existem muitas técnicas diferentes para quantização de imagens(uniforme, igual probabilidade, *clustering* por *machine learning*, etc). Sendo que cada possui suas vantagens em desvantagens.

Nesse estudo somente a quantização de igual probabilidade foi considerada. Essa é a equalização recomendada no artigo original por Haralick, Shanmugam e Dinstein (1973), devido a sua vantagem de gerar os mesmos valores para cada característica independentemente dos níveis de quantização.

Essa quantização se baseia na aplicação de uma equalização do histograma da imagem e, em sequência, de uma quantização uniforme. Essa técnica resulta em um histograma mais horizontal o possível na imagem resultante, o que explica seu nome, visto que ela objetiva que todos os tons possuam a mesma probabilidade. Na FIGURA 25 é mostrado o efeito dessa quantização na imagem e seus histogramas.

A comparação entre a imagem equalizada e sua versão quantizada para um revestimento está apresentada na FIGURA 26.

FIGURA 25 – EXEMPLO DE QUANTIFICAÇÃO DE IGUAL PROBABILIDADE



(b) Quantizada 32 níveis





FONTE: O autor(2021).
FIGURA 26 – DEMONSTRAÇÃO DO MÉTODO DE QUANTIZAÇÃO DE UM REVESTIMENTO DE 256 PARA 32 NIVEIS



FONTE: O autor(2021).

4.7.5.2 Seleção de tamanho de janela

A propriedade de textura advêm de uma imagem ou área da mesma, de forma que, um píxel da imagem não pode ter associado a si um valor de textura. Assim sendo, para que cada píxel da imagem possua um valor de textura, é feito o uso de uma janela quadrada que percorre a imagem. Essa janela tem dimensão nxn, sendo n um valor impar visando que haja um píxel central, a esse píxel central são então atribuídos os valores de textura daquela janela.

Essa aplicação já foi usada com sucesso na análise metalúrgica de aço por Naik, Sajid e Kiran (2019), além de já ter visto seu uso em várias outras áreas como reconhecimento de regiões urbanas em imagens de satélites. (HAN et al., 2011; ZHANG et al., 2017; PUISSANT; HIRSCH; WEBER, 2005; CLAUSI, 2001).

A escolha do tamanho de janela é de alta importância, visto que, uma janela pequena terá pouca informação sobre a textura e consequentemente não possibilitara a identificação da região analisada. Enquanto uma janela muito grande faz com que varias regiões diferentes estejam na área avaliada novamente dificultando a classificação. (HALL-BEYER, 2017; PUISSANT; HIRSCH; WEBER, 2005). Logo, um equilíbrio deve ser encontrado onde o tamanho de janela contenha informação suficiente da área desejada e seja o menor possível.

No caso da análise de imagens de aspersão térmica esse tamanho será definido pelas regiões de poros e óxidos, devido a seu menor tamanho nas imagens de

seção de revestimentos.

Em seu trabalho Naik, Sajid e Kiran (2019) conseguiu otimizar o tamanho de janela para análise de diferentes estruturas presentes no aço através da comparação da efetividade de classificação de cada modelo treinado com janelas de diferentes tamanhos.

Outra abordagem possível é pelo cálculo do coeficiente de variação de uma das características de textura para todas as classes usando diferentes tamanhos de janela e plotar os resultados de forma a observar quando os valores se estabilizam, e assim escolher o menor valor de janela onde os valores das diferentes classes tenham se estabilizado, esse método já foi empregado com sucesso na análise de imagens de satélites por Puissant, Hirsch e Weber (2005), Anys e He (1995) e Anys, Abdou et al. (1994).

Por fim, devido à necessidade de se analisar a imagem em janelas surge o problema de análise dos pixeis de borda da imagem, sobre os quais não é possível centralizar uma janela devido à falta de dados. Para possibilitar o cálculo das propriedades de tais pixeis foi aplicada sobre a imagem a técnica de *padding* de espelhamento. A qual se baseia em espelhar os pixeis em relação à borda, permitindo assim o posicionamento da janela nos pixeis de borda. (HALL-BEYER, 2017). Um exemplo de tal técnica é apresentado na FIGURA 27.

FIGURA 27 – DEMONSTRAÇÃO DO MÉTODO DE *PADDING* POR REFLEXÃO PARA ANÁ-LISE DAS CARACTERÍSTICAS DE HARALICK Original Padded





FONTE: O autor(2021).

4.7.5.3 Características de Haralick

As características de Haralick são equações que são avaliadas sobre a GLCM, oferecendo assim diferentes informações sobre a textura da imagem, as 14 características originais propostas por Haralick, Shanmugam e Dinstein (1973) estão demonstradas no seção 2.

A décima quarta característica de haralick, coeficiente de correlação máxima é considerada computacionalmente instável. (LÖFSTEDT et al., 2019; COELHO, 2013). Sendo a sua estabilidade dependente de cada aplicação, ou seja, da textura avaliada e janela escolhida, assim sendo, o uso dessa característica geralmente é definido conforme a execução do código apresentar problemas ou não.

Notação	Característica	Fórmula
F ₁	Segundo momento angular	$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \{p(i,j)\}^2$
F ₂	Contraste	$\sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{\substack{i=1\\N_g N_g}}^{N_g} \sum_{j=1}^{N_g} p(i,j) \right\}, i-j = n$
F ₃	Correlação	$\frac{\sum\limits_{i}\sum\limits_{j}(ij)p(i,j)-\mu_{x}\mu_{y}}{\sigma_{x}\sigma_{y}}$
F ₄	Soma dos quadrados: Variância	$\sum_{i}^{N_g} \sum_{j}^{N_g} (i-\mu)^2 p(i,j)$
F_5	Momento da diferença inversa	$\sum_{i}^{N_{g}} \sum_{j}^{N_{g}} \frac{1}{1 + (i - j)^{2}} p(i, j)$
F ₆	Média da soma (μ_{x+y})	$\sum_{k=2}^{2N_g} ip_{x+y}(i)$
F ₇	Variância da soma*	$\sum_{k=2}^{2N_g} (i - F_6)^2 p_{x+y}(i)$
F ₈	Entropia da soma	$-\sum_{k=2}^{2N_g} p_{x+y}(i) log(p_{x+y}(i))$
F ₉	Entropia	$-\sum\limits_{i}^{N_g}\sum\limits_{j}^{N_g}p(i,j)log(p(i,j))$
F ₁₀	Variância da diferença	$\sum_{k=0}^{N_g-1} i^2 p_{x-y}(i)$
F ₁₁	Entropia da diferença	$-\sum_{k=0}^{N_g-1} p_{x-y}(i) log(p_{x-y}(i))$
F ₁₂	Informação da medida de correlação I	$\frac{H_{XY} - H_{XY1}}{max(H_X, H_Y)}$
F ₁₃	Informação da medida de correlação II	$\sqrt{1 - e^{-2(H_{XY2} - H_{XY})}}$
F ₁₄	Coeficiente de correlação máxima	$\sqrt{\lambda_{m2}}$, sendo λ_{m2} o segundo maior autovalor de $Q(i,j) = \sum_{k}^{N_g} \frac{p(i,k)p(j,k)}{p_x(i)p_y(k)}$

QUADRO 2 – CARACTERÍSTICAS ESTATÍSTICAS TEXTURAIS DE SEGUNDO GRAU DE HARALICK

FONTE: Adaptado de Haralick, Shanmugam e Dinstein (1973) e Löfstedt et al. (2019) NOTA: Notação: p(i, j): valor da posição i, j da GLCM normalizada; N_g : níveis de quanti-

Notaçao: p(i, j): valor da posição i, j da GLCM normalizada; N_g : niveis de quantização da imagem; μ : média dos pixeis da imagem; $p_{x+y}(k) = \sum_i^{N_g} \sum_j^{N_g} p(i, j)$, $i + j = k; p_{x-y}(k) = \sum_i^{N_g} \sum_j^{N_g} p(i, j), |i - j| = k; p_x(i) = \sum_j^{N_g} p(i, j);$ $p_y(j) = \sum_i^{N_g} p(i, j); \mu_x = \sum_i^{N_g} ip_x(i); \mu_y = \sum_j^{N_g} jp_y(j); \mu_{x-y} = \sum_{k=0}^{N_g-1} kp_{x-y}(k);$ $\sigma_x = \sum_i^{N_g} (i - \mu_x)^2 p_x(i); \sigma_y = \sum_j^{N_g} (j - \mu_y)^2 p_y(j); H_X = -\sum_i^{N_g} p_x(i) log(p_x(i));$ $H_Y = -\sum_j^{N_g} p_y(j) log(p_y(j)); H_{XY} = -\sum_i^{N_g} \sum_j^{N_g} p(i, j) log(p(i, j)); H_{XY1} = -\sum_i^{N_g} \sum_j^{N_g} p(i, j) log(p_x(i)p_y(j)); H_{XY2} = -\sum_i^{N_g} \sum_j^{N_g} p_x(i) p_y(j) log(p_x(i)p_y(j)).$ *No artigo original por Haralick, Shanmugam e Dinstein (1973) a variância da soma foi definida com um erro, em seu lugar a fórmula correta usada por Löfstedt et al. (2019) é apresentada.

4.7.6 Seleção de características para treino

Existem vários motivos para se reduzir a quantidade de dados ofertados à modelos de *machine learning*. Entre os mais importantes estão custo computacional e *over-fitting*.

Em questão de custo computacional quanto mais dados são passados ao modelo, mais espaço da memória é requerido e tempo de computação. Além disso, tem se o problema de *over-fitting*. É de interesse que o modelo tenha dados suficiente para conseguir generalizar e ajustar a curva do problema a ser resolvido, mas dados demais permitem que o modelo consiga ajustar seus parâmetros de forma excessiva e comece a perder seu poder de generalização se ajustando mais as peculiaridades dos dados de treino do que ao problema a ser resolver. (NIELSEN, 2015; BISHOP, 2006).

Dessa forma é de interesse selecionar antes do treino do modelo, as características que mais contribuam ao entendimento do problema. Consequentemente, vários algoritmos já foram criados usando diferentes abordagens, mas sempre com o objetivo de avaliar a correlação de certa característica e cada uma das classes a ser estudada. Um desses algoritmos é o ReliefF.

O algoritmo Relief foi originalmente desenvolvido por Kira e Rendell (1992) com o objetivo de criar uma abordagem mais prática de selecionar os dados a serem usados favorecendo o uso de métodos estatísticos, em contrapartida, a uma abordagem eurística, e assim tentar melhorar o desempenho de modelos de *machine learning* ao oferecer um valor numérico de rank para as características avaliadas. O algoritmo inicial se baseava em problemas com duas classes e tinha problemas para lidar com dados ruidosos. Porém, uma nova versão foi desenvolvida por Kononenko (1994), esse novo algoritmo hoje é conhecido como ReliefF, mais sobre seu funcionamento pode ser encontrado em Kononenko (1994) e Robnik-Sikonja e Kononenko (2003).

Outro passo que pode ser tomado para reduzir a quantidade de dados é diferenciar entre os tipos de dados oferecidos para o modelo. Para a obtenção de dados diversos filtros podem ser aplicados sobre as imagens, cada um desses filtros pode ser classificado como sendo de um diferente tipo. Essa abordagem tem por objetivo não somente escolher dados que tenham a maior correlação com as classes a serem analisadas, mas também garantir que cada filtro adicionado esteja de fato adicionando novas informações.

Por exemplo, filtros de remoção de ruído tendem a ter um maior valor de correlação que outros filtros, mas a adição de vários filtros desse tipo é ineficiente, já que eles carregam a mesma informação sobre o problema. Consequentemente, é mais interessante passar ao modelo menos filtros de remoção de ruído para poder incluir outros filtros, que apesar de sua menor correlação, ofereçam novas informações para o

modelo.

Essa abordagem pode ser feita sobre as características de Haralick, conforme as recomendações dos trabalhos de Clausi (2002) e HAN et al. (2011). Em seu trabalho Clausi (2002) conseguiu avaliar a correlação entre as diversas características de Haralick as separando em 3 grupos aos quais ele deu nome de características de suavidade(*smoothness*), uniformidade e correlação, sendo que no terceiro grupo apenas a característica de correlação está presente, devido, segundo as próprias palavras do autor, a sua surpreendentemente falta de correlação com todas as outras características. Por fim tem se o grupo de estatísticas descritivas como chamado por HAN et al. (2011).

5 MATERIAIS E MÉTODOS

5.1 MATERIAIS

Como substrato foi selecionada a liga de alumínio 5052 na forma de chapa, esta foi cortada em vários corpos de prova menores de dimensão 50x75x1,5 mm. A composição da liga, sua resistência e alongamento, oferecidos pelo revendedor, podem ser vistos na TABELA 1.

TABELA 1 – DADOS DA LIGA DO SUBSTRATO DOS CORP	OS DE PROVA
--	-------------

	Liga	Grupo	Zn(%)	Mg(%)	Cu(%)	LE(Mpa)	LR(MPa)	Alongamento(%)
	5052	5xxx	-	2,5	-	60	170	20
- 0								

FONTE: O autor(2021).

Como material de aporte foram usados arame de alumínio puro comercial de 2,5 mm de diâmetro e arame de cobre para fiação elétrica comercial com pureza de 99,99%. A bitola informada do arame de cobre é de 1,5 mm, mas quando medida com um micrômetro se revelou, na verdade, ser de apenas 1,4 mm. A proporção de material alimentada pode ser calculada pela densidade linear(ρ) dos dois arames como pode ser visto na EQUAÇÃO 5.1. O diâmetro do arame está representado por d e ρ representa a densidade do material. Usando valores de densidade do alumínio de 2,7 g/cm³ e para o cobre 8,96 g/cm³ chega-se ao resultado da EQUAÇÃO 5.2.

$$\rho_l = \frac{\pi * d_{arame}^2}{4} * \rho_{arame} \tag{5.1}$$

$$\frac{Cu}{Al} = \frac{\frac{\pi * d_{Cu}^2}{4} * \rho_{Cu}}{\frac{\pi * d_{Al}^2}{4} * \rho_{Al}} = \frac{d_{Cu}^2 * \rho_{Cu}}{d_{Al}^2 * \rho_{Al}} = \frac{(1, 4e^{-1}cm)^2 * 8,96g/cm^3}{(2, 5e^{-1}cm)^2 * 2,7g/cm^3} = 1,04$$
(5.2)

Esse valor pode ser convertido para porcentagem de cobre, levando a uma fração em de 51% de cobre em peso. Tal liga, caso possuísse completa liga metalúrgica do alumínio e cobre, estaria no campo hiper-eutético do diagrama de equilíbrio Al-Cu, se aproximando da composição do intermetálico Al₂Cu(54,08%Cu em peso).

5.2 EQUIPAMENTOS USADOS NA ASPERSÃO

As deposições foram realizadas através de uma fonte Sulzer-Metco LCARE ValuArc[™] 300E integrada a uma pistola Sulzer-Metco Electric Arc Gun LCAG, sistema de controle ValuArc[™] LCACE. A FIGURA 28 mostra os equipamentos utilizados.

FIGURA 28 – EQUIPAMENTO SULZER-METCO VALUE ARC 300E DE ASPERSÃO TÉRMICA ASP UTILIZADO



FONTE: O autor(2021).

O sistema de alimentação de arames desse equipamento foi feito para trabalhar com arames de até 1,6 mm de diâmetro, de forma que o sistema de alimentação dos arames, componentes internos da pistola e o bico da pistola de aspersão tiveram de ser adaptados para a aplicação. O diâmetro da tubulação interna da pistola e do bico foi aumentada com o uso de uma furadeira de bancada e uma broca de 3 mm. Para alimentação de arame foi necessário expandir o canal angular da roldana de alimentação inferior, essa adaptação foi feita preservando o angulo da roldana, as dimensões finais podem ser vistas no Anexo A. O furo do bico da pistola foi expandido para ter um diâmetro de 9,5 mm para permitir a passagem do arame de alumínio sem que o mesmo entrasse em contato com o bico, evitando assim, que o arame de alumínio soldasse na pistola durante as aspersões.

5.3 AVALIAÇÃO DAS CONDIÇÕES DE DEPOSIÇÃO

Devido ao uso do processo de deposição dissimilar de Al-Cu por arco elétrico, efeitos que geralmente não são considerados nesse processo de aspersão térmica podem ter uma grande influência na morfologia observada nos revestimentos. Assim, é de interesse estudar a influência dos mecanismos de formação de partículas nos diferentes eletrodos, da distribuição do alumínio e cobre no jato de aspersão e da dispersão do jato para melhor compreender as propriedades observadas nos revestimentos.

5.3.1 Análise auxiliada pelo DPV 2000 particle diagnostics system™

Para uso do *DPV 2000 particle diagnostics system™* a pistola de aspersão foi fixada sobre uma bancada a uma distância de 100 mm da câmera do equipamento. Essa configuração pode ser vista na FIGURA 29.

FIGURA 29 – CONFIGURAÇÃO DPV™ E PISTOLA DE ASPERSÃO PARA MEDIÇÃO DAS PARTÍCULAS



FONTE: O autor(2021).

Para cada experimento a máquina foi calibrada para os parâmetros desejados e esperou-se pela estabilização do arco, dando início, então, ao processo de medição pelo equipamento. Para cada configuração o arco foi mantido aberto até que as características de temperatura, velocidade e diâmetro de 500 partículas fossem obtidas.

5.4 METODOLOGIA EXPERIMENTAL

Nessa seção são discutidos a metodologia para escolha dos parâmetros de controle para produção dos corpos de prova e para análise por DPV, além dos passos tomados para realizar a análise estatística dos lados levantados.

5.4.1 Planejamento experimental ortogonal de Taguchi L8

A escolha dos parâmetros de controle foi feita baseado nos resultados por Costa (2018) e Moreira (2019). Além dos parâmetros já antes avaliados por esses estudos, foi adicionado a polaridade dos arames. Essa decisão se deu, pois, em aplicações normais a polaridade não afeta o revestimento, dado que ambos arames possuem a mesma composição, mas no caso do ASP dissimilar com arames de espessuras e

materiais diferentes esse parâmetro pode influenciar nos resultados observados, e assim foi considerado no planejamento robusto.

Os parâmetros de controle selecionados para a análise podem ser vistos no QUADRO 3.

QUADRO 3 – FATORES DE CONTROLE PARA ANÁLISE DE TAGUCHI

Fatores Polaridade Arame Alumínio Corrente Pressão Tensão Pré-aquecimento Distância

FONTE: O autor(2021).

Os fatores de resposta a serem avaliados dos revestimento e das condições de deposição podem ser vistos no QUADRO 4.



QUADRO 4 – FATORES DE RESPOSTA PARA ANÁLISE DE TAGUCHI

FONTE: O autor(2021).

Os valores escolhidos para os níveis de cada parâmetro de controle estão apresentados no QUADRO 5. Os valores selecionados de tensão, pressão e corrente foram obtidos experimentalmente, observando-se a estabilidade do arco e o funcionamento do equipamento.

QUADRO 5 – VALORES DOS NÍVEIS DOS F	ATORES DE CONTR	OLE OBTIDOS EXPERI-			
MENTALMENTE DO ARRANJO ORTOGONAL DE TAGUCHI L8 ADAPTADO					
Parâmetros	Nívois				

Parâmetros	Νίν	veis
Polaridade Arame Al	cátodo	ânodo
Corrente	150 A	200 A
Pressão	45 psi	55 psi
Tensão	30 V	40 V
Pré-aquecimento	T.Amb	120 <i>°</i> C
Distância	150 mm	250 mm
	Parâmetros Polaridade Arame Al Corrente Pressão Tensão Pré-aquecimento Distância	ParametrosNivPolaridade Arame AlcátodoCorrente150 APressão45 psiTensão30 VPré-aquecimentoT.AmbDistância150 mm

FONTE: O autor(2021).

O arranjo de Taguchi então adaptado para 6 fatores de controle para análise das propriedades dos revestimentos está apresentado na TABELA 2.

TABELA 2 – EXPERIMENTOS DO ARRANJO ORTOGONAL L8 DE TAGUCHI ADAPTADO PARA 6 PARÂMETROS PARA ANÁLISE DOS REVESTIMENTOS

Nº	Polaridade Arame Al	Corrente (A)	Pressão (psi)	Tensão (V)	Pré.Aq (℃)	Distância (mm)
1	-	150	45	30	T.Amb	150
2	-	150	45	40	120	250
3	-	200	55	30	T.Amb	250
4	-	200	55	40	120	150
5	+	150	55	30	120	150
6	+	150	55	40	T.Amb	250
7	+	200	45	30	120	250
8	+	200	45	40	T.Amb	150

FONTE: O autor(2021).

