

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE
SANTA CATARINA - CÂMPUS FLORIANÓPOLIS
DEPARTAMENTO ACADÊMICO DE METAL MECÂNICA
CURSO DE GRADUAÇÃO EM ENGENHARIA MECATRÔNICA**

BRUNO PELOI CARMINATTI

**PREDIÇÃO DA GEOMETRIA DO CORDÃO DE DEPOSIÇÃO EM LASER CLADDING
POR APRENDIZADO DE MÁQUINA**

FLORIANÓPOLIS, 2026.

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE
SANTA CATARINA - CÂMPUS FLORIANÓPOLIS
DEPARTAMENTO ACADÊMICO DE METAL MECÂNICA
CURSO DE GRADUAÇÃO EM ENGENHARIA MECATRÔNICA**

BRUNO PELOI CARMINATTI

**PREDIÇÃO DA GEOMETRIA DO CORDÃO DE DEPOSIÇÃO EM LASER CLADDING
POR APRENDIZADO DE MÁQUINA**

Trabalho de Conclusão de Curso submetido
ao Instituto Federal de Educação, Ciência
e Tecnologia de Santa Catarina como parte
dos requisitos para obtenção do título de
Engenheiro Mecatrônico.

Orientador:
Prof. Cassiano Bonin, Dr.

FLORIANÓPOLIS, 2026.

Ficha de identificação da obra elaborada pelo autor.

Carminatti, Bruno

**PREDIÇÃO DA GEOMETRIA DO CORDÃO DE DEPOSIÇÃO EM LASER
CLADDING POR APRENDIZADO DE MÁQUINA / Bruno Carminatti;
orientação de Cassiano Bonin. - Florianópolis, SC,
2026.
96 p.**

**Trabalho de Conclusão de Curso (TCC) - Instituto Federal
de Santa Catarina, Câmpus Florianópolis. Bacharelado
em Engenharia Mecatrônica. Departamento
Acadêmico de Metal Mecânica.
Inclui Referências.**

**1. Laser Cladding. 2. Manufatura aditiva. 3. Aprendizado
de máquina. 4. XGBoost. 5. Quantificação de incerteza.
I. Bonin, Cassiano. II. Instituto Federal de Santa
Catarina. III. PREDIÇÃO DA GEOMETRIA DO CORDÃO
DE DEPOSIÇÃO EM LASER CLADDING POR APRENDIZADO DE MÁQUINA.**




INSTITUTO FEDERAL

MINISTÉRIO DA EDUCAÇÃO

SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SANTA CATARINA
CAMPUS FLORIANÓPOLIS

**ATA DA BANCA FINAL DO TRABALHO DE CONCLUSÃO DO CURSO DE ENGENHARIA
MECATRÔNICA DO INSTITUTO FEDERAL DE SANTA CATARINA – Nº 225**

Aos 7 dias do mês de julho, de 2026 às 11h, o (a) estudante Bruno Peloi Carminatti apresentou o seu Trabalho de Conclusão de Curso para julgamento à Banca Examinadora constituída pelos seguintes integrantes: Prof Cassiano Bonin (orientador/presidente da banca/IFSC), Prof Erwin Werner Teichmann (IFSC) e Prof Mauricio Edgar Stivanello (IFSC). A sessão pública de defesa foi aberta pelo Presidente da Banca, que apresentou a Banca Examinadora e deu continuidade aos trabalhos, fazendo uma breve referência ao TCC que tem como título Predição da Geometria do Cordão de Deposição em Laser Cladding por Aprendizado de Máquina. Na sequência, o(a) estudante teve até 30 minutos para a exposição de seu trabalho, e cada integrante da Banca Examinadora fez a arguição após a apresentação do mesmo. Finalmente, foi aberto um espaço aos presentes para eventuais perguntas ou comentários sobre o trabalho apresentado. Ouvidas as explicações do(a) estudante, a Banca Examinadora, reunida em caráter sigiloso, para proceder à avaliação final, deliberou pelo conceito 10. Foi dada ciência ao(à) estudante que a versão final do trabalho deverá ser entregue até o dia 15/7/2026, com as devidas alterações sugeridas pela banca. Nada mais havendo a tratar, a sessão foi encerrada às 11h 00min, dela sendo lavrada a presente ata, que, uma vez aprovada, foi assinada por todos os membros da Banca Examinadora e pelo(a) estudante.


Prof.(a) Orientador(a) / Presidente: Cassiano Bonin


Prof.(a) Avaliador 1: Erwin Werner Teichmann


Prof.(a) Avaliador 2: Mauricio Edgar Stivanello


Acadêmico(a): Bruno Peloi Carminatti

RESUMO

Este trabalho apresenta um sistema de aprendizado de máquina para prever a largura, a altura e a área da seção transversal do cordão depositado pela técnica a laser L-DED (*Laser Directed Energy Deposition*), em função dos parâmetros do processo. A principal contribuição é integrar, em um único fluxo, a extração automática da geometria a partir de imagens, a modelagem preditiva com restrições baseadas na física do processo, a quantificação da incerteza e uma ferramenta interativa de uso. O conjunto experimental reúne 36 anéis depositados sobre um eixo cilíndrico de aço AISI 1045 em rotação, com variação contínua dos parâmetros, totalizando 25.920 comandos em código G e um vídeo lateral do processo. As três dimensões foram medidas imagem por imagem por visão computacional, após corrigir uma defasagem de sincronização entre o vídeo e os comandos e adotar uma suavização temporal leve, que atenua o ruído sem destruir a variação real da geometria. Treinaram-se modelos XGBoost com restrições de monotonicidade físicas, com um Ridge polinomial como linha de base, validados anel por anel e por verificações de coerência física frente à potência e à velocidade. A avaliação prioriza o erro absoluto médio (da ordem de 0,12 mm para largura e altura), métrica diretamente interpretável na prática, em vez do coeficiente de determinação, cujos valores (entre 0,60 e 0,65) refletem a opção por preservar a variação real da geometria, sem recorrer a uma suavização agressiva que os elevaria artificialmente. A incerteza foi estimada por regressão quantílica conformalizada (CQR), alcançando cobertura empírica próxima de 80% nos dados avaliados. Por fim, uma interface gráfica reúne a predição pontual, a visualização das faixas de operação e a comparação de cenários, além de um modo de predição inversa que sugere os parâmetros mais próximos de produzir uma geometria-alvo.

Palavras-chave: Laser cladding. Manufatura aditiva. Aprendizado de máquina. XGBoost. Quantificação de incerteza.

ABSTRACT

This work presents a machine learning system for predicting the width, height, and cross-sectional area of the bead deposited by the L-DED (Laser Directed Energy Deposition) technique from the process parameters. Its main contribution is to integrate, in a single workflow, the automatic extraction of the geometry from images, predictive modeling with physics-based constraints, uncertainty quantification, and an interactive tool. The experimental dataset comprises 36 rings deposited on a rotating AISI 1045 steel cylindrical shaft, with continuous variation of the parameters, totaling 25,920 G-code commands and a lateral video of the process. The three dimensions were measured frame by frame using computer vision, after correcting a synchronization offset between the video and the commands and adopting a light temporal smoothing that attenuates noise without destroying the real variation of the geometry. XGBoost models were trained with physics-based monotonicity constraints, with a polynomial Ridge model as a baseline, validated ring by ring and through physical-consistency checks against power and velocity. The evaluation prioritizes the mean absolute error (on the order of 0.12 mm for width and height), a metric directly interpretable in practice, over the coefficient of determination, whose values (between 0.60 and 0.65) reflect the choice to preserve the real variation of the geometry rather than relying on aggressive smoothing that would inflate them. Uncertainty was estimated by conformalized quantile regression (CQR), achieving empirical coverage near 80% on the evaluated data. Finally, a graphical interface brings together point predictions, visualization of the operating ranges, and scenario comparison, as well as an inverse prediction mode that suggests the parameters closest to producing a target geometry.

Keywords: Laser cladding. Additive manufacturing. Machine learning. XGBoost. Uncertainty quantification.

LISTA DE FIGURAS

Figura 1 – Paradigmas de manufatura	18
Figura 2 – Esquema do processo L-DED com alimentação coaxial de pó	19
Figura 3 – Esquema do processo de <i>boosting</i> para aprendizagem em conjunto	25
Figura 4 – Limiarização de uma imagem monocromática	30
Figura 5 – Visão geral do <i>pipeline</i> metodológico	33
Figura 6 – Fotografia do arranjo experimental	34
Figura 7 – <i>Frame</i> antes e depois da binarização	39
Figura 8 – <i>Frame</i> antes e depois dos tratamentos	40
Figura 9 – Algoritmo de medição por quadro	41
Figura 10 – Quadros laterais de medição fácil e difícil	43
Figura 11 – <i>Frame</i> com as zonas de detecção e a largura	46
Figura 12 – Etapas de suavização e redução do conjunto	53
Figura 13 – Representação da validação cruzada por anel	55
Figura 14 – Semielipse da seção transversal	61
Figura 15 – Exemplo da guia de predição direta	62
Figura 16 – Janela dos intervalos de predição	62
Figura 17 – Comparador de cenários	63
Figura 18 – Guia de predição inversa	65
Figura 19 – Análise do erro de predição	69
Figura 20 – Valores SHAP do modelo de altura	71
Figura 21 – Valores SHAP do modelo de área	72
Figura 22 – Valores SHAP do modelo de largura	73
Figura 23 – Varreduras paramétricas unitárias dos três alvos	75
Figura 24 – Mapas de calor no plano $P \times F$	76
Figura 25 – Geometria predita versus energia linear	77
Figura 26 – Diagnóstico da calibração CQR (área)	79
Figura 27 – Cordão real <i>versus</i> seção predita	80

LISTA DE QUADROS

Quadro 1 – Componentes do arranjo experimental	34
Quadro 2 – Envelope operacional contemplado no experimento	35
Quadro 3 – Atributos da modelagem organizados em grupos	49
Quadro 4 – Atributos físicos derivados	50
Quadro 5 – Restrições de monotonicidade do XGBoost	51
Quadro 6 – Hiperparâmetros do XGBoost por variável-alvo	54
Quadro 7 – Construção dos 18 pontos de canto	77
Quadro 8 – Fórmulas das variáveis de entrada	96

LISTA DE TABELAS

Tabela 1 – Estatísticas das variáveis-alvo	48
Tabela 2 – Métricas de regressão (LOGO-CV)	67
Tabela 3 – Violações de monotonicidade por versão	75
Tabela 4 – Cobertura e largura dos intervalos CQR	78

LISTA DE ABREVIATURAS E SIGLAS

CNC	Controle Numérico Computadorizado
CQR	<i>Conformalized Quantile Regression</i> (regressão quantílica conformalizada)
CSV	<i>Comma-Separated Values</i> (valores separados por vírgula)
DED	<i>Directed Energy Deposition</i> (deposição por energia direcionada)
FPS	<i>Frames per Second</i> (quadros por segundo)
L-DED	<i>Laser Directed Energy Deposition</i> (deposição por energia direcionada a laser)
LMP	Laboratório de Mecânica de Precisão
LOGO-CV	<i>Leave-One-Group-Out Cross-Validation</i> (validação cruzada com exclusão de um grupo)
MAE	<i>Mean Absolute Error</i> (erro absoluto médio)
PBF	<i>Powder Bed Fusion</i> (fusão em leito de pó)
RGB	<i>Red, Green, Blue</i> (canais de cor primários)
RMSE	<i>Root Mean Squared Error</i> (raiz do erro quadrático médio)
ROI	<i>Region of Interest</i> (região de interesse)
RPM	Rotações por minuto
SHAP	<i>Shapley Additive exPlanations</i> (explicações aditivas de Shapley)
UFSC	Universidade Federal de Santa Catarina

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Justificativa	13
1.2	Definição do problema	14
1.3	Objetivo geral	15
1.4	Objetivos específicos	15
1.5	Estrutura do trabalho	15
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	Manufatura aditiva e o processo L-DED	17
2.1.1	Manufatura aditiva metálica	17
2.1.2	O processo L-DED	18
2.2	Parâmetros do processo e geometria do cordão	20
2.3	Aprendizado de máquina supervisionado	20
2.3.1	Sobreajuste e regularização	21
2.3.2	Validação cruzada	21
2.3.3	Métricas de avaliação	22
2.3.4	Engenharia de atributos	23
2.4	Modelos baseados em árvores: XGBoost	24
2.4.1	<i>Gradient boosting</i> e XGBoost	25
2.4.2	Restrições de monotonicidade	25
2.5	Regressão Ridge polinomial	26
2.6	Interpretabilidade por SHAP	27
2.7	Quantificação de incerteza por CQR	27
2.7.1	Regressão quantílica	28
2.7.2	Calibração conformal	28
2.8	Visão computacional para medição da geometria	29
2.8.1	Operações de processamento de imagem	29
2.8.2	Perfis de intensidade e detecção de bordas	30
2.8.3	Representação da seção por semielipse	31
3	METODOLOGIA	32
3.1	Visão geral do <i>pipeline</i>	32
3.2	Configuração experimental	33
3.2.1	Plano experimental	35
3.3	Aquisição dos dados	35
3.3.1	Câmera lateral e calibração espacial	36
3.3.2	Câmera frontal	36
3.3.3	Gravação contínua e parâmetros do código G	37
3.3.4	Detecção automática dos <i>timings</i> dos anéis	37
3.4	Processamento de vídeo	37
3.4.1	Correção da deriva por anel	38
3.4.2	Binarização e filtragem espacial	38
3.4.3	Estabilização temporal e limpeza	39
3.4.4	Geração do vídeo silhueta	40
3.5	Extração da geometria por <i>frame</i>	40
3.5.1	Região de interesse e perfil horizontal	41
3.5.2	Medição da altura	42

3.5.3	Detecção das bordas e cálculo da largura	42
3.5.4	Cálculo da área	43
3.5.5	Sincronização entre quadros e comandos em código G	43
3.5.6	Correção da defasagem entre deposição e imageamento	44
3.5.7	Pós-processamento das medições	45
3.5.8	Resultado da extração	45
3.6	Construção do conjunto de dados de treinamento	46
3.6.1	Agregação e junção dos dados	46
3.6.2	Suavização temporal por anel	47
3.6.3	Composição final do conjunto de dados	47
3.7	Engenharia de atributos e modelagem	48
3.7.1	Atributos físicos derivados	48
3.7.2	Restrições de monotonicidade	51
3.7.3	Agregação por faixas de velocidade	52
3.7.4	Modelo principal: XGBoost	53
3.7.5	Linha de base: Ridge polinomial	54
3.7.6	Interpretabilidade por SHAP	54
3.8	Validação por LOGO-CV	55
3.9	Validação física dos modelos	56
3.9.1	Testes de coerência física	56
3.9.2	Refinamento iterativo do modelo	57
3.10	Quantificação de incerteza por CQR	58
3.10.1	Construção do intervalo de incerteza	58
3.10.2	Cobertura empírica e limitação teórica	59
3.11	Visualização preditiva da seção transversal	60
3.11.1	Forma adotada: semi-elipse	60
3.11.2	Módulo de visualização	60
3.12	Ferramenta interativa de inferência	61
3.12.1	Predição pontual com banda de incerteza	61
3.12.2	Mapa operacional $P \times F$	63
3.12.3	Comparador de cenários	63
3.12.4	Predição inversa	64
3.12.4.1	<i>Diversificação por configuração de empilhamento</i>	<i>64</i>
4	APRESENTAÇÃO DOS RESULTADOS	66
4.1	Estatísticas do conjunto de dados final	66
4.2	Métricas de regressão por LOGO-CV	66
4.2.1	Desempenho dos modelos treinados	66
4.2.2	Interpretação do erro de predição	68
4.2.3	Evolução das métricas ao longo do desenvolvimento	69
4.3	Importância das variáveis (SHAP)	70
4.4	Validação dos modelos de acordo com tendências físicas	74
4.4.1	Varreduras paramétricas	74
4.4.2	Mapa $P \times F$ e cantos do envelope	76
4.4.3	Consistência da energia linear	77
4.4.4	Síntese da validação física	78
4.5	Cobertura empírica do CQR	78
4.6	Exemplos da visualização preditiva	79
4.7	Avaliação da ferramenta de predição	81

4.8	Discussão integrada	81
4.8.1	Suavização, sincronização e seu efeito sobre o R^2	82
4.8.2	Validade do conjunto reduzido com o uso de XGBoost	83
4.8.3	Ausência de vazamento entre treino e teste	84
4.8.4	Limitação estrutural: sensibilidade da área à potência	84
4.8.5	Alcance prático da cobertura CQR	85
5	CONSIDERAÇÕES FINAIS	86
5.1	Síntese dos resultados	86
5.2	Sugestões para trabalhos futuros	87
5.2.1	Sincronismo lateral aprimorado	88
5.2.2	Reaquisição dedicada do processo com câmera especializada	88
5.2.3	Ampliação do plano experimental para a sensibilidade à potência	88
5.2.4	Redução adicional da janela de suavização em conjuntos de dados futuros	89
5.2.5	Caracterização e predição do fator de forma do cordão	89
	REFERÊNCIAS	91
	APÊNDICES	93
	APÊNDICE A – PSEUDOCÓDIGO DO ALGORITMO DE MEDIÇÃO DA GEOMETRIA POR QUADRO	94
	APÊNDICE B – CONJUNTO COMPLETO DE ATRIBUTOS DERIVADOS	96

1 INTRODUÇÃO

A manufatura aditiva metálica vem ocupando, nas últimas décadas, um papel crescente em aplicações industriais nas quais o custo unitário das peças é elevado, os volumes de produção são reduzidos e a flexibilidade geométrica é determinante. Entre as técnicas de manufatura aditiva metálica, o *Laser Directed Energy Deposition* (L-DED) destaca-se pela capacidade de depositar material diretamente sobre substratos pré-existentes, o que o torna particularmente adequado a operações de revestimento e de reparo de peças de alto valor agregado.

Apesar de seu potencial, o processo de L-DED é sensível a uma combinação grande de parâmetros operacionais (potência do laser, velocidade de avanço, taxa de alimentação de pó, número de camadas e incremento vertical entre camadas, entre outros) cujos efeitos sobre a geometria final do cordão depositado são, frequentemente, explorados por meio de repetidas deposições de teste até que o operador encontre, por tentativa e erro, uma combinação aceitável. Esse processo é demorado, consome material e tempo de máquina, e introduz incertezas no planejamento da produção.

O presente trabalho propõe uma alternativa baseada em aprendizado de máquina. A partir dos dados experimentais coletados no Laboratório de Mecânica de Precisão da UFSC (LMP/UFSC) por Bonin et al. (2023), foi desenvolvido um sistema capaz de estimar, a partir dos parâmetros do processo, três grandezas geométricas centrais do cordão: a largura, a altura e a área da seção transversal. O sistema desenvolvido inclui modelos preditivos, estimativas de incerteza calibradas estatisticamente e uma ferramenta interativa de inferência, permitindo ao operador antecipar a geometria esperada antes de realizar a deposição.

1.1 Justificativa

A predição antecipada da geometria do cordão depositado em L-DED traz três benefícios concretos para a operação industrial. O primeiro é econômico: reduzir o número de ensaios de deposição diminui o consumo de pó metálico, o tempo de uso da máquina e o desgaste de componentes auxiliares (bico, sistema de alimentação). O segundo benefício é operacional: ter uma boa estimativa do formato do cordão antes de ligar a máquina permite que o operador configure o equipamento com base em números reais, e não apenas na intuição ou na base da tentativa e erro. O terceiro diz respeito ao próprio método de trabalho: ao contar com um sistema capaz de prever os resultados, criam-se condições para futuras estratégias de automação. Um exemplo disso seria o desenvolvimento de uma automação em que a própria máquina ajusta seus controles sozinha para entregar exatamente as medidas que o projeto da peça exige.

O trabalho de referência que originou os dados experimentais (BONIN et al., 2023) adotou redes neurais profundas, alimentadas por dados numéricos e por imagens das câmeras de processo, com objetivo distinto: prever obstruções (*clogging*) do alimentador de pó em tempo real. Para a finalidade citada, a dependência de informação visual da pluma e da poça de fusão justifica a adoção de modelos que tendem a demandar volumes maiores de dados para evitar sobreajuste. O presente trabalho, por sua vez, busca prever a geometria estática do cordão, e não o *clogging* em tempo real, a partir exclusivamente dos parâmetros tabulares do processo, sem processamento adicional de imagens da câmera frontal. Para esse problema, modelos baseados em *gradient boosting* (impulsioneamento por gradiente) sobre dados tabulares, em particular o XGBoost, apresentam, segundo a literatura, desempenho elevado mesmo com conjuntos de treinamento de algumas centenas de observações (CHEN; GUESTRIN, 2016; HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Essa adequação algoritmo-problema é discutida em detalhe nos Capítulos 3 e 4. A lacuna enfrentada é a ausência de uma ferramenta simples, calibrada e fisicamente coerente para prever geometria a partir de parâmetros tabulares.

1.2 Definição do problema

O problema tratado neste trabalho é formulado como três tarefas de regressão (uma para cada grandeza geométrica). Dado um vetor de cinco parâmetros do processo de L-DED,

$$\mathbf{x} = (P, F, L, z_{\text{step}}, \text{pfr}),$$

em que P é a potência do laser, F é a velocidade de avanço, L é o número de camadas, z_{step} é o incremento vertical entre camadas e pfr é a taxa de alimentação de pó, deseja-se estimar três grandezas geométricas escalares do cordão:

$$\mathbf{y} = (w, h, A),$$

em que w é a largura, h é a altura e A é a área da seção transversal. As três grandezas são medidas, neste trabalho, a partir de imagens de uma câmera lateral posicionada perpendicularmente ao eixo de rotação do substrato durante a deposição. Para que a predição seja útil na prática, o sistema deve estimar essas grandezas com erro compatível com a tolerância dimensional esperada do processo; por isso, a avaliação dos modelos é organizada em torno das métricas de erro absoluto, e não apenas do ajuste estatístico global.

O envelope operacional considerado é o do experimento original (BONIN et al., 2023), onde P varia entre 282 e 2.198 W em nove níveis, F entre 343 e 2.062 mm/min em quarenta níveis, L assume os valores $\{1, 2, 3\}$, z_{step} assume os valores

{0,2; 0,5; 0,8; 1,1} mm e pfr assume os valores {2, 3, 4} RPM. Predições do modelo para combinações de parâmetros fora desse envelope são consideradas como extrapolação e devem ser interpretadas com cautela.

1.3 Objetivo geral

Desenvolver um sistema de aprendizado de máquina capaz de prever a geometria do cordão depositado por L-DED (largura, altura e área da seção transversal) em função dos parâmetros do processo, validar fisicamente as predições obtidas e disponibilizar uma ferramenta interativa de inferência para uso por operadores ou pesquisadores.

