

Desenvolvimento e avaliação de um sistema monocular com triangulação laser dinâmica

Universidade Federal de Santa Catarina

Rafael Silva de Souza

Florianópolis
2026

Programa Institucional de Iniciação Científica e Tecnológica - PIICT
Bolsas PIBIC
2025/2026

Desenvolvimento e avaliação de um sistema monocular com triangulação laser dinâmica

Departamento de Engenharia Mecânica
Especialidade: Metrologia Científica e Industrial

Autor: Rafael Silva de Souza
Orientador: Prof. Tiago Loureiro Figaro da Costa Pinto

Palavras-chave: Visão estéreo, Triangulação Laser, Veículo Subaquático Operado Remotamente.

Florianópolis, 10 de junho de 2025.

RESUMO

Este relatório apresenta o desenvolvimento, a implementação e a avaliação de um sistema de triangulação a laser destinado à reconstrução tridimensional de superfícies, no contexto de uma Iniciação Científica vinculada ao Projeto VORIS (Veículo Operado Remotamente para Inspeção Submarina). O sistema proposto utiliza uma câmera monocular, uma fonte laser e um espelho rotativo controlado eletronicamente, permitindo a varredura angular da cena e a aquisição sincronizada de imagens.

A reconstrução tridimensional é realizada inicialmente por meio de um modelo geométrico clássico de triangulação, fundamentado na geometria projetiva da câmera e na medição precisa dos ângulos de varredura. Foram desenvolvidos algoritmos para detecção da linha laser, extração subpixel de suas coordenadas e conversão das informações bidimensionais da imagem em coordenadas tridimensionais no espaço.

Como extensão ao modelo físico, investigou-se o uso de técnicas de aprendizado de máquina supervisionado para estimativa de profundidade, com o objetivo de reduzir erros sistemáticos associados a imperfeições de calibração, desalinhamentos mecânicos, distorções ópticas e ruídos de imagem. Para isso, foram construídas bases de dados experimentais rotuladas e treinados modelos de regressão baseados em árvores de decisão impulsionadas por gradiente.

Os resultados indicam que a triangulação baseada no modelo geométrico apresentou maior precisão quando comparada à abordagem por aprendizado de máquina. Ainda assim, a abordagem baseada em dados mostrou-se coerente e promissora, especialmente considerando a possibilidade de aprimoramento por meio da ampliação e diversificação da base de treinamento.

Palavras-chave: Visão estéreo, Triangulação Laser, Veículo Subaquático Operado Remotamente.

SUMÁRIO

Sumário 3

Lista de ilustrações 3

1 INTRODUÇÃO 5

1.1 Justificativa e Objetivos 5

2 MATERIAL E MÉTODOS 7

2.1 Arquitetura Geral do Sistema 7

2.2 Descrição do Hardware 8

2.3 Aquisição e Pré-processamento das Imagens 9

2.4 Extração Subpixel da Linha Laser 10

2.5 Modelo de Triangulação Geométrica 11

2.5.1 Normalização das Coordenadas da Imagem 11

2.5.2 Configuração Geométrica do Sistema Câmera–Laser 11

2.5.3 Correção do Ângulo de Varredura por Reflexão no Espelho 12

2.5.4 Estimativa da Profundidade por Triangulação 12

2.5.5 Reconstrução das Coordenadas Tridimensionais 12

2.6 Limitações do Modelo Geométrico 13

2.7 Aprendizado de Máquina para Estimativa de Profundidade 14

2.7.1 Parâmetros de Entrada do Modelo 15

2.7.2 Formulação da Função de Profundidade 16

2.7.3 Modelo de Regressão Utilizado 16

2.7.4 Considerações sobre a Abordagem 17

2.8 Limitações da Abordagem Baseada em Aprendizado de Máquina . . 19

2.9 Interface Gráfica 21

3 RESULTADOS E DISCUSSÃO 23

3.1 Avaliação do Modelo Geométrico 23

3.2 Influência da Qualidade da Extração da Linha Laser 23

3.3 Resultados da Abordagem por Aprendizado de Máquina 24

3.4 Comparação entre as Abordagens 24

3.5 Discussão Geral 24

4 CONCLUSÃO 26

REFERÊNCIAS 28

LISTA DE ILUSTRAÇÕES

Figura 1 – Fluxo funcional do sistema de triangulação a laser. Fonte: autoria própria. 8
Figura 2 – Hardware utilizado para a aquisição de imagens e disparo do laser. Fonte: autoria própria 9
Figura 3 – Resultado da reconstrução tridimensional de uma caveira pelo modelo geométrico. Fonte: autoria própria. 13
Figura 4 – Resultado da reconstrução tridimensional de uma trena pelo modelo geométrico. Fonte: autoria própria. 13
Figura 5 – Análise das diferenças entre os processos com uma caixa. Fonte: Autoria própria. 18
Figura 6 – Análise das diferenças entre os processos com uma mão. Fonte: Autoria própria 19
Figura 7 – Análise das diferenças entre os processos com uma caveira. Fonte: autoria própria 21
Figura 8 – Interface gráfica. Fonte: autoria própria 22