Na TABELA 3 é apresentado o arranjo de Taguchi adaptado para 4 fatores de controle para análise das condições de deposição. Os parâmetros de pré-aquecimento e distância foram desconsiderados nessa análise, visto que não há nela um substrato a ser analisado.

Experimento	Polaridade Al	Corrente(A)	Pressão(psi)	Tensão(V)
1	-	150	45	30
2	-	150	45	40
3	-	200	55	30
4	-	200	55	40
5	+	150	55	30
6	+	150	55	40
7	+	200	45	30
8	+	200	45	40

TABELA 3 – EXPERIMENTOS DO ARRANJO ORTOGONAL L8 DE TAGUCHI ADAPTADO PARA 4 PARÂMETROS PARA ANÁLISE POR DPV™

FONTE: O autor(2021).

A partir do planejamento de Taguchi foram aplicadas análises estatísticas para avaliação dos resultados obtidos. Essas análises foram realizadas com auxílio do *software* Minitab[™] e da linguagem R, desenvolvida por R Core Team (2020). As análises a serem feitas estão listadas a seguir:

- Análise de variância(ANOVA) para identificar quão significativo é o efeito de cada parâmetro sobre os diferentes fatores de resposta;
- Análise de variância por permutação para lidar com as limitações da ANOVA clássica;
- Ranqueamento para identificar quais fatores de controle tem o maior efeito sobre os fatores de resposta;
- HSD(*Honestly Significant Difference* ou teste de Tukey). O teste de diferença honesta significante é um teste *post hoc* que permite avaliar se existe diferença estatística entre níveis e assim os agrupar conforme sua significância.

Antes de aplicar as análises um estudo de normalidade foi feito para checar se os dados respeitavam a suposição de normalidade requerida para o uso da ANOVA.

Apesar de a ANOVA ter a suposição de normalidade esse método é geralmente considerado robusto para dados não normais, e já teve sua robustez testada por Blanca et al. (2017) que teve resultados positivos. Ainda assim, os dados coletados quebraram a suposição e, dessa forma, a análise ANOVA foi realizada juntamente a uma PERMANOVA considerada mais robusta para análises com dados não normais.

A ANOVA, testes de normalidade e teste de Tukey foram realizados usando o *software* Minitab[™]. A ANOVA foi feita usando o ajuste de modelo linear generalizado, enquanto o teste de normalidade aplicado foi o de Anderson-Darling, proposto por Anderson e Darling (1952).

A PERMANOVA foi feita através da linguagem R, desenvolvida por R Core Team (2020) usando da biblioteca ImPerm, desenvolvida por Wheeler e Torchiano (2016).

5.4.2 Preparo dos corpos de prova

O processo de jateamento foi realizado objetivando-se um grau de limpeza SA3(limpeza por jateamento abrasivo ao metal branco), para o mesmo foi feito o uso de padrões oferecidos pela norma SABESP NTS 085 (2001) para comparação. No processo de jateamento foi aplicada uma pressão de 55 psi a uma distância de jateamento de 150 mm usando como abrasivo óxido de alumina reciclado de 35 mesh, de forma que o grau de limpeza SA3 foi atingido em todos os corpos de prova.

Em seguência os corpos de prova foram levados para a aspersão. Cada corpo de prova passou pelo processo com 2 passes verticais e 2 horizontais alternados, como pode ser visto na FIGURA 30.





FONTE: O autor(2021).

Nesse estudo foi optado pelo uso de um mesmo número de passes em todos os corpos de provas. Visto que a outra opção, a de aspergir visando uma espessura especifica, iria requerer a parada do processo e diferentes números de passes para cada configuração usada, o que por fim poderia resultar em diferentes ciclos térmicos para cada corpo de prova. E assim, resultaria em diferentes morfologias em cada um, devido à baixa temperatura de precipitação das ligas de Al-Cu.

Na FIGURA 31, é apresentado um fluxograma das atividades realizadas.



FIGURA 31 – FLUXOGRAMA DOS EXPERIMENTOS

FONTE: O autor(2021).

5.5 ANÁLISES PARA CARACTERIZAÇÃO DO REVESTIMENTO

Para visualização nos microscópios os corpos de prova foram submetidos a preparação metalográfica. Cada corpo de prova foi cortado na mesma região, visando obter regiões que passaram por ciclos térmicos similares, e teve sua seção transversal embutida a frio com resina de poliéster, essa foi então lixada com lixas de 220, 400, 600 e 1200 mesh e foram posteriormente polidos com pasta de diamante de 1 µm até se obter uma superfície espelhada. O embutimento a frio foi feito com o intuito de evitar precipitação no revestimento.

5.5.1 Obtenção de imagens por microscópio ótico

As imagens de microscópio ótico foram feitas no microscópio do Grupo de Engenharia de Superfícies da UFPR. O equipamento se encontra no prédio de Materiais e está aberto ao uso dos estudantes.

Através do microscópio ótico foram obtidas 5 imagens de cada amostra com um aumento de 100 vezes para avaliação de fração de área das fases presentes. Essas imagens foram processadas pela distribuição científica FIJI do software ImageJ, um software de código aberto extensivamente usado para análises científicas. (RUEDEN et al., 2017). A versão utilizada do *software* ImageJ foi a 2.0.0-rc-69 com Java[™] 1.8.0-172 64 bits.

5.5.2 Análise por MEV e EDS

As análises de MEV e EDS foram realizadas através do centro de microscopia eletrônica(CME) da UFPR. As análises podem ser marcadas por formulário online e são um serviço oferecido a comunidade da UFPR.

A técnica aplicada no MEV foi a BSE(*backscattered electron* - Elétrons retro espalhados). Foram realizadas 5 imagens de cada amostra usando-se uma ampliação de duas mil vezes, com uma tensão de feixe 15 kV.

O mapeamento químico por EDS dos elementos presentes no revestimento foi realizado obtendo-se também o espectro de soma dos elementos presentes no revestimento. Para cada amostra foi obtido 1 mapa com uma ampliação de duas mil vezes para melhor observação das fases presentes e a distribuição dos elementos no revestimento.

Além disso, foram selecionadas 3 imagens entre as imagens de MEV dos revestimentos para a obtenção de um EDS de linha. Essa linha passa através das panquecas de alumínio e cobre, de forma a permitir a visualização do gradiente de composição entre as lamelas depositadas.

Por fim diversas regiões foram selecionadas em diferentes imagens para fazer EDS em ponto para melhor compreender a composição das fases presentes.

5.6 ANÁLISE DE MICROESTRUTURA E FASES POR MACHINE LEARNING

Para análise quantitativa dos corpos de prova foi feito o uso de um segmentador baseado em *machine learning*. Essa análise foi realizada em duas etapas, uma primeira para avaliar a viabilidade do uso de *machine learning* para avaliar revestimento de aspersão térmica e uma segunda visando melhorar o desempenho de classificação usando de técnicas mais complexas através da linguagem Python[™] e suas bibliotecas.

5.6.1 Análise de viabilidade da técnica de *machine learning* através do *plugin Trainable Classification Weka* do *software* ImageJ

Essa primeira análise, sendo mais simples, foi feita usando o *plugin Weka Treinable Segmentation* criado por Arganda-Carreras et al. (2017) do *software* ImageJ criado por Rueden et al. (2017). Para a auxiliar foi feito também o uso do *software* WEKA[™] versão 3.8.4 desenvolvido por Hall et al. (2009).

O classificador foi treinado usando a primeira imagem de microscopia ótica com 500 vezes de aumento de cada amostra e depois foi usado para classificar as outras automaticamente através do uso de uma macro escrita na linguagem própria do *software* ImageJ.

Para essa primeira análise os dados levantados das imagens foram dividas em 2 grupos, um de treino e outro de teste com 25% dos dados. O modelo foi treinado no primeiro grupo no *software* ImageJ, esse então foi exportado para o *software* WEKA[™], onde o desempenho do modelo foi testado no segundo grupo. Nessa fase não foram usadas as técnicas de pré-tratamento da imagem, seleção de características ou busca em grade, visto que seu objetivo era avaliar a viabilidade da análise por *machine learning* e comparar os resultados obtidos com uma análise feita usando métodos

mais robustos através da linguagem de programação Python™, a qual permite maior liberdade nos procedimentos realizados.

A análise usando o ImageJ, assim, se limitou nas funcionalidades já disponíveis no próprio *sofware*. Dessa forma, a análise foi feita usando a configuração padrão do *software* para as características coletadas e o modelo usado foi o algoritmo padrão *Fast Random Forest*, com o uso de 200 árvores. O classificador foi treinado com uma imagem de cada amostra através da seleção manual das diferentes regiões, fases e morfologias presentes no revestimento. Após o treinamento o segmentador foi aplicado às outras imagens de cada amostra para avaliar a fração em área da mistura, intermetálicos, porosidade, óxidos e lamelas de alumínio e cobre nos revestimentos.

Por fim as imagens de classificação obtidas passaram por um pós-tratamento de suavização para reduzir o erro de sal e pimenta observado. O tratamento foi realizado usando a função *smooth* do *software* ImageJ.

5.6.2 Análise por machine learning através da linguagem Python™ e suas bibliotecas

A análise por Python[™] foi realizada em cima das imagens de MEV devido a sua melhor qualidade visual. Para essa análise foi usado o Python[™] 3.7.7 com auxílio de diversas bibliotecas, as quais são descritas nas subseções a seguir.

5.6.3 Pré-tratamento das imagens para treino

Nesse trabalho foi empregada a técnica de equalização de histograma que visa deixar o histograma cumulativo da imagem o mais perto possível de uma reta, visando o melhor preenchimento de toda a extensão dos níveis de cinza disponíveis e assim obter um melhor contraste.

A equalização foi feita usando uma função de quantização escrita em Python™ baseada no algoritmo por Haralick, Shanmugam e Dinstein (1973) usando 256 níveis. Dessa maneira a imagem foi convertida para 8 bits enquanto teve seu histograma equalizado. A função está disponibilizada no Anexo B.

5.6.3.1 Cálculo das características de Haralick

Para cálculo das características de Haralick as imagens já equalizadas foram quantizadas para 32 níveis. Nesse trabalho foi utilizada a quantização por igual probabilidade, devido a sua vantagem de gerar os mesmos valores para cada característica independentemente dos níveis de quantização, o algoritmo dessa está disponível no artigo de Haralick, Shanmugam e Dinstein (1973) e foi implementado em Python[™], o código resultante pode ser visto no Anexo B.

Para cálculo da GLCM nesse estudo foram apenas consideradas a distância de um píxel e ângulo de zero graus de forma similar aquela usada por Naik, Sajid e Kiran (2019). A GLCM após ser calculada foi normalizada de forma que seus valores representam a matriz de probabilidade de coexistência dos diferentes níveis de cinza na região avaliada.

Observadas as imagens colhidas por MEV os tamanhos de janela escolhidos para otimização foram todos os números impares de 3 a 25. O menor tamanho de opções de janela escolhidos se deu a dimensão muito pequena dos poros e óxidos obtidos. Nesse trabalho foi usada a abordagem de cálculo do coeficiente de variação das propriedades para seleção da melhor janela, visto que ela diminui o número de treinos necessários dos modelos e resulta em um hiper-parâmetro a menos para ser considerado na procura de grade reduzindo, assim, consideravelmente a quantidade de tempo de processamento necessário.

O processo de escolha do tamanho de janela foi realizado em apenas uma imagem devido ao alto custo computacional do cálculo das características de Haralick de forma que após selecionado o tamanho de janela ideal esse foi usado para cálculo das características de Haralick das outras imagens.

Por fim, foi aplicada sobre as imagens a técnica de *padding* de espelhamento, a qual se baseia de espelhar os pixeis em relação à borda, permitindo assim o posicionamento da janela nos pixeis de borda. (HALL-BEYER, 2017).

Para tanto o cálculo da GLCM tal como as características de Haralick foi usada a biblioteca de visão computacional Mahotas, desenvolvida e mantida por Coelho (2013). No cálculo das características a décima quarta característica não foi avaliada devido ao problema de instabilidade presenciado durante o uso das menores janelas.

Adicionalmente, devido ao alto custo computacional da obtenção da GLCM e cálculo das características de Haralick, foi feito o uso da biblioteca padrão do Python[™] *multiprocessing*, de forma que cada imagem a ser avaliada foi divida em 8 partes iguais enviadas a diferentes processadores lógicos, de forma a tentar diminuir o tempo requerido para obtenção de todos os dados.

5.6.4 Escolha de características para treino por ReliefF

Para cálculo do ranqueamento por ReliefF das características de treino foi usada a implementação *scikit-rebate* versão 0.61 em Python[™] por Urbanowicz et al. (2017) em cima dos dados de treino.

Para realizar a escolha entre filtros de mesma categoria, feito nesse trabalho, mais funcionalidade foi adicionada a classe ReliefF da biblioteca *scikit-rebate*. Para tanto, foi necessária a produção de uma *wrapper class* para permitir a comunicação entre os códigos da biblioteca *scikit-learn*™ e *scikit-rebate* modificada. O código resultante pode ser encontrado no Anexo C.

O algoritmo foi rodado sobre os dados usando os 100 valores vizinhos mais próximos.

Os filtros avaliados e suas categorias podem ser vistos no QUADRO 6. Os filtros gerais avaliados foram selecionados baseado nos filtros oferecidos pelo *plugin Trainable Weka Segmentation* do *software* ImageJ.

Filtros gerais			
	Média		
	Minimo		
Remoção de ruído	Máximo		
	Mediana		
	Borrão gaussiano		
	Sobel		
Detecção de borda	Variância		
	Diferença de Gauss		
Filtros úr	nicos		
Avaliação de textura	Gabor		
Avaliação de informação	Entropia		
Remoção de ruído preservando bordas	Bilateral		
Remoção de ruídos adaptado a forma	Difusão anisotrópica		
Características de Ha	aralick da GLCM		
Madidas da supvidada	Contraste		
	Momento da diferença inversa		
Modidas do uniformidado	Entropia		
	Segundo momento angular		
Medidas de correlação	Correlação		
	Média da soma		
Estatísticas descritivas o outros	Variância da soma		
	Diferença da variância		
	Soma dos quadrados da variância		

QUADRO 6 – SEPARAÇÃO EM CATEGORIAS DOS FILTROS E CARACTERÍSTICAS USADAS PARA TREINO DO MODELO DE *MACHINE LEARNING*

FONTE: O autor(2021).

Para cálculo de todas as características, exceção às de Haralick, a difusão anisotrópica e variância foi usada a biblioteca *scikit-image*[™] versão 0.18.dev0, desenvolvida por Walt et al. (2014).

A difusão anisotrópica foi calculada usando a biblioteca científica *Medpy-Medical Image Processing in Python™* versão 0.4.0. O filtro de variância foi avaliado usando a biblioteca *OpenCV*[™] versão 3.4.2 para Python[™], desenvolvido por Bradski (2000). Para tal foi usado o modulo *ndimage.filters* para acesso à função de filtro genérico para criar o filtro de variância.

As outras características de Haralick não presentes no QUADRO 6 não são tão aplicadas quanto as outras, conforme Clausi (2002). E, dessa forma, apenas as características mostradas foram consideradas para uso no treino dos modelos.

Os parâmetros usados para o cálculo de todos os filtros, exceto os de Haralick, estão apresentados no QUADRO 7

Ca	itegoria	Característica	Parâmetros do filtro
		Média	
	Domocão	Minimo	
ais	de ruído	Máximo	$r_{kernel} = 2$
gera		Mediana	
so		Borrão gaussiano	
-ilt	Dotocoão	Sobel	-
	de borda	Variância	$r_{kernel} = 2$
		Diferença de Gauss	$\sigma_{inferior} = 2$
		Gabor	$\xi = 0.35, \Theta = 0, \sigma_x = \sigma_y = 2$
sos		Entropia	$r_{kernel} = 2$
inic Tiltr		Bilateral	$r_{kernel} = 25, \sigma_{cor} = 50, \sigma_{espacial} = 3$
- `		Difusão anisotrópica	Iterações = 20, κ = 75, γ = 0.15, opção = 3

QUADRO 7 – PARÂMETROS USADOS PARA CÁLCULO DOS DIFERENTES FILTROS USA-DOS PARA TREINO DO MODELO DE *MACHINE LEARNING*

FONTE: O autor(2021).

NOTA: Notação: r_{kernel} : Raio do *kernel* do filtro; $\sigma_{inferior}$: Desvio padrão inferior para cálculo do filtro de diferença de Gauss; σ_{cor} : Desvio padrão no espaço de cores do filtro bilateral; $\sigma_{espacial}$: Desvio padrão no espaço de coordenadas do filtro bilateral; ξ : Frequência espacial da função harmônica do filtro de gabor; Θ : Ângulo de orientação para o filtro de gabor; σ_x : Desvio padrão na direção horizontal para cálculo do filtro de gabor; σ_y : Desvio padrão na direção vertical para cálculo do filtro de gabor; κ : Coeficiente de condutividade do filtro de difusão anisotrópica; γ : Controle da velocidade de difusão do filtro de difusão anisotrópica

5.6.5 Treino e aplicação do modelo matemático

Nessa análise foram usados os algoritmos de segmentação supervisionada de árvore de decisão e floresta aleatória da biblioteca *scikit-learn*[™] do Python[™] desenvolvida por Pedregosa et al. (2011) versão 0.21.3. Essa biblioteca usa o modelo CART. Os hiper-parâmetros de ambos os modelos, juntamente das faixas de valores avaliados para cada parâmetro, estão apresentados no QUADRO 8 e QUADRO 9, respectivamente.

QUADRO 8 – RESUMO DOS HIPER-PARÂMETROS AVALIADOS PARA O MODELO DE ÁR-VORE DE DECISÃO PELA TÉCNICA DE BUSCA EM GRADE COM VALIDAÇÃO CRUZADA COM 5 DOBRAS

Hiper-parâmetro	Valores/Opções
Estratégia de divisão	Melhor, Aleatório
Critério de divisão	Gini, Entropia
Profundidade máxima da árvore	None
N° máximo de propriedades	sqrt, log ₂ , <i>None</i>
Semente para aleatoriedade	0
Diminuição de impureza miníma	0, 1e-3, 1e-2, 1e-1
Peso das classes	Balanceado
N° mínimo de pontos por divisão	2, 10, 20, 40
N° mínimo de pontos por folha	1, 5, 10, 20

FONTE: O autor(2021).

QUADRO 9 – RESUMO DOS HIPER-PARÂMETROS AVALIADOS PARA O MODELO DE FLO-RESTA ALEATÓRIA PELA PELA PRIMEIRA BUSCA EM GRADE COM VALIDA-ÇÃO CRUZADA COM 5 DOBRAS

Hiper-parâmetro	Valores/Opções
N° de árvores	5, 10, 15, 20
Critério de divisão	Gini, Entropia
Profundidade máxima da árvore	None
N° máximo de propriedades	sqrt, log ₂ , <i>None</i>
Semente para aleatoriedade	0
Diminuição de impureza miníma	0, 1e-3, 1e-2, 1e-1
Peso das classes	Balanceado
N° mínimo de pontos por divisão	2, 10, 20, 40
N° mínimo de pontos por folha	1, 5, 10, 20

FONTE: O autor(2021).

Para a escolha de hiper-parâmetros nesse estudo foi aplicada a abordagem de busca em grade, já implementada na biblioteca *scikit-learn*™.

A profundidade máxima da árvore não foi utilizada, visto que outros parâmetros foram usados com o objetivo de controlar o problema de *over-fitting*, como a diminuição de impuridade miníma e número mínimo de pontos por divisão e por folha. Adicionalmente, segundo Gomes Mantovani et al. (2018) os fatores de número mínimo de ponto por divisão e folha são os mais influentes na capacidade de generalização do modelo.

Devido ao alto desbalanceamento esperado na presença das diferentes classes nos revestimentos, foi aplicada a opção balanceada do algoritmo, que avalia automaticamente os pesos de cada classe baseado na sua proporção nos dados de treino. Para avaliação de cada combinação de parâmetros o modelo foi treinado em um grupo separado de dados. Dessa forma, os dados colhidos das imagens foram dividos em 2(75% dos dados para treino e 25% para teste). Enquanto a validação foi obtida por uma técnica chamada de validação cruzada.