1.4 Objetivos específicos

Para alcançar o objetivo geral, este trabalho organizou-se em torno dos seguintes objetivos específicos:

- a) extrair a geometria do cordão (largura, altura e área) a partir dos vídeos da câmera lateral, por meio de um *pipeline* que gera quadros silhueta e mede cada quadro;
- b) construir um conjunto de dados de treinamento que reúna, em uma única estrutura tabular, os parâmetros do processo registrados pela CNC e as medições geométricas associadas a cada bloco de comando;
- c) treinar e validar modelos preditivos a partir do conjunto de dados construído;
- d) quantificar a incerteza das predições e validar empiricamente a cobertura dos intervalos resultantes;
- e) disponibilizar uma ferramenta interativa de inferência que apresente a predição pontual, a banda de incerteza e a visualização da seção transversal, além de um modo de predição inversa que, a partir de alvos de geometria informados pelo usuário, sugira as combinações de parâmetros mais próximas de produzi-los.

1.5 Estrutura do trabalho

O restante deste trabalho está organizado em quatro capítulos. O Capítulo 2 apresenta a fundamentação teórica necessária para acompanhar o desenvolvimento, cobrindo o processo de L-DED, os conceitos de aprendizado de máquina supervisionado empregados (XGBoost, regressão Ridge polinomial, valores SHAP e regressão quantílica conformalizada) e os elementos de visão computacional utilizados na medição da geometria do cordão. O Capítulo 3 descreve, em detalhe, o *pipeline* desenvolvido

(da aquisição dos dados à construção da ferramenta interativa de inferência). O Capítulo 4 apresenta os resultados obtidos: estatísticas do conjunto de dados, métricas de regressão na validação cruzada, análise da importância dos atributos por SHAP, resultados da validação física, cobertura empírica do CQR e exemplos da visualização preditiva. O Capítulo 5 sintetiza os resultados, retoma as limitações reconhecidas e indica direções para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA


Este capítulo apresenta os conceitos necessários para acompanhar o desenvolvimento metodológico do trabalho. A exposição é organizada em três blocos. O primeiro (Seções 2.1 e 2.2) trata do processo de manufatura aditiva por L-DED e das grandezas geométricas e operacionais envolvidas. O segundo (Seções 2.3 a 2.7) trata dos métodos de aprendizado de máquina supervisionado utilizados para predição e quantificação de incerteza. O terceiro (Seção 2.8) apresenta os elementos de visão computacional usados para medir a geometria do cordão a partir do vídeo lateral.

2.1 Manufatura aditiva e o processo L-DED

2.1.1 Manufatura aditiva metálica

A manufatura aditiva é definida pela norma ISO/ASTM 52900 (International Organization for Standardization; ASTM International, 2021) como o processo de unir materiais para produzir peças a partir de modelos tridimensionais, geralmente por adição sucessiva de camadas, em contraposição às metodologias subtrativas (usinagem) e formativas (fundição, conformação), como ilustra a Figura 1. A norma classifica as tecnologias de manufatura aditiva em sete categorias, entre as quais as mais relevantes para o presente trabalho são as de *powder bed fusion* (PBF) e *directed energy deposition* (DED).

A relevância industrial dessa família de processos cresceu de forma consistente nas últimas décadas. Como sintetiza Silva et al. (2020, p. 84502) em revisão sistemática da literatura, a manufatura aditiva “é percebida atualmente como um tipo de tecnologia com a tendência de ser uma das principais metodologias de fabricação para o futuro”. Esse crescimento é atribuído, em boa parte, à consequente redução do custo dos equipamentos, que ampliaram o alcance da tecnologia para além da prototipagem rápida em direção à fabricação de produtos finais.

Figura 1 – Comparação entre os paradigmas de manufatura formativa, subtrativa e aditiva

Fonte: Adaptado de Gawde (2023).

Na categoria DED, o material é introduzido na região de fabricação no momento da deposição, ao contrário do PBF, em que o material já se encontra distribuído em camadas. A introdução do material durante o processo confere ao DED uma flexibilidade geométrica que o torna particularmente útil em três aplicações industriais: a deposição de revestimentos funcionais sobre substratos pré-existentes; o reparo de peças desgastadas, em que cordões são adicionados sobre regiões faltantes para restaurar a geometria original; e a fabricação de peças de geometria complexa em pequenas séries.

No caso específico dos materiais metálicos, que utilizam majoritariamente pó ou fio metálico como matéria-prima, Ladeira (2021, p. 4) observa que “os métodos de processamento de materiais metálicos a partir de manufatura aditiva podem ser separados em processos de *Powder Bed Fusion* (PBF) e em processos de *Directed Energy Deposition* (DED), classificados com relação à fonte de energia utilizada”. O presente trabalho situa-se na categoria DED, mais especificamente na sua variação a laser, descrita a seguir.


2.1.2 O processo L-DED

O *Laser Directed Energy Deposition* (L-DED) é uma variação do DED em que o feixe focado de um laser de alta potência é utilizado como fonte de energia para fundir, simultaneamente, o material introduzido na região de deposição (em geral pó metálico, embora fios também sejam comuns) e uma fina camada da superfície do substrato. A interação resulta em uma poça de fusão metálica que, ao se resfriar, forma o cordão depositado. A Figura 2 ilustra esquematicamente esse processo, com a entrega coaxial de pó convergindo para a poça de fusão formada sob o feixe laser. Toyserkani,

Khajepour e Corbin (2004) fornecem uma descrição abrangente do processo, da física da interação laser-material e dos parâmetros operacionais que controlam o resultado da deposição.

O processo é também conhecido como *laser cladding*. Segundo Teixeira (2021, p. 21), trata-se de “uma técnica de deposição de metais a laser usada para fabricar ou reparar componentes feitos de ligas metálicas com alto valor agregado”. Em comparação com a soldagem a arco convencional, o aporte térmico concentrado do feixe produz taxas de resfriamento mais altas e uma zona termicamente afetada mais estreita, o que favorece o controle metalúrgico do depósito (TEIXEIRA, 2021).

Figura 2 – Esquema do processo L-DED com alimentação coaxial de pó



Fonte: Adaptado de Guan e Zhao (2020).

Os bicos de deposição empregados em L-DED dividem-se, em linhas gerais, em duas categorias: laterais, em que o pó é introduzido por um único bocal ao lado do feixe, e coaxiais, em que o pó é entregue ao redor do eixo do laser, formando um cone que converge para a poça de fusão. Bicos coaxiais oferecem como vantagem a independência em relação ao sentido de deslocamento do bico, o que os torna particularmente adequados a trajetórias com mudança de direção e a deposições orbitais sobre substratos cilíndricos. É justamente essa configuração, com bico coaxial e trajetória orbital sobre um cilindro em rotação, que caracteriza o arranjo experimental do LMP/UFSC empregado neste trabalho, descrito na Seção 3.2.

2.2 Parâmetros do processo e geometria do cordão

A geometria do cordão depositado é controlada por um conjunto amplo de parâmetros do processo, dos quais cinco são considerados neste trabalho. A potência do laser (P), medida em watts, define a energia liberada por unidade de tempo na poça de fusão. A velocidade de avanço (F), medida em milímetros por minuto, define o tempo de exposição local. A taxa de alimentação de pó (pfr), medida indiretamente pela rotação do disco alimentador, define a massa de material introduzida por unidade de tempo. O número de camadas (L) e o incremento vertical entre camadas (z_{step}) atuam sobre o empilhamento de cordões sucessivos e sobre a posição relativa entre o bico e o substrato.

Duas combinações desses parâmetros são particularmente úteis para discutir a geometria resultante. A primeira é a energia linear $E_{lin} = P/F$, que expressa a quantidade de energia depositada por unidade de comprimento percorrido pelo bico e é a escala fundamental que determina, em primeira aproximação, a profundidade da fusão e a diluição do depósito (TOYSERKANI; KHAJEPOUR; CORBIN, 2004). A segunda é a taxa de massa por comprimento, pfr/F , que expressa a quantidade de material introduzido por unidade de comprimento e está diretamente relacionada à altura e à área do cordão resultante. Ambas as grandezas serão tratadas como atributos do modelo preditivo na Seção 3.7 do Capítulo 3, em que a definição formal de E_{lin} aparece na Equação 8.

As grandezas geométricas de interesse neste trabalho são três: a largura (w), definida como a extensão horizontal do cordão medida em sua base; a altura (h), definida como a distância vertical entre o topo do cordão e a superfície original do substrato; e a área da seção transversal (A), definida como a área da figura plana delimitada pelo contorno do cordão visto em corte. Cabe ressaltar que essas são definições de referência: operacionalmente, neste trabalho, w , h e A são estimadas a partir da silhueta do cordão extraída do vídeo lateral, com as bordas detectadas dentro de uma região de interesse, conforme detalhado na Seção 3.5. Essas três grandezas são suficientes, para a maior parte das aplicações, para caracterizar a qualidade da deposição. Em cordões de L-DED com boa molhabilidade, a seção transversal aproxima-se de uma semi-elipse, e essas três grandezas se relacionam de forma compacta, conforme discutido na Seção 3.11.1 do Capítulo 3.

2.3 Aprendizado de máquina supervisionado

O aprendizado de máquina supervisionado consiste em ajustar uma função $\hat{f} : \mathbf{x} \mapsto \hat{y}$ a partir de um conjunto de pares observados $\{(\mathbf{x}_i, y_i)\}_{i=1}^n$, de modo que a função aprendida produza, para entradas novas, previsões tão próximas quanto

possível dos valores reais de y (JAMES et al., 2013; GÉRON, 2019). Quando o alvo y é uma variável contínua, fala-se em regressão; quando é uma variável categórica, fala-se em classificação. Este trabalho trata de três problemas de regressão simultâneos, sendo um para a largura, um para a altura e um para a área da seção transversal do cordão.

2.3.1 Sobreajuste e regularização

Um modelo treinado com flexibilidade excessiva pode ajustar não apenas o sinal contido nos dados, mas também o ruído de medição, fenômeno conhecido como sobreajuste (*overfitting*). O sintoma típico do sobreajuste é o desempenho elevado no conjunto de treinamento acompanhado por desempenho fraco em dados novos (JAMES et al., 2013). Estratégias para mitigar o sobreajuste incluem a regularização das funções aprendidas, por exemplo, a penalização da norma dos coeficientes em modelos lineares, e a imposição de restrições estruturais ao espaço de funções aprendidas, como a monotonicidade em relação a determinadas variáveis. Ambas as estratégias são utilizadas neste trabalho e descritas em detalhe nas Seções 2.4 e 2.5.

O risco de sobreajuste é especialmente relevante neste trabalho porque o número efetivo de amostras de treinamento é pequeno: as sucessivas etapas de suavização e de agregação aplicadas às medições (Capítulo 3) reduzem os milhares de blocos de comando brutos a apenas algumas centenas de observações efetivas. Esse tamanho reduzido reforça tanto a importância de um esquema de validação que não superestime o desempenho, discutido a seguir, quanto a opção por modelos que preservam bom desempenho com poucos dados tabulares, como os baseados em *gradient boosting*.

2.3.2 Validação cruzada

Para estimar o desempenho de um modelo em dados não vistos é necessário separar o conjunto disponível em uma parte usada para o treinamento e outra reservada para o teste. A forma mais simples é a divisão única (*holdout*), em que uma fração fixa das observações é retida para teste. Em conjuntos pequenos, contudo, o resultado dessa divisão depende fortemente de quais observações caíram em cada parte, o que produz estimativas instáveis e, em geral, pessimistas, pois uma parcela dos dados nunca é aproveitada no treinamento (JAMES et al., 2013).

A validação cruzada contorna essa limitação ao reaproveitar todas as observações, em rodadas distintas, tanto para treino quanto para teste. Na variante *k-fold*, o conjunto é particionado em k subconjuntos (*folds*) de tamanho aproximadamente igual, onde a cada uma das k iterações, um *fold* é usado como teste e os $k - 1$ restantes formam o treino, de modo que cada observação é testada exatamente uma vez. A

estimativa de desempenho é a média das k avaliações.

A escolha da quantidade de *folds* exige um certo equilíbrio prático. Se esse número for muito pequeno, o modelo treina com menos dados em cada rodada, o que pode gerar uma avaliação de desempenho mais pessimista do que a realidade. Por outro lado, criar subdivisões demais deixa o processamento mais pesado e faz com que as estimativas oscilem bastante. O limite extremo dessa divisão ocorre quando o número de *folds* é igual ao total de amostras disponíveis (abordagem conhecida como *leave-one-out*). Nesse cenário, o modelo é testado isoladamente em cada uma das informações, uma por vez, enquanto utiliza todo o restante do conjunto para o treinamento (JAMES et al., 2013; GÉRON, 2019).

A partição aleatória do *k-fold* pressupõe que as observações sejam independentes entre si. Quando os dados apresentam estrutura de grupos, com observações que compartilham características por pertencerem a uma mesma unidade experimental, uma divisão aleatória tende a alocar observações fortemente correlacionadas simultaneamente no treino e no teste. Isso provoca vazamento de informação (*data leakage*) e produz métricas artificialmente otimistas. Nesses casos, recorre-se à validação cruzada por grupos, na qual cada *fold* é definido por um grupo inteiro, garantindo que nenhum grupo apareça ao mesmo tempo nos dois conjuntos.

A variante adotada neste trabalho é a *Leave-One-Group-Out* (LOGO-CV), em que k é igual ao número de grupos e cada *fold* contém todas as observações de exatamente um grupo, deixado de fora do treinamento. Neste trabalho, cada grupo corresponde a um anel de deposição; deixar um anel inteiro de fora a cada rodada simula a generalização do modelo para uma nova deposição, realizada sob uma condição experimental ainda não vista no treinamento. Essa escolha é necessária porque, no experimento que originou os dados (BONIN et al., 2023), dentro de cada anel alguns dos valores dos parâmetros são constantes, em particular o número de camadas, o incremento vertical e a taxa de alimentação de pó. Uma partição aleatória por bloco de comando faria o modelo “ver”, durante o treino, os mesmos valores presentes no teste, mascarando sua real capacidade de generalização. A discussão detalhada dessa decisão e de seu efeito sobre os resultados encontra-se na Seção 3.8 do Capítulo 3.

2.3.3 Métricas de avaliação

O desempenho dos modelos de regressão é reportado neste trabalho por três métricas complementares, calculadas sobre as n observações de teste, em que y_i é o valor medido, $\hat{y}_i$ é o valor predito e $\bar{y}$ é a média dos valores medidos.

O erro absoluto médio (MAE) é a média dos valores absolutos dos resíduos, conforme a Equação 1:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (1)$$

Por ponderar todos os erros de forma igual, o MAE é pouco sensível a observações atípicas e é expresso na mesma unidade do alvo (mm ou mm²), o que torna sua interpretação direta.

A raiz do erro quadrático médio (RMSE), definida pela Equação 2, eleva as diferenças ao quadrado e, em seguida, extrai a raiz do resultado, de forma a retornar à unidade do alvo:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (2)$$

Em razão do termo quadrático, o RMSE penaliza mais fortemente os erros de maior magnitude, sendo portanto mais sensível a *outliers* (valores atípicos) que o MAE. Vale sempre a relação $\text{RMSE} \geq \text{MAE}$, e a diferença entre as duas métricas aumenta com a dispersão dos erros, funcionando como um indicador da presença de poucos desvios grandes.

O coeficiente de determinação R^2 , definido pela Equação 3, mede a fração da variância da variável-alvo explicada pelo modelo:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad (3)$$

O numerador é a soma dos quadrados dos resíduos do modelo e o denominador, a soma dos quadrados em torno da média. Assim, $R^2 = 1$ indica predição perfeita; $R^2 = 0$, desempenho equivalente ao de prever sempre a média $\bar{y}$; e valores negativos, desempenho inferior a essa referência. Por não apresentar dimensão, o R^2 permite comparar diretamente alvos de naturezas e escalas distintas, ao passo que o MAE e o RMSE fornecem a magnitude concreta do erro em cada unidade (JAMES et al., 2013; GÉRON, 2019).


2.3.4 Engenharia de atributos

Além da escolha do algoritmo, o desempenho de um modelo supervisionado depende fortemente da representação das variáveis de entrada. A engenharia de

atributos consiste em derivar, a partir dos parâmetros brutos, novas variáveis que tornem explícitas relações úteis à predição, seja por transformações não lineares (por exemplo, o logaritmo de uma variável), por razões e produtos entre parâmetros (termos de interação), ou pela expansão polinomial dos atributos originais (JAMES et al., 2013; GÉRON, 2019). Quando essas variáveis derivadas codificam conhecimento físico do processo, o modelo passa a dispor de um sinal mais informativo do que o contido nos parâmetros isolados. Neste trabalho, os cinco parâmetros do processo são complementados por um conjunto de atributos derivados de motivação física, conforme detalhado na Seção 3.7 do Capítulo 3.

2.4 Modelos baseados em árvores: XGBoost

Árvores de decisão são modelos preditivos que dividem recursivamente o espaço dos atributos em regiões retangulares, a cada divisão escolhendo a variável e o valor de corte que mais reduzem o erro de predição (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Quando utilizadas de forma isolada, as árvores de decisão costumam se ajustar excessivamente aos dados de treinamento (fenômeno conhecido como sobreajuste). Para contornar esse problema e gerar resultados mais robustos, elas são agrupadas em conjuntos matemáticos, chamados de *ensembles*. Existem duas estratégias clássicas para realizar essa combinação. A primeira é o *bagging* (agregação por reamostragem), em que várias árvores independentes são treinadas utilizando amostras *bootstrap* (ou seja, por meio de um sorteio aleatório com reposição, em que a mesma informação pode ser selecionada mais de uma vez para gerar diversidade de aprendizado), e ao final suas previsões são unidas. A segunda estratégia é o *boosting* (impulsionamento), em que as árvores são treinadas em sequência, de modo que cada nova etapa busca corrigir justamente os erros deixados pelas árvores anteriores. A Figura 3 ilustra esse princípio: a cada rodada, um novo modelo concentra-se nos casos em que os anteriores erraram, e a combinação de todos compõe o preditor final em conjunto.

Figura 3 – Esquema do processo de *boosting* para aprendizagem em conjunto

Fonte: Adaptado de Sirakorn (2020).

2.4.1 *Gradient boosting* e XGBoost

O *gradient boosting* é a forma mais difundida de *boosting* aplicado a problemas de regressão. A cada iteração, uma nova árvore é ajustada para aproximar o gradiente negativo da função de perda em relação às previsões atuais, empurrando o modelo na direção de menor erro (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). O XGBoost é uma implementação amplamente adotada de *gradient boosting* que combina três características importantes: regularização explícita dos pesos das folhas (controlando a complexidade do modelo), suporte a imposição de restrições de monotonicidade por atributo e implementação eficiente que permite treinamento rápido mesmo com muitas árvores (CHEN; GUESTRIN, 2016).

Além disso, modelos baseados em *gradient boosting* costumam ser utilizados sobre dados tabulares por apresentarem um bom desempenho mesmo em conjuntos de treinamento de tamanho reduzido (CHEN; GUESTRIN, 2016; SHWARTZ-ZIV; ARMON, 2022), enquanto que trabalhos baseados em redes neurais profundas (como o de Bonin et al. (2023)) frequentemente demandam maior volume de dados, especialmente quando treinadas diretamente sobre imagens.

2.4.2 Restrições de monotonicidade

Uma restrição de monotonicidade obriga a função aprendida a ser monotonicamente crescente ou decrescente em relação a um determinado atributo: imposto o sentido crescente, um aumento no valor do atributo nunca pode reduzir a previsão, mantidos os demais constantes; imposto o sentido decrescente, vale o oposto. O XGBoost permite definir essa restrição individualmente para cada atributo. Durante o crescimento de cada árvore, o algoritmo rejeita as divisões que produziram, no atributo restrito,

predições contrárias ao sentido imposto e propaga limites aos nós descendentes, de modo que a função resultante seja monótona em todo o domínio.

O interesse dessas restrições neste trabalho é incorporar ao modelo o conhecimento físico do processo: espera-se, em primeira aproximação, que aumentar a potência do laser ou a taxa de alimentação de pó tenda a ampliar as dimensões do cordão, ao passo que aumentar a velocidade de avanço tenda a reduzi-las, por diminuir a energia e a massa depositadas por unidade de comprimento. Esses sentidos correspondem a tendências dominantes, e não a regras rígidas; em particular, a redução com a velocidade costuma ser mais nítida para a altura e a área do que para a largura, cuja resposta é mais fraca e dependente do regime de operação. Tais relações de sentido entre os parâmetros e a geometria do cordão são amplamente reportadas na literatura de modelagem do processo de deposição por energia direcionada (GUAN; ZHAO, 2020), o que torna o sentido predominante de cada restrição esperado de antemão. Forçar esse comportamento garante predições fisicamente plausíveis mesmo em regiões do espaço de parâmetros pouco representadas nos dados e atua, ao mesmo tempo, como uma forma de regularização estrutural, no sentido discutido na Seção 2.3.1. As restrições efetivamente adotadas, e a verificação de que as predições as respeitam, são apresentadas nas Seções 3.7.2 e 3.9 do Capítulo 3.

2.5 Regressão Ridge polinomial

A regressão linear ajusta uma combinação linear dos atributos a um alvo contínuo por meio da minimização do erro quadrático (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Quando a relação entre os atributos e o alvo apresenta não linearidades, é comum expandir o conjunto de atributos originais com produtos e potências (por exemplo, todos os produtos pares de duas variáveis), passando assim a um modelo de regressão polinomial. A regressão polinomial é, ainda, uma regressão linear nos novos atributos expandidos, mas com capacidade de representar superfícies curvas.

Modelos de regressão polinomial são propensos a sobreajuste em conjuntos pequenos. A regressão Ridge, descrita por Hastie, Tibshirani e Friedman (2009), adiciona à função objetivo um termo de penalização proporcional à soma dos quadrados dos coeficientes, controlado por um parâmetro α .

O efeito da penalização é reduzir a magnitude dos coeficientes (em especial aqueles associados a atributos correlacionados) e produzir estimativas mais estáveis em conjuntos de tamanho moderado. Neste trabalho, o Ridge polinomial é utilizado como modelo de linha de base, a partir do qual o desempenho do XGBoost é comparado para detectar a presença ou não de não linearidades relevantes (Seção 4.2.1).

2.6 Interpretabilidade por SHAP

Modelos baseados em *ensembles* de árvores são, em geral, mais difíceis de interpretar do que modelos lineares: o efeito de um único atributo sobre a predição varia ao longo do espaço dos atributos e depende das interações capturadas pelas árvores. O método SHAP (*Shapley Additive exPlanations*), proposto por Lundberg e Lee (2017), oferece uma decomposição aditiva da predição em contribuições atribuídas a cada atributo, com fundamento na teoria de jogos.

A teoria de jogos cooperativos, da qual o método SHAP deriva seu fundamento, estuda como distribuir de forma justa o ganho obtido por um grupo de participantes que cooperam para um resultado comum. O conceito central é o valor de Shapley, proposto por Shapley (1953), que estabelece a única forma de repartir esse ganho total respeitando um conjunto de propriedades desejáveis, entre elas a eficiência (a soma das parcelas individuais recupera o ganho total), a simetria (participantes que contribuem igualmente recebem o mesmo) e a nulidade (quem nada acrescenta recebe zero). A parcela atribuída a cada participante corresponde à sua contribuição média. Uma analogia possível ao contexto de aprendizado de máquina: cada atributo assume o papel de um "jogador", a predição do modelo para uma observação é o "ganho" a ser repartido, e o valor de Shapley de cada atributo quantifica, então, quanto ele contribuiu para afastar aquela predição de um valor de referência (a predição média). Isso é o que confere ao SHAP suas garantias teóricas de consistência e aditividade, e o que o distingue de medidas de importância puramente heurísticas, justificando seu uso para interpretar a hierarquia de atributos aprendida pelos modelos baseados em árvores deste trabalho, cujos resultados são apresentados na Seção 4.3.