1 INTRODUÇÃO

A obtenção de informações tridimensionais precisas constitui um desafio central em diversas áreas da engenharia moderna, como metrologia óptica, robótica, visão computacional e inspeção industrial. Em ambientes subaquáticos, o processo de reconstrução tridimensional torna-se ainda mais desafiador devido às condições ópticas adversas características do meio aquático, que comprometem a qualidade das imagens adquiridas e reduzem a confiabilidade das informações geométricas extraídas. Tais limitações impactam diretamente métodos baseados em princípios ópticos, exigindo abordagens mais robustas e estratégias de modelagem capazes de lidar com a degradação visual e as incertezas inerentes ao processo de aquisição (1).

Nesse contexto insere-se o Projeto VORIS, desenvolvido pelo Laboratório de Metrologia e Automação (LABMETRO/UFSC) com financiamento da FINEP, cujo objetivo é a concepção de um veículo operado remotamente capaz de executar inspeções subaquáticas detalhadas em estruturas de interesse industrial. Para isso, o projeto contempla a integração de múltiplas técnicas de sensoriamento, com destaque para métodos ópticos de reconstrução tridimensional (2).

Dentre essas técnicas, a triangulação a laser destaca-se pela elevada resolução espacial, simplicidade conceitual e viabilidade de aplicação em ambientes controlados e semi-controlados. Contudo, apesar de sua fundamentação teórica bem estabelecida, a aplicação prática dessa técnica é frequentemente limitada por erros sistemáticos decorrentes da interação entre componentes ópticos, mecânicos e eletrônicos do sistema (3, 4).

Diante desse cenário, este trabalho propõe não apenas a implementação de um sistema funcional de triangulação a laser, mas também a investigação de uma abordagem alternativa na qual técnicas de aprendizado de máquina são empregadas de forma exclusiva na reconstrução tridimensional de objetos, em consonância com tendências recentes da literatura que exploram métodos orientados por dados para estimação de profundidade monocular e multissensorial (5).

1.1 JUSTIFICATIVA E OBJETIVOS

A adoção de um sistema de triangulação a laser no escopo do Projeto VORIS é justificada pela necessidade de validar técnicas ópticas em ambiente de laboratório antes de sua integração em um veículo subaquático real. Além disso, o desenvolvimento do sistema permite a geração de dados experimentais essenciais para estudos comparativos e para o treinamento de modelos baseados em aprendizado de máquina.

Os principais objetivos deste trabalho são:

- Projetar e implementar um sistema físico de varredura a laser com controle eletrônico preciso;
- Desenvolver algoritmos robustos para detecção da linha laser em imagens;
- Implementar a reconstrução tridimensional baseada em triangulação geométrica;
- Investigar o uso de aprendizado de máquina supervisionado para estimativa de profundidade;
- Avaliar comparativamente as abordagens geométrica e por aprendizado de máquina.

2 MATERIAL E MÉTODOS

2.1 ARQUITETURA GERAL DO SISTEMA

O sistema foi projetado de forma modular, separando claramente os subsistemas de aquisição de dados, controle eletrônico, processamento computacional e visualização. Essa arquitetura facilita a validação individual de cada módulo e permite futuras modificações sem a necessidade de reformulação completa do sistema.

O princípio de funcionamento baseia-se na projeção de um feixe laser sobre a superfície de interesse. A posição aparente desse feixe na imagem capturada pela câmera depende diretamente da profundidade do ponto iluminado e da geometria relativa entre câmera, laser e espelho rotativo.