Uma validação cruzada com 5 dobras foi usada em paralelo à busca de grade para otimizar os hiper-parâmetros dos modelos. Adicionalmente, foi utilizada a pontuação f1 para avaliar cada um dos modelos obtidos na busca em grade e como avaliação do modelo final. Além disso, para apresentação do desempenho dos modelos foi usada a matriz de confusão.

Depois da análise da primeira procura em grade para o modelo de floresta aleatória uma segunda procura em grade foi realizada para otimizar o número de árvores usados pelo modelo, os hiper-parâmetros e suas faixas de valores podem ser vistos no QUADRO 10. O modelo de floresta aleatória final obtido com esses hiper-parâmetros foi então usado para classificar as imagens de MEV.

QUADRO 10 – RESUMO DOS HIPER-PARÂMETROS AVALIADOS PARA O MODELO DE FLORESTA ALEATÓRIA PELA PELA PRIMEIRA BUSCA EM GRADE COM VALIDAÇÃO CRUZADA COM 5 DOBRAS

Hiper-parâmetro	Valores/Opções
N° de árvores	2 - 50
Critério de divisão	Entropia
Profundidade máxima da árvore	None
N° máximo de propriedades	sqrt
Semente para aleatoriedade	0
Diminuição de impureza miníma	0
Peso das classes	Balanceado
N° mínimo de pontos por divisão	2
N° mínimo de pontos por folha	1

FONTE: O autor(2021).

Por fim as imagens de classificação obtidas passaram por um pós-tratamento de suavização para reduzir o erro de sal e pimenta observado. O tratamento foi realizado usando um filtro *"mode"* com um *kernel* de tamanho 3. Esse procedimento foi realizado usando a biblioteca de manipulação de imagens Pillow para Python[™] versão 7.2.0. Pillow é uma ramificação da biblioteca PIL desenvolvida por Umesh (2012), e é mantida por Clark (2015).

6 RESULTADOS E DISCUSSÃO

Nas próximas seções são apresentadas em ordem os resultados de análise das condições de deposição, morfologia dos revestimentos de forma qualitativa, os resultados das análises por *machine learning* e por fim os resultados obtidos pelo uso do equipamento DPV.

6.1 AVALIAÇÃO DAS CONDIÇÕES DE DEPOSIÇÃO E ADAPTAÇÃO DO EQUIPA-MENTO

A possibilidade de adaptar a máquina para funcionar com o arame de 2,5 mm de Al como descrita na seção 5.2 foi comprovada. A máquina foi adaptada e conseguiu manter um arco estável e constante para a deposição.

Assim foram feitos testes usando os dois arames para avaliar as regiões de funcionamento da fonte de aspersão. Os testes revelaram os valores mínimos e máximos de funcionamento estável da máquina, estes valores foram então usados para definir o arranjo Taguchi apresentado no QUADRO 5 na subseção 5.4.1.

Vale ressaltar que o equipamento funcionou em uma região muito maior, em relação ao parâmetro de corrente, e de maneira mais estável, ou seja, menor números de estouros e paradas do equipamento por falha do arco, com o alumínio como ânodo quando comparado a seu uso como cátodo.

A presença de estouros e paradas durante o processo são gerados pelo contato e soldagem das pontas dos arames, devido à falta de fusão dos mesmos, e consequente aumento de corrente até que os arames se fundam e o arco reabra com um estouro ou a fonte do equipamento alcance seu valor máximo nominal acarretando a parada do processo.

O uso de alumínio como cátodo se revelou complicado com falta de fusão do arame de alumínio e constante parada da máquina, devido a isso foi necessário a redução da taxa de alimentação do equipamento e consequentemente no uso de correntes menores do que aquelas aplicadas em estudos anteriores dessa pesquisa. Em contrapartida, o uso de alumínio como ânodo acabou funcionando no primeiro teste e se mostrou muito mais estável durante o processo.

O melhor funcionamento do equipamento com o alumínio na posição de ânodo pode ser associada aos dois mecanismos presentes em cada arame durante o processo. Devido à polaridade do arco elétrico, esse tem uma atração pelo ânodo de forma que ele o aquece de maneira mais homogênea e sobre uma área, o que pode ter ajudado com o maior diâmetro e, consequentemente, maior quantidade em volume de material do arame de Al. Além disso, o efeito de polaridade faz com que o aquecimento do cátodo seja quase pontual acarretando o seu superaquecimento, o que pode ter ajudado na fusão do arame de cobre que possui maior ponto de fusão do que o alumínio.

Com os arranjos adaptados de Taguchi definidos os experimentos foram realizados, sendo os seus resultados explorados nas próximas seções.

6.2 RUGOSIDADE DOS SUBSTRATOS

A rugosidade obtida para cada corpo de prova está apresentada na TABELA 4. Além da medição de rugosidade uma inspeção visual foi realizada de forma que se confirmou a obtenção de SA3 em todas as amostras.

TABELA 4 – RUGOSIDADE OBTIDA NOS SUBSTRATOS POR JATEAMENTO DE ABRASIVO DE ALUMINA RECLICLADO DE 30 MESH

		-
Amostra	Ra(µm)	Rt(μm)
1	11,75 ± 0,61	99,28 ± 22,52
2	10,37 ± 0,80	94,87 ± 10,95
3	13,83 ± 0,32	111,83 ± 7,10
4	12,42 ± 0,97	92,08 ± 5,48
5	11,93 ± 0,28	96,59 ± 12,76
6	10,76 ± 0,42	89,82 ± 9,44
7	11,35 ± 1,08	85,29 ± 10,28
8	11,71 ± 0,24	98,16 ± 6,36

FONTE: O autor(2021).

6.3 ANÁLISE MORFOLÓGICA DOS REVESTIMENTOS

Nessa seção são discutidas as morfologias observadas nos revestimentos obtidos através da análise das imagens obtidas por microscópio ótico, MEV e EDS, revelando a fases formadas e suas distribuições nos revestimentos.

6.3.1 Imagens de microscópio ótico

As imagens obtidas por microscópio ótico revelaram a formação de diversas fases no revestimento. As fases obtidas e suas distribuições podem ser observadas na FIGURA 32.

FIGURA 32 – IMAGEM DE MICROSCÓPIO ÓTICO DA AMOSTRA 1 MOSTRANDO AS DIFE-RENTES FASES PRESENTES E SUA MORFOLOGIA



FONTE: O autor(2021).

Nos revestimentos pode-se observar lamelas empilhadas de alumínio e cobre com o formato de panquecas paralelas ao substrato, morfologia clássica do ASP. O alumínio se caracterizada pelo seu tom de cinza, e o cobre pelo seu tom verde.

Entre as panquecas são observáveis regiões mais escuras que acompanham o contorno das mesmas, caracterizando os óxidos.

Além dos óxidos nos contornos entre panquecas é observado também a formação de uma região mais acinzentada onde houve a mistura metalúrgica dos dois elementos conforme já descrito e comprovado por Costa (2018) e Moreira (2019).

Ainda se tem a formação de uma região de tonalidade mais clara, quase branca e reflexiva, com poucos riscos nos contornos de partículas. Essa já foi caracterizada como a região onde se tem a formação dos intermetálicos conforme descrito por Costa (2018) e Moreira (2019), que adicionalmente em seus estudos confirmaram a presença dos intermetálicos θ e γ_1 nos revestimentos através de análise por DRX.

Além disso, percebe-se entre as imagens a presença de diferentes colorações nas panquecas alumínio. Essas indicam que além das regiões onde houve a formação mais visível da mistura de alumínio e cobre, pode ter havido também a difusão de cobre para dentro das partículas de alumínio criando um gradiente de concentração dentro dessas.

Imagens dos revestimentos obtidos para cada corpo de prova podem ser vistas no Anexo D.

6.3.2 Imagens de MEV

Nas imagens de MEV foi possível melhor observar a microestrutura do material devido à maior ampliação e ao contraste diferente. As regiões observadas e suas morfologias podem ser vistas na FIGURA 33.



FIGURA 33 – IMAGEM MEV-BSE DA AMOSTRA 5 MOSTRANDO AS DIFERENTES FASES PRESENTES E SUA MORFOLOGIA

FONTE: O autor(2021).

As imagens de MEV confirmam as observações microscópio ótico como já foi notado por Costa (2018) e Moreira (2019). Entre as panquecas de alumínio e cobre observasse a formação de uma região com tonalidade variável, indicando a formação de um gradiente de composição. Ainda nessas regiões, mais próximo do cobre, se localizam os intermetálicos, sendo que o MEV revela sua presença no constituinte eutético. A presença e distribuição do eutético podem ser melhor observadas na FIGURA 34.

A observação do eutético nos contornos de partícula leva à conclusão de que houve a presença de líquido nessas regiões durante a deposição. Além disso, verifica-se na FIGURA 34, que os intermetálicos presentes no constituinte eutético possuem estrutura dendrítica que dá início no cobre e cresce para dentro do alumínio.

FIGURA 34 – IMAGEM MEV-BSE DA AMOSTRA 5 DESTACANDO A PRESENÇA E MORFO-LOGIA DO EUTÉTICO



FONTE: O autor(2021).

Esse crescimento direcional dos compostos intermetálicos indica que a nucleação dos grãos se iniciou na superfície das partículas de cobre crescendo então para dentro do alumínio. Essa observação é interessante, visto que o cobre tem maior ponto de fusão que o alumínio e que no ASP o interior das partículas de alumínio chega em estado líquido no substrato no ASP.

Isso acarreta a conclusão de que a formação de liga nos revestimentos se deu por um mecanismo de difusão solido-liquido entre o alumínio e o cobre. Esse efeito é interessante, dado que o coeficiente de difusão nesse par é maior que na difusão em sólidos, e assim pode ser usado para aumentar a formação de liga por ASP dissimilar.

Adicionalmente, a técnica de MEV permitiu a observação de uma nova fase. Essa se encontra nos contornos das panquecas de alumínio e cobre e possui um aspecto homogêneo por toda a sua extensão categorizando uma fase de AI e Cu e não somente uma região de mistura dos mesmos, de forma que essas regiões caracterizam um intermetálico formado durante a aspersão.

A presença predominante dessa fase com o cobre usado na posição de cátodo pode ser mais uma consequência dos diferentes mecanismos de fusão dos arames.

Também pelas imagens de MEV foi constatado o efeito negativo da presença de óxidos e dessa nova fase intermetálica nos contornos de panqueca para a formação de liga metalúrgica e consequentemente do constituinte eutético. É observado nessas regiões que o gradiente de composição não se forma quando essas fases estão presentes no contorno de panquecas, e logo, há menor formação de liga em todo o

revestimento.

Imagens de MEV dos revestimentos obtidos para cada corpo de prova podem ser vistas no Anexo E.

6.3.3 Análise por EDS

Por EDS foram obtidos o mapeamento dos elementos presentes no revestimento e sua distribuição, sobre os quais podem ser feitas várias observações. Além disso, foram obtidos dados de EDS em linha que demonstram o gradiente de composição nos revestimentos e EDS em ponto que indicam a composição das fases observadas.

6.3.3.1 Mapeamento EDS

Os elementos reconhecidos e mapeados pelo equipamento foram Alumínio(Al), Cobre(Cu), Oxigênio (O) e Carbono(C). A distribuição desses elementos pode ser vista na FIGURA 35.



FIGURA 35 – MAPEAMENTO EDS OBTIDO DA AMOSTRA 5

Na FIGURA 35 pode-se ver dois mapas que indicam elementos que não estavam nos materiais de aporte, O e C. A presença do C se justifica pelo processo de lixamento. O carbono vem da resina de embutimento, que ao ser lixada durante a preparação metalográfica preenche os vazios do revestimento, esse efeito pode ser melhor observado na segunda ampliação da FIGURA 35. Outra fonte poderia ser da pasta de diamante usada durante o processo de polimento através do preenchimento de vazios ou reação com o revestimento formando carbetos.

Outra característica observada é a distribuição de oxigênio no revestimento. No mapeamento observam-se regiões com alta concentração de oxigênio que caracterizam assim as fases óxidas. Além disso, é observável a presença de oxigênio por toda a seção do revestimento, resultante da oxidação da superfície polida, esse efeito é inevitável no processo de preparação metalográfica, visto que a formação de óxidos de alumínio é quase instantânea. Adicionalmente, pode-se observar a predominância de óxidos de alumínio ao se comparar as regiões de alta concentração de oxigênio com os mapas de alumínio e cobre. Nessas regiões verifica-se a sobreposição dos mapas de Al e O, enquanto nos mapas de cobre as mesmas regiões se encontram vazias, resultado que já era esperado dada a maior reatividade do alumínio com o oxigênio.

Por fim pode-se identificar na interface das partículas de alumínio e cobre a presença de uma região menos saturada dos dois materiais, mas com a presença de ambos, revelando a mistura dos dois materiais na forma de liga e do intermetálico Al₂Cu, esse ultimo em sua maior parte no constituinte eutético que é reconhecível pela sua configuração de fases intercaladas na forma de lamelas, a qual é melhor observada na primeira ampliação da FIGURA 35. Ainda nessa região pode ser observada a presença de ambos Al e Cu, como era esperado para a formação do constituinte.

6.3.3.2 EDS em Linha

O mapeamento em linha teve por objetivo melhor observar o gradiente de composição encontrado nos revestimentos entre os contornos de panqueca. No EDS de linha feito na amostra 5, apresentado na FIGURA 36, pode se ver a variação de alumínio e cobre conforme há a transição entre as panquecas dos diferentes materiais.



FONTE: O autor(2021).

Na FIGURA 36 fica comprovada mais uma vez a formação de liga nos contornos de panquecas, além de confirmar o gradiente de composição previamente observado nas imagens de MEV e por microscopia ótica.

6.3.3.3 EDS em ponto

Na FIGURA 37 pode-se observar a composição da nova fase observada nesse estudo nos contornos das panquecas de cobre. A composição pobre em O e rica em Al e Cu acarreta a conclusão da formação de um intermetálico de Al e Cu. Mais provavelmente o θ , Al₂Cu, devido á composição observada de 58,9% Cu e 40,0% Al. Outro fato que contribui para a essa classificação é sua aparência, sendo que essas regiões parecem uma região continua de mesma coloração e aspecto, sem gradientes de composição indicando a formação de uma fase e não somente a difusão entre Al e Cu.

A formação desse intermetálico fora do constituinte eutético é prejudicial ao revestimento devido à sua fragilidade. Além disso, sua posição nos contornos de panqueca prejudica a formação de liga e consequentemente do constituinte eutético.



6.4 ANÁLISE QUANTITATIVA DOS REVESTIMENTOS POR MACHINE LEARNING

Nessa seção são discutidos os resultados obtidos pelas duas diferentes abordagens aplicadas para a análise de machine learning.

6.4.1 Análise de viabilidade do uso de *machine learning* usando o *plugin Trainable Weka Segmentation* do *software* ImageJ

A quantidade de instâncias de cada classe selecionadas e usadas para treino e teste do modelo se encontram na TABELA 5.

TABELA 5 – NÚMERO DE INSTÂNCIAS USADAS NO TREINO E TESTE DO MODELO FAST RANDOM FOREST USANDO O PLUGIN TRAINABLE WEKA SEGMENTATION DO SOFTWARE IMAGEJ

Dados para treino				
Porosidade	16205			
Óxidos	15883			
Cobre	43302			
Alumínio	51610			
Mistura	28609			
Dados para	a teste			
Porosidade	5401			
Óxidos	5294			
Cobre	14436			
Alumínio	17204			
Mistura	9536			
ONTE: O autor(2021)				

FONTE: O autor(2021).

As medidas de desempenho de matriz de confusão e pontuação f1 obtidas pelo modelo de "*Fast Random Forest*" do *plugin Trainable Weka Segmentation* do *software* ImageJ nos dados de treino e teste são apresentadas na TABELA 6 e na TABELA 7, respectivamente.

 REST" NOS DADOS DE TREINO

 Matriz de confusão
 Matriz de confusão normalizada
 f1

TABELA 6 - MEDIDAS DE AVALIAÇÃO E PONTUAÇÃO DO MODELO "FAST RANDOM FO-

	Matriz	z de con	fusão		Matriz d	e cont	usão	norm	alizada	f1
$\begin{bmatrix} Poros \\ 16205 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}$	$\acute{Ox.} 0 \\ 15883 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0$	$\begin{array}{c} Cu \\ 0 \\ 0 \\ 43295 \\ 0 \\ 8 \end{array}$	$\begin{array}{c}Al\\0\\0\\51605\\4\end{array}$	Mis. 0 0 6 5 28597	$\begin{bmatrix} Poros \\ 1, 0 \\ 0, 0 \\ 0, 0 \\ 0, 0 \\ 0, 0 \end{bmatrix}$	$ \begin{array}{c} \acute{O}x. \\ 0, 0 \\ 1, 0 \\ 0, 0 \\ 0, 0 \\ 0, 0 \end{array} $	$\begin{array}{c} Cu \\ 0,0 \\ 0,0 \\ 1,0 \\ 0,0 \\ 0,0 \end{array}$	$\begin{array}{c} Al \\ 0,0 \\ 0,0 \\ 0,0 \\ 1,0 \\ 0,0 \end{array}$	$\begin{bmatrix} Mis. \\ 0, 0 \\ 0, 0 \\ 0, 0 \\ 0, 0 \\ 1, 0 \end{bmatrix}$	1,000

FONTE: O autor(2021).

NOTA: Óx:Óxidos, Mis:Mistura

TABELA 7 - MEDID)AS DE AVALIAÇÃO E PON	ITUAÇÃO DO MODEL	O "FAST RANDOM FO-
REST"	' NOS DADOS DE TESTE		

	Matriz	z de con	Ifusão		Matri	z de co	nfusão	normaliz	zada	f1
$ \begin{bmatrix} Poros \\ 5229 \\ 91 \\ 3 \\ 4 \end{bmatrix} $	$ \begin{array}{c} $	$\begin{array}{c} Cu \\ 3 \\ 111 \\ 13881 \\ 91 \\ 304 \end{array}$	$\begin{array}{c} Al \\ 13 \\ 62 \\ 327 \\ 16880 \\ 647 \end{array}$	$\begin{array}{c} Mis. \\ 3 \\ 46 \\ 162 \\ 206 \\ 8539 \end{array}$	$\begin{array}{c} Poros \\ 0,968 \\ 0,017 \\ 0,000 \\ 0,000 \\ 0,000 \end{array}$		$\begin{array}{c} Cu \\ 0,001 \\ 0,021 \\ 0,962 \\ 0,005 \\ 0,032 \end{array}$	$\begin{array}{c} Al \\ 0,002 \\ 0,012 \\ 0,023 \\ 0,981 \\ 0,068 \end{array}$	$\begin{array}{c} Mis. \\ 0,001 \\ 0,009 \\ 0,011 \\ 0,012 \\ 0,895 \end{array}$	0,955

FONTE: O autor(2021). NOTA: Óx:Óxidos. Mis:Mistura

Esses resultados demonstram que o modelo conseguiu quase perfeitamente se adequar aos dados de treino de maneira que o seu f1 é basicamente 1 até a quarta casa de precisão, porém observasse uma queda na sua habilidade de classificação nos dados de treino que obteve uma pontuação f1 de 0,955.

A partir desses resultados foi comprovada a viabilidade do uso *machine learning* para análises de revestimentos obtidos por aspersão térmica. Com uma pontuação f1 de 0,955 o modelo apresentou uma boa capacidade de generalização e excedeu as expectativas iniciais para uma aplicação limitada com um *software* com pouca liberdade para controle e análise de hiper-parâmetros e outras técnicas empregadas dentro de *machine learning*.

Um fato, porém, se destaca. O valor de *recall* obtido pelo modelo para a análise da mistura de 0,895, presente na posição 5x5 da matriz normalizada. Esse foi o pior desempenho do modelo e revela que o mesmo teve a sua maior dificuldade na generalização dos dados de mistura. Além disso, a grande queda do desempenho do classificador entre os dados de treino e os dados de teste indica que esta ocorrendo o problema de *over-fitting* durante o treino.

Esse resultado, ainda assim, é animador para uma primeira análise e reforça a necessidade dos outros procedimentos usados em *machine learning* para melhorar o desempenho de modelos.

Um exemplo da classificação obtida por esse modelo pode ser visto na FI-GURA 38.

Exemplos de classificação obtidos para cada revestimento podem ser vistos no Anexo F.