Cabe ressaltar que os valores SHAP descrevem como o modelo utiliza cada atributo para formar suas predições, e não uma relação causal física direta entre o parâmetro e a geometria do cordão. A hierarquia de atributos revelada reflete, portanto, a estrutura aprendida pelo modelo a partir dos dados disponíveis, podendo ser influenciada por correlações entre os parâmetros e pela própria estrutura do experimento.

2.7 Quantificação de incerteza por CQR

A predição pontual fornecida por um modelo de regressão raramente é suficiente para o uso prático em engenharia. É comum ser necessário acompanhar cada predição de uma faixa de valores plausíveis que represente, com confiança especificada, o intervalo em que o valor real deve cair.

2.7.1 Regressão quantílica

Em vez de calcular apenas o valor médio esperado, a regressão quantílica, formalizada por Koenker e Bassett (1978), foca em estimar limites específicos (os quantis) da distribuição condicional do alvo. Para construir o intervalo de cobertura de 80% utilizado neste estudo, foram treinados dois modelos independentes: um focado na linha de base inferior (o quantil 0, 10) e outro na linha superior (o quantil 0, 90).

Para que o algoritmo ajuste esses limites de forma precisa, ele utiliza uma métrica de cálculo de erro conhecida como perda quantílica (*pinball loss*). Para um determinado quantil-alvo τ e um resíduo u (que é a diferença entre o valor observado na prática e a previsão do modelo), essa perda é definida matematicamente pela Equação 4:

$$\rho_{\tau}(u) = \begin{cases} \tau u, & \text{se } u \geq 0, \\ (\tau - 1) u, & \text{se } u < 0. \end{cases} \quad (4)$$

O grande diferencial dessa equação é que ela pondera os erros de forma assimétrica. Na prática, funciona assim: durante o treinamento do modelo inferior ($\tau = 0, 10$), o sistema sofre uma punição matemática muito maior se estimar um valor acima do real. Isso força o algoritmo a empurrar suas estimativas para baixo, consolidando o "pisso" da previsão. Já no treinamento do limite superior ($\tau = 0, 90$), a lógica se inverte: o erro tem um peso maior quando o modelo chuta um valor baixo, o que obriga a linha de estimativa a subir. Ao combinar esses dois modelos treinados separadamente, delimita-se o intervalo de predição completo.

2.7.2 Calibração conformal

A cobertura nominal estimada pelos modelos quantílicos raramente coincide com a cobertura empírica observada em dados novos: o intervalo pode ser largo demais (cobrindo mais que o nominal) ou estreito demais (cobrindo menos). O método CQR (*Conformalized Quantile Regression*), proposto por Romano, Patterson e Candès (2019), corrige esse desvio por meio de uma calibração conformal sobre predições obtidas em dados fora do treinamento direto. Esse ajuste é feito de forma simétrica nas duas pontas do intervalo: calcula-se, em um conjunto de calibração, o valor δ necessário para que a fração de observações capturadas pelo intervalo expandido $[q_{\alpha} - \delta, q_{1-\alpha} + \delta]$ atinja a cobertura desejada.

A garantia formal de cobertura do CQR pressupõe que as observações sejam intercambiáveis. Quando o esquema de validação tem estrutura de grupos, como no LOGO-CV adotado neste trabalho, essa hipótese deixa de valer estritamente, e a

cobertura calibrada passa a ser interpretada como uma estimativa empírica em vez de garantia teórica. Essa limitação é retomada e quantificada no Capítulo 4.

2.8 Visão computacional para medição da geometria


A medição quadro a quadro da geometria do cordão a partir do vídeo lateral envolve operações clássicas de processamento de imagens e de sinais. Esta seção apresenta as mais relevantes para o trabalho, agrupadas em operações sobre a imagem (Seção 2.8.1) e em análise dos perfis de intensidade para a detecção de bordas (Seção 2.8.2). Ao final, descreve-se a forma adotada para representar a seção transversal prevista (Seção 2.8.3). A exposição apoia-se na literatura clássica de processamento digital de imagens e de visão computacional (GONZALEZ; WOODS, 2018; SZELISKI, 2011). Os detalhes de implementação e as bibliotecas de visão computacional efetivamente empregadas são apresentados no Capítulo 3. Vale destacar que a câmera lateral não foi idealizada para metrologia fina; as medições dela extraídas têm, portanto, resolução espacial limitada, fator a considerar na interpretação da exatidão dos modelos (Seção 4.2.2).

2.8.1 Operações de processamento de imagem

Uma imagem em tons de cinza pode ser tratada como uma função discreta $f(x, y)$ que associa a cada posição de pixel um valor de intensidade. As operações descritas a seguir transformam essa função com o objetivo de isolar o cordão do restante do quadro (GONZALEZ; WOODS, 2018).

A binarização, ou limiarização (*thresholding*), separa o objeto de interesse do fundo atribuindo a cada pixel um de dois valores conforme sua intensidade ultrapasse, ou não, um limiar T : os pixels com $f(x, y) > T$ passam a representar o cordão e os demais, o fundo. Quando o limiar é único para todo o quadro, fala-se em limiarização global. Conforme MARQUES FILHO e VIEIRA NETO (1999, p. 74), “Quando T depende apenas de $f(x, y)$, o limiar é chamado global”, em contraste com os casos em que o valor de corte varia segundo propriedades locais da vizinhança. Essa estratégia é adequada quando objeto e fundo ocupam faixas de intensidade bem separadas, condição favorecida, neste trabalho, pelo forte contraste do vídeo lateral binarizado (GONZALEZ; WOODS, 2018). A Figura 4 ilustra essa separação no histograma: os dois modos correspondem ao fundo e ao objeto, e o limiar T situa-se no vale entre eles.

Figura 4 – Limiarização de uma imagem monocromática: (a) histograma original, com fundo e objeto separados pelo limiar T ; (b) histograma após a binarização



Fonte: Adaptado de MARQUES FILHO e VIEIRA NETO (1999, p. 72).

Antes da binarização, é comum aplicar filtros espaciais para atenuar o ruído. O filtro de mediana é um filtro de ordenação não linear que substitui cada pixel pela mediana das intensidades de sua vizinhança; por se apoiar em uma estatística de ordem, e não em uma média, remove de forma eficaz o ruído impulsivo, ou seja, pixels isolados muito claros ou escuros, conhecido como ruído sal e pimenta (do inglês *salt and pepper*), preservando a nitidez das bordas (GONZALEZ; WOODS, 2018). O filtro gaussiano, por sua vez, é um filtro linear que substitui cada pixel por uma média ponderada da vizinhança, com pesos dados por uma função gaussiana cujo desvio padrão controla a intensidade da suavização. Ele atenua variações de alta frequência e suaviza contornos serrilhados, ao custo de um leve borramento proporcional ao tamanho do núcleo (GONZALEZ; WOODS, 2018).

Após a binarização da imagem, realiza-se uma varredura para identificar e agrupar os pixels que formam o objeto principal. Esse processo verifica quais pontos estão conectados uns aos outros (seja na horizontal, na vertical ou nas diagonais), e os une em um bloco contínuo. Esse rótulo permite descartar fragmentos pequenos e isolados (como respingos de material ou ruído residual) e reter apenas a maior região, correspondente ao cordão (GONZALEZ; WOODS, 2018; SZELISKI, 2011).

2.8.2 Perfis de intensidade e detecção de bordas

Reduzir a imagem binária a um perfil unidimensional simplifica a localização das bordas do cordão, ao trocar a busca em duas dimensões por uma análise de uma única curva. O perfil por coluna, também chamado de projeção vertical, é obtido somando, em cada coluna x da imagem, o número de pixels do objeto, o que produz uma curva $P(x)$ cujo máximo corresponde à região de maior espessura do cordão (GONZALEZ; WOODS, 2018).

Como a medição realizada coluna por coluna é muito sensível a qualquer

imperfeição nas bordas da imagem, o contorno do cordão passa inicialmente por um processo de suavização utilizando um filtro gaussiano unidimensional. Na prática, essa etapa serve para limpar os pequenos ruídos de leitura sem distorcer o formato ou deslocar o posicionamento real da curva original. Sobre o perfil suavizado, a detecção de picos localiza os máximos locais que satisfaçam dois critérios: uma altura mínima, que descarta máximos de baixa amplitude, e uma proeminência mínima, que mede o quanto um pico se eleva em relação ao vale mais alto que o separa de um pico vizinho maior, distinguindo picos reais de pequenas ondulações.

A partir do pico central, as bordas laterais do cordão são localizadas por dois mecanismos complementares. O primeiro busca vales (mínimos locais do perfil, identificados pela troca de sinal de sua derivada discreta) entre o pico e a periferia, interpretando-os como o ponto em que a espessura do cordão cai a um patamar de fundo. Quando essa busca não obtém êxito, recorre-se à análise do gradiente do perfil: a posição de maior módulo da derivada $\partial P / \partial x$, estimada por diferenças finitas, assinala a transição mais abrupta entre o cordão e o fundo e é, então, tomada como a borda (SZELISKI, 2011).

2.8.3 Representação da seção por semi-elipse

Para a visualização da seção transversal prevista, foi adotada a semi-elipse como forma de representação. A semi-elipse é a forma padrão empregada para descrever a seção transversal de cordões de L-DED com boa molhabilidade, em que o material fundido se acomoda sobre o substrato com perfil arredondado.

A curva é definida apenas pela largura e pela altura do cordão, sem parâmetros adicionais de forma. Para uma semi-elipse de largura w e altura h , a área compreendida sob a curva vale $A = \frac{\pi}{4} w h$; de modo equivalente, o fator de forma $c = A / (w \cdot h)$ assume o valor $\pi/4 \approx 0,785$. Essa relação geométrica vincula as três grandezas previstas e é retomada na discussão do fator de forma observado no conjunto de dados, no Capítulo 5. Vale ressaltar que a forma da seção não é objeto de predição neste trabalho: o sistema prevê apenas as três dimensões (largura, altura e área), e a semi-elipse serve unicamente como representação visual padronizada dessas dimensões, conforme detalhado na Seção 3.11 do Capítulo 3.

3 METODOLOGIA


Este capítulo descreve a metodologia adotada para desenvolver um sistema de predição da geometria do cordão depositado por *Laser Directed Energy Deposition* (L-DED). O trabalho foi organizado como um *pipeline* sequencial de processamento de dados, no qual o vídeo bruto da deposição é convertido, de forma progressiva, em medidas geométricas, em um conjunto de dados de treinamento e, por fim, em modelos preditivos. A esses procedimentos acrescentam-se três etapas complementares: a validação física dos modelos, a quantificação da incerteza das predições e a construção de uma ferramenta interativa de inferência.

Os dados experimentais utilizados neste trabalho (o vídeo lateral da deposição e os parâmetros do código G dos cordões) foram coletados no LMP/UFSC por Bonin et al. (2023), em pesquisa original cujo foco era prever obstruções do alimentador de pó. Este trabalho reaproveita os mesmos dados experimentais com objetivo distinto: prever a geometria do cordão depositado (largura, altura e área da seção transversal) a partir dos parâmetros de processo.

As seções a seguir percorrem o *pipeline* na mesma ordem em que ele foi executado, partindo da configuração experimental (Seção 3.2) e indo até a ferramenta interativa (Seção 3.12). Em cada etapa, são descritos os parâmetros utilizados, as decisões metodológicas e suas justificativas físicas ou empíricas.

3.1 Visão geral do *pipeline*

O *pipeline* é composto por quatro blocos principais e três blocos auxiliares. Os blocos principais correspondem à transformação direta dos dados experimentais em modelos preditivos: processamento de vídeo, extração da geometria por *frame* (quadro), construção do conjunto de dados e modelagem por aprendizado de máquina. Os blocos auxiliares (validação física, quantificação de incerteza e visualização preditiva) operam sobre os modelos já treinados, oferecendo diagnósticos e ferramentas de uso. A Figura 5 ilustra esse encadeamento.

Figura 5 – Visão geral do *pipeline* metodológico adotado neste trabalho

Fonte: Elaboração própria (2026).

Cada bloco do *pipeline* foi implementado em um *script* (rotina de código) Python independente, o que facilitou a depuração, o reprocessamento parcial e a documentação. A reprodutibilidade foi assegurada pela adoção de uma semente aleatória fixa (igual a 42), em todas as etapas que envolvem amostragem ou inicialização estocástica, boa prática recomendada para experimentos de aprendizado de máquina, conforme Pineau et al. (2021).

3.2 Configuração experimental

Os experimentos foram realizados no Laboratório de Mecânica de Precisão (LMP) da Universidade Federal de Santa Catarina (UFSC) por Bonin et al. (2023).


O equipamento utilizado e os principais consumíveis estão listados no Quadro 1. A escolha do conjunto buscou reproduzir uma configuração típica de deposição por L-DED para fins de restauração e revestimento, mantendo todos os elementos de processo bem caracterizados.

Quadro 1 – Componentes do *setup* (arranjo experimental) e suas especificações

Componente	Especificação
Máquina	Sistema SL1, com movimentação CNC Siemens SINUMERIK 840D
Laser	Fonte <i>fiber laser</i> IPG Photonics YLS-10000, potência máxima de 10 kW
Cabeçote óptico	Precitec YW52
Bico de deposição	Coax-50-S (Fraunhofer ILT), diâmetro do feixe focal de 0,8 mm
Alimentador de pó	GTV PF 2/1LC
Gás de proteção	Argônio, vazão de 15 l/min
Substrato	Cilindro de aço AISI 1045, diâmetro de 100 mm, comprimento de 120 mm e massa aproximada de 8 kg
Pó depositado	Ferro puro (Fe)
Câmera lateral	Pulnix tmc-76dsp, 0,38 MP, a 60 FPS
Câmera frontal	Nikon D5200, 24,1 MP (RGB), a 30 FPS

Fonte: Adaptado de Bonin et al. (2023).

A escolha do substrato cilíndrico em aço AISI 1045 é compatível com a prática usual em ensaios de revestimento ferroso, dada sua boa soldabilidade e a disponibilidade comercial. O pó de Fe puro simplifica a interpretação dos resultados, evitando efeitos de segregação química e de transformação de fases típicos de ligas mais complexas (TOYSERKANI; KHAJEPOUR; CORBIN, 2004). O bico coaxial Coax-50-S apresenta um diâmetro nominal de feixe focal de 0,8 mm, valor que define o limite físico inferior da largura do cordão e que servirá como referência em discussões posteriores sobre o envelope de validade do modelo. A Figura 6 apresenta uma fotografia do *setup* com alguns cordões já depositados sobre o substrato.

Figura 6 – Fotografia do *Setup* do experimento com alguns cordões já depositados

Fonte: Cassiano Bonin (2022).

3.2.1 Plano experimental

O experimento foi estruturado em 36 anéis concêntricos depositados sobre a superfície lateral do substrato em rotação. Cada anel mantém constantes três parâmetros: número de camadas (L), incremento vertical entre camadas (z_{step}) e taxa de alimentação de pó (pfr). Ao longo de sua deposição, varia a potência do laser (P) e a velocidade de avanço do bico (F). Em resumo, P e F são os únicos parâmetros que mudam dentro de um anel, enquanto L , z_{step} e pfr permanecem fixos por anel e só mudam de um anel para outro. A combinação do incremento vertical z_{step} com o número da camada em deposição é o que determina a distância final entre o bico de deposição e o substrato no momento de cada cordão.

Essa distinção é o que torna necessária a avaliação por validação cruzada deixando um anel inteiro de fora a cada iteração (LOGO-CV), em vez de uma divisão aleatória por bloco de comando. A justificativa detalhada dessa escolha, e do vazamento que a divisão aleatória provocaria, encontra-se na Seção 3.8.

Dentro de cada anel são percorridos 9 níveis discretos de P e 40 níveis discretos de F , totalizando, no plano completo,

$$(36 \text{ anéis}) \times (9 \text{ níveis de } P) \times (40 \text{ níveis de } F) = 25.920 \text{ blocos de comando.}$$

Cada bloco de comando (termo padrão para uma instrução individual de uma máquina CNC) corresponde a um pequeno trecho de deposição com parâmetros constantes. O envelope operacional contemplado é apresentado no Quadro 2.

Quadro 2 – Envelope operacional contemplado no experimento

Parâmetro	Faixa / Níveis	Tipo
Potência do laser (P)	282 a 2.198 W (9 níveis)	varia por bloco
Velocidade de avanço (F)	343 a 2.062 mm/min (40 níveis)	varia por bloco
Número de camadas (L)	{1, 2, 3}	constante por anel
Incremento vertical (z_{step})	{0,2; 0,5; 0,8; 1,1} mm	constante por anel
Taxa de alimentação (pfr)	{2, 3, 4} RPM	constante por anel

Fonte: Elaboração própria (2026).

Os 36 anéis efetivamente depositados correspondem a uma seleção das combinações possíveis de (L , z_{step} , pfr), escolhida de modo a cobrir o envelope operacional com diversidade adequada. Predições do modelo para combinações de parâmetros fora desse envelope são consideradas como extrapolação e devem ser interpretadas com cautela.

3.3 Aquisição dos dados

A aquisição reúne dois tipos de dado: as imagens do cordão durante a deposição e os parâmetros de processo registrados pela CNC. As imagens foram

captadas por duas câmeras: uma lateral, voltada ao perfil do cordão, e outra frontal, voltada à região de fusão. Os parâmetros de processo foram exportados pela CNC após cada deposição na forma de um arquivo de código G consolidado.

3.3.1 Câmera lateral e calibração espacial

A câmera lateral foi posicionada perpendicularmente ao eixo de rotação do substrato. Para realçar o contraste entre o cordão e o fundo, a iluminação ambiente do laboratório foi reduzida ao mínimo e o cordão foi iluminado por uma luz vermelha dirigida. A taxa de captura adotada foi de 60 quadros por segundo (FPS), e os quadros originais foram posteriormente recortados e binarizados pelo *script* Python de processamento de vídeo descrito na Seção 3.4, resultando em uma matriz binária de 320×320 pixels por quadro, na qual os pixels brancos correspondem à região visível do cordão e os pixels pretos, ao fundo.

A calibração espacial foi realizada por meio da medição de um padrão físico no *setup*, resultando na relação

$$1 \text{ pixel} = 0,016875 \text{ mm},$$

equivalente a aproximadamente 59,3 pixels por milímetro. A linha do substrato no quadro binarizado encontra-se em $y = 170$ pixels; esse valor é fixo e serve como referência para o cálculo da altura do cordão, conforme descrito na Seção 3.5.

3.3.2 Câmera frontal

A câmera frontal RGB voltada para a região de fusão foi instalada como sensor principal por Bonin et al. (2023) no trabalho original, no qual o objetivo era prever obstruções do alimentador de pó a partir da pluma de vapor metálico e da poça de fusão. No projeto atual, os quadros dessa câmera foram aproveitados, em uma versão inicial do modelo, como tentativa de otimização da predição da geometria do cordão: deles foram extraídas representações vetoriais (*embeddings*, vetores numéricos que resumem o conteúdo de cada imagem) por meio de uma rede neural pré-treinada. Como discutido na Seção 3.9 e detalhado no Capítulo 4, essa estratégia não trouxe os ganhos esperados para o problema deste trabalho e foi descartada na versão final do modelo.

Por isso, o *pipeline* final opera não sobre a câmera frontal, mas sobre a gravação da câmera lateral (Seção 3.3.1), realizada de modo lateral e em filmagem posterior à deposição, conforme a condição experimental. Esse é, justamente, o modo de aquisição pressuposto pelo *pipeline* de processamento de vídeo descrito na Seção 3.4, inclusive na correção de sincronização entre o vídeo e os comandos do código G.

3.3.3 Gravação contínua e parâmetros do código G

A deposição dos 36 anéis foi registrada em um único arquivo de vídeo contínuo, com duração total de aproximadamente 67 minutos e 241.964 quadros. Em paralelo, os parâmetros enviados à CNC foram consolidados em um arquivo CSV contendo 25.920 linhas e 19 colunas. Cada linha corresponde a um bloco de comando e armazena, entre outros campos, a potência do laser, a velocidade de avanço, o número do anel, o número de camadas, o incremento vertical, a taxa de alimentação e os instantes de início e fim do comando, em segundos contados a partir do início do respectivo anel. Esses dois últimos campos são essenciais para a sincronização entre quadros de vídeo e blocos de comando, descrita na Seção 3.5.

3.3.4 Detecção automática dos *timings* dos anéis

Como o vídeo foi gravado de forma contínua, foi necessário identificar, após a aquisição, os instantes de início e de fim de cada um dos 36 anéis. Para isso, foi implementado um procedimento automático baseado na luminância média de cada quadro. O algoritmo aplica um limiar adaptativo igual a 5% do valor máximo observado na sequência, agrupa intervalos próximos para evitar fragmentação por oscilações momentâneas e valida o resultado contra a duração esperada de cada anel segundo o código G. O erro médio absoluto da detecção, avaliado contra a marcação manual de um subconjunto, foi de 0,28 segundos, com valor máximo de 0,67 segundos. Esses valores são pequenos em relação à duração típica de um anel (da ordem de dezenas de segundos) e, portanto, considerados aceitáveis para as etapas seguintes do *pipeline*. Adicionalmente, foi realizada inspeção visual em boa parte dos resultados, abrangendo anéis com diferentes combinações de parâmetros, o que confirmou que os instantes detectados delimitam corretamente o início e o fim de cada anel. Os instantes detectados são armazenados em um arquivo auxiliar que serve de entrada para o algoritmo de sincronização entre quadros e blocos de comando.

3.4 Processamento de vídeo

O processamento de vídeo converte o vídeo bruto da deposição (com 241.964 quadros a 60 FPS) em um vídeo silhueta, no qual cada quadro contém apenas a região do cordão em branco sobre fundo preto. A saída direta da câmera, apesar de registrar o cordão sob uma luz vermelha de alto contraste, ainda não é binarizada e contém diversos artefatos que precisam ser removidos antes da medição da geometria. Entre os mais relevantes estão: ruído impulsivo de pixels isolados, respingos de material expelidos pela poça de fusão, reflexos da estrutura do bico, fragmentos da pluma de vapor metálico e pequenas oscilações de posição do cordão entre quadros vizinhos.

Se mantidos, esses artefatos contaminariam tanto a detecção das bordas do cordão quanto o cálculo de sua área.


3.4.1 Correção da deriva por anel

Pequenas oscilações da câmera ao longo da gravação dos 36 anéis produzem um deslocamento residual do cordão tanto na direção horizontal quanto na vertical. Para compensar esse efeito, foi ajustado um modelo senoidal de deriva para cada anel, parametrizado em função do ângulo de rotação do substrato. Sem essa correção, a posição aparente do cordão varia entre quadros vizinhos, o que afetaria diretamente a medição da largura e induziria a resultados inconsistentes em todas as etapas subsequentes do projeto.