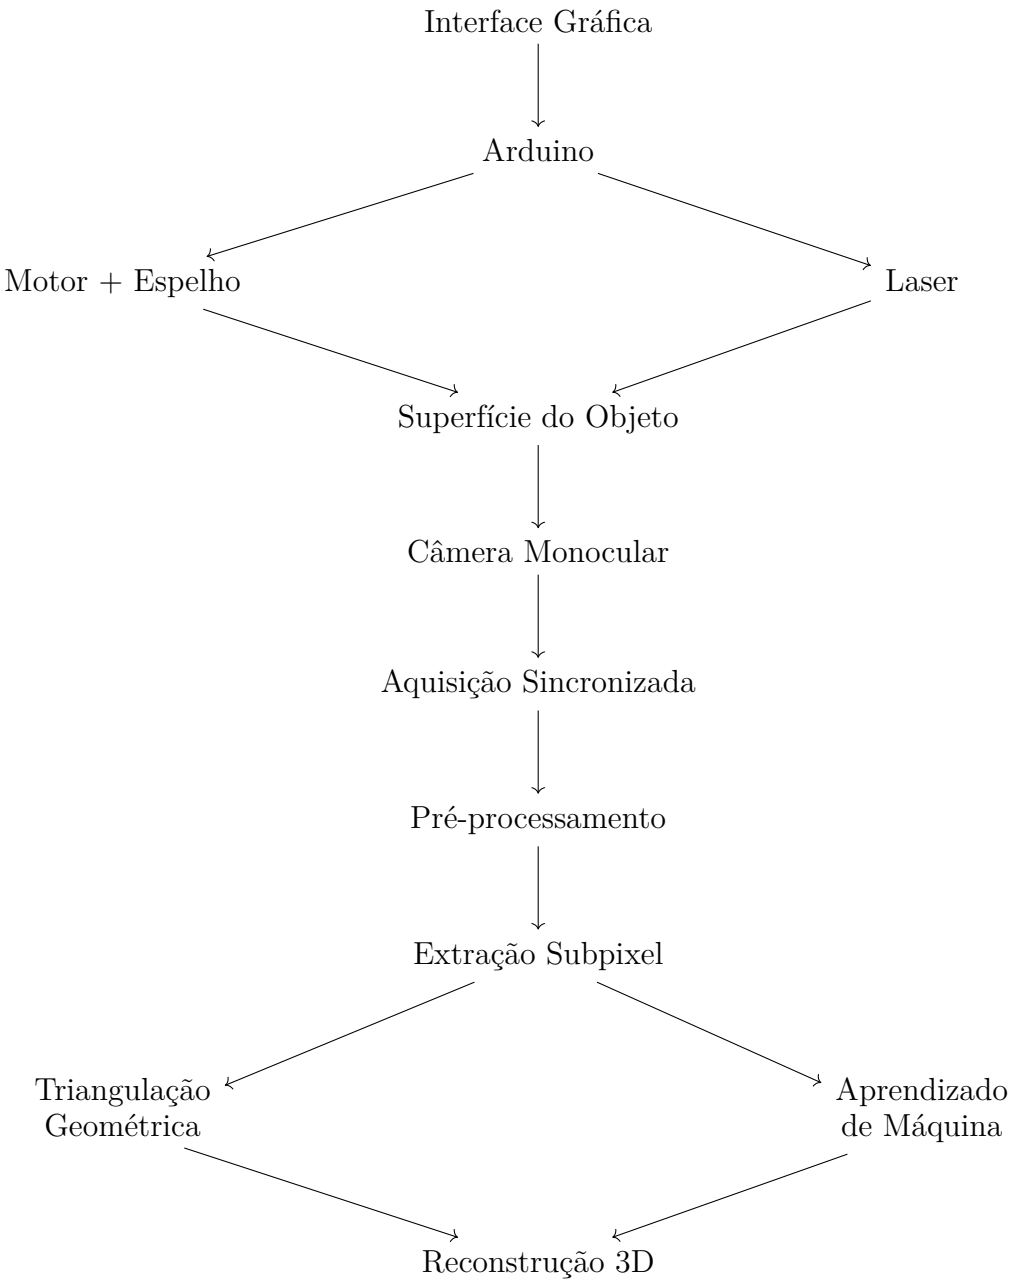


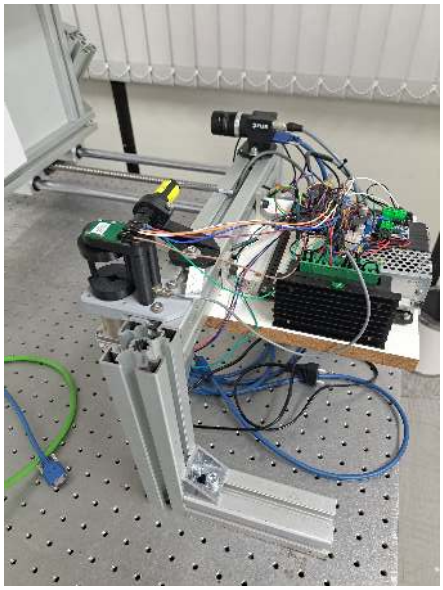
Figura 1 – Fluxo funcional do sistema de triangulação a laser. Fonte: autoria própria.

2.2 DESCRIÇÃO DO HARDWARE

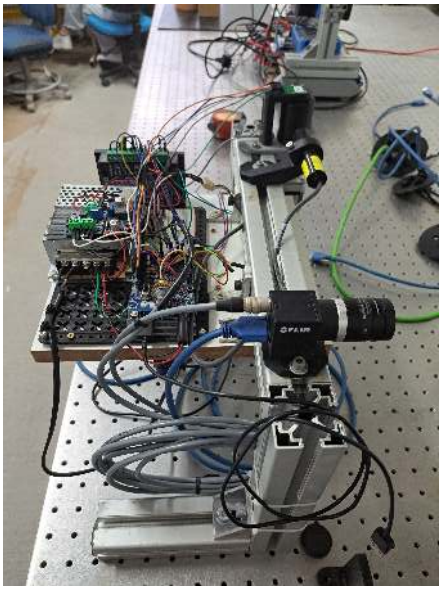
O sistema físico é composto por um microcontrolador Arduino (Arduino Uno R4 Minima) responsável pelo controle do motor de passo, pela ativação do laser e pela sincronização dos eventos de aquisição. O motor de passo aciona um espelho rotativo, permitindo a varredura angular da cena. Um encoder absoluto acoplado ao eixo do espelho fornece a medição precisa do ângulo de varredura a cada instante.