FIGURA 38 – CLASSIFICAÇÃO DE IMAGEM DE MISCROSCOPIA ÓTICA OBTIDA PELO MODELO "*FAST RANDOM FOREST*" DO *PLUGIN TRAINABLE WEKA SEG-MENTATION* DO *SOFTWARE* IMAGEJ



FONTE: O autor(2021). NOTA: Vermelho: Porosidade, Verde: Óxidos, Roxo: Cobre, Amarelo: Alumínio, Azul: Mistura

6.4.2 Análise usando Python™ e suas bibliotecas

Nessa seção são avaliadas as técnicas para melhora do desempenho de modelos de *machine learning*.

6.4.2.1 Tamanho de janela selecionado para cálculo da GLCM

Para seleção do tamanho da janela foi usada a técnica proposta por Anys, Abdou et al. (1994). Nela se observa o ponto em que o coeficiente de variação da característica analisada começa a estabilizar, de forma que a menor janela onde o valor estiver estabilizado é escolhida.

Na FIGURA 39 é apresentada a variação do coeficiente de variação para duas características de Haralick. Nela percebe-se que os valores para o momento de diferença inversa de todas as classes avaliadas tendem a se estabilizar mais cedo pela janela de tamanho 9. Enquanto para os valores de contraste a estabilização se dá entre as janelas 9 e 11, com exceção dos valores para óxidos e porosidades que continuam reduzindo até o final do gráfico.

Assim sendo, a janela de tamanho 13 foi escolhida como um meio-termo, visto que a maioria dos valores já se estabilizou antes dela e ela ainda oferece uma janela um pouco maior para melhor avaliar os valores do coeficiente de variação para o contraste da porosidade e dos óxidos, os quais não apresentam tendencia a estabilizar nos tamanhos de janela avaliados.



FONTE: O autor(2021).

A escolha de uma janela menor poderia acarretar uma pior análise dos dados de óxido e porosidade, dado que a janela ainda teria poucos dados para compreensão de sua textura. Enquanto janelas maiores poderiam piorar gradualmente os resultados para as outras classes.

6.4.2.2 Características selecionadas para o treino

Na TABELA 8 é apresentado o ranqueamento dos diferentes filtros considerados para treino dos modelos de *machine learning* segundo o algoritmo ReliefF.

Categoria		Característica	BeliefF	Ranqu	eamento	Selecionado
		Caracteriotica		Geral	Grupo	Colocionado
Características Base		Níveis de cinza	0,36971	5	2	
		Imagem equalizada	0,46900	1	1	\leftarrow
		Média	0,37034	4	3	
	Remoção	Minimo	0,38170	2	1	\leftarrow
rais	de ruído	Máximo	0,17837	18	5	
s ge		Mediana	0,37348	3	2	
iltro		Borrão gaussiano	0,36483	8	4	
ш	Deteccão	Sobel	0,14368	21	3	
	de borda	Variância	0,16406	19	2	
		Diferença de Gauss	0,27469	13	1	\leftarrow
		Gabor	0,01597	23	4	\leftarrow
Filtros únicos		Entropia	0,36203	9	3	\leftarrow
		Bilateral	0,36510	7	2	\leftarrow
		Difusão anisotrópica	0,36569	6	1	\leftarrow
	Medidas de	Contraste	0,24444	14	2	
CM	suavidade	Momento da diferença inversa	0,27651	12	1	\leftarrow
a Gl	Medidas de	Entropia	0,24193	15	1	\leftarrow
ralick d	uniformidade	Segundo momento Angular	0,16355	20	2	
as de Hai	Medidas de correlação	Correlação	0,33021	10	1	\leftarrow
cterístic		Média da soma	0,27766	11	1	\leftarrow
	Estatísticas descritivas	Variância da soma	0,19277	16	2	
Cara	e outros	Diferença da variância	0,11546	22	4	
0		Soma dos quadrados da variância	0,19139	17	3	

TABELA 8 – RANQUEAMENTO POR RELIEFF DAS CARACTERÍSTICAS CONSIDERADAS PARA TREINO

FONTE: O autor(2021).

6.4.2.3 Hiper-parâmetros selecionados para o modelo

Através do processo de procura em grade com validação cruzada da biblioteca *scikit-learn* foram selecionados os hiper-parâmetros ótimos para o treino do modelo. Os hiper-parâmetros escolhidos pela primeira busca em grade para os modelos de árvore

de decisão e floresta aleatória estão apresentados no QUADRO 11 e QUADRO 12.

QUADRO 11 – HIPER-PARÂMETROS SELECIONADOS PARA O MODELO DE ÁRVORE DE DECISÃO PELA TÉCNICA DE BUSCA EM GRADE COM VALIDAÇÃO CRU-ZADA COM 5 DOBRAS

Hiper-parâmetro	Valores/Opções
Estratégia de divisão	Melhor
Critério de divisão	Entropia
Profundidade máxima da árvore	None
N° máximo de propriedades	None
Semente para aleatoriedade	0
Diminuição de impureza miníma	0
Peso das classes	Balanceado
N° mínimo de pontos por divisão	2
N° mínimo de pontos por folha	1

FONTE: O autor(2021).

QUADRO 12 – HIPER-PARÂMETROS SELECIONADOS PARA O MODELO DE FLORESTA ALEATÓRIA PELA PRIMEIRA BUSCA EM GRADE COM VALIDAÇÃO CRU-ZADA COM 5 DOBRAS

Hiper-parâmetro	Valores/Opções
N° de árvores	25
Critério de divisão	Entropia
Profundidade máxima da árvore	None
N° máximo de propriedades	sqrt
Semente para aleatoriedade	0
Diminuição de impureza miníma	0
Peso das classes	Balanceado
N° mínimo de pontos por divisão	2
N° mínimo de pontos por folha	1

FONTE: O autor(2021).

No QUADRO 12 observa-se que o número de árvores que resultou na melhor classificação foi o valor máximo da faixa de valores usada na procura em grade. Esse resultado indica que o modelo pode ser melhorado usando um número ainda maior de árvores.

Dessa maneira, decidiu-se fazer uma segunda procura de grade, onde os parâmetros ótimos já achados previamente foram repetidos com excessão do número de árvores, o qual foi variado entre 2 e 50. A partir dessa análise levantou-se o gráfico mostrado na FIGURA 40.


FIGURA 40 – DESEMPENHO MÉDIO ENTRE AS 5 DOBRAS DA SEGUNDA BUSCA EM GRADE COM VALIDAÇÃO CRUZADA DO MODELO FLORESTA ALEATÓRIA PELA QUANTIDADE DE ÁRVORES AVALIADAS

O gráfico da FIGURA 40 visualmente mostra um comportamento exponencial do formato da EQUAÇÃO 6.1. Sendo que esse tipo de equação tende ao valor de b conforme x cresce tendendo, assim, a se estabilizar.

$$y = a * e^{-t * x} + b$$
 (6.1)

Na FIGURA 40 observa-se que os valores de f1 obtidos pelos modelos tendem a se estabilizar a partir de 35 árvores indicando que um valor maior de árvores não ajudaria no poder de generalização do modelo, e assim, somente custaria mais tempo para ser avaliado, como pode ser visto na FIGURA 41, a qual mostra que o tempo de avaliação continuou crescendo com um comportamento quase linear com o número de árvores utilizado.

Dessa maneira o número de árvores final usado para a classificação foi de 40, visto que esse está na região onde o valor f1 já está bem estabilizado. Os hiperparâmetros desse modelo são mostrados no QUADRO 13.

140 Reta ajustada y = 2.829x - 2.378 R^2 : 0.995 **** 22.2.2.2.2.2.4. 10 0 0 10 20 50 30 40 N° de Árvores

FIGURA 41 – TEMPO DE TREINAMENTO DO MODELO FLORESTA ALEATÓRIA PELA QUANTIDADE DE ÁRVORES AVALIADAS

FONTE: O autor(2021).

QUADRO 13 – HIPER-PARÂMETROS SELECIONADOS PARA O MODELO DE FLORESTA ALEATÓRIA PELA SEGUNDA BUSCA EM GRADE COM VALIDAÇÃO CRU-ZADA COM 5 DOBRAS

Hiper-parâmetro	Valores/Opções
N° de árvores	40
Critério de divisão	Entropia
Profundidade máxima da árvore	None
N° máximo de propriedades	sqrt
Semente para aleatoriedade	0
Diminuição de impureza miníma	0
Peso das classes	Balanceado
N° mínimo de pontos por divisão	2
N° mínimo de pontos por folha	1

FONTE: O autor(2021).

6.4.2.4 Desempenho dos modelos finais

A quantidade de instâncias de cada classe selecionadas e usadas para treino e teste dos modelos se encontram na TABELA 9.

TABELA 9 – NÚMERO DE INSTÂNCIAS USADAS NO TREINO E TESTE DOS MODELOS DE ÁRVORE DE DECISÃO E FLORESTA ALEATÓRIA USANDO PYTHON™ E SUAS BIBLIOTECAS

Dados para treino						
Alumínio	35292					
Cobre	18297					
Mistura	36168					
Óxidos	10712					
Porosidade	2605					
Dados para teste						
Alumínio	11764					
Alumínio Cobre	11764 6100					
Alumínio Cobre Mistura	11764 6100 12056					
Alumínio Cobre Mistura Óxidos	11764 6100 12056 3571					

FONTE: O autor(2021).

Os modelos de árvore de decisão e floresta aleatória obtiveram bons resultados de classificação. Os resultados da árvore de decisão sobre os dados de treino e teste são mostrados na TABELA 10 e TABELA 11, enquanto os dados para o modelo de floresta aleatória podem ser vistos na TABELA 12 e TABELA 13.

TABELA 10 – MEDIDAS DE AVALIAÇÃO E PONTUAÇÃO DO MODELO ÁRVORE DE DECI-SÃO DA BIBLIOTACA *SCIKIT-LEARN* NOS DADOS DE TREINO

Matriz de confusão					Matriz de confusão normalizada	f1
 $\begin{bmatrix} Al\\ 35292\\ 0\\ 0\\ 0\\ 0\\ 0 \end{bmatrix}$	$\begin{array}{c} Cu\\ 0\\ 18297\\ 0\\ 0\\ 0\\ 0\end{array}$	Mis. 0 36168 0		Poros 0 0 0 0	$\begin{bmatrix} Al & Cu & Mis. & \acute{Ox.} & Poros \\ 1, 0 & 0, 0 & 0, 0 & 0, 0 & 0, 0 \\ 0, 0 & 1, 0 & 0, 0 & 0, 0 & 0, 0 \\ 0, 0 & 0, 0 & 1, 0 & 0, 0 & 0, 0 \\ 0, 0 & 0, 0 & 0, 0 & 1, 0 & 0, 0 \\ 0, 0 & 0, 0 & 0, 0 & 0, 0 & 1, 0 \end{bmatrix}$	1,000

FONTE: O autor(2021). NOTA: Óx:Óxidos, Mis:Mistura

TABELA 11 – MEDIDAS DE AVALIAÇÃO E PONTUAÇÃO DO MODELO DE ÁRVORE DE DECISÃO DA BIBLIOTACA *SCIKIT-LEARN* NOS DADOS DE TESTE

Matriz de confusão				Matriz de confusão normalizada				f1		
$\begin{bmatrix} Al \\ 11469 \\ 2 \\ 145 \\ 128 \\ 5 \end{bmatrix}$	$\begin{array}{c} Cu \\ 1 \\ 6075 \\ 30 \\ 2 \\ 1 \end{array}$	Mis. 159 21 11840 36 10	$ \begin{array}{c} $	Poros 6 0 14 19 820	$\begin{array}{c} Al \\ 0,975 \\ 0,000 \\ 0,012 \\ 0,036 \\ 0,006 \end{array}$	$\begin{array}{c} Cu \\ 0,000 \\ 0,996 \\ 0,002 \\ 0,001 \\ 0,001 \end{array}$	$\begin{array}{c} Mis. \\ 0,014 \\ 0,003 \\ 0,982 \\ 0,010 \\ 0,012 \end{array}$	$\acute{Ox}.$ 0,011 0,000 0,002 0,948 0,037	$\begin{array}{c} Poros \\ 0,001 \\ 0,000 \\ 0,001 \\ 0,005 \\ 0,945 \end{array}$	0,978

NOTA: Óx:Óxidos, Mis:Mistura

TABELA 12 – MEDIDAS DE AVALIAÇÃO E PONTUAÇÃO DO MODELO FLORESTA ALEATÓ-RIA DA BIBLIOTACA *SCIKIT-LEARN* NOS DADOS DE TREINO

Matriz de confusão					Matriz de confusão normalizada f	1
$ \begin{array}{c} Al\\ 35292\\0\\1\\1\\0\\\end{array} $	$egin{array}{c} Cu \\ 0 \\ 18297 \\ 0 \\ 0 \\ 0 \\ 0 \end{array}$	Mis. 0 36167 0 0	$egin{array}{c} \dot{O}x. & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 107111 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 $	$\begin{array}{c} Poros \\ 0 \\ 0 \\ 6 \\ 0 \\ 2605 \end{array}$	$\begin{bmatrix} Al & Cu & Mis. & \acute{Ox.} & Poros \\ 1,0 & 0,0 & 0,0 & 0,0 & 0,0 \\ 0,0 & 1,0 & 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 1,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 & 1,0 & 0,0 \\ 0,0 & 0,0 & 0,0 & 0,0 & 1,0 \end{bmatrix}$)00

FONTE: O autor(2021).

NOTA: Óx:Óxidos, Mis:Mistura

TABELA	🗤 13 – MEDIDAS DE AVALIAÇÃO E PONTUAÇÃO DO MODELO FLORESTA ALE	EATÓ-
	RIA DA BIBLIOTACA SCIKIT-LEARN NOS DADOS DE TESTE	

Matriz de confusão					Matriz de confusão normalizada	f1
$ \begin{bmatrix} Al \\ 11650 \\ 0 \\ 60 \\ 100 \\ 2 \end{bmatrix} $	$\begin{array}{c} Cu \\ 1 \\ 6089 \\ 15 \\ 3 \\ 2 \end{array}$	Mis. 74 10 11978 14 5		$\begin{array}{c} Poros \\ 0 \\ 0 \\ 0 \\ 6 \\ 842 \end{array}$	$\begin{bmatrix} Al & Cu & Mis. & \acute{O}x. & Poros \\ 0,990 & 0,000 & 0,006 & 0,003 & 0,000 \\ 0,000 & 0,998 & 0,002 & 0,000 & 0,000 \\ 0,005 & 0,001 & 0,994 & 0,000 & 0,000 \\ 0,028 & 0,001 & 0,004 & 0,966 & 0,002 \\ 0,002 & 0,002 & 0,006 & 0,020 & 0,970 \end{bmatrix}$	0,990

FONTE: O autor(2021).

NOTA: Óx:Óxidos, Mis:Mistura

Os resultados da TABELA 10 e TABELA 11 demonstram que o modelo de árvore de decisão conseguiu se adaptar perfeitamente aos dados de treino de maneira que o seu f1 é 1, porém, ao contrário do observado na subseção 6.4.1, a queda dos valores de *recall* e da pontuação f1 entre o desempenho do modelo nos dados de treino e nos dados de teste foi bem menor, de forma a obter uma pontuação f1 final de 0,978 com pior *recall* de 0,945.

Adicionalmente pelo uso do modelo de floresta aleatória o poder de classificação foi aumentado novamente, atingindo não somente um valor f1 de 0,990, mas também quedas ainda menores nos valores de *recall* com o menor valor de *recall* de 0,966, como pode ser visto na TABELA 12 e TABELA 13.

A partir desses resultados foi confirmada a viabilidade do uso *machine learning* para análises de revestimentos obtidos por aspersão térmica. Além de mostrar a importância das técnicas de procura em grade e validação cruzada para seleção dos hiper-parâmetros. Esse fato se destaca ainda mais, pois, através do uso de apenas uma árvore, já foram obtidos resultados melhores do que as 200 árvores usadas pelo *software* ImageJ.

Um exemplo da classificação obtida pelo modelo de floresta aleatória pode ser visto na FIGURA 42. Enquanto exemplos de classificação obtidos para cada revestimento podem ser vistos no Anexo G.

FIGURA 42 – CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 3 PELO MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BIBLIOTECAS



FONTE: O autor(2021). NOTA: Vermelho: Porosidade, Verde: Óxidos, Azul: Cobre, Rosa: Alumínio, Amarelo: Mistura

6.5 ANÁLISE DOS DADOS OBTIDOS PELO *PLUGIN TRAINABLE WEKA SEGMEN-TATION* DO *SOFTWARE* IMAGEJ SOBRE AS IMAGENS DE MICROSCÓPIO ÓTICO

Através do modelo obtido todas as imagens de microscópio ótico foram classificadas e, usando a contagem de pixeis do *software* ImageJ, foram então estimadas a quantidade de cada fase. Os resultados obtidos para porosidade, óxidos e mistura observados nos revestimentos são apresentados na FIGURA 43, FIGURA 44 e FIGURA 45.



FIGURA 44 – BOXPLOT DA FRAÇÃO EM ÁREA DE ÓXIDOS(%) DOS REVESTIMENTOS



NOTA: o - Mediana, — - Média





Na FIGURA 43 e FIGURA 44 pode ser observado imediatamente os efeitos

da polaridade. Com os revestimentos com o alumínio como cátodo tendo maiores valores de porosidade e óxidos(corpos de prova de 1 a 4) e os outros com a outra polaridade possuindo visivelmente menores valores de ambos. Fato extremamente interessante, visto que essas são duas propriedades que sempre se buscam reduzir em revestimentos de aspersão térmica, visando a maior coesão dos revestimentos.

Além disso, observa-se que os corpos de prova obtiveram valores de porosidade que não passaram de 12% e com média de 6,08%. Enquanto isso, maiores valores de óxidos foram obtidos, com o maior valor observado de 21,61% e média de 11,53%, valor alto para o ASP, resultado dos altos valores de oxidação predominantemente observados nos revestimentos obtidos com a primeira polaridade. As medições de mistura apresentaram valores entre 13 e 26,5% com uma média de 16,46%.

6.5.1 Análise estatística dos dados

Primeiramente para a realização da ANOVA foi testada a suposição do modelo de que os dados possuem uma distribuição normal. Os resultados do teste de normalidade feitos pelo *software* Minitab[™] podem ser vistos na FIGURA 46, FIGURA 47 e FIGURA 48.



FIGURA 46 – TESTE DE NORMALIDADE DA FRAÇÃO EM ÁREA DE POROSIDADE(%) DOS REVESTIMENTOS OBTIDOS PARA TODAS AS MEDIÇÕES

FONTE: O autor(2021).

99 95 90 80 70 Percentual 60 50 40 30 Média 11,53 DesvPad 5,899 20 Ń 40 10 AD 1,693 5 Valor-P < 0,005 1 Ó 5 10 15 20 25 Oxidos(%)

FIGURA 47 – TESTE DE NORMALIDADE DA FRAÇÃO EM ÁREA DE ÓXIDOS(%) DOS REVESTIMENTOS OBTIDOS PARA TODAS AS MEDIÇÕES



FIGURA 48 – TESTE DE NORMALIDADE DA FRAÇÃO EM ÁREA DE MISTURA(%) DOS REVESTIMENTOS OBTIDOS PARA TODAS AS MEDIÇÕES



FONTE: O autor(2021).

Nesse teste a hipótese nula é de que os dados seguem uma distribuição normal, ao passo que a hipótese alternativa é de que os dados não seguem uma distribuição normal. Assim, como os valores de p foram menores que p < 0,05 para os dados de porosidade e óxidos, recusa-se a hipótese nula e aceita-se que nenhuma dessas propriedades segue uma distribuição normal. De forma que para essas duas propriedades o modelo de ANOVA por permutação deve ser usado.

Embora os valores de mistura tenham uma distribuição normal, o modelo de permutação também foi usado nos dados de mistura para mostrar a semelhança dos resultados e a vantagem de se implementar o algoritmo com permutação.

No QUADRO 14 são apresentadas as hipóteses usadas nessas duas análises, sendo que quando o p de cada análise for menor que 0,1 será rejeitada a hipótese nula do fator, isso para uma análise com 90% de confiabilidade.