3.4.2 Binarização e filtragem espacial

A binarização atua sobre cada quadro em três passos. Primeiro, são aplicadas máscaras laterais que removem regiões do quadro permanentemente fora do interesse: mantém-se a faixa entre $x = 0$ e $x = 280$ pixels. O limite esquerdo em $x = 0$ é uma das diferenças em relação a uma versão anterior do *pipeline*, na qual esse parâmetro valia 40 pixels e ocultava a borda esquerda real do cordão, que costuma aparecer entre $x = 20$ e $x = 70$ pixels. A correção dessa máscara é a principal responsável pelo aumento de exatidão observado nas medições de largura, conforme discutido naquele capítulo.

Em seguida, é aplicado um filtro de mediana com janela de 5 pixels, que remove ruído impulsivo (pixels brancos isolados sobre fundo preto), seguido de um filtro Gaussiano 5×5 , que suaviza bordas serrilhadas. Por fim, é aplicado um limiar fixo de 50 sobre a intensidade resultante, separando cordão (acima do limiar) e fundo (abaixo). Essas operações de filtragem e limiarização são realizadas com a biblioteca de visão computacional OpenCV (BRADSKI, 2000). A Figura 7 compara um mesmo *frame* antes e depois dessa etapa.

Figura 7 – Mesmo frame antes e depois da etapa de binarização e filtragem espacial

Fonte: Elaboração própria (2026).

3.4.3 Estabilização temporal e limpeza

A binarização ainda deixa, após a filtragem espacial, dois tipos de artefato. O primeiro é uma oscilação vertical residual entre quadros vizinhos, com amplitude típica entre 3 e 10 pixels, decorrente de pequenas vibrações do conjunto durante a deposição. Para suprimi-la, foi pré-computada uma curva de correção vertical em forma de *spline* (curva polinomial por partes) por anel, aplicada na etapa de interpolação vertical. O segundo artefato são pequenas componentes conexas isoladas, originadas de respingos ou de ruído de imagem, que não fazem parte do cordão principal. Essas componentes são identificadas por extração de contornos externos e descartadas, mantendo-se apenas as maiores componentes em cada quadro.

A última transformação dessa etapa é o preenchimento por coluna: para cada coluna x do cordão, estima-se a altura do seu topo e preenche-se com branco toda a faixa entre esse ponto e a linha de base $y = 170$. Esse valor de $y = 170$ para a linha de base do substrato foi herdado do trabalho original de Bonin et al. (2023) e confirmado, neste trabalho, por inspeção visual de quadros de diferentes anéis, nos quais a superfície do substrato coincide com essa linha. Esse valor é único para todos os anéis: são as correções verticais por anel (o modelo de deriva da Seção 3.4.1 e a interpolação por *spline* descrita acima) que mantêm o substrato alinhado a essa linha de base comum. Cabe observar que, em sistemas de imagem, o eixo y é orientado de cima para baixo, de modo que o pixel visualmente mais alto do quadro corresponde ao menor valor numérico de y . As alturas dos topos são interpoladas ao longo da largura do cordão; nas bordas laterais, em vez de manter constante a altura da borda até o limite do quadro (o que geraria um ombro plano artificial, de altura constante acima do substrato), a altura decresce linearmente até a linha de base (preenchimento por

declive). Esse cuidado faz com que a silhueta reconstruída afunile até o substrato nas extremidades, como na seção real do cordão, em vez de exibir um patamar lateral. Ainda assim, o preenchimento é uma reconstrução (não corresponde pixel a pixel ao interior medido do cordão), mas é necessário para que a área obtida na etapa seguinte seja proporcional à seção transversal aparente do cordão. A coerência entre esse procedimento e o cálculo de área é garantida pela definição adotada na Seção 3.5.4.

3.4.4 Geração do vídeo silhueta

Como passo final, eventuais pixels remanescentes em tom avermelhado (provenientes da iluminação da câmera) são convertidos em branco e a imagem é normalizada para o formato *grayscale* (em tons de cinza) de 8 bits (0 a 255). O resultado é salvo como um novo vídeo, preservando a resolução e a taxa de quadros originais. Esse vídeo silhueta é a entrada do *script* Python de extração da geometria, descrito a seguir. A Figura 8 mostra um mesmo *frame* antes e depois de aplicados todos os tratamentos de imagem desta etapa.

Figura 8 – Mesmo *frame* antes e depois de aplicados todos os tratamentos de imagem




Fonte: Elaboração própria (2026).

3.5 Extração da geometria por *frame*

A partir do vídeo silhueta, cada quadro é processado individualmente para produzir três medições escalares: a largura, a altura e a área da seção transversal do cordão. Em seguida, cada quadro é associado a um bloco de comando do código G por meio de uma sincronização temporal. O resultado é um arquivo CSV no qual cada linha corresponde a um quadro válido, com cordão detectado e bloco de comando atribuído. O fluxo geral do algoritmo de medição aplicado a cada quadro está resumido

na Figura 9, e as subseções seguintes detalham cada etapa; o pseudocódigo completo consta no Apêndice A.

Figura 9 – Fluxo do algoritmo de medição da geometria em cada quadro



Fonte: Elaboração própria (2026).

3.5.1 Região de interesse e perfil horizontal

A região de interesse (ROI) adotada cobre 200 colunas e 170 linhas do quadro, abrangendo a faixa $20 \leq x \leq 220$ pixels e $0 \leq y \leq 170$ pixels. O limite inferior em $y = 170$ corresponde à linha de base do substrato. Sobre essa ROI é construído um perfil horizontal $P(x)$, definido como o número de pixels brancos em cada coluna x . O perfil é então suavizado por um filtro Gaussiano unidimensional com desvio padrão $\sigma = 3$, que substitui cada valor por uma média ponderada de seus vizinhos próximos. Essa suavização estabiliza a detecção subsequente de picos e vales sem deslocar significativamente as bordas (deslocamento típico inferior a 2 pixels). As funções de processamento de sinais utilizadas nesta etapa são da biblioteca SciPy (VIRTANEN et al., 2020), especificamente *gaussian_filter1d* (de *scipy.ndimage*) para a suavização e

find_peaks e *argrelemin* (de *scipy.signal*) para detecção de picos e vales.

3.5.2 Medição da altura


A altura do cordão é definida como a distância vertical entre a linha de base ($y = 170$) e o pixel branco mais alto encontrado dentro da ROI. Essa busca é restrita à metade esquerda do quadro ($x < 160$), por decisão de projeto: o cordão é tipicamente depositado nessa metade do campo de visão da câmera lateral, e a contagem feita nessa região é mais consistente entre anéis. Em pixels, $\text{altura}_{\text{px}} = 170 - y_{\text{topo}}$; em milímetros, $\text{altura}_{\text{mm}} = \text{altura}_{\text{px}} \times 0,016875$. Quadros nos quais nenhum pixel branco é encontrado nessa metade são descartados.

3.5.3 Detecção das bordas e cálculo da largura

A detecção das bordas do cordão localiza primeiro o pico do perfil suavizado, exigindo altura mínima igual a 20% do pico observado e proeminência mínima de 10%. A partir do pico assim localizado, busca-se a borda esquerda entre os pixels 20 e 100 (na horizontal), por duas estratégias sucessivas. A primeira estratégia procura um vale significativo (com valor inferior a 50% do pico), o mais próximo possível deste, em direção à esquerda. Se essa busca falha, é empregada uma estratégia complementar baseada no gradiente: define-se a borda esquerda como o ponto de máxima derivada (onde a taxa de crescimento dos valores entre colunas vizinhas é maior) do perfil suavizado na zona considerada. A borda direita é determinada de modo análogo, na zona entre os pixels 140 e 220 (na horizontal), tomando o primeiro vale após o pico ou, na ausência deste, o último pixel branco da zona. A região intermediária, compreendida entre os pixels 100 e 140 (na horizontal), não é pesquisada, porque corresponde tipicamente à região central do cordão-alvo. A Figura 11 ilustra essas zonas delimitadoras sobre um *frame*, com a largura detectada indicada pela seta bidirecional.

A qualidade dos quadros laterais varia ao longo do processo, o que afeta diretamente a facilidade e a confiabilidade da medição. A Figura 10 contrasta dois casos extraídos do vídeo bruto. No quadro à esquerda, o cordão aparece proeminente e isolado, e a geometria é obtida com facilidade. No quadro à direita, a deriva da câmera ao longo da deposição (corrigida na Seção 3.4.1) desloca o campo de visão e faz surgir um cordão vizinho à direita; o cordão a medir é o mais à esquerda, e é a zona de busca da borda direita que permite excluir o vizinho. Esse exemplo ainda mostra os dois cordões com forma relativamente bem definida, mas, em parte dos quadros, a separação entre o cordão-alvo e o adjacente é bem mais difícil. Essa interferência é uma das principais fontes do ruído da medição de largura, a dimensão mais ruidosa entre as três avaliadas.

Figura 10 – Quadros laterais brutos: à esquerda, um cordão proeminente e isolado, de medição fácil; à direita, dois cordões no campo de visão, evidenciando a deriva da câmera e a possível interferência do cordão vizinho, sendo o alvo o mais à esquerda



Fonte: Elaboração própria (2026).

A largura é calculada como $\text{larg}_{\text{px}} = x_{\text{dir}} - x_{\text{esq}}$. Quadros com largura inferior a 0,5 mm são descartados nesta etapa, pois esse valor está bem abaixo do diâmetro do feixe focal do laser (0,8 mm) e, portanto, não correspondem a um cordão fisicamente plausível.

3.5.4 Cálculo da área

A área da seção transversal é calculada como a soma de pixels brancos da ROI restrita à faixa entre as bordas detectadas, conforme a Equação 5:

$$\text{area}_{\text{px}} = \sum_{x=x_{\text{esq}}}^{x_{\text{dir}}} P(x), \quad \text{area}_{\text{mm}}^2 = \text{area}_{\text{px}} \times (0,016875)^2. \quad (5)$$

A restrição da soma à faixa $[x_{\text{esq}}, x_{\text{dir}}]$ é importante: em versões anteriores do *pipeline*, a área era calculada equivocadamente sobre toda a ROI, o que inflava consideravelmente o valor quando havia cordões vizinhos visíveis no mesmo quadro. Quadros com área inferior a 80 pixels também são descartados, pois apresentam um valor de área inviável para o cenário configurado.

Para permitir o recálculo da área após eventuais ajustes das bordas no pós-processamento (Seção 3.5.7), o vetor $P(x)$ de cada quadro é armazenado em um arquivo intermediário, um vetor de 200 inteiros por quadro.

3.5.5 Sincronização entre quadros e comandos em código G

Cada quadro é associado a um bloco de comando por meio de uma sincronização temporal feita anel a anel. Como o vídeo registra a circunferência completa do

substrato (incluindo a parte sem deposição) e a CNC só registra o tempo do arco ativo, a duração do vídeo por anel é aproximadamente o dobro da duração registrada pela CNC. Sejam t_{video} o instante do quadro dentro do anel e t_{cnc} o instante equivalente na escala da CNC; a relação adotada é dada pela Equação 6:

$$t_{\text{cnc}} = t_{\text{cnc,min}} + \frac{t_{\text{video}} - t_{\text{video,inicio}}}{\rho_r}, \quad (6)$$

em que ρ_r é o quociente entre a duração do vídeo e a duração registrada pela CNC para o anel r , com valor típico próximo a 1,97. Conhecido t_{cnc} , o bloco de comando correspondente é identificado escolhendo, dentre todos os blocos do anel, aquele cujo instante de início é o mais próximo de t_{cnc} sem ultrapassá-lo.

Quadros cujo t_{cnc} ocorre entre o término de um comando e o início do próximo (situações em que a CNC está em transição de aceleração ou de desaceleração e não há deposição efetiva) são descartados. Esse filtro remove 26.056 quadros do total. Sem ele, esses quadros seriam atribuídos ao último comando ativo, contaminando suas medidas com informação de transição.

3.5.6 Correção da defasagem entre deposição e imageamento

A relação da Equação 6 pressupõe que o quadro registrado no instante t_{video} corresponde ao comando ativo no mesmo instante. Essa hipótese ignora, contudo, uma defasagem física do arranjo experimental: o ponto em que o laser funde o pó e o ponto que a câmera lateral imageia não coincidem sobre a circunferência do cilindro em rotação. Existe um deslocamento angular entre eles, de modo que a geometria observada em um quadro foi efetivamente produzida por um comando emitido em um instante ligeiramente distinto.

Para compensar essa defasagem, introduz-se um deslocamento temporal constante Δ_s na conversão entre as escalas de tempo, conforme a Equação 7:

$$t_{\text{cnc}} = t_{\text{cnc,min}} + \frac{t_{\text{video}} + \Delta_s - t_{\text{video,inicio}}}{\rho_r}. \quad (7)$$

O valor $\Delta_s = 1,0$ s foi determinado empiricamente por varredura, como o que recupera de forma honesta o desempenho preditivo, isto é, sem recorrer a artifícios de suavização. Em termos angulares, $\Delta_s = 1,0$ s equivale a cerca de 8° de rotação (a razão entre Δ_s e o período de revolução do cilindro, de 46,5 s), valor compatível com a separação geométrica entre o bico de deposição e o campo de visão da câmera. A evidência que sustenta essa correção e o seu efeito sobre as métricas (em particular, o fato de ela revelar o efeito da velocidade de avanço, que a sincronização sem deslocamento mantinha encoberto) são apresentados na Seção 4.8.

3.5.7 Pós-processamento das medições


Duas operações de pós-processamento são aplicadas ao conjunto de medições por quadro. A primeira substitui valores anômalos de largura: quadros com largura inferior a 1,0 mm e superior a 0,5 mm têm sua largura substituída pela média do grupo definido por (anel, P , F arredondado). Após a substituição, a área é recalculada a partir do vetor $P(x)$ armazenado, considerando a nova janela [x_{esq} , (x_{esq} + nova largura)]. Esse procedimento afeta 2.886 quadros.

A segunda operação corrige bordas espúrias localizadas exatamente nos limites da zona de busca. Se a borda esquerda detectada coincide com $x = 20$, ou se a borda direita coincide com $x = 220$, o valor é substituído pela média dos cinco vizinhos temporais que não estejam, por sua vez, nos respectivos limites. Caso todos os vizinhos estejam no limite (situação rara), o valor original é mantido por ser considerado real. Visualmente, na Figura 11, uma borda espúria corresponderia à situação em que a extremidade esquerda da seta de largura (a seta azul apontando para a esquerda) estivesse encostada na linha tracejada verde mais à esquerda do quadro, indicando que a borda esquerda colapsou no limite $x = 20$ da zona de busca em vez de marcar a borda real do cordão. Essa operação atinge 38.683 bordas esquerdas e 35 bordas direitas. A área é recalculada após cada substituição.

3.5.8 Resultado da extração

O *script* Python de extração da geometria gera um arquivo CSV com 175.153 linhas e 9 colunas: identificação do quadro, do anel e do bloco de comando; bordas x_{esq} e x_{dir} ; largura, altura e área em milímetros; e o vetor $P(x)$ usado para o recálculo de área. Esse arquivo é a entrada do *script* Python de construção do conjunto de dados, descrito na seção seguinte.

Figura 11 – Frame do cordão com as zonas delimitadoras (linhas tracejadas) e predição da largura (seta bidirecional)



Fonte: Elaboração própria (2026).

3.6 Construção do conjunto de dados de treinamento

O conjunto de dados utilizado no treinamento dos modelos é construído a partir do arquivo gerado na seção anterior em três passos: agregação por bloco de comando, junção com os parâmetros de processo e suavização temporal por anel.

3.6.1 Agregação e junção dos dados

Cada bloco de comando é coberto, em média, por entre 7 e 9 quadros de vídeo. Para reduzir o ruído de medição associado a um único quadro, adota-se a mediana das medições associadas a cada bloco. A mediana, em vez da média, é preferida por lidar melhor com *outliers* e possíveis erros de medição em quadros isolados (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Essa agregação produz 25.121 blocos de comando únicos efetivamente cobertos pelo vídeo.

Em seguida, é feita uma junção pelo bloco de comando entre as medições agregadas e o arquivo CSV de parâmetros do código G, totalizando 25.920 linhas. Os blocos não cobertos pelo vídeo recebem valores ausentes nas colunas de geometria; essas linhas representam menos de 3% do total e são preenchidas pela suavização temporal descrita a seguir ou, quando isso não é possível, descartadas pela agregação por faixas de velocidade aplicada antes do treinamento, apresentada na Seção 3.7.3.

3.6.2 Suavização temporal por anel

A última etapa de redução de ruído aplica uma média móvel centrada, com janela $W = 15$ blocos de comando, de forma separada para cada anel. Por ser calculada anel a anel (agrupando os blocos por anel antes do cálculo), a janela nunca cruza a fronteira entre dois anéis, de modo que a medição de um anel não contamina a suavização de um anel vizinho. Essa janela é deliberadamente curta. Como cada nível de potência é mantido por cerca de 40 blocos de comando consecutivos dentro de um anel, uma janela de 15 blocos permanece, na maior parte do percurso, dentro de um mesmo patamar de potência, sem misturar pontos de operação distintos. Dessa forma, a média móvel atenua o ruído de medição entre blocos vizinhos (de mesma potência e velocidade próxima) sem destruir a variação real da geometria ao longo do anel.

Essa escolha é uma das mudanças centrais desta versão do trabalho. As versões anteriores empregavam uma janela larga, de $W = 200$ blocos (cerca de 100° de rotação), selecionada por maximizar a soma do R^2 dos três alvos. Demonstrou-se, contudo, que essa janela larga atravessa de cinco a seis níveis de potência e várias varreduras completas de velocidade dentro do mesmo anel, o que comprime artificialmente a variância do alvo e infla o coeficiente de determinação. Por esse motivo, a janela $W = 200$ é retomada no Capítulo 4 apenas como um cenário comparativo idealizado, e a análise crítica do efeito da suavização sobre o R^2 é apresentada na Seção 4.8.

Esta é a segunda das três etapas de suavização aplicadas ao longo do *pipeline* — as outras duas são a mediana por bloco de comando (Seção 3.6.1) e a agregação por faixas de velocidade aplicada antes do treinamento, descrita na Seção 3.7.

3.6.3 Composição final do conjunto de dados

O conjunto de dados final contém 25.920 linhas e 48 colunas distribuídas em quatro grupos: parâmetros de processo do código G, variáveis-alvo já suavizadas, caminhos relativos das imagens das câmeras de processo e lateral, e dados de contagem de quadros. As estatísticas descritivas das variáveis-alvo após a suavização estão resumidas na Tabela 1, comparadas às estatísticas no nível de quadro (antes da agregação). A redução das faixas observadas é uma consequência esperada da suavização e será retomada por meio do Capítulo 4.

Tabela 1 – Estatísticas das variáveis-alvo no nível de quadro e no nível de bloco de comando

Variável	N válidos	Mín.	Média	Máx.
Por quadro (antes da agregação)				
Largura (mm)	171.032	0,743	2,309	3,358
Altura (mm)	171.032	0,017	0,675	2,835
Área (mm ²)	170.780	0,023	1,176	7,390
Por bloco de comando (após suavização temporal $W = 15$)				
Largura (mm)	24.995	0,835	2,323	3,191
Altura (mm)	24.995	0,073	0,659	2,509
Área (mm ²)	24.995	0,052	1,148	6,290

Fonte: Elaboração própria (2026).

Os caminhos relativos das imagens são incluídos para permitir auditoria posterior, mas, como será detalhado na Seção 3.7, os modelos atuais utilizam exclusivamente as variáveis de processo do código G e atributos derivados delas. A coluna de identificação do anel é a chave usada para a validação cruzada por grupos descrita na Seção 3.8.

3.7 Engenharia de atributos e modelagem

A partir do conjunto de dados construído na seção anterior, os modelos preditivos são treinados sobre um conjunto enriquecido de atributos. Os cinco parâmetros brutos de processo são complementados por dezenove atributos derivados, projetados para representar quantidades físicas conhecidas do L-DED ou interações esperadas entre os parâmetros originais. Sobre o modelo principal (XGBoost) são impostas restrições de monotonicidade que refletem o sentido físico esperado de cada efeito. Um segundo modelo (Ridge polinomial) é treinado em paralelo como linha de base, e a importância dos atributos é examinada por meio de valores SHAP.

3.7.1 Atributos físicos derivados

O conjunto de atributos compreende vinte e quatro variáveis, organizadas em quatro grupos, conforme o Quadro 3; suas fórmulas completas constam no Apêndice B. Os atributos brutos correspondem diretamente às colunas do código G, sem transformação. Os atributos físicos correspondem a quantidades clássicas do processo L-DED, em particular a energia linear E_{lin} , grandeza clássica do processo (TOYSERKANI; KHAJEPOUR; CORBIN, 2004), definida pela Equação 8:

$$E_{lin} = \frac{P}{F}, \quad (8)$$

que expressa a quantidade de energia depositada por unidade de comprimento percorrido pelo bico. Os atributos de interação capturam efeitos cruzados entre parâmetros

(por exemplo, a energia linear ponderada pelo número de camadas), enquanto os atributos extras incluem transformações não lineares úteis para o ajuste por árvores, como a raiz quadrada de E_{lin} e a energia volumétrica $E_v = P/(F \cdot z_{step} \cdot 0,8)$.

Quadro 3 – Atributos da modelagem organizados em grupos

Grupo	Atributos
Brutos (5)	P, F, L, z_{step}, pfr
Físicos (5)	$E_{lin} = P/F, pfr/F, L \cdot z_{step}, \log P, \log F$
Interações (9)	$E_{lin} \cdot L, E_{lin} \cdot z_{step}, E_{lin} \cdot pfr, P \cdot L, F \cdot L, P \cdot pfr, F \cdot pfr, P \cdot z_{step}, E_{lin} \cdot L \cdot z_{step}$
Extras (5)	$E_v, \sqrt{E_{lin}}, P^2/F, P/(F \cdot pfr), pfr/P$

Fonte: Elaboração própria (2026).

Para os atributos de maior significado físico, o Quadro 4 reúne a fórmula, a unidade, o efeito esperado, a justificativa física e a ressalva de processo associada a cada um. As unidades seguem diretamente das unidades dos parâmetros brutos (P em W, F em mm/min, z_{step} em mm e pfr em RPM); assim, E_{lin} é proporcional à energia depositada por comprimento (J/mm) e pfr/F à massa de pó fornecida por comprimento (g/mm). Cabe ressaltar que a coluna de efeito esperado indica apenas o sentido fisicamente previsto de cada atributo sobre a geometria do cordão, fundamentado na literatura do processo, e não uma confirmação do comportamento efetivamente observado nos dados deste trabalho. A verificação de que os modelos treinados de fato reproduzem esses sentidos é apresentada mais adiante, na validação física (Seção 3.9) e na análise de importância dos atributos por SHAP (Seção 3.7.6).