A câmera monocular é rigidamente fixada à estrutura, garantindo a estabilidade dos parâmetros extrínsecos durante os experimentos. A intensidade do laser é controlada por modulação por largura de pulso (PWM), possibilitando ajustes finos conforme as

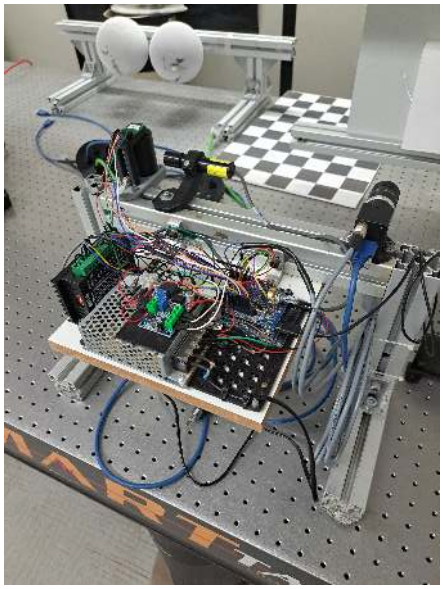
condições de iluminação e refletância da superfície analisada.



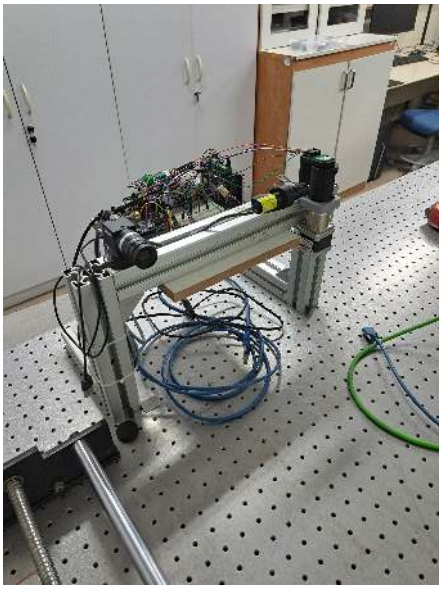
(a) Vista lateral esquerda



(b) Vista lateral direita



(c) Vista frontal



(d) Vista posterior

Figura 2 – Hardware utilizado para a aquisição de imagens e disparo do laser. Fonte: autoria própria

2.3 AQUISIÇÃO E PRÉ-PROCESSAMENTO DAS IMAGENS

As imagens são adquiridas de forma sincronizada com a leitura do encoder, assegurando que cada quadro esteja associado a um ângulo de varredura conhecido. Inicialmente, as imagens são convertidas para um espaço de cor apropriado, priorizando o canal no qual o feixe laser apresenta maior contraste em relação ao fundo, especificamente o canal de valor (V) do espaço de cor HSV.

Em seguida, realiza-se a segmentação da linha do laser por meio de limiarização de intensidade (thresholding) no espaço HSV, isolando os pixels correspondentes ao feixe projetado. Para atenuar ruídos e eliminar artefatos de pequena escala, aplica-se uma filtragem morfológica por abertura, utilizando um elemento estruturante adequado, podendo ser complementada por filtros espaciais para refinamento da máscara binária.

2.4 EXTRAÇÃO SUBPIXEL DA LINHA LASER

A determinação precisa da posição da linha laser é essencial para a qualidade da reconstrução tridimensional, uma vez que erros na localização do feixe propagam-se diretamente para a estimativa das coordenadas espaciais reconstruídas. Para cada coluna da imagem, calcula-se o centroide ponderado dos pixels pertencentes ao laser, permitindo uma estimativa subpixel da posição do feixe. Essa abordagem explora a distribuição contínua de intensidade luminosa registrada pelo sensor e reduz significativamente o erro de quantização associado à resolução discreta da câmera.

O método do centroide ponderado, também conhecido como *intensity-weighted centroid*, é amplamente empregado em sistemas clássicos de triangulação a laser devido à sua simplicidade computacional e boa robustez frente a ruídos moderados. No presente trabalho, essa técnica constitui a base da extração subpixel utilizada no pipeline geométrico tradicional, no qual as posições subpixel da linha laser são posteriormente corrigidas quanto à distorção da lente, suavizadas por splines cúbicas e empregadas diretamente na triangulação analítica.