QUADRO 14 – HIPÓTESES PARA O EFEITO DE CADA FATOR DE CONTROLE DO ARRANJO ORTOGONAL L8 DE TAGUCHI ADAPTADO PARA 6 FATORES

	Hipóteses
H ₀₁	A Polaridade não é significativa
H ₁₁	A Polaridade é significativa
H ₀₂	A Corrente não é significativa
H ₁₂	A Corrente é significativa
H ₀₃	A Pressão não é significativa
H ₁₃	A Pressão é significativa
H ₀₄	A Tensão não é significativa
H ₁₄	A Tensão é significativa
H ₀₅	O Pré-Aquecimento não é significativo
H ₁₅	O Pré-Aquecimento é significativo
H ₀₆	A Distância não é significativa
H ₁₆	A Distância é significativa

FONTE: O autor(2021).

6.5.1.1 Análise estatística da porosidade

Na TABELA 14 e TABELA 15 são apresentados os resultados da análise de variância e análise de variância por permutação respectivamente para os dados de porosidade.

TABELA	14 – ANÁLISE DE VARIÂNCIA DA FRAÇÃO EM ÁREA DE POROSIDADE DOS
	REVESTIMENTOS EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO

Fatores	GL	SQ (Aj.)	MQ (Aj.)	Valor-F	Valor-P
Polaridade Al	1	239,86	239,86	61,91	0,000
Corrente	1	4,31	4,31	1,11	0,299
Pressão	1	2,13	2,13	0,55	0,464
Tensão	1	56,62	56,62	14,61	0,001
Pré-Aquecimento	1	83,49	83,49	21,55	0,000
Distância	1	0,13	0,13	0,03	0,855
Residuais	33	127,86	3,87		
Total	39	514,40			

TABELA 15 – ANÁLISE DE VARIÂNCIA POR PERMUTAÇÃO DA FRAÇÃO EM ÁREA DA POROSIDADE DOS REVESTIMENTOS EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO

Fatores	GL	SQ (Aj.)	MQ (Aj.)	Iterações	Valor-P
Polaridade Al	1	239,86	239,86	5000	0,000
Corrente	1	4,31	4,31	190	0,347
Pressão	1	2,13	2,13	146	0,411
Tensão	1	56,62	56,62	5000	0,000
Pré-Aquecimento	1	83,49	83,49	5000	0,000
Distância	1	0,13	0,13	51	0,863
Residuais	33	127,86	3,87		
Total	39	514,40			

FONTE: O autor(2021).

Para análise de variância com 90% de significância para todo p < 0,10 é rejeitada a hipótese nula e para os fatores onde p > 0,10 é rejeitada a hipótese não nula. Dessa maneira, são rejeitadas as hipóteses H_{01} , H_{12} , H_{13} , H_{04} , H_{05} e H_{16} do QUADRO 14. Ou seja, apenas a polaridade, tensão e pré-aquecimento afetaram a porosidade dos revestimentos de maneira significativa. Notasse que o resultado dessa análise para ambas as técnicas, com e sem permutação, se encontrou na mesma faixa de confiabilidade de cada parâmetro, demonstrando a robustez do processo da ANOVA em relação a dados não normais.

Para avaliar a influência de cada fator sobre a porosidade e as comparar uma análise de ranqueamento por delta foi feita e está apresentada na TABELA 16.

Portanto, vê-se que o fator que teve a maior influência na média de porosidade nos revestimentos foi a polaridade seguida por, em ordem de importância: pré-aquecimento, tensão de aspersão, corrente, pressão e distância. Na FIGURA 49 são apresentados os efeitos que cada fator teve sobre a porosidade dos revestimentos.

TABELA 16 – RANQUE DE INFLUÊNCIA DOS FATORES PARA A FRAÇÃO EM ÁREA MÉDIA DE POROSIDADE(%) NOS REVESTIMENTOS

Nível	Polaridade Al	Corrente	Pressão	Tensão	Pré.Aq	Distância
1	8,53	6,41	5,85	7,27	7,52	6,13
2	3,63	5,75	6,31	4,89	4,63	6,02
Variação	4,90	0,66	0,46	2,38	2,89	0,11
Ranque	1	4	5	3	2	6

FIGURA 49 – GRÁFICOS DE EFEITOS PRINCIPAIS SOBRE A FRAÇÃO EM ÁREA MÉDIA DE POROSIDADE(%) DOS REVESTIMENTOS



FONTE: O autor(2021).

Por fim, a TABELA 17 apresenta os resultados do teste Tukey para 90% de confiança para os dados de porosidade. Os resultados do teste Tukey para a porosidade foram compatíveis com os da análise de variância, ou seja, os fatores considerados significativos para a análise de variância também obtiveram diferença significativa.

Ao observar as setas na TABELA 17 vê-se que para a otimização da porosidade a polaridade do arame de alumínio deve ser como ânodo, tensão de 40 V e com uso de pré-aquecimento. Os outros parâmetros não foram significativamente diferentes, mas apresentaram os melhores valores de porosidade para corrente de 200 A, pressão de 45 psi, e distância de 250 mm.

Fator		Nível	Média(%)	Ag	rupa	amento
Polaridade Al	1	Cátodo	8,53	А		
	2	Ânodo	3,63		В	\leftarrow
Correpto(A)	1	150	6,41	А		
Corrente(A)	2	200	5,75	А		\leftarrow
	1	45	5,85	А		\leftarrow
Pressao(psi)	2	55	6,31	А		
Tanaãa(\/)	1	30	7,27	А		
Tensao(v)	2	40	4,89		В	\leftarrow
	1	T.Amb	7,52	А		
Pre.Aq(³ C)	2	120	4,63		В	\leftarrow
Dietâncie (mm)	1	150	6,13	Α		
Distancia(mm)	2	250	6,02	А		\leftarrow

TABELA 17 – TESTE DE COMPARAÇÃO TUKEY COM 90% DE CONFIANÇA PARA POROSI-DADE

NOTA: Condição para otimização de menor é melhor LEGENDA: ←: indica o nível que apresentou o melhor valor médio para cada fator de controle

6.5.1.2 Análise estatística dos óxidos

Na TABELA 18 e TABELA 19 são apresentados os resultados da análise de variância e análise de variância por permutação respectivamente para os óxidos.

 TABELA 18 – ANÁLISE DE VARIÂNCIA DA FRAÇÃO EM ÁREA DE ÓXIDOS DOS REVESTI-MENTOS EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO

Fatores	GL	SQ (Aj.)	MQ (Aj.)	Valor-F	Valor-P
Polaridade Al	1	1167,05	1167,05	410,59	0,000
Corrente	1	2,87	2,87	1,01	0,322
Pressão	1	0,06	0,06	0,02	0,883
Tensão	1	82,08	82,08	28,88	0,000
Pré-Aquecimento	1	10,94	10,94	3,85	0,058
Distância	1	0,17	0,17	0,06	0,807
Residuais	33	93,80	2,84		
Total	39	1356,97			

FONTE: O autor(2021).

TABELA 19 – ANÁLISE DE VARIÂNCIA POR PERMUTAÇÃO DA FRAÇÃO EM ÁREA DE ÓXIDOS DOS REVESTIMENTOS EM RELAÇÃO AOS PARÂMETROS DE DE-POSIÇÃO

Fatores	GL	SQ (Aj.)	MQ (Aj.)	lterações	Valor-P
Polaridade Al	1	1167,05	1167,05	5000	0,000
Corrente	1	2,87	2,87	312	0,244
Pressão	1	0,06	0,06	51	0,824
Tensão	1	82,08	82,08	5000	0,000
Pré-Aquecimento	1	10,94	10,94	1474	0,064
Distância	1	0,17	0,17	51	0,725
Residuais	33	93,80	2,84		
Total	39	1356,97			

Para análise de variância com 90% de significância para todo p < 0,10 é rejeitada a hipótese nula e para os fatores onde p > 0,10 é rejeitada a hipótese não nula. Dessa maneira, são rejeitadas as hipóteses H_{01} , H_{12} , H_{13} , H_{04} , H_{05} e H_{16} do QUADRO 14. Ou seja, apenas a polaridade, tensão e pré-aquecimento afetaram os óxidos dos revestimentos de maneira significativa. Notasse que o resultado dessa análise para ambas as técnicas, com e sem permutação, também se encontrou na mesma faixa de confiabilidade de cada parâmetro.

Para avaliar a influência de cada fator sobre os óxidos e as comparar uma análise de ranqueamento por delta foi feita está apresentada na TABELA 20.

Nível	Polaridade Al	Corrente	Pressão	Tensão	Pré.Aq	Distância
1	16,93	11,26	11,57	12,96	12,05	11,46
2	6,13	11,80	11,49	10,10	11,01	11,59
Variação	10,80	0,54	0,08	2,86	1,04	0,13
Ranque	1	4	6	2	3	5

TABELA 20 – RANQUE DE INFLUÊNCIA DOS FATORES PARA A FRAÇÃO EM ÁREA MÉDIA DE ÓXIDOS(%) NOS REVESTIMENTOS

FONTE: O autor(2021).

Portanto, vê-se que o fator que teve a maior influência na média de óxidos nos revestimentos foi a polaridade seguida por, em ordem de importância, tensão de aspersão, pré-aquecimento, corrente, distância e pressão. Na FIGURA 50 são apresentados os efeitos que cada fator teve sobre os óxidos dos revestimentos.

Por fim, TABELA 21 apresenta os resultados do teste Tukey para 90% de confiança para os dados de fração em área de óxidos.



TABELA 21 – TESTE DE COMPARAÇÃO TUKEY COM 90% DE CONFIANÇA PARA ÓXIDOS

Fator	Nível		Média (%)	Ag	rupa	amento
Polaridado Al	1	Cátodo	16,93	А		
I Ulanuaue Al	2	Ânodo	6,13		В	\leftarrow
Corrente(A)	1	150	11,26	А		\leftarrow
	2	200	11,80	А		
Proceão(pei)	1	45	11,57	А		
Flessao(psi)	2	55	11,49	А		\leftarrow
Tonsão(\/)	1	30	12,96	А		
Terisau(V)	2	40	10,10		В	\leftarrow
Prá Aq(∞C)	1	T.Amb	12,05	А		
FIE.Aq(C)	2	120	11,01		В	\leftarrow
Dictância(mm)	1	150	11,46	А		\leftarrow
Distancia(IIIII)	2	250	11,59	А		

FONTE: O autor(2021).

NOTA: Condição para otimização de menor é melhor

LEGENDA: ←: indica o nível que apresentou o melhor valor médio para cada fator de controle

Os resultados do teste Tukey para os óxidos foram compatíveis com os da análise de variância, ou seja, os fatores considerados significativos para a análise de variância também obtiveram diferença significativa.

Ao observar as setas na TABELA 21 vê-se que para a otimização dos óxidos a polaridade do arame de alumínio deve ser como ânodo, tensão de 40 V e com uso de pré-aquecimento. Os outros parâmetros não foram significativamente diferentes, mas apresentaram os melhores valores de óxidos para corrente de 150 A, pressão de 55 psi e distância de 150 mm.

6.5.1.3 Análise estatística da mistura

Pressão

Tensão

Na TABELA 22 e TABELA 23 são apresentados os resultados da análise de variância e análise de variância por permutação respectivamente para os dados de mistura.

MENTOS EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO					
Fatores	GL	SQ (Aj.)	MQ (Aj.)	Valor-F	Valor-P
Polaridade Al	1	29,86	29,86	3,71	0,063
Corrente	1	52,30	52,30	6,50	0,016

47,18

8 05

5,86

1 00

0,021

0.325

TABELA 22 – ANÁLISE DE VARIÂNCIA DA FRAÇÃO EM ÁREA DA MISTURA DOS REVESTI-MENTOS EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO

	1011040		0,00	0,00	1,00	0,020
	Pré-Aquecimento	1	1,31	1,31	0,16	0,689
	Distância	1	108,44	108,44	13,47	0,001
	Residuais	33	265,59	8,05		
	Total	39	512,72			
FO	NTE: O autor(2021).				

47,18

8 05

1

1

TABELA 23 – ANÁLISE DE VARIÂNCIA POR PERMUTAÇÃO DA FRAÇÃO EM ÁREA DA MISTURA NOS REVESTIMENTOS EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO

-					
Fatores	GL	SQ (Aj.)	MQ (Aj.)	lterações	Valor-P
Polaridade Al	1	29,86	29,86	967	0,094
Corrente	1	52,30	52,30	5000	0,013
Pressão	1	47,18	47,18	5000	0,014
Tensão	1	8,05	8,05	341	0,229
Pré-Aquecimento	1	1,31	1,31	85	0,541
Distância	1	108,44	108,44	5000	0,002
Residuais	33	265,59	8,05		
Total	39	1356,97			

FONTE: O autor(2021).

Para análise de variância com 90% de significância para todo p < 0,10 é rejeitada a hipótese nula e para os fatores onde p > 0,10 é rejeitada a hipótese não nula. Dessa maneira, são rejeitadas as hipóteses H_{01} , H_{02} , H_{03} , H_{14} , H_{15} e H_{06} do QUADRO 14. Ou seja, apenas a polaridade, corrente, pressão tensão e distância afetaram a mistura nos revestimentos de maneira significativa.

Notasse que novamente o resultado dessa análise para ambas as técnicas, com e sem permutação, se encontrou na mesma faixa de confiabilidade de cada parâmetro, demonstrando assim a vantagem do algoritmo com permutação, dado que ele conduz a resultados semelhantes de confiabilidade e ainda assim é mais robusto a dados não normais. Como pode ser visto na TABELA 22 e TABELA 23, visto que os dados de mistura apresentaram uma distribuição normal de acordo com o teste de normalidade empregado.

Para avaliar a influência de cada fator sobre a mistura e as comparar uma análise de ranqueamento por delta foi feita é apresentada na TABELA 24.

TABELA	24 – RANQUE DE INFLUÊNCIA DOS FATORES PARA	A FRAÇÃO EM	ÁREA MÉDIA
	DE MISTURA(%) NOS REVESTIMENTOS		

Nível	Polaridade Al	Corrente	Pressão	Tensão	Pré.Aq	Distância
1 2	17,33 15,60	15,32 17,61	17,55 15,38	16,91 16,02	16,28 16,65	18,11 14,82
Variação	1,73	2,29	2,17	0,89	0,37	3,29
Ranque	4	2	3	5	6	1

FONTE: O autor(2021).

Portanto, vê-se que o fator que teve a maior influência na mistura média nos revestimentos foi a distância seguida por, em ordem de importância: corrente de aspersão, pressão, polaridade, tensão e uso de pré-aquecimento. Na FIGURA 51 são apresentados os efeitos que cada fator teve sobre a mistura dos revestimentos.

FIGURA 51 – GRÁFICOS DE EFEITOS PRINCIPAIS SOBRE A FRAÇÃO EM ÁREA MÉDIA DE MISTURA(%) DOS REVESTIMENTOS



FONTE: O autor(2021).

Por fim, a TABELA 25 apresenta os resultados do teste Tukey para 90% de confiança para os dados de mistura.

Fator		Nível	Média (%)	Ag	Agrupamento	
Delaridada Al	1	Cátodo	17,33	А		\leftarrow
Folanuaue Al	2	Ânodo	15,60		В	
Correpto(A)	1	150	15,32	А		
Contente(A)	2	200	17,61		В	\leftarrow
Proceão(pei)	1	45	17,55	Α		\leftarrow
Fiessau(psi)	2	55	15,38		В	
Topsão(\/)	1	30	16,91	А		\leftarrow
Terisa0(V)	2	40	16,02	А		
Prá Aq(℃)	1	T.Amb	16,28	А		
	2	120	16,65	Α		\leftarrow
Distância(mm)	1	150	18,11	A		\leftarrow
Distancia(IIIII)	2	250	14,82		В	

TABELA 25 – TESTE DE COMPARAÇÃO TUKEY COM 90% DE CONFIANÇA PARA MISTURA

NOTA: Condição para otimização de maior é melhor LEGENDA: ←: indica o nível que apresentou o melhor valor médio para cada fator de controle

Os resultados do teste Tukey para mistura foram compatíveis com os da análise de variância, ou seja, os fatores considerados significativos para a análise de variância também obtiveram diferença significativa.

Ao observar as setas na TABELA 25 vê-se que para a otimização da mistura a polaridade do arame de alumínio deve ser como cátodo, corrente de 200A, pressão do gás de arraste de 45 psi e distância de 150 mm. Os outros parâmetros não foram significativamente diferentes, mas apresentam os melhores valores de mistura para tensão de aspersão de 30 V e com uso de pré-aquecimento.

6.5.1.4 Escolhas dos parâmetros para otimização

Baseado nas análises das subsubseção 6.5.1.1, subsubseção 6.5.1.2 e subsubseção 6.5.1.3, pode-se selecionar quais valores dos fatores de controle resultariam nas melhores propriedades para um revestimento considerando a prioridade dada a cada uma das propriedades analisadas.

Como o objetivo principal da pesquisa da qual esse estudo faz parte é a maximização da mistura dos dois materiais, visando a maior produção de eutético, a essa propriedade foi dada a maior prioridade. Em sequência foi selecionada a otimização dos óxidos, devido a sua fragilidade, predisposição a nucleação de trincas e pelo seu efeito de evitar a formação de liga nos contornos de panqueca onde os mesmos estão presentes. Dessa forma a otimização da porosidade ficou com a menor prioridade.

Dessa maneira, observou-se que os fatores significativos para os valores de mistura foram, em ordem de importância: distância, corrente, pressão e polaridade. Com os maiores valores de mistura obtidos com os parâmetros: 150mm, 200A, 45 psi e alumínio como cátodo, respectivamente.

Já para os valores de óxidos observou-se que os fatores significativos foram, em ordem de importância: polaridade, tensão e pré-aquecimento. Com os menores valores de óxidos obtidos com os parâmetros: alumínio como ânodo, 40 V e usando pré-aquecimento, respectivamente.

Por fim para os valores de porosidade observou-se que os fatores significativos foram, em ordem de importância, foram: polaridade, pré-aquecimento e tensão. Com os menores valores de porosidade obtidos com os parâmetros: alumínio como ânodo, usando pré-aquecimento e 40 V, respectivamente.

Dessa maneira, os primeiros fatores escolhidos foram distância de 150mm, corrente de 200 A e pressão de 45 psi baseado nos resultados para mistura. A escolha da polaridade também poderia ter sido feita baseado nos valores de mistura, resultando na escolha do arame de alumínio na posição de cátodo. Porém, dentre os fatores significativos a polaridade do arame demonstrou a menor influência sobre os valores de mistura e, em contrapartida, foi o fator mais influente sobre os valores de óxidos e porosidade, consequentemente a polaridade foi definida com o alumínio como ânodo. Por fim, baseado nos óxidos e porosidade foi selecionada a tensão de 40 V e uso de pré-aquecimento.

Na TABELA 26 são apresentados os parâmetros selecionados.

TABELA 26 – DADOS SELECIONADOS PARA OTIMIZAÇÃO DAS PROPRIEDADES CON-FORME ANÁLISE DE TAGUICHI

Polaridade	Corrente	Pressão	Tensão	Pré.Aq	Distância			
Arame Al	(A)	(psi)	(V)	(°C)	(mm)			
+	200	45	40	120	150			

FONTE: O autor(2021).

6.6 ANÁLISE DAS CONDIÇÕES DE DEPOSIÇÃO

Os histogramas das variáveis de velocidade, temperatura e diâmetro das partículas durante o voo foram levantados. Para demonstração da distribuição de valores um exemplo de cada histograma obtido da amostra 8 é apresentado na FIGURA 52, FIGURA 53 e FIGURA 54.



FIGURA 53 – HISTOGRAMA DA TEMPERATURA(℃) AVALIADA POR DPV DAS PARTÍCU-LAS OBTIDAS NO EXPERIMENTO 8



FONTE: O autor(2021).



FIGURA 54 – HISTOGRAMA DO DIÂMETRO(μm) AVALIADO PELO DPV DAS PARTÍCULAS OBTIDAS NO EXPERIMENTO 8

Na FIGURA 53 é visto que temperaturas acima de 2000 °C foram atingidas. Tal fato condiz com a formação do intermetálico γ_1 , observado por Costa (2018) e Moreira (2019) e reforça a hipótese de formação do intermetálico γ_1 durante a zona de transferência, devido à sua alta temperatura de formação.

Adicionalmente a temperatura média de todas as partículas medidas foi de 1823 ℃. Um valor mais alto que os pontos de fusão do alumínio e cobre, 660 ℃ e 1085 ℃ respectivamente.

Essa alta temperatura indica que o arco pode estar passando aos arames mais energia do que o necessário a sua fundição antes dos materiais fundidos serem cisalhados. Outra contribuição menor para tais temperaturas é a formação de óxidos de alumínio e sua reação altamente exotérmica(399 kcal/mol de energia liberada) conforme é discutido por Pormousa (2007), que em seu estudo, ao trabalhar com gás de transporte de nitrogênio observou uma queda de 150 °C, mostrando que a maior parte da temperatura das partículas vem diretamente da energia do arco e apenas uma parte pequena do processo de oxidação.