Quadro 4 – Atributos físicos derivados: efeito esperado, justificativa física e ressalvas de processo

Fórmula	Unidade	Efeito esperado	Justificativa física e ressalva de processo
$E_{\text{lin}} = P/F$	W min/mm	Aumenta w , h e A	Mais energia por comprimento funde mais material e alarga a poça. Ressalva: aporte excessivo eleva a temperatura e a molhabilidade, espalhando o cordão, o que pode reduzir a altura em vez de aumentá-la
pfr/F	RPM min/mm	Aumenta h e A	Mais massa de pó por comprimento tende a elevar o cordão. Ressalva: se a energia não basta para fundir o pó adicional, a poça esfria e a aderência cai, podendo reduzir a deposição efetiva
$L \cdot z_{\text{step}}$	mm	Aumenta h	Empilhar mais camadas eleva o topo do cordão. Ressalva: com z_{step} muito elevado, a tocha passa a construir “no ar”, além da camada anterior, e o pó não adere, sendo desperdiçado sem ganho de espessura
$\log P$	adimensional	Aumenta w , h e A	Mesmo sentido de P (mais energia depositada); aplica-se a mesma ressalva de E_{lin} quanto à altura
$\log F$	adimensional	Reduz w , h e A	Mesmo sentido de F (menos energia e menos massa por unidade de comprimento)

Fonte: Elaboração própria (2026).

Os atributos de interação, por sua vez, não possuem unidade de interpretação direta: representam a modulação do efeito de um parâmetro por outro. O sentido esperado de cada interação acompanha o do fator dominante e, nos três casos em que esse sentido poderia ser violado pelo ajuste ($F \cdot L$, $F \cdot \text{pfr}$ e pfr/P), ele é imposto de forma explícita pelas restrições de monotonicidade descritas na Seção 3.7.2.

3.7.2 Restrições de monotonicidade

A biblioteca XGBoost permite impor, individualmente para cada atributo, uma restrição que obriga a função aprendida a ser monotonicamente crescente (+1) ou decrescente (−1) em relação a esse atributo. Essas restrições foram utilizadas neste trabalho para garantir que as predições do modelo respeitem o comportamento físico esperado do processo: aumentar a potência ou a taxa de alimentação de pó deve aumentar as dimensões do cordão, enquanto aumentar a velocidade de avanço deve diminuí-las. As restrições principais aplicadas estão resumidas no Quadro 5.

Quadro 5 – Principais restrições de monotonicidade aplicadas ao XGBoost

Atributo	altura	área	largura
P	+1	+1	+1
F	−1	−1	−1
L	+1	—	—
pfr	+1	—	—
E_{lin}	+1	+1	+1
$\log P$	+1	+1	+1
$\log F$	−1	−1	−1
$F \cdot L$	−1	−1	−1
$F \cdot pfr$	−1	−1	−1
pfr/P	−1	−1	−1

Fonte: Elaboração própria (2026).

A justificativa física de cada restrição já foi apresentada, junto com as ressalvas de processo correspondentes, no Quadro 4: as restrições sobre P , E_{lin} e $\log P$ refletem o efeito da energia depositada; as restrições sobre F e $\log F$, o efeito da velocidade; e as restrições sobre L e pfr, limitadas à altura, o efeito do empilhamento de camadas e do aporte de massa de pó.

É importante reconhecer o que essas restrições fazem e o que não fazem. Ao impor um sentido fixo, elas incorporam conhecimento físico prévio ao modelo, mas, por construção, impedem que ele represente eventuais contradições locais presentes nos dados: caso um subconjunto de observações sugerisse, por ruído de medição ou efeito de borda, um efeito contrário ao imposto, a restrição o suprimiria. Os sentidos impostos correspondem ao comportamento esperado do processo na maior parte do envelope operacional, mas não são leis absolutas: como mostram as ressalvas do Quadro 4, há regimes em que o efeito real pode se inverter, como uma energia linear elevada que espalha o cordão e reduz a altura, ou um z_{step} excessivo que impede a construção da camada. As restrições sobre os atributos compostos $F \cdot L$, $F \cdot pfr$ e pfr/P vão além disso: não derivam de uma lei física direta e foram introduzidas, em refinamentos posteriores, como hipóteses de modelagem (salvaguardas de regularização), para evitar que esses termos invertam, nas predições, os efeitos redutor de F e crescente de P . A coerência

das predições resultantes com o comportamento físico esperado é verificada de forma independente na validação física descrita na Seção 3.9.


Por fim, é necessário deixar muito claro o alcance dessa abordagem. Tanto os atributos físicos derivados quanto as restrições de monotonicidade fazem com que o projeto se apoie, de forma integral, em comportamentos esperados do processo, ou seja, em regras gerais que se admite valerem para o L-DED. Optou-se por impor esse conhecimento prévio porque os dados disponíveis não foram adquiridos com o objetivo de prever a geometria do cordão por aprendizado de máquina: o vídeo lateral foi gravado para outra finalidade, sem otimização de iluminação, enquadramento ou resolução para a metrologia do cordão. Em consequência, as variações observadas nas medições não correspondem necessariamente às variações reais da geometria em função dos parâmetros; elas combinam o efeito físico do processo com erros do procedimento automático de extração descrito na Seção 3.5. Em um número expressivo de quadros, a confiabilidade das medições, sobretudo da largura, não pode ser admitida (Seção 3.5.7). Nesse cenário, impor o comportamento esperado funciona como uma regularização que evita que o modelo aprenda relações espúrias originadas desses erros de medição, ao custo de não capturar eventuais comportamentos reais que se desviem das regras gerais. A obtenção das variações verdadeiras do processo exigiria uma aquisição dedicada e otimizada, conforme discutido entre as sugestões para trabalhos futuros (Seção 5.2).

3.7.3 Agregação por faixas de velocidade

Mesmo após a suavização temporal por anel descrita na Seção 3.6.2, observa-se ruído residual nas medições por bloco de comando, principalmente para a largura. Para suprimir esse ruído sem descartar informação, foi adotada uma agregação prévia ao treinamento: as observações são agrupadas por (anel, P , faixa de F) e cada grupo é reduzido à sua média. O número de faixas de velocidade, V_{BIN} , é o único parâmetro dessa agregação. Para altura e área, adotou-se $V_{\text{BIN}} = 3$, gerando grupos com aproximadamente 27 observações cada. Para largura, adotou-se $V_{\text{BIN}} = 2$, gerando grupos com aproximadamente 40 observações. A redução adicional foi necessária porque a medição de largura é mais ruidosa que as demais, conforme as faixas de variação apresentadas na Tabela 1. O resultado é um conjunto de treinamento com 944 observações para altura e área, e 630 observações para largura. Embora esses totais possam parecer poucas amostras, cada observação resume dezenas de blocos de comando de mesma potência e faixa de velocidade dentro de um anel, e não uma medição isolada. A partição empregada na validação, por sua vez, mantém todos os blocos de um mesmo anel no mesmo conjunto, o que evita vazamento entre treino e teste (Seção 3.8, com discussão adicional na Seção 4.8.3).

Esta agregação é a terceira e última das três etapas de suavização aplicadas ao longo do *pipeline*; juntas, as três etapas reduzem o conjunto de 25.920 blocos de comando brutos para algumas centenas de observações efetivas, conforme resumido na Figura 12. Essa supressão de ruído é necessária para que os modelos não se ajustem a flutuações de medição, mas tem como efeito colateral inflar o R^2 obtido na validação cruzada. Esse aspecto, junto com a relação entre o tamanho efetivo reduzido do conjunto e o desempenho obtido, é discutido na Seção 4.8.1.

Figura 12 – As três etapas de suavização e a redução do conjunto de dados, dos blocos de comando brutos às observações de treinamento



Fonte: Elaboração própria (2026).

3.7.4 Modelo principal: XGBoost

Com base em todas as demais informações descritas neste capítulo, o modelo principal escolhido foi o XGBoost, que constrói um conjunto (*ensemble*) de árvores de decisão de forma sequencial, em que cada nova árvore é ajustada para corrigir os erros cometidos pelas anteriores, abordagem conhecida como *gradient boosting* (impulsioneamento por gradiente). A escolha por essa família de modelos se deve a três fatores: a capacidade de capturar nativamente interações entre atributos, sem necessidade de defini-las manualmente (CHEN; GUESTIN, 2016); a possibilidade de impor restrições de monotonicidade (recurso utilizado neste trabalho para garantir coerência física, conforme a Seção 3.7.2); e o bom desempenho para problemas que envolvem dados tabulares de tamanho moderado (SHWARTZ-ZIV; ARMON, 2022).

Os hiperparâmetros foram fixados nos valores listados no Quadro 6, definidos a partir de uma exploração preliminar. Vale destacar que não foi conduzida uma

busca exaustiva de hiperparâmetros, dado o tempo limitado para a realização deste trabalho em adição ao tamanho reduzido do conjunto de treinamento após as três etapas de suavização e o risco de *overfitting* ao esquema de validação fixo.

Quadro 6 – Hiperparâmetros do XGBoost por variável-alvo

Hiperparâmetro	Altura	Área	Largura
n_estimators	600	600	600
max_depth	4	5	4
learning_rate	0,03	0,03	0,03
subsample	0,8	0,8	0,8
colsample_bytree	0,8	0,8	0,8
reg_alpha	0,1	0,1	0,1
reg_lambda	5,0	5,0	5,0
min_child_weight	3	1	3
tree_method	hist	hist	hist

Fonte: Elaboração própria (2026).

3.7.5 Linha de base: Ridge polinomial

Para servir como referência ao XGBoost e auxiliar na interpretação dos seus resultados, foi treinado em paralelo um modelo de regressão Ridge sobre atributos polinomiais de grau dois (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). O *pipeline* desse modelo aplica, em sequência, a expansão polinomial dos vinte e quatro atributos originais, a padronização das colunas resultantes (com média zero e variância unitária) e o ajuste de uma regressão Ridge com penalização alfa igual a 10. A escolha do grau dois e do valor de alfa buscou equilibrar capacidade de ajuste e estabilidade do estimador, a fim de manter o modelo simples e interpretável.

A comparação entre o XGBoost e o Ridge, apresentada no Capítulo 4, fornece uma indicação útil sobre a natureza dominante das relações entre os parâmetros e a geometria do cordão: se o Ridge polinomial atinge desempenho comparável ao do XGBoost, isso sugere que a parte mais explicativa do problema é log-linear ou polinomial. Caso contrário, indica que pode haver não linearidades relevantes capturadas apenas pelo XGBoost.

3.7.6 Interpretabilidade por SHAP

Para examinar quais atributos contribuem mais para as predições de cada variável-alvo, foram calculados valores SHAP (*Shapley Additive exPlanations*) (LUNDBERG; LEE, 2017) por meio de uma implementação dedicada a modelos baseados em árvores, aplicada aos modelos XGBoost treinados. Os valores SHAP atribuem, a cada atributo e a cada observação, uma contribuição aditiva para a predição correspondente. A média do valor absoluto dessas contribuições, sobre todo o conjunto de treinamento, fornece um indicador robusto de importância por atributo. Os gráficos resultantes são

apresentados no Capítulo 4 e ajudam a verificar se a hierarquia de atributos encontrada pelos modelos é compatível com o conhecimento físico do processo.

3.8 Validação por LOGO-CV

A avaliação do desempenho dos modelos é feita por validação cruzada seguindo a estratégia *Leave-One-Group-Out* (LOGO-CV), em que cada um dos 36 anéis depositados é, um por vez, deixado de fora do treinamento e usado como conjunto de teste. A cada uma das 36 iterações, o modelo é treinado nos 35 anéis restantes e avaliado sobre o anel excluído. As métricas resultantes, o coeficiente de determinação R^2 , o erro absoluto médio (MAE) e a raiz do erro quadrático médio (RMSE), são calculadas como a média das métricas obtidas a partir das 36 iterações.

A opção pela validação por anel, em vez de uma divisão aleatória por bloco de comando, tem importância metodológica. Como discutido na Seção 3.2.1, todos os blocos de comando de um mesmo anel compartilham os valores de L , z_{step} e p_{fr} . Uma divisão aleatória colocaria observações do mesmo anel simultaneamente nos conjuntos de treinamento e de teste, provocando vazamento de informação dessas três variáveis para o modelo e produzindo métricas muito otimistas. Já na validação por anel, é simulada a generalização do modelo para combinações de $(L, z_{\text{step}}, p_{\text{fr}})$ não observadas no treinamento, situação mais próxima do uso real objetivado para a ferramenta de predição (Seção 3.12). A Figura 13 representa esse esquema de validação aplicado aos 36 anéis.

Figura 13 – Representação da validação cruzada por anel



Fonte: Elaboração própria (2026).

Tecnicamente, o LOGO-CV é um caso particular de k -fold em que k é

fixado pelo número de grupos disponíveis e cada *fold* contém todas as observações de exatamente um grupo. A diferença essencial não está no algoritmo, mas no que cada estratégia mede. Em um k -fold com partições aleatórias, observações de um mesmo anel poderiam aparecer simultaneamente nos conjuntos de treinamento e de teste, e o modelo "veria" os valores de L , z_{step} e pfr daquele anel durante o treinamento. O coeficiente R^2 obtido refletiria, em parte, essa informação compartilhada e seria artificialmente otimista. O LOGO-CV elimina essa situação por construção: para cada anel testado, nenhum bloco de comando daquele anel participa do treinamento, e o modelo é forçado a generalizar para uma combinação de $(L, z_{\text{step}}, pfr)$ inédita. Essa é a única estratégia de validação que reflete o uso real previsto para a ferramenta de inferência: prever a geometria do cordão em condições operacionais novas, fora do conjunto de anéis depositados.

A implementação utilizou a classe *LeaveOneGroupOut* da biblioteca *scikit-learn* (PEDREGOSA et al., 2011), com o número do anel servindo como variável de agrupamento. Como dito anteriormente neste mesmo capítulo, a semente aleatória utilizada em todas as etapas estocásticas (inicialização das árvores, amostragem do XGBoost e amostragem do SHAP) foi fixada em 42, garantindo a reprodutibilidade integral do procedimento.

3.9 Validação física dos modelos

A avaliação dos modelos neste trabalho apoia-se em dois eixos complementares e de naturezas distintas. O primeiro é a validação estatística por LOGO-CV, descrita na Seção 3.8, que quantifica o erro de predição (MAE e RMSE) e o coeficiente de determinação (R^2) sobre anéis não vistos no treinamento. O segundo é a validação física, objeto desta seção, que verifica se as predições respeitam o comportamento esperado do processo, independentemente do ajuste estatístico.

A separação entre os dois eixos é necessária porque um modelo pode atingir R^2 elevado na validação estatística e, ainda assim, produzir predições fisicamente incoerentes, como uma largura de cordão que aumenta com a velocidade de avanço. A validação física é organizada em três famílias de testes, aplicadas às predições dos modelos já treinados: a verificação de monotonicidade, por varreduras unitárias de cada parâmetro; a inspeção por mapas bidimensionais no plano $P \times F$; e o teste de energia linear, que avalia se o modelo trata E_{lin} como escala primária do processo. Esses testes também orientaram os refinamentos sucessivos do modelo, descritos no Capítulo 4.

3.9.1 Testes de coerência física

A verificação de monotonicidade se inicia por varreduras unitárias por parâmetro: para cada um dos três parâmetros principais do processo (P , F e pfr), é

executada uma varredura independente, em que aquele parâmetro varia em 60 pontos uniformemente espaçados em sua faixa de operação, enquanto os demais (incluindo L e z_{step}) são fixados em valores centrais de referência. Os valores centrais adotados foram $P = 1.200 \text{ W}$, $F = 700 \text{ mm/min}$, $\text{pfr} = 3 \text{ RPM}$, $L = 1$ e $z_{\text{step}} = 0,5 \text{ mm}$. O objetivo de cada teste foi calcular a porcentagem de vezes em que o modelo gerou uma resposta que contrariava a física do processo, como, por exemplo, prever que o cordão diminuiria de tamanho mesmo com o aumento da potência do laser. Essa taxa de falhas lógicas foi adotada como o indicador principal para medir se as previsões do sistema faziam sentido na prática.

A inspeção por mapas amplia a varredura anterior para um mapa bidimensional, com $30 \times 30 = 900$ pontos cobrindo o plano $P \times F$ no envelope operacional. Esse mapa é representado como um *heatmap* (mapa de calor) para cada uma das três variáveis-alvo, o que permite identificar visualmente regiões em que o modelo extrapola de forma implausível, como descontinuidades abruptas, ilhas isoladas ou comportamento não monotônico em direções compostas. O comportamento do modelo também foi observado em 18 pontos extremos do envelope, definidos por combinações de valores mínimos e máximos dos parâmetros principais, a fim de checar o comportamento nas fronteiras (próximo a extrapolação do modelo).

O teste de energia linear verifica em que medida o modelo trata E_{lin} (Equação 8) como uma escala primária do processo. Para isso, são selecionados pares (P_1, F_1) e (P_2, F_2) com o mesmo valor de E_{lin} , gerados respectivamente pelas varreduras de P e de F , e calcula-se o resíduo médio entre as previsões nesses pares. Um resíduo pequeno indica que o modelo reconhece E_{lin} como variável dominante e um resíduo grande aponta para dependência residual significativa de P e F individualmente.

3.9.2 Refinamento iterativo do modelo

A aplicação dos testes descritos nas subseções anteriores, ao longo do desenvolvimento do trabalho, permitiu a identificação de três causas distintas de incoerência física em versões iniciais do modelo. A primeira foi o uso de representações vetoriais de imagens (*embeddings*) extraídas da câmera de processo, que não gerou ganhos expressivos e acabou mascarando o efeito da potência sobre grande parte das previsões. A segunda foi a ausência de restrições de monotonicidade sobre atributos compostos contendo F no numerador, como $F \cdot \text{pfr}$ e $F \cdot L$, cuja variação também acabava escondendo o efeito esperado de F . A terceira foi a falta de restrição para o atributo pfr/P , que decresce com P e, sem restrição, acaba anulando parte do impacto positivo que a própria potência deveria trazer para as previsões.

Cada uma dessas causas foi tratada de uma maneira específica: a remoção integral dos *embeddings* do conjunto de atributos; a adição das restrições -1 sobre

$F \cdot pfr$ e $F \cdot L$; e a adição da restrição -1 sobre pfr/P . Essas iterações sucessivas, detalhadas no Capítulo 4, eliminaram completamente as violações de monotonicidade detectadas nas varreduras de P para as variáveis altura e área, ao custo de uma pequena redução do R^2 obtido na validação cruzada. Os valores numéricos dessa evolução são apresentados também no Capítulo 4.

3.10 Quantificação de incerteza por CQR

Os modelos descritos na Seção 3.7 fornecem uma predição pontual para cada uma das três variáveis-alvo (largura, altura e área). Para o uso prático do sistema, no entanto, é desejável acompanhar cada predição de uma faixa que represente, com um grau de confiança determinado, o intervalo no qual o valor real deve cair. Com essa finalidade, adotou-se o método CQR (*Conformalized Quantile Regression*), proposto por Romano, Patterson e Candès (2019), que combina regressão quantílica com calibração conformal, detalhados a seguir.

3.10.1 Construção do intervalo de incerteza

A regressão quantílica estima diretamente um quantil específico da distribuição condicional do alvo, em vez do valor médio estimado por modelos de regressão comuns. Para cada variável-alvo, foram treinados dois modelos XGBoost adicionais: um que estima o quantil de 10% e outro que estima o quantil de 90% da distribuição condicional. Juntos, esses dois modelos definem um intervalo nominal de 80% de cobertura. A estrutura desses modelos é a mesma dos modelos principais descritos na Seção 3.7.4; eles diferem apenas pela função de perda, adaptada ao problema quantílico, e pelo nível de quantil que cada um deles estima. Ambos foram treinados sob o mesmo esquema LOGO-CV descrito na Seção 3.8.

A seguir, descreve-se a etapa de calibração conformal. Na prática, o intervalo entre q_{10} e q_{90} predito pelos modelos quantílicos raramente cobre exatamente 80% dos casos: ele pode ser largo demais (e cobrir muito mais) ou estreito demais (e cobrir menos). Para corrigir esse desvio, o método CQR usa as predições obtidas na validação cruzada para medir, em cada observação, o quanto o valor real ficou fora do intervalo predito. A partir desse desvio típico, o método amplia ou estreita o intervalo de forma uniforme, até que a cobertura observada atinja o valor desejado.

Para cada bloco de comando i usado na validação, calcula-se o desvio E_i definido conforme o procedimento de calibração conformal de Romano, Patterson e Candès (2019) pela Equação 9:

$$E_i = \max\left(q_{10}^{(i)} - y_i, y_i - q_{90}^{(i)}\right). \quad (9)$$

O valor E_i é positivo quando a observação y_i cai fora do intervalo predito $[q_{10}^{(i)}, q_{90}^{(i)}]$ e negativo quando cai dentro. Em seguida, define-se um fator de correção δ como o valor de E_i que separa, na distribuição dos desvios, os 80% menores dos 20% maiores. Ou seja, escolhe-se a margem necessária para cobrir 80% dos casos observados. O intervalo calibrado para uma nova observação x é então o intervalo predito original expandido por δ em ambos os lados, conforme a Equação 10:

$$I_{\text{CQR}}(x) = [q_{10}(x) - \delta, q_{90}(x) + \delta]. \quad (10)$$

A distribuição dos dados entre as etapas de treino, calibração e teste segue diretamente do esquema LOGO-CV. Em cada uma das 36 iterações, os modelos q_{10} e q_{90} são treinados sobre os 35 anéis de treino e produzem predições para o anel deixado de fora. Reunindo as 36 iterações, cada observação recebe um par (q_{10}, q_{90}) estimado por modelos que não foram treinados com o seu anel, isto é, predições *out-of-fold*. Os desvios E_i da Equação 9 são calculados sobre esse conjunto completo de predições *out-of-fold*, que cumpre o papel de conjunto de calibração, e é a partir deles que se obtém o fator δ . A cobertura empírica relatada na Seção 3.10.2 é medida sobre esse mesmo conjunto. Não há, portanto, um conjunto de teste independente do conjunto de calibração: como δ é escolhido justamente para que cerca de 80% das observações *out-of-fold* fiquem dentro do intervalo, a cobertura resultante aproxima-se do alvo por construção, o que reforça a ressalva apresentada na Seção 3.10.2. Para a inferência na ferramenta final, os modelos q_{10} e q_{90} são, por fim, re-treinados sobre todos os anéis disponíveis, mantendo-se o δ já calibrado.

3.10.2 Cobertura empírica e limitação teórica

Depois de aplicar o fator de correção δ , mede-se quantas observações reais efetivamente caem dentro do intervalo calibrado. Idealmente, esse percentual deve ficar próximo de 80%. Os valores obtidos para as três variáveis-alvo são apresentados no Capítulo 4.

É importante destacar a seguinte limitação teórica: para que o método estatístico usado na margem de erro (CQR) ofereça garantia matemática, os dados analisados precisariam ser totalmente independentes uns dos outros e seguir um mesmo padrão. No entanto, como a separação dos testes foi feita por anéis inteiros, e cada anel mantém algumas das configurações fixas durante toda a deposição, os pontos de leitura de um mesmo anel acabam sendo muito parecidos e influenciando uns aos outros. Por esse motivo, a margem de acerto calculada deve ser vista apenas como um resultado prático que funciona bem para a faixa de operação testada neste estudo, e não como uma regra definitiva caso a máquina opere com combinações de parâmetros muito diferentes do que foi visto.