Além da abordagem geométrica convencional, este trabalho também considera uma estratégia alternativa inspirada em métodos recentes de triangulação a laser livres de equações de deslocamento, nos quais a reconstrução tridimensional é realizada diretamente por modelos de aprendizado de máquina (6). Nesse contexto, a extração subpixel da linha laser não se limita ao centroide ponderado, sendo estendida para incluir múltiplos descritores do perfil de intensidade do feixe, tais como a posição obtida por ajuste Gaussiano e por métodos geométricos alternativos.

Esses descritores subpixel são utilizados como vetores de características de entrada para modelos supervisionados, que aprendem a relação não linear entre a posição da linha laser no sensor, o ângulo de varredura e a profundidade correspondente, eliminando a dependência explícita das equações clássicas de triangulação e reduzindo a sensibilidade a erros nos parâmetros estruturais do sistema. Resultados recentes demonstram que essa abordagem pode reduzir significativamente erros não lineares e aumentar a robustez do sistema frente a desalinhamentos ópticos e incertezas geométricas (6).

Dessa forma, a extração subpixel da linha laser desempenha um papel central em ambas as abordagens investigadas neste trabalho: como etapa fundamental para a triangulação geométrica clássica e como mecanismo de geração de características informativas

para a reconstrução tridimensional baseada em aprendizado de máquina.

2.5 MODELO DE TRIANGULAÇÃO GEOMÉTRICA

Nesta seção é apresentado o modelo analítico de triangulação geométrica adotado como referência para a reconstrução tridimensional dos pontos iluminados pelo feixe laser. O modelo fundamenta-se na geometria projetiva do modelo de câmera pinhole e na interseção entre o raio visual associado a cada pixel detectado e o plano definido pela projeção do feixe laser no espaço.

2.5.1 Normalização das Coordenadas da Imagem

Considerando o modelo de câmera pinhole, as coordenadas do pixel (u, v) detectado na imagem são inicialmente convertidas em coordenadas normalizadas (X_n, Y_n) no plano da imagem, a partir dos parâmetros intrínsecos da câmera. Esse procedimento remove os efeitos da distância focal e do ponto principal, permitindo associar cada pixel a um raio visual no espaço tridimensional.

A normalização é expressa por:

$$X_n = \frac{u - c_x}{f_x}, \qquad Y_n = \frac{v - c_y}{f_y}, \tag{2.1}$$

em que (f_x, f_y) representam as distâncias focais efetivas nos eixos horizontal e vertical, respectivamente, e (c_x, c_y) correspondem às coordenadas do ponto principal da câmera.

2.5.2 Configuração Geométrica do Sistema Câmera–Laser

A reconstrução da profundidade baseia-se no princípio da triangulação geométrica, no qual a posição tridimensional de um ponto iluminado é obtida a partir da interseção entre o raio visual da câmera e o plano de emissão do feixe laser. Considera-se uma configuração em que o laser é projetado com um ângulo θ em relação ao eixo óptico da câmera, sendo esse ângulo controlado por um sistema de varredura acionado por um atuador mecânico e monitorado por um encoder angular.

O principal parâmetro geométrico do sistema é o *baseline* B, definido como a distância entre o centro óptico da câmera e a origem do feixe laser. Além do *baseline*, o modelo considera um deslocamento fixo D, que representa a distância entre o plano de emissão do laser e o centro óptico da câmera ao longo do eixo perpendicular ao plano de varredura. Esse termo é necessário para representar de forma mais fiel a geometria real do sistema experimental.

2.5.3 Correção do Ângulo de Varredura por Reflexão no Espelho

O ângulo θ utilizado no modelo de triangulação não corresponde diretamente ao ângulo mecânico medido pelo encoder. Devido ao fenômeno de reflexão especular no espelho de varredura, uma rotação mecânica θ_m do espelho resulta em uma variação angular do feixe refletido igual ao dobro desse valor.

Assim, o ângulo efetivo de projeção do laser empregado nas equações de triangulação é dado por:

$$\theta = 2\,\theta_m. \tag{2.2}$$

Essa correção é essencial para garantir a consistência geométrica do modelo e está explicitamente incorporada na formulação matemática utilizada na reconstrução tridimensional.

2.5.4 Estimativa da Profundidade por Triangulação

Sob as hipóteses descritas, a profundidade Z do ponto iluminado pode ser estimada a partir da seguinte relação trigonométrica:

$$Z = \frac{B \cdot \sin(\theta) - D \cdot \cos(\theta)}{\cos(\theta) - X_n \cdot \sin(\theta)}. \tag{2.3}$$

Nessa expressão, X_n corresponde à coordenada horizontal normalizada do ponto detectado na imagem, B representa o *baseline* do sistema e D o deslocamento fixo entre o plano do laser e o centro óptico da câmera. A equação decorre diretamente da análise geométrica do triângulo formado pelo eixo óptico da câmera, pelo plano de emissão do laser e pelo raio visual associado ao ponto observado.