Já a velocidade média de todas as partículas foi de 92 m/s estando na extremidade superior para a faixa de velocidades de partículas geralmente encontradas no ASP de 50 e 100 m/s, conforme Davis (2004). Por fim um diâmetro médio de 59 µm foi

FONTE: O autor(2021).

obtido entre todas as partículas avaliadas.

Na FIGURA 55, FIGURA 56 e FIGURA 57 é apresentado um resumo dos valores obtidos para cada amostra dessas três propriedades.





NOTA: \diamond - Mediana, — - Média

FIGURA 56 – *BOXPLOT* DA TEMPERATURA(℃) AVALIADA PELO DPV DAS PARTÍCULAS OBTIDAS EM TODOS OS EXPERIMENTOS



NOTA: <- Mediana, — - Média



6.6.1 Análise estatística dos dados obtidos por DPV

Primeiramente para a realização da ANOVA foi testada a suposição do modelo de que os dados possuem uma distribuição normal. Os resultados do teste de normalidade feitos pelo *software* Minitab[™] podem ser vistos na FIGURA 58, FIGURA 59 e FIGURA 60.



FONTE: O autor(2021).







FONTE: O autor(2021).

No teste de normalidade a hipótese nula é de que os dados seguem uma distribuição normal, ao passo que a hipótese alternativa é de que os dados não seguem uma distribuição normal. Assim, como todos os valores de p foram menores que p <

0,05, se recusa a hipótese nula e aceita-se que nenhuma das propriedades avaliadas segue uma distribuição normal.

Através da observação da FIGURA 52, FIGURA 53 e FIGURA 54, é observável que as distribuições obtidas para cada propriedade realmente não são normais. Isso se deve a dois fatores, o primeiro sendo que a distribuição de diâmetros no ASP já é conhecida por ter formato log-normal. (LEFEBVRE; MCDONELL, 2017; PORMOUSA, 2007). O segundo é a presença de diferentes mecanismos em ação nas pontas dos arames na produção de partículas pelo arco elétrico, de forma que é esperado que as curvas obtidas sejam, na verdade, a soma de duas curvas.

Dessa forma, foi feita também uma análise de ANOVA por permutação, considerada mais robusta para dados não normais.

No QUADRO 15 são apresentadas as hipóteses usadas nessas duas análises, sendo que quando o p de cada análise for menor que 0,05 será rejeitada a hipótese nula do fator, isso para uma análise com 95% de confiabilidade.

QUADRO 15 – HIPÓTESES PARA O EFEITO DE CADA FATOR DE CONTROLE DO ARRANJO ORTOGONAL L8 DE TAGUCHI ADAPTADO PARA 4 FATORES

	Hipóteses							
H ₀₁	A Polaridade não é significativa							
H ₁₁	A Polaridade é significativa							
H ₀₂	A Corrente não é significativa							
H ₁₂	A Corrente é significativa							
H ₀₃	A Pressão não é significativa							
H ₁₃	A Pressão é significativa							
H ₀₄	A Tensão não é significativa							
H ₁₄	A Tensão é significativa							

FONTE: O autor(2021).

6.6.1.1 Análise estatística da velocidade

Na TABELA 27 e TABELA 28 são apresentados os resultados da análise de variância e análise de variância por permutação respectivamente para os dados de velocidade.

TABELA 27 – ANÁLISE DE VARIÂNCIA PARA VELOCIDADE DAS PARTÍCULAS EM RELA-ÇÃO AOS PARÂMETROS DE DEPOSIÇÃO

Fatores	GL	SQ (Aj.)	MQ (Aj.)	Valor-F	Valor-P
Polaridade Al	1	222189	222189	630,65	0,000
Corrente	1	45	45	0,13	0,721
Pressão	1	74546	74546	211,59	0,000
Tensão	1	234	234	0,66	0,415
Residuais	3995	1407504	352		
Total	3999	1704517			

TABELA 28 – ANÁLISE DE VARIÂNCIA POR PERMUTAÇÃO PARA VELOCIDADE DAS PAR-TÍCULAS EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO

Fatores	GL	SQ (Aj.)	MQ (Aj.)	Iterações	Valor-P
Polaridade Al	1	222189	222189	5000	0,000
Corrente	1	45	45	51	1,000
Pressão	1	74546	74546	5000	0,000
Tensão	1	234	234	149	0,403
Residuais	3995	1407504	352		
Total	3999	1704517			

FONTE: O autor(2021).

Para análise de variância com 95% de significância para todo p < 0,05 é rejeitada a hipótese nula e para os fatores onde p > 0,05 é rejeitada a hipótese não nula. Dessa maneira, são rejeitadas as hipóteses H_{01} , H_{12} , H_{03} , e H_{14} do QUADRO 15. Ou seja, apenas a polaridade e pressão afetaram a velocidade das partículas de maneira significativa. Notasse que o resultado dessa análise para ambas as técnicas, com e sem permutação, se encontrou na mesma faixa de confiabilidade de cada parâmetro, demonstrando a robustez do processo da ANOVA em relação a dados não normais.

Para avaliar a influência de cada fator sobre a velocidade de partículas e as comparar uma análise de ranqueamento por delta foi feita e está apresentada na TABELA 29.

TABELA	29 – RANQUE DE INFLUÊNCIA	DOS FATORES PARA	VELOCIDADE MÉDIA DAS
	PARTÍCULAS (m/s)		

Nível	Polaridade Al	Corrente	Pressão	Tensão
1	99,28	91,93	87,51	91,58
2	84,37	91,72	96,14	92,07
Variação	14,91	0,21	8,63	0,48
Ranque	1	4	2	3

FONTE: O autor(2021).

Portanto, vê-se que o fator que teve a maior influência na velocidade das partículas foi a polaridade dos arames seguida por, em ordem de importância: pressão do gás de araste, tensão de aspersão e corrente. Na FIGURA 61 são apresentados os efeitos que cada fator teve sobre as propriedades das partículas em voo.



Através da FIGURA 61 fica claro que a polaridade teve o maior efeito sobre a velocidade média das partículas, concordando com a análise de ranqueamento. A redução da velocidade com a troca de polaridade era esperada devido aos diferentes mecanismos presentes na fundição dos arames conforme é descrito por Watanabe et al. (1996), sendo que no ânodo tem-se o mecanismo de *arc-attachment* que resulta em aquecimento mais homogêneo do arame gerando partículas maiores do que as do cátodo, conforme observado por Pormousa (2007). Dessa forma, ao trocar a polaridade se troca os mecanismos operantes em cada arame e como os arames são de materiais e diâmetros diferentes sua resposta aos mecanismos também muda. Esse fato reforça que no ASP dissimilar a seleção da polaridade para cada arame é de extrema importância, dado que esse parâmetro influencia diretamente nas condições de deposição e consequentemente nas propriedades do revestimento, como já visto na seção 6.5.

Em seguida tem-se a influência da pressão, outro resultado já esperado, visto que o aumento da pressão se traduz diretamente na velocidade das partículas, conforme descrito por Pawlowski (2008).

A baixa influência da tensão sobre a velocidade, porém, foi de contra ao esperado. Segundo o descrito por Davis (2004) uma maior tensão resultas em partículas de menor tamanho, e logo era esperado que resultasse em maior velocidade, esse efeito é de fato observado, mas de maneira muito sútil, não chegando a ser significativo. Similarmente ocorre com a corrente, dado que um aumento da mesma aumenta o tamanho das partículas e assim era esperado uma redução da velocidade, o que ocorreu, mas novamente, não de maneira significativa.

Uma possível explicação para isso seriam as forças magnéticas presentes no arco elétrico e como elas interferem com a atomização e o cisalhamento das partículas, requerendo assim mais estudos na área.

Por fim, a TABELA 30 apresenta os resultados do teste Tukey para 95% de confiança para os dados de velocidade.

Fator		Nível	Média (m/s)	Ag	rupa	amento
Polaridade Al	1 2	Cátodo Ânodo	99,28 84,37	A	В	\leftarrow
Corrente(A)	1 2	150 200	91,93 91,72	A A		\leftarrow
Pressão(psi)	1 2	45 55	87,51 96,14	A	В	\leftarrow
Tensão(V)	1 2	30 40	91,58 92,07	A A		\leftarrow

TABELA 30 – TESTE DE COMPARAÇÃO TUKEY COM 95% DE CONFIANÇA PARA VELOCI-DADE

FONTE: O autor(2021).

NOTA: Condição para otimização de maior é melhor LEGENDA: ←: indica o nível que apresentou o melhor valor médio para cada fator de controle

Os resultados do teste Tukey para velocidade foram compatíveis com os da análise variância, ou seja, os fatores considerados significativos para a análise de variância também foram obtiveram diferença significativa.

Ao observar as setas na TABELA 30 vê-se que para a otimização da velocidade a polaridade do arame de alumínio deve ser como cátodo e pressão do gás de arraste de 55 psi. Os outros parâmetros não foram significativamente diferentes, mas apresentam os melhores valores de velocidade para corrente de aspersão de 150 A e Tensão de 40 V.

6.6.1.2 Análise estatística da temperatura

Na TABELA 31 e TABELA 32 são apresentados os resultados da análise de variância e variância por permutação respectivamente para os dados de temperatura.

TABELA 31 – ANÁLISE DE VARIÂNCIA DA TEMPERATURA DAS PARTÍCULAS EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO

Fatores	GL	SQ (Aj.)	MQ (Aj.)	Valor-F	Valor-P
Polaridade Al	1	756113	756113	58,04	0,000
Corrente	1	368122	368122	28,26	0,000
Pressão	1	252063	252063	19,35	0,000
Tensão	1	68434	68434	5,25	0,022
Residuais	3995	52042666	13027		
Total	3999	53487398			

TABELA 32 – ANÁLISE DE VARIÂNCIA POR PERMUTAÇÃO DA TEMPERATURA DAS PAR-TÍCULAS EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO

Fatores	GL	SQ (Aj.)	MQ (Aj.)	Iterações	Valor-P
Polaridade Al	1	756113	756113	5000	0,000
Corrente	1	368122	368122	5000	0,000
Pressão	1	252063	252063	5000	0,000
Tensão	1	68434	68434	5000	0,001
Residuais	3995	52042666	13027		
Total	3999	53487398			

FONTE: O autor(2021).

Para análise de variância com 95% de significância para todo p < 0,05 é rejeitada a hipótese nula e para os fatores onde p > 0,05 é rejeitada a hipótese não nula. Dessa maneira, são rejeitadas as hipóteses H_{01} , H_{02} , H_{03} e H_{04} do QUADRO 15. Ou seja, todos os fatores afetaram a temperatura das partículas de maneira significativa. Notasse, novamente, que o resultado dessa análise para ambas as técnicas, com e sem permutação, se encontrou na mesmo faixa de confiabilidade de cada parâmetro, reforçando a robustez do processo da ANOVA em relação a dados não normais.

Para avaliar a influência de cada fator sobre a temperatura de partículas e as comparar uma análise de ranqueamento por delta foi feita e está apresentada na TABELA 33.

TABELA	33 -	- RANQUE	DE INFL	UÊNCIA	DOS	FATORES	PARA	TEMPERATU	JRA	MÉDIA	DAS
		PARTÍCU	LAS(℃)								

	Nível	Polaridade Al	Corrente	Pressão	Tensão
	1	1837,59	1833,43	1831,78	1827,98
	2	1810,09	1814,25	1815,90	1819,70
	Variação	27,50	19,18	15,88	8,28
-	Ranque	1	2	3	4

FONTE: O autor(2021).

Portanto, vê-se que o fator que teve a maior influência na temperatura das partículas foi a polaridade dos arames seguida por, em ordem de importância: corrente de aspersão, pressão do gás de araste e tensão. Na FIGURA 62 são apresentados os efeitos que cada fator teve sobre as propriedades das partículas em voo.



Assim vê-se que a polaridade teve o maior efeito sobre a temperatura média das partículas, concordando com a análise de ranqueamento. A redução da temperatura com a troca de polaridade era esperada devido aos diferentes mecanismos presentes na fundição dos arames conforme é descrito por Watanabe et al. (1996), sendo que no ânodo se encontra o mecanismo chamado de *arc-attachment* que resulta em aquecimento mais homogêneo do arame, o cátodo, em contrapartida, tem um aquecimento localizado. Adicionalmente os diferentes mecanismos acarretam a formação de partículas maiores do ânodo do que as do cátodo, conforme observado por Pormousa (2007). Como a maioria dos óxidos observados são óxidos de alumínio, como foi observado na subsubseção 6.3.3.1, o aumento das partículas de alumínio pela sua posição como ânodo resulta em menor oxidação, devido à menor superfície total, o que pode acarretar a queda de temperatura. Esse fato reforça novamente que no ASP dissimilar a seleção da polaridade é de extrema importância, visto que esse parâmetro influencia diretamente nas condições de deposição e consequentemente nas propriedades do revestimento, como já visto na seção 6.5.

Em seguida tem-se a influência da corrente, a qual, de início, parece contradizer a teoria, visto que o aumento da corrente aumenta diretamente a energia disponível para o processo. Porém, com aumento da corrente também há um aumento equivalente da taxa de deposição e logo a temperatura não devia variar conforme observado por Guillen e Williams (2006). O qual estudou em seu trabalho o efeito da corrente na temperatura de partículas de alumínio durante a deposição, sendo observado que a temperatura de partículas na linha central não muda com a mudança da corrente. O mesmo resultado contraditório pode ser visto na influência da tensão. Dessa maneira mais estudos são necessários para melhor entender esses resultados.

Uma explicação seria a diferente dispersão do jato gerado nessas condições. Onde uma maior corrente e tensão tendem a gerar arcos mais dispersos e que, consequentemente, sofrem maior resfriamento. O efeito de dispersão do arco é estudado por Horner, Hall e McCloskey (2015). Em seu estudo foi avaliado que a corrente não muda significativamente a área do jato, mas aumenta a sua planicidade (*"flatness"*), indicando que com maiores correntes as partículas estão dispersas mais regularmente pelo jato, ao invés de concentradas no centro o que poderia acarretar o maior resfriamento.

A influência da pressão era esperada, dado que maiores pressões resultam em um maior fluxo de ar na saída da pistola, resfriando as partículas.

Por fim, a TABELA 34 apresenta os resultados do teste Tukey para 95% de confiança para os dados de temperatura.

Os resultados do teste Tukey para temperatura foram compatíveis com os da análise variância, ou seja, os fatores considerados significativos para a análise de variância também foram obtiveram diferença significativa.

Ao observar as setas na TABELA 34 vê-se que para a otimização da temperatura a polaridade do arame de alumínio deve ser como cátodo, corrente de 150 A, pressão do gás de arraste de 45 psi e tensão de 30 V.

Fator		Nível	Média (℃)	Ag	rupa	amento
Delevide de Al	1	Cátodo	1837,59	А		\leftarrow
Polaridade Al	2	Ânodo	1810,09		В	
Correpto(A)	1	150	1833,43	А		\leftarrow
Corrente(A)	2	200	1814,25		В	
Dragače(poi)	1	45	1831,78	А		\leftarrow
Pressao(psi)	2	55	1815,90		В	
Tanaña(\/)	1	30	1827,98	А		\leftarrow
Terisa0(V)	2	40	1819,70		В	

TABELA 34 – TESTE DE COMPARAÇÃO TUKEY COM 95% DE CONFIANÇA PARA TEMPE-RATURA

FONTE: O autor(2021).

NOTA: Condição para otimização de maior é melhor

LEGENDA: ←: indica o nível que apresentou o melhor valor médio para cada fator de controle 137

6.6.2 Análise estatística do diâmetro

Na TABELA 35 e TABELA 36 são apresentados os resultados da análise de variância e análise de variância por permutação respectivamente para os dados de diâmetro.

TABELA 35 – ANÁLISE DE VARIÂNCIA DO DIÂMETRO DAS PARTÍCULAS EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO

Fatores	GL	SQ (Aj.)	MQ (Aj.)	Valor-F	Valor-P
Polaridade Al	1	28106	28105,9	49,09	0,000
Corrente	1	7837	7837,2	13,69	0,000
Pressão	1	79	78,7	0,14	0,711
Tensão	1	384	383,8	0,67	0,413
Residuais	3995	2287182	572,5		
Total	3999	2323588			

FONTE: O autor(2021).

TABELA 36 – ANÁLISE DE VARIÂNCIA POR PERMUTAÇÃO DO DIÂMETRO DAS PARTÍCU-LAS EM RELAÇÃO AOS PARÂMETROS DE DEPOSIÇÃO

Fatores	GL	SQ (Aj.)	MQ (Aj.)	lterações	Valor-P
Polaridade Al	1	28106	28105,9	5000	0,000
Corrente	1	7837	7837,2	5000	0,000
Pressão	1	79	78,7	51	1,000
Tensão	1	384	383,8	132	0,432
Residuais	3995	2287182	572,5		
Total	3999	2323588			

FONTE: O autor(2021).

Para análise de variância com 95% de significância para todo p < 0,05 é rejeitada a hipótese nula e para os fatores onde p > 0,05 é rejeitada a hipótese não nula. Dessa maneira, são rejeitadas as hipóteses H_{01} , H_{02} , H_{13} e H_{14} do QUADRO 15. Ou seja, somente a polaridade dos arames e a corrente de aspersão afetaram o diâmetro das partículas de maneira significativa. Notasse uma última vez que o resultado dessa análise para ambas as técnicas, com e sem permutação, se encontrou na mesma faixa de confiabilidade de cada parâmetro, confirmando assim através de todas as análises de ANOVA a robustez do processo da ANOVA em relação a dados não normais e as vantagens de se usar o processo com permutação.

Para avaliar a influência de cada fator sobre o diâmetro das partículas e as comparar uma análise de ranqueamento por delta foi feita e está apresentada na TABELA 37.

Portanto, vê-se que o fator que teve a maior influência no diâmetro das partículas foi a polaridade dos arames seguida por, em ordem de importância: corrente de aspersão, tensão e pressão do gás de araste. Na FIGURA 63 são apresentados os efeitos que cada fator teve sobre as propriedades das partículas em voo.

TABELA 37 – RANQUE DE INFLUÊNCIA DOS FATORES PARA DIÂMETRO MÉDIO DAS PARTÍCULAS (µm)

Nível	Polaridade Al	Corrente	Pressão	Tensão
1 2	56,47 61,77	57,72 60,52	59,26 58,98	59,43 58,81
Variação	5,30	2,80	0,28	0,62
Ranque	1	2	4	3

FONTE: O autor(2021).

FIGURA 63 – GRÁFICOS DE EFEITOS PRINCIPAIS SOBRE O DIÂMETRO MÉDIO DAS PARTÍCULAS



Assim vê-se que a polaridade teve o maior efeito sobre o diâmetro das partículas, concordando com a análise do ranqueamento.

A grande influência no tamanho das partículas com a troca de polaridade era esperada devido aos diferentes mecanismos presentes na fundição dos arames conforme é descrito por Watanabe et al. (1996), sendo que no ânodo tem o mecanismo de *arc-attachment* que resulta em aquecimento mais homogêneo do arame enquanto o cátodo, em contrapartida, tem um aquecimento localizado. Isso resulta na formação de partículas maiores do ânodo do que as do cátodo conforme observado por Pormousa (2007).

Adicionalmente, a observação da redução do tamanho das partículas com a troca da polaridade do arame de alumínio de cátodo para ânodo concorda com as observações feitas nos dados de velocidade e temperatura.

Em seguida tem-se a influência da corrente onde seu aumento acarreta diretamente no aumento do tamanho das partículas, o que era esperado pelo conhecimento histórico do ASP descrito por Davis (2004).

Similarmente Davis (2004) explica que o aumento de tensão resulta em menores partículas, efeito também observado nesse estudo. Apesar de as diferenças não terem sido estatisticamente significantes.

Ademais a influência da pressão se mostrou a menor entre todas, sendo considerada insignificativa. Ainda assim seu efeito seguiu a tendência histórica de diminuição de tamanho de partículas conforme aumento da pressão do gás de arraste. (DAVIS, 2004). Assim sendo, pode ser o caso onde a faixa de valores usados não foi suficiente para se observar uma influência significativa no tamanho das partículas.