3.11 Visualização preditiva da seção transversal

A predição pontual de largura, altura e área não permite, por si só, visualizar de forma intuitiva o tamanho esperado da seção transversal do cordão. Para oferecer ao usuário uma representação gráfica, optou-se por desenhar a seção como uma semi-elipse de largura w e altura h previstas. Cabe destacar que a forma do cordão não é, neste trabalho, objeto de predição: o sistema prediz apenas as três dimensões (largura, altura e área), e a semi-elipse é empregada somente como representação visual padronizada dessas dimensões.

3.11.1 Forma adotada: semi-elipse

A semi-elipse é a forma canônica usada para descrever a seção transversal de cordões de L-DED com boa molhabilidade. Considerando apenas a metade superior do perfil, com a linha de base do substrato em $y = 0$, a curva adotada é dada pela Equação 11:


$$y(x) = h \cdot \sqrt{1 - \left(\frac{2x}{w} - 1\right)^2}, \quad x \in [0, w], \quad (11)$$

na qual w é a largura e h é a altura previstas. A curva vale zero nas bordas ($x = 0$ e $x = w$) e atinge o máximo h no centro ($x = w/2$), conforme ilustrado na Figura 14. A escolha da semi-elipse é coerente com a análise empírica do fator de forma do conjunto de dados e a razão média entre a área medida e o produto $w \cdot h$ é próxima de $\pi/4 \approx 0,785$, exatamente o valor associado a uma semi-elipse.

A área é uma saída numérica independente do modelo, apresentada ao usuário como valor ao lado do desenho, e não é usada para deformar a curva: a semi-elipse é uma visualização padronizada baseada apenas em w e h . Essa decisão simplifica a representação e evita induzir o leitor a interpretar a forma desenhada como uma predição de geometria fina, que não é objetivo deste trabalho.

3.11.2 Módulo de visualização

As funções de visualização foram organizadas em um módulo Python independente, com duas funções principais. A primeira renderiza a seção transversal correspondente ao par (w, h) predito, com uma banda sombreada em torno da curva nominal que representa a faixa de incerteza obtida pelo CQR para a largura e a altura, conforme as Equações 9 e 10. A segunda recebe dois pares e desenha as duas seções lado a lado, permitindo a comparação direta entre cenários operacionais. Essas funções são utilizadas tanto pela ferramenta interativa descrita na seção seguinte quanto pela geração de figuras estáticas reproduzidas no Capítulo 4.

Figura 14 – Semiellipse adotada para representar a seção transversal do cordão

Fonte: Elaboração própria (2026).

3.12 Ferramenta interativa de inferência


Para tornar o sistema acessível ao operador da máquina e a outros usuários sem familiaridade com Python, os modelos treinados foram encapsulados em uma ferramenta interativa construída com a biblioteca Streamlit (Streamlit Inc., 2026). A ferramenta é executada localmente e oferece duas modalidades de uso, organizadas em guias. Na predição direta, o usuário informa os parâmetros do processo e obtém a geometria prevista, acompanhada da incerteza, do mapa operacional e do comparador de cenários (Seções 3.12.1 a 3.12.3). Na predição inversa, o caminho é o oposto: o usuário informa a geometria desejada e a ferramenta sugere as combinações de parâmetros que mais se aproximam dela (Seção 3.12.4).

3.12.1 Predição pontual com banda de incerteza

A primeira seção da ferramenta recebe os cinco parâmetros de processo (P , F , L , z_{step} e pfr) por meio de campos numéricos e controles deslizantes. A potência e a velocidade são informadas como valores contínuos (qualquer valor inteiro dentro do intervalo experimental, de 282 a 2.198 W e de 343 a 2.062 mm/min), enquanto o número de camadas, o incremento vertical e a taxa de alimentação permanecem restritos aos níveis discretos configuráveis no equipamento. Essa escolha é coerente com a amostragem do experimento: P e F foram observados em muitos níveis distintos, de modo que estimar valores intermediários é interpolação dentro da faixa treinada. Já L , z_{step} e pfr assumem poucos valores fisicamente realizáveis. Ao acionar a predição, são exibidos três cartões numéricos com os valores preditos de largura, altura e área, e uma renderização da seção transversal do cordão, gerada pela função de desenho da seção descrita na seção anterior, com a banda de incerteza CQR sombreada em torno da curva nominal.

A Figura 15 mostra um exemplo dessa guia, na qual são visíveis os parâmetros de entrada, os valores de saída de largura, altura e área e a seção transversal do cordão com a banda de incerteza, representada pelas linhas tracejadas que envolvem a curva contínua central. Os valores numéricos desses intervalos são obtidos ao acionar o botão *Intervalos*, destacado na Figura 16, que abre uma janela com o limite inferior, o limite superior e a amplitude previstos para cada dimensão.

Figura 15 – Exemplo da guia de predição direta, com os parâmetros de entrada, os valores previstos e a seção transversal do cordão com a banda de incerteza



Fonte: Elaboração própria (2026).

Figura 16 – Janela com os intervalos de predição, acessada pelo botão *Intervalos* (em destaque)



Fonte: Elaboração própria (2026).


3.12.2 Mapa operacional $P \times F$

A segunda seção apresenta, simultaneamente para as três variáveis-alvo, mapas de calor sobre uma grade de 30×30 pontos no plano $P \times F$, cobrindo o envelope operacional. Os valores dos parâmetros não plotados (L , z_{step} e p_{fr}) são definidos pelo usuário por meio de controles secundários. Uma transformação por z -score (escore padronizado) é aplicada às predições antes da renderização, o que destaca regiões de operação particularmente favoráveis ou desfavoráveis em relação ao comportamento médio do envelope. Essa seção permite ao usuário identificar visualmente corredores de parâmetros que produzem geometrias desejadas.

3.12.3 Comparador de cenários

A terceira seção fornece a possibilidade de informar dois conjuntos de entrada distintos e apresentá-los de forma simultânea. Para cada conjunto, a ferramenta calcula uma predição pontual e renderiza a seção transversal correspondente por meio da função de desenho conjunto/comparativo. Essa funcionalidade é útil para analisar trocas operacionais (por exemplo, o efeito de aumentar a velocidade de avanço em troca de maior potência, ou de variar a taxa de alimentação de pó) de forma que seja viável manter um conjunto como referência e experimentar os resultados ocasionados por uma diversidade de alterações nos parâmetros de entrada. A Figura 17 ilustra o comparador, com as seções transversais dos dois cordões sobrepostas e os valores numéricos das geometrias previstas para cada um.

Figura 17 – Comparador de cenários: seções transversais de dois cordões sobrepostas e respectivos valores de geometria previstos



Fonte: Elaboração própria (2026).

3.12.4 Predição inversa

As três seções anteriores operam no sentido direto: dos parâmetros para a geometria. Na prática, porém, o operador costuma ter o problema oposto, onde se conhece a largura e a altura desejada para o cordão e precisa-se descobrir quais parâmetros produzem esse resultado. A guia de predição inversa atende a essa necessidade. O usuário informa os alvos desejados (largura, altura e área, cada um opcional) e a ferramenta retorna as cinco combinações de parâmetros cuja geometria prevista mais se aproxima dos alvos.

A busca é feita por força bruta sobre uma versão discretizada do envelope operacional. Como a potência e a velocidade são contínuas, não é viável avaliar todos os seus valores; em vez disso, cada uma é amostrada em 50 valores uniformemente espaçados entre os limites experimentais, formando uma grade de $50 \times 50 = 2.500$ pares (P , F). Essa grade é combinada com as 36 configurações discretas de empilhamento, dadas pelos 3 níveis de camadas, 4 de incremento vertical e 3 de taxa de alimentação ($3 \times 4 \times 3 = 36$), o que totaliza 90.000 combinações. A geometria de cada combinação é prevista uma única vez, com os mesmos modelos da predição direta, e o resultado é reaproveitado entre consultas, pois independe dos alvos informados. Cada combinação recebe um erro relativo médio em relação aos alvos marcados, calculado pela Equação 12:

$$E = \sqrt{\frac{1}{m} \sum_{j=1}^m \left(\frac{y_j - y_j^*}{y_j^*} \right)^2}, \quad (12)$$

em que y_j^* é cada alvo informado, y_j é a predição correspondente e m é o número de alvos marcados. O erro é relativo (dividido pelo alvo) porque largura, altura e área têm escalas diferentes, e o desvio quadrático médio evita que um único alvo domine a soma. Vale destacar que essa amostragem não garante o ótimo global absoluto, mas sim o melhor ponto dentro da grade. É a discretização de P e F em 50 valores cada que viabiliza a busca interativa: varrê-los de forma praticamente contínua sobre o envelope, em conjunto com as 36 configurações de empilhamento, levaria a centenas de milhões de predições por consulta, sem ganho prático que justifique o custo.

3.12.4.1 Diversificação por configuração de empilhamento

Uma simples ordenação das melhores combinações tende a devolver cinco receitas quase idênticas (mesma configuração de camadas, incremento vertical e taxa de alimentação, variando apenas ligeiramente a potência e a velocidade). Isso ocorre porque, fixada uma boa configuração, existe toda uma faixa de pares (P , F) com energia

linear semelhante que produz praticamente a mesma geometria. Uma lista assim seria pouco útil ao operador.

Para oferecer alternativas realmente distintas, a ferramenta diversifica os resultados por configuração de empilhamento, isto é, por cada combinação de (L , z_{step} , p_{fr}). De cada configuração distinta guarda-se apenas a melhor dupla (P , F) e, em seguida, esses representantes são ordenados pelo erro e os cinco primeiros são exibidos. A primeira linha é, portanto, tida como o ótimo global (a receita de menor erro), e as demais são as melhores receitas que empregam outras configurações de camadas, incremento vertical ou alimentação, respondendo a perguntas como “se não for possível usar três camadas, qual é a melhor receita com apenas uma?”.

Cabe registrar a contrapartida dessa escolha: como cada linha é forçada a usar uma configuração diferente, as alternativas a partir da segunda podem apresentar erro consideravelmente maior que a primeira, caso apenas uma configuração atinja bem os alvos. A coluna de erro relativo exibida na tabela torna essa diferença visível, e a ferramenta emite um aviso quando nem a melhor combinação se aproxima o suficiente, indicando que os alvos informados provavelmente estão fora da faixa que o processo consegue produzir neste envelope. A Figura 18 apresenta uma visão geral da guia de predição inversa.

Figura 18 – Visão geral da segunda guia da ferramenta interativa de predição

Predição direta Predição inversa

?

☒ Mirar largura
 Largura alvo (mm)

2,13
- +

☒ Mirar altura
 Altura alvo (mm)

0,64
- +

☐ Mirar área
 Área alvo (mm²)

1,06
- +

Top 5 combinações

#	Potência (W)	Velocidade (mm/min)	Camadas	Z-step (mm)	Alimentação (RPM)	Largura (mm)	Altura (mm)	Área (mm ²)	Erro rel.
1	1885	483	1	0.8	3	2.127	0.639	0.859	0.1%
2	2002	589	1	1.1	2	2.124	0.641	0.929	0.2%
3	1690	1746	1	0.5	4	2.132	0.636	0.778	0.4%
4	1963	729	2	1.1	2	2.148	0.643	1.117	0.7%
5	1572	448	1	1.1	3	2.134	0.646	0.835	0.7%

Fonte: Elaboração própria (2026).

4 APRESENTAÇÃO DOS RESULTADOS

Este capítulo apresenta os resultados obtidos pelo *pipeline* metodológico descrito no Capítulo 3. As seções estão organizadas na mesma ordem em que os artefatos foram produzidos: estatísticas do conjunto de dados final, métricas de regressão obtidas por validação cruzada, análise da importância dos atributos pelo método SHAP, resultados da validação física dos modelos, cobertura empírica dos intervalos de incerteza calibrados, exemplos da visualização preditiva da seção transversal e a avaliação funcional da ferramenta interativa de inferência. Ao final, é apresentada uma discussão integrada que retoma, de forma crítica, as limitações estruturais identificadas ao longo do trabalho.

4.1 Estatísticas do conjunto de dados final

As estatísticas descritivas das três variáveis da geometria do cordão, nos níveis de quadro e de bloco de comando, foram apresentadas na Tabela 1. Duas observações que devem ser consideradas serão descritas a seguir e retomadas posteriormente na discussão integrada (Seção 4.8).

A primeira é que a suavização leve adotada na versão final ($W = 15$) preserva, em grande medida, a faixa de variação observada no nível de quadro. A largura, por exemplo, varia entre 0,74 e 3,36 mm no nível de quadro e entre 0,84 e 3,19 mm após a suavização. A média se mantém praticamente inalterada (próxima de 2,32 mm em todos os casos), mas a variância (que carrega o sinal a ser predito) é majoritariamente conservada. Esse é, justamente, o efeito pretendido pela mudança de janela, e é o que sustenta a leitura honesta das métricas apresentadas adiante.

A segunda é a compressão do tamanho efetivo do conjunto após a agregação por faixas de velocidade descrita na Seção 3.7.3. Para altura e área, o conjunto disponível para o treinamento contém 944 observações; para largura, 630 observações. Esses valores são bem menores do que os 25.920 blocos de comando brutos do conjunto de dados, e qualquer interpretação das métricas apresentadas a seguir deve considerar essa agregação.

4.2 Métricas de regressão por LOGO-CV

4.2.1 Desempenho dos modelos treinados

A Tabela 2 apresenta as métricas obtidas por validação cruzada LOGO-CV sobre os modelos XGBoost e Ridge polinomial treinados conforme descrito na Seção 3.7. Cada valor é a média dos 36 *folds* da validação cruzada.

Tabela 2 – Métricas de erro (MAE, RMSE) e de ajuste (R^2) obtidas por validação cruzada LOGO-CV (36 *folds*) sobre os modelos XGBoost e Ridge da versão final

Alvo	Modelo	MAE	RMSE	R^2	N
Altura (mm)	XGBoost	0,131	0,182	0,646	944
Altura (mm)	Ridge	0,129	0,179	0,656	944
Área (mm ²)	XGBoost	0,247	0,355	0,651	944
Área (mm ²)	Ridge	0,247	0,346	0,669	944
Largura (mm)	XGBoost	0,117	0,156	0,598	630
Largura (mm)	Ridge	0,136	0,180	0,466	630

Fonte: Elaboração própria (2026).

A avaliação de desempenho deste trabalho privilegia o erro absoluto médio (MAE), métrica expressa na própria unidade física de cada variável, que independe da amplitude do alvo e traduz diretamente a precisão útil ao operador. O MAE do XGBoost é de 0,131 mm para a altura, 0,117 mm para a largura e 0,247 mm² para a área. Considerando que a calibração espacial do vídeo é de 0,016875 mm por *pixel* (Seção 3.3.1), o erro de altura e largura equivale a cerca de sete a oito *pixels*, margem pequena diante da resolução de medição e da própria variabilidade do processo de deposição. A interpretação detalhada dessas margens (em *pixels*, em relação à faixa de operação e frente à variabilidade do processo) é retomada na Seção 4.2.2.

O coeficiente de determinação (R^2), por sua vez, situa-se entre 0,598 (largura) e 0,651 (área). Valores modestos devido a adoção de suavização temporal leve ($W = 15$), que preserva a variância real do alvo em vez de comprimi-la. Esses valores poderiam ser elevados de forma expressiva sob uma suavização mais agressiva, possibilidade quantificada e deliberadamente descartada na Seção 4.8, por destruir a variação da geometria dentro de cada anel. O R^2 deve, portanto, ser lido como medida complementar (sensível à agregação e à variância preservada), e não como o resultado principal.

A comparação entre o XGBoost e o Ridge polinomial mantém o padrão observado nas versões anteriores. Para a altura e a área, o Ridge atinge desempenho ligeiramente superior ao do XGBoost ($R^2 = 0,656$ contra 0,646 na altura; 0,669 contra 0,651 na área), o que sugere que a relação entre os parâmetros do processo e essas duas dimensões é majoritariamente capturada por interações polinomiais de grau dois sobre os atributos derivados. Já para a largura, o XGBoost supera o Ridge com folga ($R^2 = 0,598$ contra 0,466), sinalizando não-linearidades relevantes nas extremidades do envelope operacional, onde o modelo baseado em árvores tem atuação melhor. Por essa razão, e por obedecer às restrições de monotonicidade física, o XGBoost é mantido como modelo de referência.

4.2.2 Interpretação do erro de predição


A magnitude do MAE só adquire significado quando confrontada com a resolução da medição e com a faixa de operação de cada alvo. A calibração do vídeo lateral é de 0,016875 mm por *pixel* (Seção 3.3.1); assim, o MAE de 0,131 mm na altura e de 0,117 mm na largura corresponde a, respectivamente, cerca de oito e sete *pixels*. Em outras palavras, o erro típico do modelo é da mesma ordem de grandeza da menor distância que o sistema de imagem consegue distinguir — não há margem relevante a recuperar abaixo desse patamar sem aumentar a resolução do próprio vídeo.

Relacionado à faixa de valores efetivamente observada para cada alvo (Tabela 1), o erro é igualmente pequeno: o MAE equivale a cerca de 5,4% da faixa da altura, 5,0% da faixa da largura e 4,0% da faixa da área. Quando referido à média de cada alvo, em vez de à faixa, o erro relativo é naturalmente maior para a altura (da ordem de 20%, por ser a grandeza de menor magnitude absoluta) e bem menor para largura e área. Para um processo de deposição experimental, sujeito a respingos, oscilações do fluxo de pó e variações térmicas do substrato, prever as três dimensões do cordão com erro médio estimado de cerca de 5% da amplitude de operação é um resultado expressivo e diretamente útil ao operador que precise antecipar a geometria antes da deposição.

A Figura 19 detalha esse comportamento. Nos painéis superiores, as predições *out-of-fold* acompanham de perto a reta $y = x$, com a maioria dos pontos contida na banda de $\pm$ MAE em torno do valor ideal. Nos painéis inferiores, a distribuição dos resíduos é concentrada e aproximadamente simétrica em torno de zero (não há viés sistemático de sub ou superestimação), com 63%, 66% e 61% dos pontos dentro de $\pm$ MAE para altura, área e largura, respectivamente. A razão RMSE/MAE, entre 1,3 e 1,4 nos três alvos, indica uma cauda de erros grandes pouco pronunciada: os desvios mais significativos são raros e concentram-se nos extremos do envelope operacional.

Figura 19 – Análise do erro de predição dos modelos XGBoost: predito versus observado e distribuição dos resíduos por alvo

Análise do erro de predição (XGBoost, predições out-of-fold da LOGO-CV)



Fonte: Elaboração própria (2026).

4.2.3 Evolução das métricas ao longo do desenvolvimento

O *pipeline* descrito no Capítulo 3 é o resultado de uma sucessão de versões, cada uma incorporando uma mudança estrutural no algoritmo de medição, no conjunto de atributos ou nas restrições de monotonicidade. A comparação direta de R^2 entre elas, porém, não é imediata: as versões anteriores tiveram esse coeficiente obtido com a suavização larga ($W = 200$), que comprime a variância do alvo e o infla artificialmente, enquanto a versão final adota a suavização leve ($W = 15$), que preserva a variância real. O R^2 mais baixo da versão final não indica, portanto, um modelo pior, e sim uma métrica mais fiel ao processo.


As primeiras versões utilizaram um *pipeline* anterior de processamento de vídeo, com região de interesse mais estreita e algoritmos de medição diferentes. Uma versão posterior introduziu o *pipeline* atual, com as restrições de monotonicidade e o uso de representações vetoriais (*embeddings*) extraídas da câmera frontal como atributos adicionais. Ela atingiu o maior R^2 em todos os três alvos, mas a validação física descrita na Seção 3.9 (com resultados detalhados na Seção 4.4) revelou um comportamento contrário ao esperado: ao variar a potência do laser, as predições de altura e área apresentavam sensibilidade muito baixa, inconsistente com a física do processo. Esse achado motivou a remoção integral dos *embeddings* na versão seguinte. Em seguida, a restrição de monotonicidade $pfr/P = -1$ e a correção do cálculo de

área (Seção 3.5.4) eliminaram completamente as violações de monotonicidade em varreduras de P para altura e área.

Por fim, a versão final introduz as duas mudanças centrais deste trabalho: a correção da defasagem entre deposição e imageamento, por meio do deslocamento temporal Δ_s na sincronização (Seção 3.5.6), e a substituição da suavização larga pela leve (Seção 3.6.2). Em versões iniciais, o R^2 chegava a cerca de 0,84 na largura, por exemplo, mas apenas sob a suavização larga; a queda observada na versão final reflete a remoção dessa inflação, e não perda de capacidade do modelo. Isso se confirma ao reavaliar o mesmo *pipeline* sob a suavização larga (Seção 4.8): altura e área recuperam o R^2 elevado das versões anteriores. Na largura, porém, mesmo esse valor idealizado fica abaixo do melhor resultado anterior, porque duas correções da versão final removeram correlações espúrias que antes o inflavam: o preenchimento do cordão por declive em vez de platô (Seção 3.5), que eliminou variações artificiais de largura, e o recálculo da área após a substituição de larguras pequenas pela média do grupo, que antes criava uma correlação estatística espúria entre largura e área aproveitada pelo modelo. As métricas relatadas na Tabela 2 são as adotadas para o restante deste capítulo.

4.3 Importância das variáveis (SHAP)

As Figuras 20, 21 e 22 apresentam os valores SHAP calculados para cada um dos três modelos XGBoost da versão final. Os nomes dos atributos exibidos nos gráficos seguem a nomenclatura técnica das variáveis do modelo, cujas fórmulas constam no Apêndice B (Quadro 8). Em cada gráfico, os atributos aparecem em ordem decrescente de importância média, e cada ponto corresponde a uma observação do conjunto de treinamento. A posição horizontal indica a contribuição da observação para a predição (positiva à direita, negativa à esquerda) e a cor representa o valor original do atributo, do azul (valor baixo) ao vermelho (valor alto).

Figura 20 – Valores SHAP para o modelo XGBoost de predição da altura do cordão

Fonte: Elaboração própria (2026).


A Figura 20 mostra que os três atributos mais influentes na predição da altura são, em ordem, a taxa de alimentação de pó (pfr), o número de camadas (L) e o atributo de interação $P \cdot pfr$. O padrão de cores indica, para os dois primeiros, uma relação direta e bem comportada entre o valor do atributo e a sua contribuição SHAP. Essa hierarquia é coerente com a física do processo de L-DED: mais pó depositado por unidade de tempo e mais camadas empilhadas produzem cordões mais altos.

O incremento vertical entre camadas (z_{step}) aparece em posição intermediária, com magnitude moderada. A potência do laser (P), quando tomada isoladamente, aparece abaixo dos atributos derivados que combinam P com outros parâmetros, como $P \cdot pfr$ e $P \cdot L$, o que sugere que o efeito da potência sobre a altura, no envelope considerado, é capturado principalmente por meio dessas interações em vez do parâmetro bruto.