Observa-se que a profundidade estimada apresenta forte dependência tanto da posição subpixel do feixe laser na imagem quanto da precisão da medição angular, tornando o modelo sensível a ruídos, desalinhamentos mecânicos e erros de calibração.

2.5.5 Reconstrução das Coordenadas Tridimensionais

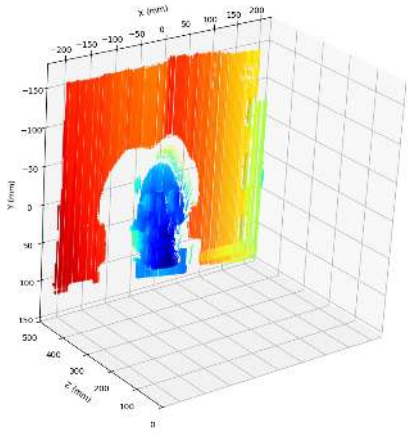
Uma vez determinada a profundidade Z, as coordenadas espaciais completas do ponto no sistema de referência da câmera são obtidas por meio das relações de projeção inversa do modelo pinhole:

$$X = Z \cdot X_n, \qquad Y = Z \cdot Y_n. \tag{2.4}$$

Dessa forma, cada ponto iluminado pelo feixe laser é reconstruído no espaço tridimensional como (X, Y, Z), sendo Z obtido pela triangulação geométrica e (X_n, Y_n) derivados diretamente da posição do feixe laser na imagem.



(a) Caveira analisada

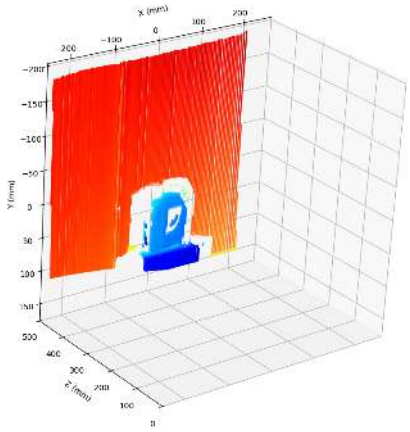


(b) Caveira reconstruída pelo modelo geométrico

Figura 3 – Resultado da reconstrução tridimensional de uma caveira pelo modelo geométrico. Fonte: autoria própria.



(a) Trena em análise



(b) Trena reconstruída pelo modelo geométrico

Figura 4 – Resultado da reconstrução tridimensional de uma trena pelo modelo geométrico. Fonte: autoria própria.

2.6 LIMITAÇÕES DO MODELO GEOMÉTRICO

Embora teoricamente consistente, o modelo geométrico de triangulação apresenta limitações práticas que afetam diretamente a acurácia da reconstrução tridimensional. Em particular, o método é altamente sensível a erros de calibração da câmera, desalinhamentos

mecânicos entre o emissor laser e o sistema óptico, bem como a distorções ópticas residuais que não são completamente compensadas durante o processo de correção de imagem.

Erros nos parâmetros intrínsecos da câmera, como distância focal e posição do ponto principal, propagam-se de forma não linear para a estimativa da profundidade, uma vez que esses parâmetros influenciam diretamente o cálculo das coordenadas normalizadas (X_n, Y_n). Da mesma forma, imprecisões nos parâmetros extrínsecos, como a posição relativa entre a câmera e o plano do laser (baseline B), introduzem erros sistemáticos que tendem a aumentar com a profundidade do ponto reconstruído. Esse comportamento é particularmente crítico em regiões próximas aos limites do campo de visão, onde pequenas variações angulares resultam em grandes variações na coordenada Z.

Além disso, o modelo assume um alinhamento ideal entre o plano do feixe laser e o sistema de referência da câmera, o que raramente é plenamente alcançado em sistemas experimentais. Vibrações mecânicas, folgas no mecanismo de varredura e não linearidades no encoder do espelho contribuem para desvios angulares que não são explicitamente modelados na formulação geométrica. Tais desvios tornam-se ainda mais relevantes em sistemas baseados em reflexão especular, nos quais o ângulo efetivo do feixe laser depende diretamente da precisão da medição angular e da estabilidade do espelho.

Outro fator limitante está relacionado à largura finita do feixe laser e aos efeitos de espalhamento e saturação do sensor, que podem deslocar a posição aparente da linha laser na imagem. Mesmo com técnicas de extração subpixel, como o cálculo do centroide ponderado, esses efeitos introduzem incertezas adicionais que não são capturadas pelo modelo puramente geométrico. Como consequência, erros de quantização, ruído eletrônico e variações de refletância da superfície do objeto contribuem para a degradação da precisão final da reconstrução.

Essas limitações são amplamente reconhecidas na literatura, incluindo a forte dependência da calibração geométrica precisa, a sensibilidade ao ruído óptico e as dificuldades impostas por superfícies com propriedades refletivas complexas (7, 8, 9).