Por fim, a TABELA 38 apresenta os resultados do teste Tukey para 95% de confiança para os dados de diâmetro.

Fator		Nível	Média (µm)	Ag	Agrupamento	
Polaridade Al	1 2	Cátodo Ânodo	56,47 61,77	A	В	<i>←</i>
Corrente(A)	1 2	150 200	57,72 60,52	A	В	<i>←</i>
Pressão(psi)	1 2	45 55	59,26 58,98	A A		\leftarrow
Tensão(V)	1 2	30 40	59,43 58.81	A A		\leftarrow

TABELA 38 – TESTE DE COMPARAÇÃO TUKEY COM 95% DE CONFIANÇA PARA DIÂME-TRO DAS PARTÍCULAS

FONTE: O autor(2021).

NOTA: Condição para otimização de maior é melhor

 $\mathsf{LEGENDA:} \leftarrow: \mathsf{indica} \text{ o nível que apresentou o melhor valor médio}$

para cada fator de controle

Os resultados do teste Tukey para diâmetro das partículas foram compatíveis com os da análise variância, ou seja, os fatores considerados significativos para a análise de variância também foram obtiveram diferença significativa.

Ao observar as setas na TABELA 38 vê-se que para a otimização do diâmetro a polaridade do arame de alumínio deve ser como ânodo e corrente de 200 A. Os outros parâmetros não foram significativamente diferentes, mas apresentam os melhores valores de diâmetro para pressão do gás de arraste de 45 psi e tensão de aspersão de 30 V.

7 CONCLUSÕES

Foi verificada a viabilidade do uso de arames dissimilares no ASP com arames de diferentes diâmetros produzindo um arco estável, que permitiu a formação de liga metalúrgica no revestimento com a presença de constituinte eutético. Esse eutético apresentou uma estrutura dendrítica e distribuição preferencial no contorno de panquecas, característica de um resfriamento e solidificação lenta a partir de fase líquida, de forma que indica a presença de fase líquida nos contornos das panquecas durante a deposição.

A viabilidade do uso de *machine learning* para avaliação de revestimentos de aspersão térmica foi comprovada. Com uma pontuação f1 de 0,955, e o com o pior *recall* de 0,895 usando o *software* ImageJ.

Usando das técnicas de procura em grade, validação cruzada e alimentando aos modelos as características de Haralick usando Python[™], foi possível chegar a um modelo de classificação de floresta aleatória com pontuação f1 de 0,990 e o pior *recall* de 0,966. Dessa forma a técnica mostra potencial para facilitar a análise automática e mais precisa de revestimentos, além de permitir a melhor análise dos revestimentos obtidos nessa pesquisa que previamente se revelou complexa.

Entre os parâmetros analisados a polaridade dos arames foi o que possuiu a maior influência sobre os fatores, sendo o mais influente sobre os valores de porosidade e óxidos dos revestimentos e sobre os valores de velocidade, temperatura e diâmetro das partículas. Enquanto a distância de aspersão se revelou o fator mais importante para a formação de mistura.

A posição de alumínio como ânodo acarretou melhores propriedades em questão de teor de óxidos e porosidade, mas, em contrapartida, na pior formação de mistura metalúrgica.

O percentual de porosidade nos revestimentos não excedeu 12% em fração de área. Sendo que para a polaridade Al como ânodo um valor médio de 3,63% foi obtido, enquanto na outra polaridade a média se apresentou em 8,53%. Diferença que se provou estatisticamente significante.

O percentual de óxidos presentes nos revestimentos foi elevado para o ASP, principalmente para os revestimentos depositados com o arame de Al como cátodo, onde a média permaneceu em 16,93%, em contraste com o baixo valor médio das amostras depositadas com o Al como ânodo, onde o teor de óxidos foi de 6,13%. Diferença que se provou estatisticamente significante.

Através da técnica de EDS foi possível observar a presença de um composto intermetálico fora do constituinte eutético, além da formação de um gradiente de composição nos contornos de panqueca.

A formação dessa nova fase intermetálica nos contornos das panquecas impediu a formação de liga nessas regiões, sendo assim prejudicial a um dos objetivos principais da linha de pesquisa da qual esse trabalho faz parte, a de formar uma morfologia que seja condizente com a propriedade de auto-cura. Além disso, a formação de tal intermetálicos pode ser prejudicial à coesão do revestimento devido a sua alta fragilidade.

A técnica ANOVA clássica obteve em todos os seus usos a mesma faixa de significância que a da técnica PERMANOVA provando a robustez do método clássico, apesar de suas suposições de normalidade. Adicionalmente a obtenção das mesmas faixas de significância nos dados de mistura, os quais demonstraram uma curva normal, mostra as vantagens de se usar o processo por permutação que não depende da suposição de normalidade dos dados e mesmo assim apresenta resultados semelhantes ao método clássico.

Baseado nas análises de variância e ranqueamento concluiu-se que os fatores com significância em relação ao percentual de porosidade foram em ordem decrescente a polaridade dos arames, o pré-aquecimento do substrato a tensão de aspersão.

Baseado nas análises de variância e ranqueamento concluiu-se que os fatores com significância em relação ao percentual de óxidos foram em ordem decrescente a polaridade dos arames, a tensão da fonte de alimentação e o pré-aquecimento.

Baseado nas análises de variância e ranqueamento concluiu-se que os fatores com significância em relação ao percentual de mistura foram em ordem decrescente a distância de aspersão, a corrente, a pressão e a polaridade dos arames.

Baseado nas análises de variância e ranqueamento das propriedades dos revestimentos uma análise de otimização sugere o uso dos fatores: polaridade do Al como anodo, corrente de 200A, pressão de 45 psi, tensão de 40 V, uso de préaquecimento e distância de 150 mm. Sendo que tais fatores visam otimizar em ordem decrescente de prioridade a mistura metalúrgica, óxidos e porosidade.

8 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Vista a experiência obtida e observações feitas durante o desenvolvimento desse trabalho fazem-se algumas recomendações para obtenção de melhores resultados e observação de efeitos que nesse estudo não foram possíveis.

- Recorrer à medição de microdureza auxiliada de um microscópio para confirmar a fase identificada nos contornos de panqueca de cobre. Essa fase inicialmente foi pensada ser um óxido de cobre, mas a análise pontual de EDS indica que sua composição seja a de um intermetálico. A presença dessa fase no tamanho observado pode ser prejudicial ao revestimento, devido à sua fragilidade e localização nos contornos de panqueca dos revestimentos o que impede a formação de liga.
- Fazer aspersão em cortina da água e avaliar as partículas obtidas, de forma a poder avaliar em que estágio do processo de aspersão são formados os compostos intermetálicos observados no revestimento.
- Fazer teste de dobramento nos corpos de prova com o objetivo de avaliar o impacto da formação do intermetálico na propriedade de coesão dos revestimentos.
- Com o melhor entendimento dos efeitos da polaridade obtidos nesse estudo, escolher uma das duas opções e realizar um experimento de Taguchi com três níveis para melhor avaliar a influência dos parâmetros. Sendo que os resultados desse estudo recomendam o uso do alumínio como anodo, dada a maior estabilidade observada durante o processo e os melhores valores de porosidade e oxidação observados nessa configuração.
- Usar o ASP com ar quente visando uma curva de resfriamento mais lenta e assim uma maior formação de liga nos revestimentos obtidos.
- Confirmar se a combinação de fatores sugerida para otimização das propriedades dos revestimentos realmente acarreta melhores valores de porosidade, óxidos e mistura metalúrgica.
- Apesar da excelente generalização obtida pelo modelo de floresta aleatória usando o Python[™] e suas bibliotecas, o fato que o modelo se adaptou perfeitamente aos dados de treino indica que pode estar havendo *over-fitting*. Uma solução para tal problema seria usar em estudos futuros a técnica chamada de *prunning*, que se baseia na remoção de módulos folha da árvore, de modo que uma generalização ainda melhor possa obtida.
• Usar os parâmetros de controle selecionados pela análise de Taguchi para confirmar a otimização das propriedades do revestimento.

REFERÊNCIAS

AKOSA, Josephine. Predictive accuracy: A misleading performance measure for highly imbalanced data. In: PROCEEDINGS of the SAS Global Forum. Orlando, FL: SAS Global Forum, abr. 2017. P. 2–5. Citado 1 vez na página 65.

ANDERSON, Marti J. A new method for non-parametric multivariate analysis of variance. **Austral ecology**, Wiley Online Library, v. 26, n. 1, p. 32–46, 2001. Citado 1 vez na página 54.

ANDERSON, Theodore W; DARLING, Donald A. Asymptotic theory of certain "goodness of fit"criteria based on stochastic processes. **The annals of mathematical statistics**, JSTOR, p. 193–212, 1952. Citado 1 vez na página 83.

ANYS, H.; ABDOU, Bannari et al. Texture analysis for the mapping of urban areas using airborne MEIS-II images, in proceedings of the first international airborne remote sensing conference and exhibition. **Strasbourg, France**, v. 3, p. 231–245, jan. 1994. Citado 2 vezes nas páginas 73, 104.

ANYS, H.; HE, D.-C. APPROCHE MULTIPOLARISATION ET TEXTURALE POUR LA RECONNAISSANCE DES CULTURES À L'AIDE DE DONNÉES RADAR AÉROPORTÉ. **Canadian Journal of Remote Sensing**, Taylor & Francis, v. 21, n. 2, p. 138–157, 1995. Citado 1 vez na página 73.

ARGANDA-CARRERAS, Ignacio et al. Trainable Weka Segmentation: a machine learning tool for microscopy pixel classification. **Bioinformatics**, Oxford University Press, v. 33, n. 15, p. 2424–2426, 2017. Citado 1 vez na página 86.

BAO, Y.; ZHANG, T.; GAWNE, D.T. Non-steady state heating of substrate and coating during thermal-spray deposition. **Surface and Coatings Technology**, v. 194, n. 1, p. 82–90, 2005. ISSN 0257-8972. Citado 3 vez na página 49.

BISHOP, Christopher M. **Pattern Recognition and Machine Learning**. 1st ed. 2006. Corr. 2nd printing. [S.I.]: Springer, 2006. (Information science and statistics). ISBN 9780387310732. Citado 3 vezes nas páginas 59, 60, 76.

BLANCA, María et al. Non-normal data: Is ANOVA still a valid option? **Psicothema**, v. 29, p. 552–557, out. 2017. Citado 2 vezes nas páginas 54, 83.

BRADSKI, G. The OpenCV Library. **Dr. Dobb's Journal of Software Tools**, 2000. Citado 1 vez na página 90.

CH, Venkata; REDDY, G; RAO, K. Influence of tool pin profile on microstructure and corrosion behaviour of AA2219 Al-Cu alloy Friction Stir Weld Nuggets. v. 53, mai. 2015. Citado 1 vez na página 36.

CLARK, Alex. **Pillow (PIL Fork) Documentation**. [S.I.]: readthedocs, 2015. Disponível em: https://buildmedia.readthedocs.org/media/pdf/pillow/latest/pillow.pdf. Citado 1 vez na página 92.

CLAUSI, David. Comparison and fusion of co-occurrence, Gabor and MRF texture features for classification of SAR sea-ice imagery. **ATMOSPHERE-OCEAN**, v. 39, p. 183–194, set. 2001. Citado 2 vezes nas páginas 69, 72.

CLAUSI, David A. An analysis of co-occurrence texture statistics as a function of grey level quantization. **Canadian Journal of remote sensing**, Taylor & Francis, v. 28, n. 1, p. 45–62, 2002. Citado 6 vezes nas páginas 69, 77, 90.

COELHO, Luis Pedro. Mahotas: Open source software for scriptable computer vision. **Journal of Open Research Software**, v. 1, jul. 2013. Citado 2 vezes nas páginas 74, 88.

COSTA, F. B. T. Processamento de liga eutética Al-Cu por processo de aspersão térmica. [S.I.: s.n.], 2018. Citado 14 vezes nas páginas 28, 50, 51, 56, 57, 80, 95, 96, 127.

DAVID A. PORTER, K. E. Easterling. **Phase transformations in metals and alloys**. 2Rev Ed. [S.I.]: Chapman & Hall, 1992. P. 291–303. ISBN 0412450305. Citado 2 vezes nas páginas 34, 44.

DAVIS, J. R. **Handbook of Thermal Spray Technology**. illustrated edition. [S.I.: s.n.], 2004. P. 50–56. ISBN 0871707950. Citado 15 vezes nas páginas 37–39, 42–45, 51, 127, 133, 140.

GOMES MANTOVANI, Rafael et al. An empirical study on hyperparameter tuning of decision trees. **arXiv**, arxiv–1812, 2018. Citado 2 vezes nas páginas 62, 91.

GUILLEN, Donna; WILLIAMS, Brian. In-Flight Oxidation of Aluminum in the Twin-Wire Electric Arc Process. **Journal of Thermal Spray Technology**, v. 15, p. 63–71, mar. 2006. Citado 1 vez na página 136.

HALL, Mark et al. The WEKA data mining software: an update. **ACM SIGKDD explora-tions newsletter**, ACM New York, NY, USA, v. 11, n. 1, p. 10–18, 2009. Citado 1 vez na página 86.

HALL-BEYER, Mryka. GLCM texture: a tutorial v. 3.0 March 2017. University of Calgary, 2017. Citado 6 vezes nas páginas 68, 69, 72, 73, 88.

HAN, Ning et al. NDVI-Based Lacunarity Texture for Improving Identification of Torreya Using Object-Oriented Method. **Agricultural Sciences in China**, v. 10, n. 9, p. 1431–1444, 2011. ISSN 1671-2927. Citado 3 vezes nas páginas 72, 77.

HARALICK, Robert M; SHANMUGAM, Karthikeyan; DINSTEIN, Its' Hak. Textural features for image classification. **IEEE Transactions on systems, man, and cybernetics**, leee, n. 6, p. 610–621, 1973. Citado 9 vezes nas páginas 68–70, 74, 75, 87.

HORNER, Allison Lynne; HALL, Aaron Christopher; MCCLOSKEY, James Francis. The effect of process parameters on twin wire arc spray pattern shape. **Coatings**, Multidisciplinary Digital Publishing Institute, v. 5, n. 2, p. 115–123, 2015. Citado 3 vezes nas páginas 41, 43, 137.

KANG, Seon-Do; YOO, Hun-Woo; JANG, Dong-Sik. Color Image Segmentation Based on the Normal Distribution and the Dynamic Thresholding. Edição: Osvaldo Gervasi e Marina L. Gavrilova. Springer Berlin Heidelberg, Berlin, Heidelberg, p. 372–384, 2007. Citado 4 vezes nas páginas 29, 55, 57.

KIRA, Kenji; RENDELL, Larry A. A practical approach to feature selection. In: MA-CHINE Learning Proceedings 1992. [S.I.]: Elsevier, 1992. P. 249–256. Citado 1 vez na página 76.

KONONENKO, Igor. Estimating attributes: Analysis and extensions of RELIEF. In: BERGADANO, Francesco; DE RAEDT, Luc (Ed.). **Machine Learning: ECML-94**. Berlin, Heidelberg: Springer Berlin Heidelberg, 1994. P. 171–182. ISBN 978-3-540-48365-6. Citado 2 vez na página 76.

KOU, Sindo. Welding Metallurgy. 2ed. [S.I.]: Wiley, 2003. ISBN 9780471434917. Citado 2 vezes nas páginas 41, 44.

LEFEBVRE, Arthur H; MCDONELL, Vincent G. **Atomization and sprays**. [S.I.]: CRC press, 2017. Citado 2 vezes nas páginas 53, 131.

LIMA, Carlos Roberto Camello; CAMARGO, Flávio; LIMA., Carmo Roberto Pelliciari de. Metallographic evaluation and process correlation of thermally sprayed coatings. In: INTERNATIONAL Thermal Spray Conference – ASM International - TSS. [S.I.: s.n.], 2004. Citado 3 vezes nas páginas 45, 47.

LÖFSTEDT, Tommy et al. Gray-level invariant Haralick texture features. **PLOS ONE**, v. 14, e0212110, fev. 2019. Citado 3 vezes nas páginas 74, 75.

MARQUES, P. V. **Aspersão Térmica**. [S.I.], 2003. Disponível em: https://infosolda.com.br/wp-content/uploads/Downloads/Artigos/processos_solda/asperso-termica.pdf. Acesso em: 22 jul. 2021. Citado 1 vez na página 36.

MONDOLFO, L. F. **Aluminum Alloys. Structure and Properties**. 2nd Revised edition. [S.I.]: Butterworth & Co Publishers Ltd, 1976. ISBN 978-0-408-70932-3. Citado 2 vez na página 34.

MOREIRA, C. A. J. Aspersão térmica simultânea de alumínio e cobre sobre liga de alumínio 5052. 2019. Diss. (Mestrado) – Universidade Federal do Paraná, Curitiba. Citado 8 vezes nas páginas 28, 50, 80, 95, 96, 127.

NAIK, Dayakar L; SAJID, Hizb Ullah; KIRAN, Ravi. Texture-Based Metallurgical Phase Identification in Structural Steels: A Supervised Machine Learning Approach. **Metals**, Multidisciplinary Digital Publishing Institute, v. 9, n. 5, p. 546, 2019. Citado 8 vezes nas páginas 55, 57, 65, 68, 69, 72, 73, 88.

NIELSEN, Michael A. **Neural networks and deep learning**. [S.I.]: Determination press San Francisco, CA, 2015. v. 2018. Citado 2 vezes nas páginas 62, 76.

PAJOUH, Sara; RENAUD, Olivier. A general permutation approach for analyzing repeated measures ANOVA and mixed-model designs. **Statistical Papers**, v. 56, p. 1–21, ago. 2014. Citado 1 vez na página 54.

PAJOUH, Sara; RENAUD, Olivier. An exact permutation method for testing any effect in balanced and unbalanced fixed effect ANOVA. **Computational Statistics & Data Analysis**, v. 54, p. 1881–1893, jul. 2010. Citado 1 vez na página 54.

PAREDES, R. S. C. Estudo de revestimentos de alumínio depositados por três processos de aspersão térmica para a proteção do aço contra corrosão marinha. 1998. Tese (Doutorado) – Universidade Federal de Santa Catarina, Florianópolis. Citado 1 vez na página 52.

PAREDES, Ramón S. C. **Aspersão Térmica**. [S.I.]: Notas de aula. UFPR, 2012. Citado 2 vezes nas páginas 37, 38.

PAREDES, Ramón S. C.; OLIVEIRA, Ana Sofia C.M.d'. Efeito da rugosidade e do préaquecimento do substrato na morfologia e aderência de revestimentos de alumínio depositados por aspersão térmica, 2001. Citado 2 vezes nas páginas 44, 45.

PATEL, Harsh; PRAJAPATI, Purvi. Study and Analysis of Decision Tree Based Classification Algorithms. **International Journal of Computer Sciences and Engineering**, v. 6, p. 74–78, out. 2018. Citado 2 vez na página 59.

PAWLOWSKI, Lech. The Science and Engineering of Thermal Spray Coatings. 2. ed. [S.I.]: Wiley, 2008. ISBN 9780471490494. Citado 8 vezes nas páginas 28, 37, 39, 43, 44, 51, 133.

PEDREGOSA, F. et al. Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011. Citado 3 vezes nas páginas 62, 63, 90.

PORMOUSA, A. 'Wire-Arc Spraying System: Particle Production, Transport and Deposition. 2007. Tese (Doutorado) – University of Toronto. Citado 17 vezes nas páginas 28, 38–40, 42, 43, 52, 53, 127, 131, 133, 136, 139.

PUISSANT, Anne; HIRSCH, Jacky; WEBER, Christiane. The utility of texture analysis to improve per-pixel classification for high to very high spatial resolution imagery. **International Journal of Remote Sensing**, Taylor & Francis, v. 26, n. 4, p. 733–745, 2005. Citado 3 vezes nas páginas 72, 73.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2020. Disponível em: https://www.R-project.org/. Acesso em: 22 jul. 2021. Citado 2 vezes nas páginas 83, 84.

RABKIN, D. M. et al. Preparation and properties of Copper-Aluminun compounds. **Powder Metallurgy and Metal Ceramics**, p. 695–700, 1970. Citado 3 vezes nas páginas 35–37.

RAILEANU, Laura; STOFFEL, Kilian. Theoretical Comparison between the Gini Index and Information Gain Criteria. **Annals of Mathematics and Artificial Intelligence**, v. 41, p. 77–93, mai. 2004. Citado 1 vez na página 59.