O efeito da potência sobre a altura conecta-se a um mecanismo físico que a suavização leve da versão final permite observar com clareza. Dentro de um mesmo anel, a potência varia ao longo da deposição, e as regiões de maior potência tendem a produzir cordões mais altos: quanto mais energia é entregue ao pó e ao substrato, maior a fração de pó efetivamente fundida e incorporada, ou seja, melhor o aproveitamento

do material. No extremo oposto, no início de cada anel a potência é tão baixa que parte do pó atravessa a região do feixe sem interação suficiente e não adere ao substrato, resultando em cordões de altura mínima, ou mesmo na ausência de cordão. Essa variação da altura em função da potência dentro do anel é justamente o sinal que a suavização larga ($W = 200$) suprimia, e que a suavização leve ($W = 15$) preserva, tornando-o disponível ao modelo e coerente com a restrição de monotonicidade entre potência e altura imposta ao XGBoost (Seção 3.7.2).

Figura 21 – Valores SHAP para o modelo XGBoost de predição da área da seção transversal do cordão




Fonte: Elaboração própria (2026).

A Figura 21 mostra um perfil semelhante ao da altura: pfr e L ocupam novamente as duas primeiras posições, com magnitudes ainda maiores (contribuições SHAP entre aproximadamente $-0,4$ e $+0,4$ mm²). Esse achado é relevante pois, como pfr e L são parâmetros que permanecem constantes dentro de um anel e variam apenas entre anéis, sua importância dominante reflete a estrutura do experimento, em que boa parte da variabilidade da área é capturada pelas diferenças entre anéis. A potência do laser e o incremento vertical aparecem com magnitudes moderadas, e a velocidade de avanço (F), embora restrita por monotonicidade, contribui pouco em valor absoluto, o que é coerente com a sensibilidade moderada (porém não desprezível) da área à potência neste envelope experimental, retomada na Seção 4.8.4. De modo

geral, esse conjunto de atributos influentes é fisicamente coerente com a área refletir o balanço entre energia e material depositados por unidade de comprimento: além de pfr e L , figuram entre eles a taxa de massa por comprimento (pfr/F) e a energia linear ($E_{lin} = P/F$), que expressam diretamente, respectivamente, o material e a energia entregues por unidade de percurso do bico.

Figura 22 – Valores SHAP para o modelo XGBoost de predição da largura do cordão



Fonte: Elaboração própria (2026).

A Figura 22 mostra que, para a largura, os atributos mais importantes são o número de camadas (L) e as interações da potência com outros parâmetros ($P \cdot pfr$ e $P \cdot L$), além da própria potência (P) tomada isoladamente; a taxa de alimentação de pó (pfr) aparece logo em seguida. A velocidade de avanço (F), embora restrita por monotonicidade, contribui pouco em valor absoluto, situando-se entre os atributos de menor importância. Comparadas às duas figuras anteriores, as magnitudes das contribuições SHAP são menores (entre cerca de $-0,20$ e $+0,15$ mm). Diferentemente das versões anteriores, em que o R^2 mais baixo da largura era atribuído ao estreitamento de sua faixa pela suavização larga, na versão final a faixa da largura é preservada (Tabela 1). O desempenho mais modesto neste alvo decorre, portanto, de a largura ser a grandeza de medição mais ruidosa entre as três: por depender da detecção das bordas esquerda e direita do cordão, ela é mais sensível ao ruído de segmentação do vídeo binarizado


do que a altura (definida por um único ponto de topo) ou a área (soma de pixels). As próprias magnitudes reduzidas das contribuições SHAP refletem esse sinal mais fraco e ruidoso, coerente com o R^2 menor obtido para a largura.

4.4 Validação dos modelos de acordo com tendências físicas

Os testes complementares descritos na Seção 3.9 foram aplicados ao modelo da versão final, cujas restrições de monotonicidade e conjunto de atributos foram fixados ao longo do desenvolvimento (Seção 4.2.3). As figuras a seguir reportam o comportamento desse modelo, e a evolução das restrições que conduziu a esse comportamento é resumida na Tabela 3.

4.4.1 Varreduras paramétricas

A Figura 23 apresenta as varreduras paramétricas da versão final para cada combinação parâmetro-alvo (linhas: largura, altura, área; colunas: P , F , pfr). Observa-se que altura e área crescem monotonicamente (sempre na mesma direção, sem inverter) com P e com pfr, e decrescem com F , conforme esperado da física do processo. A largura, embora apresente pequenas oscilações em forma de degraus (típicas de modelos baseados em árvores), não apresenta um comportamento crescente ou decrescente bem definido, como os demais parâmetros-alvo analisados. As linhas tracejadas nos gráficos de largura indicam o diâmetro do feixe focal de 0,8 mm, e em nenhuma varredura a predição se aproxima desse limite. Cabe ressaltar que a largura foi a dimensão do cordão mais difícil de ser modelada, apresentando a maior margem de incerteza entre as três medidas avaliadas. Apesar dessa dificuldade, o desempenho do sistema para esse parâmetro manteve-se em um nível aceitável.

Figura 23 – Varreduras paramétricas unitárias dos três alvos em função de P , F e pfr 

Fonte: Elaboração própria (2026).

Quantitativamente, o principal indicador adotado é a fração de pares de pontos vizinhos em cada varredura que violam a monotonicidade esperada. A Tabela 3 resume a evolução desse indicador ao longo do desenvolvimento (da configuração inicial à versão final) para as varreduras de P e F aplicadas a altura e área.

Tabela 3 – Fração de violações de monotonicidade nas varreduras de P e F ao longo do desenvolvimento

Varredura	Alvo	Inicial	Intermediária	Final
Varredura P	Altura	10,2%	15,3%	0,0%
Varredura P	Área	8,5%	15,3%	0,0%
Varredura F	Altura	5,1%	0,0%	0,0%
Varredura F	Área	10,2%	0,0%	0,0%

Fonte: Elaboração própria (2026).

A primeira adição de restrições (sobre os atributos $F \cdot L$ e $F \cdot pfr$) eliminou todas as violações nas varreduras de F . A inclusão seguinte da restrição $pfr/P = -1$ eliminou todas as violações nas varreduras de P , forçando esse atributo a empurrar a predição na mesma direção que os demais atributos dependentes de P : um aumento


em P reduz pfr/P e, conseqüentemente, eleva a geometria predita. Na versão final, ambos os alvos respeitam integralmente as relações monotônicas esperadas em P e F , sem qualquer violação.

A sensibilidade absoluta das predições à potência também aumentou progressivamente ao longo do desenvolvimento, à medida que se removiam, a cada iteração, atributos ou interações que cancelavam parcialmente o efeito positivo de P sobre a geometria. Essa tendência culmina na versão final, cuja maior sensibilidade da área à potência é retomada na Seção 4.8.4.

4.4.2 Mapa $P \times F$ e cantos do envelope

A Figura 24 apresenta o mapa de calor da predição dos três alvos no plano $P \times F$, calculado sobre uma grade de $30 \times 30 = 900$ pontos no envelope operacional. Visualmente, as superfícies de altura e de área são suaves, sem descontinuidades, ilhas isoladas ou regiões com comportamentos abruptos, e crescem na direção de aumento de P e diminuição de F , conforme esperado. A largura, por sua vez, exibe um padrão mais irregular, com bandas em forma de degraus (típicas de modelos baseados em árvores) e sem um gradiente monotônico tão bem definido quanto o dos demais alvos, o que é coerente com o seu sinal mais fraco e ruidoso, já discutido nas Seções 4.3 e 4.4.1.

Figura 24 – Mapas de calor das predições dos três alvos no plano $P \times F$



Fonte: Elaboração própria (2026).

Ainda para compor a análise, foram considerados os 18 pontos extremos (cantos do envelope), gerados por um arranjo fatorial $3 \times 3 \times 2 = 18$ combinações, que mantêm o número de camadas e o passo em z fixos nos valores-base ($L = 1$, $z_{\text{step}} = 0,5$ mm), isolando o efeito dos demais parâmetros. O detalhamento dos valores utilizados é exibido no Quadro 7.

Quadro 7 – Construção dos 18 pontos das fronteiras do envelope experimental

Parâmetro	Níveis	Valores
P (W)	mín.; médio; máx.	282; 1240; 2198
F (mm/min)	mín.; médio; máx.	343; 1202,5; 2062
pfr (RPM)	apenas mín. e máx.	2; 4
L	fixo	1
Z_{step} (mm)	fixo	0,5


Fonte: Elaboração própria (2026).

A análise dos pontos citados confirmou que as previsões permanecem dentro de limites físicos plausíveis. A largura mínima predita pelo modelo da versão final, considerando todos os cantos, foi de 1,750 mm, bem acima do diâmetro do feixe focal (0,8 mm) e compatível com a faixa observada experimentalmente. A altura mínima predita foi de 0,192 mm e a área mínima, de 0,536 mm².

4.4.3 Consistência da energia linear

A Figura 25 apresenta a geometria predita em função da energia linear E_{lin} (Equação 8), separando as previsões geradas pela varredura de P (curvas em azul) das geradas pela varredura de F (curvas em laranja). Quanto mais sobrepostas estiverem as duas curvas, mais o modelo trata E_{lin} como a variável dominante do processo.

Figura 25 – Geometria predita em função da energia linear E_{lin} , a partir das varreduras de P e de F



Fonte: Elaboração própria (2026).

Para a largura, as duas curvas praticamente se sobrepõem, indicando que o modelo trata a largura essencialmente em função de E_{lin} . Para a altura e a área, observam-se ramos parcialmente distintos entre as varreduras de P e de F , indicando que esses alvos retêm alguma dependência dos parâmetros isolados além da energia linear. Esse resíduo médio entre os pares manteve-se baixo ao longo do desenvolvimento (da ordem de 0,01 a 0,03 mm², pequeno frente ao MAE de área), indicando que o modelo trata E_{lin} de forma majoritariamente consistente entre as varreduras de P e de F , ainda que a altura e a área retenham alguma dependência dos parâmetros isolados.

4.4.4 Síntese da validação física

Os três conjuntos de testes (varreduras, mapa $P \times F$ e análise da consistência de E_{lin}) convergem para o mesmo veredito: a versão final é fisicamente coerente em todas as direções relevantes do envelope operacional, sem qualquer violação de limite físico. Cabe destacar, ainda, uma melhora expressiva na sensibilidade da área à potência. O expoente empírico do ajuste área $\sim P^\alpha$, que nas versões fortemente suavizadas ficava em torno de 0,05, bem abaixo do crescimento aproximadamente proporcional ($\alpha \approx 1$) esperado em condições de boa fusão, sobe para 0,371 na versão final. Esse aumento confirma que parte da baixa sensibilidade observada anteriormente era, na verdade, um artefato da suavização larga, que comprimia a variação da área ao longo da potência; ao preservá-la, a versão final recupera boa parte desse efeito físico. A interpretação dessa sensibilidade é retomada na Seção 4.8.4.

4.5 Cobertura empírica do CQR

A Tabela 4 apresenta os resultados da calibração conformal descrita na Seção 3.10. Para cada variável-alvo, são reportados a cobertura empírica antes e após a calibração CQR, o fator de correção δ aplicado e a largura média do intervalo de incerteza resultante.

Tabela 4 – Cobertura empírica e largura média dos intervalos de incerteza antes e após a calibração CQR

Alvo	Cob. antes	Cob. após	δ	Largura calibrada
Altura (mm)	65,6%	80,1%	0,033	0,426
Área (mm ²)	64,1%	80,1%	0,087	0,825
Largura (mm)	60,3%	80,2%	0,065	0,416

Fonte: Elaboração própria (2026).


Antes da calibração, os intervalos $[q_{10}, q_{90}]$ produzidos pelos modelos quantílicos cobrem entre 60,3 e 65,6% das observações reais. Essa cobertura bruta é um indício favorável: os modelos quantílicos capturam, por si sós, boa parte da variabilidade entre anéis, em vez de depender fortemente da calibração para corrigir uma subcobertura severa. A natureza dessa subcobertura residual, ligada à validação por grupos, foi discutida na Seção 3.10.2.

Após a aplicação do fator de correção δ , a cobertura empírica (proporção de vezes em que o valor verdadeiro cai dentro do intervalo de incerteza previsto pelo modelo) atinge cerca de 80% nos três alvos, praticamente coincidente com o alvo nominal. O custo dessa correção é o aumento da largura do intervalo: o intervalo calibrado tem largura média de 0,426 mm para a altura, 0,416 mm para a largura e 0,825 mm² para a área. Esses intervalos são mais largos do que os relatados em

versões anteriores (reflexo direto de a versão final não comprimir a variância do alvo), mas representam, de forma honesta, a faixa de plausibilidade real da geometria para cada combinação de parâmetros. A Figura 26 ilustra o resultado do procedimento para o caso da área. Em cada painel, cada ponto é uma observação e a barra vertical representa o intervalo de 80% previsto para ela: os pontos em azul são os casos em que o valor real cai dentro do intervalo, e os em vermelho, os que caem fora. A fração de pontos azuis corresponde à cobertura empírica, que passa de 64,1% sem calibração (intervalos estreitos, no painel à esquerda) para 80,1% após o alargamento uniforme por δ (à direita).

Figura 26 – Diagnóstico visual da calibração CQR para a área

Calibração do intervalo de 80% — área




Fonte: Elaboração própria (2026).

Como discutido na Seção 3.10.2, essa cobertura empírica deve ser interpretada como uma estimativa válida para os regimes operacionais representados no envelope experimental, e não como garantia formal de cobertura para combinações de parâmetros muito distantes dos valores cobertos pelo envelope.

4.6 Exemplos da visualização preditiva

A Figura 27 apresenta a comparação entre o quadro binarizado real do cordão (à esquerda em cada par) e a seção transversal predita pelo modelo XGBoost, representada pela semi-elipse de largura e altura previstas conforme a Seção 3.11 (à direita em cada par). A figura é composta por quatro cenários extraídos do envelope experimental, representando combinações distintas de potência, velocidade e taxa de alimentação de pó.

Figura 27 – Comparação entre o cordão binarizado real e a seção transversal predita pelo modelo



Fonte: Elaboração própria (2026).

Em cada par, a área hachurada em torno da curva predita corresponde ao intervalo de cobertura empírica de aproximadamente 80% calibrado pelo CQR, considerando as bandas de incerteza calculadas para largura e altura. Os valores numéricos preditos são reportados no título acima de cada seção transversal predita. Visualmente, nota-se que as larguras preditas (extensão horizontal das curvas) aparentam para grande parte dos casos acompanhar as larguras dos cordões medidos, tendo em vista

a detecção de vales para limites do cordão e que a imagem real do cordão foi submetida a diversos outros tratamentos de imagem além da binarização. As alturas seguem a tendência observada nos perfis reais. Vale novamente destacar que, por construção, a seção transversal gerada é apenas uma representação geométrica simplificada do cordão: a semi-elipse traduz somente o envelope definido pela largura e pela altura previstas. Dessa forma, o sistema não prevê irregularidades locais, como assimetrias, ondulações do topo ou variações de borda, mas apenas esse contorno geométrico simplificado.

4.7 Avaliação da ferramenta de predição

A verificação funcional da ferramenta preditiva, detalhada na Seção 3.12, foi conduzida de forma exploratória, percorrendo manualmente diferentes combinações de parâmetros e conferindo a coerência das respostas. Na guia de predição direta, observou-se resposta imediata: a seção transversal e a banda de incerteza são atualizadas de modo consistente com os controles, e tanto o comparador quanto o mapa de calor reproduzem as tendências físicas esperadas, de modo que maior potência e menor velocidade resultam em cordões mais robustos. Na guia de predição inversa, os testes retornaram combinações de parâmetros coerentes com as geometrias-alvo solicitadas, com valores realistas dentro do envelope experimental, em resultado igualmente satisfatório. O comportamento mostrou-se estável na grande maioria das faixas testadas, atendendo ao objetivo de fornecer uma estimativa rápida da geometria a partir do código G.

Explicita-se que a ferramenta é um instrumento de apoio à decisão, e não um sistema de controle automático nem um substituto da validação experimental: sua exatidão é herdada dos modelos de regressão, cujo coeficiente de determinação, sob validação *leave-one-group-out*, são apresentados na Tabela 2. De modo análogo, a banda de 80 % reproduz a cobertura empírica de cerca de 80% obtida na calibração conformal (Tabela 4), cuja garantia teórica clássica pressupõe trocas independentes e identicamente distribuídas, condição que não foi plenamente satisfeita sob a validação por anéis. Dentro dessas ressalvas, e consideradas as demais limitações apontadas ao longo do trabalho, a ferramenta cumpre seu papel de forma satisfatória, entregando estimativas de geometria fisicamente plausíveis e acompanhadas de uma medida honesta de incerteza.

4.8 Discussão integrada

Esta seção revisa de forma crítica três pontos importantes observados nos resultados: o efeito das três etapas de suavização sobre o R^2 , a forma efetivamente assumida pelo cordão no conjunto de dados e a limitação estrutural na sensibilidade

da área à potência do laser. Por fim, comenta-se brevemente o alcance prático da cobertura empírica obtida com o CQR.

4.8.1 Suavização, sincronização e seu efeito sobre o R^2

Conforme detalhado nas Seções 3.6.1, 3.6.2 e 3.7.3, o *pipeline* aplica três etapas sucessivas de redução de ruído: a mediana por bloco de comando, a média móvel temporal por anel e a agregação por faixas de velocidade. As duas que calculam a média de observações de um mesmo ponto de operação (a mediana por bloco e a agregação por faixa) são estatisticamente válidas. A média móvel temporal, em contraste, calcula a média de blocos de comando vizinhos, que não correspondem necessariamente à mesma combinação de potência e velocidade.

É nessa etapa que reside a principal decisão metodológica desta versão. Demonstrou-se que a janela larga ($W = 200$) empregada nas versões anteriores atravessa, dentro de um mesmo anel, de cinco a seis níveis de potência e várias varreduras completas de velocidade. Como consequência, ela comprime artificialmente a variância do alvo e apaga o efeito da velocidade de avanço sobre a geometria: medido dentro de cada bloco de potência, esse efeito, que deveria ser negativo (maior velocidade, menor cordão), tornava-se praticamente nulo. Parte expressiva do R^2 elevado das versões anteriores (0,79 a 0,86) decorria, portanto, dessa compressão de variância, e não de maior capacidade preditiva.

A versão final corrige esse comportamento por duas vias. A primeira é a adoção da suavização leve ($W = 15$), curta o suficiente para permanecer dentro de um mesmo patamar de potência. A segunda é a correção da defasagem de sincronização (Seção 3.5.6): ao deslocar a associação entre quadros e comandos em $\Delta_s = 1,0$ s, cada medida de geometria passa a ser atribuída ao comando que de fato a produziu. O efeito dessa correção é claro: com a sincronização sem deslocamento, o efeito da velocidade sobre a área era estatisticamente igual a zero; com o deslocamento, ele aparece com o sinal físico correto. Em outras palavras, a sincronização imprecisa encobria o sinal da velocidade, e corrigi-la o revela.

O preço dessas duas decisões é um R^2 aparentemente mais baixo (0,60 a 0,65 entre os três alvos), porém honesto. Para dimensionar quanto se deve à suavização, basta aplicar a janela larga ($W = 200$) sobre o *pipeline* já corrigido: nesse cenário idealizado, o R^2 sobe para cerca de 0,93 na altura e 0,90 na área, embora apenas 0,76 na largura, agora abaixo das versões anteriores, pelas razões discutidas na Seção 4.2.3. Esse contraste deixa claro o que é sinal e o que é artefato de suavização. Por isso, os valores reportados na Tabela 2 não sustentam a alegação de que o modelo prediz a geometria de um único cordão depositado isoladamente, mas sim a de que ele prediz a geometria esperada de um trecho contínuo de deposição com parâmetros

constantes, leitura para a qual o erro absoluto médio (MAE), e não o R^2 , é a métrica mais informativa.

4.8.2 Validade do conjunto reduzido com o uso de XGBoost

O conjunto de treinamento reduzido para 630 e 944 observações, discutido na subseção anterior, é modesto diante dos 25.920 blocos de comando do conjunto de dados bruto, total que coincide com o utilizado pelo trabalho de referência (BONIN et al., 2023). É importante, no entanto, observar que essa comparação envolve algoritmos com requisitos de dados muito diferentes.

Bonin et al. (2023) adotaram redes neurais profundas alimentadas por dados numéricos e imagens. Modelos baseados em imagens e em redes neurais profundas tendem a demandar volumes maiores de dados para evitar o sobreajuste (*overfitting*), o que ajuda a explicar a escala do conjunto utilizado naquele trabalho. Os modelos adotados neste trabalho (XGBoost e Ridge polinomial) operam sobre representações estritamente tabulares dos parâmetros do processo, sem imagens. Modelos baseados em *gradient boosting* sobre dados tabulares são amplamente reconhecidos por apresentarem desempenho elevado mesmo com conjuntos consideravelmente menores (CHEN; GUESTRIN, 2016; HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Para esses casos, porém, é de extrema importância que a metodologia de validação seja rigorosa.

O conjunto de dados reduzido após a suavização tripla representa um sinal mais regular do que o cordão experimental efetivamente apresenta na operação. Em um cenário de implantação real, o modelo será solicitado a prever a geometria sobre flutuações inerentes ao processo, como variações instantâneas na vazão de pó e perturbações térmicas locais, que foram suprimidas no treinamento. A generalização do modelo para esse sinal bruto é, portanto, mais restrita do que o R^2 obtido sobre o sinal suavizado sugere, e revisar essa relação é uma sugestão explicitada no Capítulo 5.

Cabe registrar, por fim, uma limitação relativa ao escopo da comparação entre modelos. Este trabalho contrastou apenas duas famílias: o XGBoost, como modelo principal, e a regressão Ridge polinomial, como linha de base. A Ridge polinomial é uma linha de base razoável para o problema, pois captura de forma simples e interpretável as relações aproximadamente log-lineares entre os parâmetros e a geometria, servindo como referência honesta para dimensionar o ganho marginal do XGBoost. Outras famílias de modelos, contudo, não foram avaliadas e poderiam compor comparações futuras, como o Random Forest, o LightGBM (outra implementação de *gradient boosting*) e a regressão por processos gaussianos (*Gaussian Process Regression*), esta última com o diferencial de fornecer estimativas de incerteza de forma nativa. A comparação sistemática com essas alternativas depende, sobretudo, de um conjunto efetivo de treinamento maior, e é retomada entre as sugestões para trabalhos futuros

(Seção 5.2.2).

4.8.3 Ausência de vazamento entre treino e teste

Uma preocupação razoável é se a aplicação das três etapas de suavização *antes* da divisão entre treinamento e teste teria introduzido vazamento de dados (*data leakage*) entre os *folds* da validação cruzada. Esse risco foi evitado por construção do *pipeline*, e a explicação é fundamentada.

As três etapas de suavização operam sobre subconjuntos definidos pelo anel. A mediana por bloco de comando (Seção 3.6.1) combina apenas quadros do mesmo bloco, que pertence a um único anel. A média móvel temporal (Seção 3.6.2) é aplicada com agrupamento explícito por anel: cada valor suavizado de um anel R é calculado a partir de blocos de comando exclusivamente do próprio anel R . A agregação por faixas de velocidade (Seção 3.7.3) também opera dentro de cada anel. Em conjunto, as três etapas garantem que, para qualquer anel R , as observações suavizadas de R não dependem de observações de outro anel.