2.7 APRENDIZADO DE MÁQUINA PARA ESTIMATIVA DE PROFUNDIDADE

Com o objetivo de superar as limitações impostas pelo modelo geométrico clássico de triangulação, a estimativa da profundidade foi reformulada como um problema de regressão supervisionada, abordagem amplamente explorada em estudos recentes sobre estimação de profundidade monocular, estereoscópica e baseada em sensores ativos (5).

2.7.1 Parâmetros de Entrada do Modelo

A base de dados utilizada no treinamento foi construída a partir de experimentos controlados, nos quais um plano de referência rígido foi posicionado em diferentes distâncias previamente medidas em relação ao sistema câmera–laser. As aquisições foram realizadas ao longo de uma faixa compreendida entre 400 mm e 600 mm da câmera, abrangendo a região em torno da distância focal do sistema (500 mm), com o objetivo de capturar variações geométricas relevantes no intervalo operacional de interesse. O deslocamento do plano foi realizado de forma incremental, com passos uniformes de 5 mm, garantindo uma amostragem densa e aproximadamente homogênea ao longo do eixo de profundidade.

Para cada posição do plano, foram executadas varreduras sucessivas, e as imagens adquiridas foram previamente corrigidas quanto às distorções ópticas estimadas no processo de calibração da câmera. A linha laser projetada sobre o plano foi então detectada e refinada com precisão subpixel, de modo a reduzir erros de quantização associados à discretização da imagem.

A seleção dos atributos de entrada do modelo não foi realizada de forma arbitrária, mas guiada pelo conhecimento prévio do modelo geométrico clássico de triangulação. Nesse modelo, a profundidade é determinada principalmente pela posição da linha laser na imagem, pela geometria relativa entre câmera e emissor e pelo ângulo de incidência do feixe. Assim, buscou-se preservar, no vetor de características, variáveis diretamente relacionadas a esses parâmetros físicos. Além disso, a inclusão de múltiplas estimativas subpixel da posição do feixe foi inspirada na estratégia adotada por Zhang et al., que demonstram que modelos baseados em aprendizado podem substituir a formulação analítica explícita da triangulação ao explorar diretamente as medições da imagem como entradas do regressor (6).

O vetor de atributos associado a cada amostra é definido como:

$$\mathbf{x} = \begin{bmatrix} x_c & x_g & x_{circ} & y & \sin(\theta) & \cos(\theta) \end{bmatrix}, \tag{2.5}$$

onde:

- x_c corresponde à posição subpixel do feixe laser obtida por centroide ponderado pela intensidade;
- x_g representa a posição estimada por ajuste Gaussiano unidimensional ao perfil de intensidade;
- x_{circ} é uma estimativa alternativa da posição do feixe baseada em ajuste circular;
- y é a coordenada vertical do pixel na imagem;
- θ é o ângulo de varredura do laser, obtido a partir da leitura do encoder e expresso em radianos;

- $\sin(\theta)$ e $\cos(\theta)$ são utilizados para representar a informação angular de forma contínua, evitando descontinuidades associadas à periodicidade angular.

A variável alvo do modelo é a profundidade real do plano no experimento, denotada por z.

2.7.2 Formulação da Função de Profundidade

A estimativa da profundidade é formulada como uma função de regressão não linear multivariada:

$$\hat{z} = f(\mathbf{x}), \tag{2.6}$$

ou, de forma explícita,

$$\hat{z} = f(x_c,\, x_g,\, x_{circ},\, y,\, \sin(\theta),\, \cos(\theta))\,, \tag{2.7}$$

em que $f(\cdot)$ representa uma função desconhecida e altamente não linear, aprendida diretamente a partir dos dados experimentais. Diferentemente do modelo geométrico clássico de triangulação, a função aprendida não impõe relações analíticas explícitas entre os parâmetros físicos do sistema, permitindo capturar, de forma implícita, não linearidades e imperfeições experimentais presentes no processo de aquisição. Entre esses efeitos incluem-se distorções ópticas residuais, desalinhamentos mecânicos sutis, incertezas de calibração e variações na intensidade ou na incidência do feixe laser. Ressalta-se, entretanto, que as imagens utilizadas no treinamento foram previamente corrigidas com base nos parâmetros de distorção estimados durante a calibração da câmera, reduzindo parcialmente tais fontes de erro sistemático.

2.7.3 Modelo de Regressão Utilizado

Para a aproximação da função $f(\cdot)$, foi adotado o algoritmo Light Gradient Boosting Machine (LightGBM), baseado em árvores de decisão impulsionadas por gradiente. Esse método foi escolhido devido à sua elevada capacidade de modelar relações não lineares complexas, robustez a ruído e eficiência computacional em bases de dados de grande porte (10).