ROBNIK-SIKONJA, Marko; KONONENKO, Igor. Theoretical and Empirical Analysis of ReliefF and RReliefF. **Machine Learning**, v. 53, p. 23–69, out. 2003. Citado 1 vez na página 76.

RODRIGUEZ, R. M. H. P. Formação de óxidos nos revestimentos de alumínio depositados por aspersão térmica. 2003. Tese (Doutorado) – Universidade Federal do Paraná, Curitiba. Citado 2 vez na página 48.

RUEDEN, Curtis T et al. ImageJ2: ImageJ for the next generation of scientific image data. **BMC bioinformatics**, BioMed Central, v. 18, n. 1, p. 529, 2017. Citado 2 vezes nas páginas 85, 86.

SABESP NTS 085. **Preparo de superfícies metálicas para pintura**. São Paulo, 2001. Disponível em: https://www3.sabesp.com.br/normastecnicas/nts/nts085.pdf. Acesso em: 22 jul. 2021. Citado 1 vez na página 84.

SCIKIT-LEARN DEVELOPERS. **Scikit learn user guide**. 0.21. ed. [S.I.]. Disponível em: https://scikit-learn.org/0.21/user_guide.html. Acesso em: 21 jul. 2020. Citado 2 vezes nas páginas 62, 63.

SILVA, A. Estudo de revestimento com a liga stellite 6 no substrato de alumínio 6351-t6 por aspersão térmica chama-pó. 2017. Diss. (Mestrado) – Universidade Federal do Paraná, Curitiba. Citado 1 vez na página 52.

SUCHARSKI, G. B. Estudo da erosão por cavitação sobre diferentes morfologias de revestimentos de FeMnCrSiB aplicados por aspersão térmica chama FS e HVOF com tratamento de shot peening. 2016. Tese (Doutorado) – Universidade Federal do Paraná, Curitiba. Citado 1 vez na página 52.

TAGUCHI, Genichi; KONISHI, Seiso. Taguchi methods: orthogonal arrays and linear graphs; tools for quality engineering. [S.I.]: ASI press, 1987. Citado 1 vez na página 52.

THORPE, Merle L. Thermal spray industry in transition. **Advanced materials and processes**, v. 143, p. 58–62, 1993. Citado 1 vez na página 46.

UMESH, P. Image Processing in Python. **CSI Communications**, Citeseer, v. 23, 2012. Citado 1 vez na página 92.

URBANOWICZ, Ryan J. et al. **Benchmarking Relief Based Feature Selection Methods**. [S.I.: s.n.], 2017. arXiv e-print. https://arxiv.org/abs/1711.08477. Citado 1 vez na página 88.

VARIABILITÀ, Gini C. mutuabilità: contributo allo studio delle distribuzioni e delle relazioni statistiche. **Bologna (ITA): Tipogr. di P. Cuppini**, 1912. Citado 1 vez na página 58.

WALT, Stéfan van der et al. scikit-image: image processing in Python. **PeerJ**, v. 2, e453, jun. 2014. ISSN 2167-8359. Citado 1 vez na página 89.

WATANABE, T et al. Voltage and current fluctuations in wire arc spraying as indications for coating properties. **Thermal Spray: Practical Solutions for Engineering Problems**, ASM International, p. 577–583, 1996. Citado 5 vezes nas páginas 40, 43, 133, 136, 139.

WESZKA, J. S.; ROSENFELD, A. Threshold Evaluation Techniques. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 8, n. 8, p. 622–629, ago. 1978. ISSN 0018-9472. Citado 3 vez na página 55.

WHEELER, Bob; TORCHIANO, Marco. **ImPerm: Permutation Tests for Linear Models**. [S.I.], 2016. R package version 2.1.0. Disponível em: https://CRAN.Rproject.org/package=ImPerm. Acesso em: 22 jul. 2021. Citado 1 vez na página 84.

WRIGHT, Clara M; MANUEL, Michele; WALLACE, Terryl. Thermo-mechanical Evaluation of Selfhealing Metallic Structures for Aerospace Vehicles Utilizing Shape Memory Alloys, 2013. Citado 4 vezes nas páginas 33, 34.

XIA, Chunzhi et al. Microstructure and phase constitution near the interface of Cu/Al vacuum brazing using Al–Si filler metal. **Vacuum**, v. 82, n. 8, p. 799–804, 2008. ISSN 0042-207X. Citado 1 vez na página 35.

ZHANG, Xin et al. A Study for Texture Feature Extraction of High-Resolution Satellite Images Based on a Direction Measure and Gray Level Co-Occurrence Matrix Fusion Algorithm. **Sensors**, v. 17, p. 1474, jun. 2017. Citado 1 vez na página 72.

ZHU, Y.L. et al. Characterization via image analysis of cross-over trajectories and inhomogeneity in twin wire arc spraying. **Surface and Coatings Technology**, v. 162, n. 2, p. 301–308, 2003. ISSN 0257-8972. Citado 4 vezes nas páginas 39, 40, 42, 54.

ANEXOS

ANEXO A – ADAPTAÇÃO DA ROLDANA DE ALIMENTAÇÃO



ANEXO B – CÓDIGO QUANTIZADOR DE IGUAL PROBABILIDADE

```
from typing import Union
import numpy as np
import copy
def equal_prob_quantizer(image: Union[np.ndarray, list], levels: int = None):
    Apllies the equal probability quantizer to the given image
    :param image: 2d array like gray scale image
    :param levels: Integer of levels for the quantization
    :return: Quantized image in array form
    ....
   image = copy.deepcopy(image)
    if not isinstance(image, np.ndarray):
       image = np.array(image)
   # Sort the pixels by value
   sorted image = np.sort(image.flatten())
   image_size = sorted_image.size
   # Get the pixel count
   pixel_count = sorted_image.shape[0]
   # set first bin point
   bins = [0]
   bin index = -1 # because its the index
   reached image end = False
    for levels in range(levels, 1, -1):
       # Get the number of pixels per bin for the remaining levels
       samples_per_bin = int(pixel_count / levels)
       # Get location of the new bin
       bin index += samples_per_bin
       # Get the values at those locations (bin edges)
        possible bin = sorted image[bin index]
       # check if we have a different bin from the last iteraction
        i = 1
        while possible bin == bins[-1]:
           # check if the new bin index would be bigger than the actual image if so
                we stop
            if bin_index + i == image_size:
               reached image end = True
                break
           # if not try updating the bin
            possible bin = sorted image[bin index + i]
            i += 1
        if reached_image_end:
           break
       # get the positions with the same value as the possible bin
       a = np.where(sorted_image == possible_bin)
       # evaluate the distance of the possible bin from the the beginning and
           ending of the region with the same values
       erro_add = a[0][-1]-bin_index # distance from the end
        erro_dont_add = bin_index - a[0][0] + 1 # distance from the beginning
       # evaluate best option for adding or not the value to the bin
        if erro_dont_add >= erro_add:
```

```
# Add
        bins.append(possible_bin + 1)
        # Update the remaining pixels to distribute accordingly
        pixel_count = pixel_count - samples_per_bin - erro_add
        # Ppdate where we are in the list accordingly
        bin_index += erro_add
    else:
        # Add one before
        bins.append(possible bin)
        # Update the remaining pixels to distribute accordingly
        pixel_count = pixel_count - samples_per_bin + erro_dont_add
        # Update where we are in the list accordingly
        bin_index -= erro_dont_add
bins.append(sorted_image[-1]+1)
# Use the values to apply quantization
quantized = np.digitize(image, bins, right=False)-1
```

return quantized

ANEXO C – CÓDIGO WRAPPER CLASS RELIEFF

```
from skrebate import ReliefF
import numpy as np
from typing import Union
class ApplyReliefF2(ReliefF):
    def __init__(self, n_features_to_select: list,
                 n neighbors: Union[int, float] = 100, discrete threshold: int = 10,
                 verbose: bool = False, n_jobs: int = -1, n_features: list = None):
        ....
        This class expands on the functionality from the ReliefF class from
           skirebate.
        This class permits slicing the given dataset so that the feature selection
           may be done in each slice instead of in the entire dataset, allowing a
           more complex selection of features among different types of data in the
           dataset
        Here are the new or changed parameters for the new
        functionality
        :param n_features_to_select: list of ints
            list with the number of features to select for each slice of the data
        :param n_features: list of ints (default: None)
            list with the number of parameters that each slice contains. If
                n_features = None, than the data set will be treated containing a
                single slice with all the data.
       Taken from the documentation from skrebate relieff.py:
        :param n_neighbors: int or float (default: 100)
            The number of neighbors to consider when assigning feature importance
               scores. If a float number is provided, the percentage of training
               samples is used as the number of neighbors. More neighbors results
               in more accurate scores, but takes longer.
        :param discrete threshold: int (default: 10)
            Value used to determine if a feature is discrete or continuous.
            If the number of unique levels in a feature is > discrete threshold,
               then it is considered continuous, or discrete otherwise.
        :param verbose: bool (default: False)
            If True, output timing of distance array and scoring
        :param n jobs: int (default: 1)
            The number of cores to dedicate to computing the scores with joblib.
               Assigning this parameter to -1 will dedicate as many cores as are
               available on your system. We recommend setting this parameter to -1
               to speed up the algorithm as much as possible.
        For more information turn to the ReliefF parent class documentation
        # Here we use call the original init function
        # from the parent class
        super().__init__(n_features_to_select=n_features_to_select,
                         n neighbors=n neighbors,
                         discrete_threshold=discrete_threshold,
                         verbose=verbose, n_jobs=n_jobs)
```

```
# we need to make all the arguments from the init
    # function instances inside the class
    # Since ReliefF already deals with most of them here we
    # just add the n features
    self.n_features = n_features
    self.indices = []
    self.indices_new = []
    if self.n features:
        self.evaluate_new_indices()
def fit(self, x, y):
    . . .
    Scikit-learn required: applies the ReliefF algorithm
    :param x: 2d array like with different features as
    its columns
    :param y: 1d array with the labelled data
    For more information turn to the documentation of the
    ReliefF parent class method with same name
    .....
    if not isinstance(x, np.ndarray):
        x = np.array(x)
    if not isinstance(y, np.ndarray):
       y = np.array(y)
    if y.ndim != 1:
        y = y.flatten()
    # we test if the number of features in each slice was given, if not the
       entire dataset will be treated as one slice
    if not self.n_features:
        self.n_features = [x.shape[1]]
        self.evaluate new indices()
    super().fit(x, y)
def fit_transform(self, x, y):
    Scikit-learn required: applies the ReliefF algorithm and
    returns the transformed data
    :param x: 2d array like with different features as its
    columns
    :param y: 1d array with the labelled data
    :returns: numpy.ndarray with the selected features
    For more information turn to the documentation of the
    ReliefF parent class method with same name
    ....
    self.fit(x, y)
    return self.transform(x)
def transform(self, x):
    . . .
    Scikit-learn required: returns the transformed data
    :param x: 2d array like with different features as
    its columns
    :returns: numpy.ndarray with the selected features
    For more information turn to the documentation of the ReliefF parent class
       method with same name
```

```
if self._num_attributes < self.n_features_to_select:
        raise ValueError('Number_of_features_to_select_is_'
                         'larger_than_the_number_of_features'
                         '_in_the_dataset.')
   # first we divide the dataset into its different slices
   feature importances = self.split data(self.feature importances )
   x = self.split_data(x)
   # than we select the number of features desired in for each
   # slice
   x^{2} = []
    for i in range(len(feature_importances)):
        top_features_ = np.argsort(feature_importances[i][0])[::-1]
       x2.append(x[i][:, top_features_[:self.n_features_to_select[i]])
   x = self.reassemble_data(x2)
   # Here we check if the final data has only one data row,
   # if so we need to convert it from a 2d array to 1d
    if x.shape[0] == 1:
       x = x[0]
    return x
def split_data(self, data):
    Slices the data vertically into its sub-datasets
    :param data: 2d array like with different features as its
   columns
    ....
   data2 = []
   # convert the data to numpy arrays
    if not isinstance(data, np.ndarray):
       data = np.array(data)
   # if we only have one row vector we need to convert it to
   # a column vector
    if data.ndim == 1:
        data = np.array(data, ndmin=2)
   # slice the data vertically
    for i in range(len(self.indices) - 1):
        data2.append(data[:, self.indices[i]:self.indices[i+1]])
    return data2
def reassemble_data(self, data):
   Join vertically the sub-datasets in data into a unique dataset
    :param data: list of dataset each with different features as its columns
    . . .
   # allocate the memory for the new dataset
   data2 = np.empty((data[0].shape[0],
                      sum(self.n_features_to_select)),
                     dtype=object)
   # add the transformed sub-datasets to the new dataset
    for i in range(len(data)):
        data2[:, self.indices new[i]:self.indices new[i+1]] = data[i]
```

....

158

ANEXO D – IMAGENS DOS REVESTIMENTOS POR MICROSCOPIA ÓTICA

FIGURA 64 – IMAGEM DE MICROSCÓPIO ÓTICO DO REVESTIMENTO OBTIDO NA AMOS-TRA 1



FONTE: O autor(2021).

FIGURA 65 – IMAGEM DE MICROSCÓPIO ÓTICO DO REVESTIMENTO OBTIDO NA AMOS-TRA 2



FONTE: O autor(2021).

FIGURA 66 – IMAGEM DE MICROSCÓPIO ÓTICO DO REVESTIMENTO OBTIDO NA AMOS-TRA 3



FONTE: O autor(2021).

FIGURA 67 – IMAGEM DE MICROSCÓPIO ÓTICO DO REVESTIMENTO OBTIDO NA AMOS-TRA 4



FIGURA 68 – IMAGEM DE MICROSCÓPIO ÓTICO DO REVESTIMENTO OBTIDO NA AMOS-TRA 5



FONTE: O autor(2021).

FIGURA 69 – IMAGEM DE MICROSCÓPIO ÓTICO DO REVESTIMENTO OBTIDO NA AMOS-TRA 6



FONTE: O autor(2021).

FIGURA 70 – IMAGEM DE MICROSCÓPIO ÓTICO DO REVESTIMENTO OBTIDO NA AMOS-TRA 7



FIGURA 71 – IMAGEM DE MICROSCÓPIO ÓTICO DO REVESTIMENTO OBTIDO NA AMOS-TRA 8



ANEXO E – IMAGENS DOS REVESTIMENTOS POR MEV



FIGURA 72 – IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 1

FONTE: O autor(2021).



FIGURA 73 – IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 2



FIGURA 74 – IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 3

FONTE: O autor(2021).

FIGURA 75 – IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 4





FIGURA 76 – IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 5

FONTE: O autor(2021).



FIGURA 77 – IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 6



FIGURA 78 – IMAGEM MEV-BSE DO REVESTIMENTO DA AMOSTRA 7

FONTE: O autor(2021).





ANEXO F – CLASSIFICAÇÕES DOS REVESTIMENTOS USANDO O *SOFTWARE* IMAGEJ

FIGURA 80 – CLASSIFICAÇÃO DA IMAGEM DE MICROSCOPIA OTICA DA AMOSTRA 1 OBTIDA PELO MODELO "*FAST RANDOM FOREST*" DO *PLUGIN TRAINABLE WEKA SEGMENTATION* DO *SOFTWARE* IMAGEJ



FONTE: O autor(2021).

NOTA: Vermelho: Porosidade, Verde: Óxidos, Roxo: Cobre, Amarelo: Alumínio, Azul: Mistura

FIGURA 81 – CLASSIFICAÇÃO DA IMAGEM DE MICROSCOPIA OTICA DA AMOSTRA 2 OBTIDA PELO MODELO "*FAST RANDOM FOREST*" DO *PLUGIN TRAINABLE WEKA SEGMENTATION* DO *SOFTWARE* IMAGEJ

and the		
P. C. A.	19	200µm-
and the second		

FONTE: O autor(2021).

NOTA: Vermelho: Porosidade, Verde: Óxidos, Roxo: Cobre, Amarelo: Alumínio, Azul: Mistura

FIGURA 82 – CLASSIFICAÇÃO DA IMAGEM DE MICROSCOPIA OTICA DA AMOSTRA 3 OBTIDA PELO MODELO "*FAST RANDOM FOREST*" DO *PLUGIN TRAINABLE WEKA SEGMENTATION* DO *SOFTWARE* IMAGEJ



FONTE: O autor(2021).

NOTA: Vermelho: Porosidade, Verde: Óxidos, Roxo: Cobre, Amarelo: Alumínio, Azul: Mistura

FIGURA 83 – CLASSIFICAÇÃO DA IMAGEM DE MICROSCOPIA OTICA DA AMOSTRA 4 OBTIDA PELO MODELO "*FAST RANDOM FOREST*" DO *PLUGIN TRAINABLE WEKA SEGMENTATION* DO *SOFTWARE* IMAGEJ



FONTE: O autor(2021). NOTA: Vermelho: Porosidade, Verde: Óxidos, Roxo: Cobre, Amarelo: Alumínio, Azul: Mistura

FIGURA 84 – CLASSIFICAÇÃO DA IMAGEM DE MICROSCOPIA OTICA DA AMOSTRA 5 OBTIDA PELO MODELO "*FAST RANDOM FOREST*" DO *PLUGIN TRAINABLE WEKA SEGMENTATION* DO *SOFTWARE* IMAGEJ



FONTE: O autor(2021).

NOTA: Vermelho: Porosidade, Verde: Óxidos, Roxo: Cobre, Amarelo: Alumínio, Azul: Mistura

FIGURA 85 – CLASSIFICAÇÃO DA IMAGEM DE MICROSCOPIA OTICA DA AMOSTRA 6 OBTIDA PELO MODELO "*FAST RANDOM FOREST*" DO *PLUGIN TRAINABLE WEKA SEGMENTATION* DO *SOFTWARE* IMAGEJ



FONTE: O autor(2021). NOTA: Vermelho: Porosidade, Verde: Óxidos, Roxo: Cobre, Amarelo: Alumínio, Azul: Mistura FIGURA 86 – CLASSIFICAÇÃO DA IMAGEM DE MICROSCOPIA OTICA DA AMOSTRA 7 OBTIDA PELO MODELO "*FAST RANDOM FOREST*" DO *PLUGIN TRAINABLE WEKA SEGMENTATION* DO *SOFTWARE* IMAGEJ



FONTE: O autor(2021).

NOTA: Vermelho: Porosidade, Verde: Óxidos, Roxo: Cobre, Amarelo: Alumínio, Azul: Mistura

FIGURA 87 – CLASSIFICAÇÃO DA IMAGEM DE MICROSCOPIA OTICA DA AMOSTRA 8 OBTIDA PELO MODELO "*FAST RANDOM FOREST*" DO *PLUGIN TRAINABLE WEKA SEGMENTATION* DO *SOFTWARE* IMAGEJ



FONTE: O autor(2021). NOTA: Vermelho: Porosidade, Verde: Óxidos, Roxo: Cobre, Amarelo: Alumínio, Azul: Mistura

ANEXO G – CLASSIFICAÇÕES DOS REVESTIMENTOS USANDO PYTHON™ E SUAS BIBLIOTECAS

FIGURA 88 – CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 1 PELO MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BIBLIOTECAS



FIGURA 89 – CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 2 PELO MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BIBLIOTECAS



FONTE: O autor(2021).

NOTA: Vermelho: Porosidade, Verde: Óxidos, Azul: Cobre, Rosa: Alumínio, Amarelo: Mistura

FIGURA 90 – CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 3 PELO MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BIBLIOTECAS



FIGURA 91 – CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 4 PELO MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BIBLIOTECAS



FONTE: O autor(2021).

NOTA: Vermelho: Porosidade, Verde: Óxidos, Azul: Cobre, Rosa: Alumínio, Amarelo: Mistura

FIGURA 92 – CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 5 PELO MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BIBLIOTECAS



FIGURA 93 – CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 6 PELO MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BIBLIOTECAS



FONTE: O autor(2021).

NOTA: Vermelho: Porosidade, Verde: Óxidos, Azul: Cobre, Rosa: Alumínio, Amarelo: Mistura

FIGURA 94 – CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 7 PELO MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BIBLIOTECAS



FIGURA 95 – CLASSIFICAÇÃO DA IMAGEM DE MEV DA AMOSTRA 8 PELO MODELO FLORESTA ALEATÓRIA POR PYTHON™ E SUAS BIBLIOTECAS



FONTE: O autor(2021).

NOTA: Vermelho: Porosidade, Verde: Óxidos, Azul: Cobre, Rosa: Alumínio, Amarelo: Mistura