A validação cruzada LOGO-CV, conforme descrito na Seção 3.8, segura anéis inteiros como conjunto de teste a cada iteração. Combinando os dois fatos, segue que, em qualquer *fold*, nenhuma observação do conjunto de teste contribuiu para os valores das observações do conjunto de treinamento (e vice-versa). Portanto, a metodologia de validação é estatisticamente correta, e o R^2 reportado não é inflado por vazamento. O que ele reflete, conforme discutido na Seção 4.8.1, é o desempenho do modelo sobre um sinal já suavizado contra um alvo já suavizado (limitação diferente, e que foi tratada explicitamente).

4.8.4 Limitação estrutural: sensibilidade da área à potência

Como observado na Seção 4.4.4, o expoente empírico do ajuste área $\sim P^\alpha$ subiu de cerca de 0,05, nas versões fortemente suavizadas, para 0,371 na versão final, ainda abaixo do crescimento aproximadamente proporcional ($\alpha \approx 1$) esperado para o L-DED, mas substancialmente mais próximo dele. Esse resultado evidencia que parte da baixa sensibilidade observada antes era um artefato da suavização larga, e não uma característica intrínseca do conjunto de dados: ao preservar a variação da área dentro de cada anel, a versão final recupera boa parte do efeito da potência.

A parcela remanescente abaixo de $\alpha \approx 1$ tem origem na estrutura do experimento, conforme sugere a análise por SHAP (Figura 21): pfr e L variam apenas entre anéis e, no conjunto de 36 anéis disponíveis, dominam parte expressiva da variabilidade da área, ao passo que a potência P varia apenas dentro de cada anel, sobre uma faixa em que pfr e L permanecem constantes. O modelo aprende, assim, uma sensibilidade a P fiel ao que o conjunto de dados contém, ainda que menor do que

a que se observaria em um experimento desenhado para isolar o efeito da potência.

Trabalhos futuros que pretendam aproximar ainda mais a sensibilidade da área a P dos níveis da literatura deverão ampliar o plano experimental, de modo que P varie sob mais combinações distintas de pfr e L .

4.8.5 Alcance prático da cobertura CQR

A cobertura empírica de aproximadamente 80% obtida após a calibração CQR (Tabela 4) é um bom resultado, mas, como discutido na Seção 3.10.2, ela não constitui uma garantia de cobertura para pontos de operação fora do envelope representado pelos 36 anéis depositados. Para o uso prático da ferramenta de inferência descrita na Seção 3.12, a banda de incerteza CQR deve ser entendida como uma estimativa razoável da variabilidade esperada para combinações de parâmetros próximas das condições experimentais, e não como uma faixa de tolerância validada para qualquer combinação possível. Fora do envelope experimental, qualquer predição constitui extrapolação.

5 CONSIDERAÇÕES FINAIS

Este capítulo sintetiza as principais contribuições do trabalho, os resultados quantitativos obtidos e as limitações reconhecidas ao longo dos Capítulos 3 e 4, e indica direções para trabalhos futuros que possam estender ou aprimorar o sistema desenvolvido.

5.1 Síntese dos resultados

O objetivo geral do trabalho, que era desenvolver um sistema de aprendizado de máquina capaz de prever a geometria do cordão depositado por L-DED em função dos parâmetros do processo, a partir do conjunto experimental coletado no LMP/UFSC por Bonin et al. (2023), foi alcançado. As principais contribuições podem ser resumidas em três frentes:

- a) um *pipeline* completo de extração da geometria do cordão a partir do vídeo lateral binarizado, que mede largura, altura e área quadro a quadro e as associa aos blocos de comando do código G, totalizando um conjunto de 25.920 blocos;
- b) modelos preditivos baseados em XGBoost, com restrições de monotonicidade fisicamente motivadas e linha de base Ridge polinomial, validados por LOGO-CV e acompanhados de quantificação de incerteza calibrada por CQR e de uma visualização da seção transversal;
- c) uma ferramenta interativa de inferência, com predição direta e inversa, que funciona como instrumento de apoio à decisão para o operador.

No plano quantitativo, na validação cruzada LOGO-CV de 36 *folds* os modelos atingiram erro absoluto médio de cerca de 0,12 mm para a largura e a altura e 0,25 mm² para a área, margem da ordem de sete a oito *pixels*, próxima da resolução de medição e equivalente a cerca de 5% da faixa de operação. O coeficiente de determinação R^2 correspondente, entre 0,60 e 0,65 nos três alvos, deve ser lido como métrica complementar: é mais modesto do que o de versões anteriores por decorrer de uma escolha deliberada por honestidade (a suavização leve e a correção da defasagem de sincronização, que preservam a variação real da geometria em vez de comprimi-la). A validação física confirmou a coerência do modelo, com a monotonicidade respeitada em P e F , sem violações de limite físico, e com a sensibilidade da área à potência parcialmente recuperada (o expoente empírico de área $\sim P^\alpha$ subiu de cerca de 0,05 para $\alpha \approx 0,37$); a calibração CQR atingiu, ainda, cobertura empírica de aproximadamente 80% nos três alvos.

Quanto às limitações, três foram identificadas, discutidas e documentadas

no Capítulo 4: o compromisso entre suavização e preservação da variância, atenuado, mas não eliminado, pela adoção da janela leve (Seção 4.8.1); a sensibilidade reduzida da área predita à potência do laser (Seção 4.8.4); e a hipótese teórica não estritamente satisfeita pelo CQR sob o esquema LOGO-CV (Seção 4.8.5). Nenhuma delas invalida os resultados, sendo todas consequências reconhecíveis das escolhas metodológicas adotadas.

Convém enquadrar o trabalho na condição em que foi realizado. As imagens utilizadas não foram adquiridas com o propósito principal de medir a geometria do cordão: elas provêm do experimento de Bonin et al. (2023), concebido para o monitoramento de obstruções no alimentador de pó, e a câmera lateral não foi posicionada nem calibrada visando uma extração dimensional otimizada. Também não houve a possibilidade de repetir a deposição com um arranjo de aquisição otimizado para esse fim. Em consequência, o sinal extraído das imagens é ruidoso e apenas parcialmente adequado à tarefa, o que motivou a adoção da suavização e, na versão final, a opção por uma janela leve ($W = 15$) combinada à correção da defasagem de sincronização, em vez da janela larga ($W = 200$) das versões anteriores (Seção 4.8.1). Antes de ser uma fragilidade do trabalho, essa circunstância reflete uma situação recorrente na prática da engenharia: desenvolver a solução mais adequada possível a partir dos recursos efetivamente disponíveis, e não a partir do arranjo ideal, em geral mais custoso ou indisponível. Sob essa ótica, a contribuição do trabalho está justamente em demonstrar que, mesmo com dados não concebidos para o problema, é possível construir um sistema preditivo fisicamente coerente e operacionalmente útil. As melhorias de aquisição que permitiriam superar essas limitações são detalhadas nas sugestões para trabalhos futuros.

Por fim, cabe destacar dois aspectos centrais da metodologia abordada, discutidos em detalhe no Capítulo 4. O primeiro é a adequação do XGBoost ao tamanho do conjunto de treinamento efetivo, regime em que modelos baseados em *gradient boosting* sobre dados tabulares são reconhecidamente eficazes, ao contrário das redes neurais profundas alimentadas por imagens adotadas por Bonin et al. (2023), que exigem volumes substancialmente maiores de dados (Seção 4.8.2). O segundo é a ausência de vazamento de dados entre os *folds* da validação cruzada, garantida pela aplicação das três etapas de suavização estritamente dentro de cada anel e pela retenção de anéis inteiros como conjunto de teste no LOGO-CV (Seção 4.8.3).

5.2 Sugestões para trabalhos futuros

A análise crítica realizada no Capítulo 4 leva a cinco frentes de continuidade, apresentadas a seguir.

5.2.1 Sincronismo lateral aprimorado

A sincronização entre os quadros do vídeo lateral e o código G, descrita na Seção 3.5.5, adota um quociente ρ_r aproximado entre a duração do vídeo e a duração registrada pela CNC para cada anel. A correção da defasagem entre deposição e imageamento, introduzida nesta versão por meio do deslocamento constante Δ_s (Seção 3.5.6), compensa a parcela dominante do erro de atribuição, mas ainda repousa sobre o quociente aproximado e sobre um deslocamento único para todos os anéis. Uma versão definitiva poderá empregar diretamente os instantes de início e fim registrados pela CNC para cada comando do código G, eliminando o termo aproximado e oferecendo uma associação quadro-a-bloco mais precisa, em especial nas regiões de transição entre comandos.

5.2.2 Reaquisição dedicada do processo com câmera especializada

Boa parte das limitações de medição discutidas neste trabalho tem origem comum na aquisição do vídeo lateral, concebida para o estudo de *clogging* de Bonin et al. (2023) e não para a medição da geometria do cordão. Por isso, uma frente de continuidade de maior impacto é a refilmagem do processo com um arranjo de aquisição dedicado. Recomenda-se, em particular: (i) uma câmera especializada mantida fixa, sem movimento nem pausas ao longo de toda a deposição, eliminando o desalinamento temporal que hoje exige a sincronização aproximada da Seção 3.5.5 e a correção de deriva por anel; (ii) um fundo contrastado com o cordão, que dispense a binarização sensível a ruído e facilite a identificação automática das bordas; e (iii) maior espaçamento entre cordões vizinhos, de modo que cada cordão apareça isolado no campo de visão e não influencie a medição dos adjacentes, situação que, na configuração atual, motivou a detecção de bordas por zonas e a correção bilateral.

Com uma medição mais limpa e estável quadro a quadro, a dependência da suavização tripla (Seção 3.6.2) diminuiria substancialmente, expondo a variação real da geometria em vez de uma versão atenuada. Isso elevaria o número efetivo de amostras independentes e abriria espaço para avaliar outras famílias de modelos de aprendizado de máquina além do XGBoost e do Ridge, o que inclui abordagens inviáveis para o projeto atual pelo tamanho reduzido do conjunto efetivo de treinamento. A nova filmagem também permitiria extrair *embeddings* laterais corretamente sincronizados, retomando em melhores condições a hipótese de que a imagem lateral carregue sinal complementar ao do código G.

5.2.3 Ampliação do plano experimental para a sensibilidade à potência

Como discutido na Seção 4.8.4, o expoente empírico do ajuste área $\sim P^\alpha$, que nas versões fortemente suavizadas ficava em torno de 0,05, subiu para $\alpha \approx 0,31$

na versão final com a preservação da variância, mas ainda permanece abaixo do valor próximo a 1 esperado. A causa da parcela remanescente vem da estrutura adotada para o projeto, onde os 36 anéis disponíveis variam pfr e L em poucas combinações distintas, e parte expressiva da variabilidade da área observada no conjunto de dados é capturada por essas duas variáveis. Para aproximar ainda mais a sensibilidade da área à potência do valor próximo a 1, trabalhos futuros podem ampliar o plano experimental original, depositando anéis com combinações adicionais de pfr e L em que P assuma posições mais variadas dentro do envelope.

5.2.4 Redução adicional da janela de suavização em conjuntos de dados futuros

A média móvel temporal por anel (Seção 3.6.2) teve sua janela reduzida de $W = 200$, das versões anteriores, para $W = 15$ nesta versão. Conforme discutido na Seção 4.8.1, uma janela larga atenua o alvo e faz com que parte do R^2 reportado decorra da suavização, e não da capacidade do modelo de prever as flutuações reais do cordão; a redução já adotada tornou a métrica reportada substancialmente mais honesta. Ainda assim, mesmo a janela leve permanece como uma forma residual de suavização, necessária para conter o ruído da extração geométrica a partir do vídeo binarizado.

Para trabalhos futuros, uma medição mais limpa e estável quadro a quadro (por exemplo, a partir da reaquisição dedicada sugerida na Seção 5.2.2 ou da substituição do método de medição) permitiria reduzir ainda mais a janela W , idealmente até dispensar a média móvel temporal. Isso preservaria integralmente a variação real da geometria e eliminaria a última fonte de suavização não justificada por replicação de um mesmo ponto de operação.

5.2.5 Caracterização e predição do fator de forma do cordão

Ao longo deste trabalho, a forma da seção transversal foi tratada como aproximadamente constante: o fator de forma $c = A/(w \cdot h)$ (sendo A a área, w a largura e h a altura) manteve-se próximo de 0,807, valor pouco acima do $\pi/4 \approx 0,785$ de uma semi-elipse (Seção 2.8.3). Por apresentar comportamento quase constante, justifica-se o uso de uma semi-elipse fixa na visualização, e explica por que a área agrega pouca informação independente da largura e altura. Uma evolução natural do trabalho é estudar o próprio fator de forma como variável de resposta, visando caracterizar como c varia dentro do envelope e quais parâmetros de processo modulam a forma da seção. Tal estudo se beneficiaria de validação experimental por medições metalográficas em três a cinco condições do envelope, que comparariam as predições com seções físicas independentes da binarização.

Neste cenário, o objetivo principal seria alterado, onde antes visava-se

apenas os valores numéricos das três dimensões escalares e agora passaria a buscar o contorno completo da seção transversal, abandonando a hipótese de forma fixa. Como a câmera lateral registra diretamente o perfil do cordão, uma reaquisição dedicada e corretamente sincronizada (Seção 5.2.2) abriria espaço para que *embeddings* ou segmentações da imagem lateral alimentassem um modelo capaz de reproduzir a silhueta real do cordão, capturando os desvios em relação à semi-elipse que o fator de forma médio mascara. A verificação de que a imagem lateral carrega informação de forma complementar ao código G é, ela própria, parte do trabalho proposto.

REFERÊNCIAS

- BONIN, C. et al. Leveraging machine learning for predicting and monitoring clogging in laser cladding processes: An exploration of neural sensors. *Journal of Laser Applications*, Laser Institute of America, v. 35, n. 4, p. 042022, 2023.
- BRADSKI, G. The OpenCV library. *Dr. Dobbs's Journal of Software Tools*, v. 25, n. 11, p. 120–125, 2000.
- CHEN, T.; GUESTRIN, C. XGBoost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. San Francisco, CA, USA: ACM, 2016. p. 785–794.
- GAWDE, P. *3D Printing and Scanning*. 2023. Fab Academy 2023, Lab RIIDL. Disponível em: <https://fabacademy.org/2023/labs/riidl/students/pranav-gawde/assignments/week05.html>. Acesso em: 16 jun. 2026.
- GÉRON, A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. 2. ed. Sebastopol, CA: O'Reilly Media, 2019. ISBN 978-1-492-03264-9.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 4. ed. New York: Pearson, 2018. ISBN 978-0-13-335672-4.
- GUAN, X.; ZHAO, Y. F. Modeling of the laser powder-based directed energy deposition process for additive manufacturing: a review. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 107, n. 5-6, p. 1959–1982, 2020.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2. ed. New York: Springer, 2009. ISBN 978-0-387-84857-0.
- International Organization for Standardization; ASTM International. *ISO/ASTM 52900: Additive manufacturing – General principles – Fundamentals and vocabulary*. 2. ed. [S.l.], 2021.
- JAMES, G. et al. *An Introduction to Statistical Learning: with Applications in R*. New York: Springer, 2013. (Springer Texts in Statistics). ISBN 978-1-4614-7137-0.
- KOENKER, R.; BASSETT, G. Regression quantiles. *Econometrica*, The Econometric Society, v. 46, n. 1, p. 33–50, 1978.
- LADEIRA, I. J. D. *Manufatura aditiva de materiais metálicos: métodos, procedimentos e produtos*. 2021. Trabalho de Conclusão de Curso (Engenharia de Materiais) — Universidade Presbiteriana Mackenzie, São Paulo.
- LUNDBERG, S. M.; LEE, S.-I. A unified approach to interpreting model predictions. In: *Advances in Neural Information Processing Systems 30 (NeurIPS 2017)*. Long Beach, CA, USA: Curran Associates, Inc., 2017. p. 4766–4777.
- MARQUES FILHO, O.; VIEIRA NETO, H. *Processamento Digital de Imagens*. Rio de Janeiro: Brasport, 1999. ISBN 85-7452-009-8.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.

PINEAU, J. et al. Improving reproducibility in machine learning research (a report from the NeurIPS 2019 reproducibility program). *Journal of Machine Learning Research*, v. 22, n. 164, p. 1–20, 2021.

ROMANO, Y.; PATTERSON, E.; CANDÈS, E. J. Conformalized quantile regression. In: *Advances in Neural Information Processing Systems 32 (NeurIPS 2019)*. [S.l.]: Curran Associates, Inc., 2019.

SHAPLEY, L. S. A value for n -person games. In: KUHN, H. W.; TUCKER, A. W. (Ed.). *Contributions to the Theory of Games (AM-28), Volume II*. Princeton, NJ: Princeton University Press, 1953, (Annals of Mathematics Studies, 28). p. 307–318.

SHWARTZ-ZIV, R.; ARMON, A. Tabular data: Deep learning is not all you need. *Information Fusion*, Elsevier, v. 81, p. 84–90, 2022.

SILVA, P. C. et al. Manufatura aditiva: revisão sistemática da literatura. *Brazilian Journal of Development*, v. 6, n. 11, p. 84502–84515, 2020.

SIRAKORN. *Illustration of a boosting method for ensemble learning*. 2020. Wikimedia Commons. Licença CC BY-SA 4.0. Disponível em: https://commons.wikimedia.org/wiki/File:Ensemble_Boosting.svg. Acesso em: 16 jun. 2026.

Streamlit Inc. *Streamlit – A faster way to build and share data apps*. 2026. <https://streamlit.io>. Acesso em: 27 maio 2026.

SZELISKI, R. *Computer Vision: Algorithms and Applications*. London: Springer, 2011. (Texts in Computer Science). ISBN 978-1-84882-934-3.

TEIXEIRA, M. F. *Estudo da aplicação do processo laser cladding para a deposição de revestimento resistente ao impacto-abrasão sobre aço “Hadfield” de alto manganês*. 181 p. Tese (Tese (Doutorado em Ciência e Engenharia de Materiais)) — Universidade Federal de Santa Catarina, Florianópolis, 2021.

TOYSERKANI, E.; KHAJEPOUR, A.; CORBIN, S. F. *Laser Cladding*. Boca Raton, FL: CRC Press, 2004.

VIRTANEN, P. et al. SciPy 1.0: Fundamental algorithms for scientific computing in Python. *Nature Methods*, v. 17, n. 3, p. 261–272, 2020.

APÊNDICES

APÊNDICE A – PSEUDOCÓDIGO DO ALGORITMO DE MEDIÇÃO DA GEOMETRIA POR QUADRO

Este apêndice apresenta, em pseudocódigo, o algoritmo que mede a largura, a altura e a área da seção transversal em cada quadro do vídeo silhueta, descrito em prosa na Seção 3.5. As coordenadas são locais à região de interesse (ROI), com a linha de base do substrato em $y = 170$ e a calibração espacial de $PX_TO_MM = 0,016875$ mm por *pixel*. As constantes de zona ([20, 100] à esquerda e [140, 220] à direita) e os limiares de pico, vale e largura mínima são os adotados no *pipeline*.

```

1 def medir_frame(roi):                                # ROI 170 x 200 px, tons de cinza
2     mask = roi > 127                                # binariza: cordao = pixel branco
3     if not mask.any():
4         return None
5
6     # Altura: pixel branco mais alto na metade esquerda (x < 160)
7     esquerda = mask[:, :140]                        # 140 = 160 - 20 (offset da ROI)
8     linhas = where(esquerda.any(eixo=colunas))
9     y_topo = min(linhas) if linhas else min(where(mask.any(eixo=colunas)))
10    altura_px = 170 - y_topo
11
12    # Perfil horizontal P(x) e suavizacao
13    P = mask.sum(eixo=linhas)                        # n. de brancos por coluna
14    suave = gaussian_filter1d(P, sigma=3)
15    picos = find_peaks(suave, altura=0.20*max(suave),
16                      proeminencia=0.10*max(suave))
17    x_pico = picos[0] if picos else argmax(suave)
18
19    # Borda esquerda: zona [0, 80] local ([20, 100] absoluto)
20    vales = argrelemin(suave[0 : x_pico+1], ordem=5)
21    x_esq = None
22    for v in reversed(vales):                        # do vale mais proximo ao pico
23        if suave[v] < 0.50 * suave[x_pico]:
24            x_esq = v
25            break
26    if x_esq is None:                                # fallback: ponto de maior subida
27        x_esq = argmax(diff(suave[0 : x_pico+1]))
28
29    # Borda direita: zona [120, 200] local ([140, 220] absoluto)
30    inicio_dir = max(x_pico, 120)
31    vales_dir = argrelemin(suave[inicio_dir : 201], ordem=5)
32    x_dir = (inicio_dir + vales_dir[0]) if vales_dir \
33            else (ultimo pixel ativo na zona direita)
34
35    larg_px = x_dir - x_esq
36    if larg_px < 29.6:                                # < 0,5 mm: ruído, descarta o quadro
37        return None
38
39    area_px = mask[:, x_esq : x_dir+1].sum()
40    return altura_px, larg_px, area_px

```

Programa A.1 – Medição da geometria de um quadro (largura, altura e área).

No pós-processamento (Seção 3.5.7), larguras menores que 1 mm são

substituídas pela média do grupo e as bordas coincidentes com os limites das zonas são corrigidas pela média dos vizinhos temporais, recalculando-se a área a partir do perfil $P(x)$ armazenado por quadro.

APÊNDICE B – CONJUNTO COMPLETO DE ATRIBUTOS DERIVADOS

A Seção 3.7.1 apresenta os atributos por grupo e detalha os de maior significado físico. Este apêndice reúne, para reprodutibilidade, as fórmulas exatas das vinte e quatro variáveis efetivamente usadas no treinamento, em função dos cinco parâmetros brutos: potência P (W), velocidade de avanço F (mm/min), número de camadas L , incremento vertical z_{step} (mm) e taxa de alimentação de pó pfr (RPM). A energia linear é $E_{\text{lin}} = P/F$ e o diâmetro do feixe focal vale 0,8 mm.

Quadro 8 – Fórmulas das vinte e quatro variáveis de entrada dos modelos

Atributo	Fórmula
<i>Brutos</i>	
potencia_laser	P
F	F
layers	L
z_step	z_{step}
powder_feed_rate	pfr
<i>Físicos</i>	
energia_linear	$E_{\text{lin}} = P/F$
taxa_massa_comprimento	pfr/F
interacao_layers_zstep	$L \cdot z_{\text{step}}$
log_potencia	$\ln P$
log_F	$\ln F$
<i>Interações</i>	
E_lin_layers	$E_{\text{lin}} \cdot L$
E_lin_zstep	$E_{\text{lin}} \cdot z_{\text{step}}$
E_lin_pfr	$E_{\text{lin}} \cdot \text{pfr}$
P_layers	$P \cdot L$
v_layers	$F \cdot L$
P_pfr	$P \cdot \text{pfr}$
v_pfr	$F \cdot \text{pfr}$
P_zstep	$P \cdot z_{\text{step}}$
E_lin_layers_zstep	$E_{\text{lin}} \cdot L \cdot z_{\text{step}}$
<i>Extras</i>	
Ev	$P/(F \cdot z_{\text{step}} \cdot 0,8)$
sqrt_E_lin	$\sqrt{E_{\text{lin}}}$
P2_v	P^2/F
razao_aspecto	$P/(F \cdot \text{pfr})$
pfr_P	pfr/P

Fonte: Elaboração própria (2026).