O modelo final consiste em um conjunto de árvores de regressão, cuja saída combinada fornece a estimativa de profundidade:

$$\hat{z} = \sum_{k=1}^{K} \alpha_k\, h_k(\mathbf{x}), \tag{2.8}$$

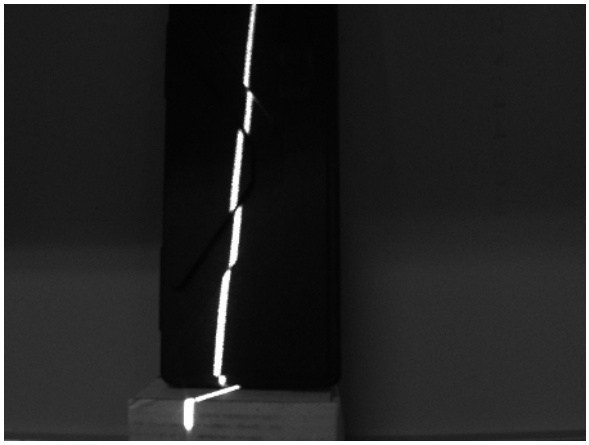
onde $h_k(\mathbf{x})$ representa a k-ésima árvore de decisão treinada, α_k são os pesos aprendidos durante o processo de boosting e K é o número total de estimadores. O

treinamento foi realizado minimizando o erro quadrático médio entre a profundidade estimada $\hat{z}$ e a profundidade real z fornecida pelos experimentos.

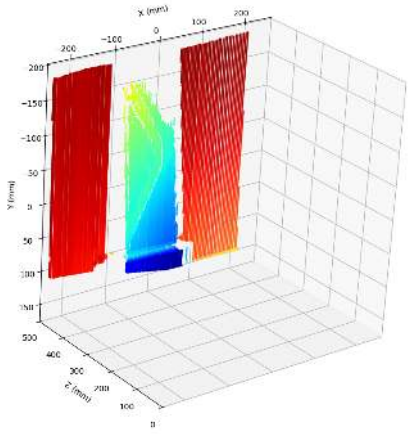
2.7.4 Considerações sobre a Abordagem

Embora a triangulação geométrica tenha sido empregada durante a fase de geração da base de dados para fins de referência e análise comparativa, o modelo de aprendizado de máquina foi treinado de forma independente, sem incorporar explicitamente a equação geométrica no processo de inferência. Dessa forma, a profundidade passa a ser estimada exclusivamente pela função aprendida $f(\cdot)$, caracterizando uma abordagem puramente orientada a dados.

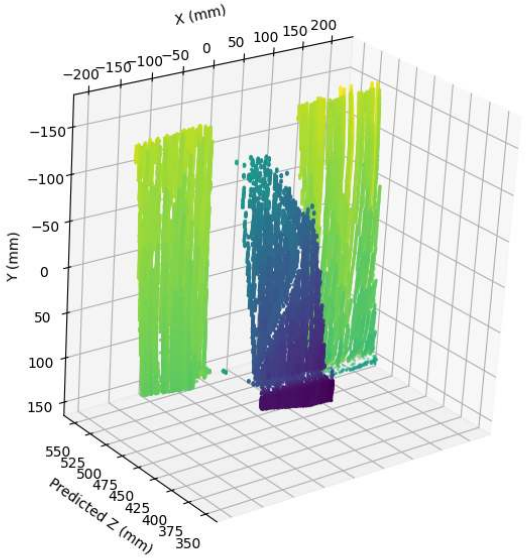
As coordenadas tridimensionais completas são posteriormente obtidas projetando-se os raios normalizados da câmera em função da profundidade estimada, permitindo a reconstrução tridimensional do objeto sem a dependência direta de parâmetros geométricos explícitos. Ressalta-se que, no escopo deste trabalho, as abordagens geométrica e baseada em aprendizado de máquina são tratadas de forma separada, não sendo exploradas arquiteturas híbridas que combinem ambos os métodos.



(a) Caixa em análise

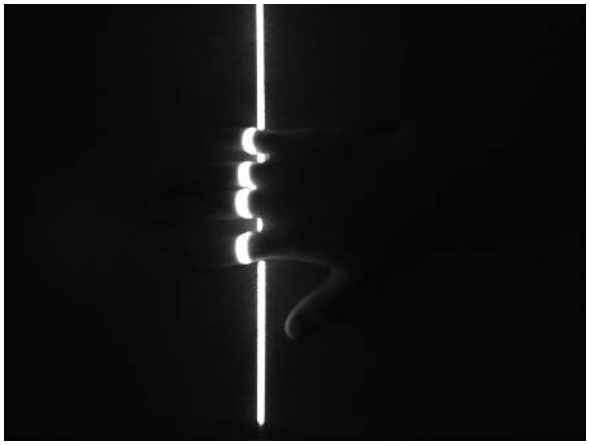


(b) Reconstrução pelo modelo geométrico

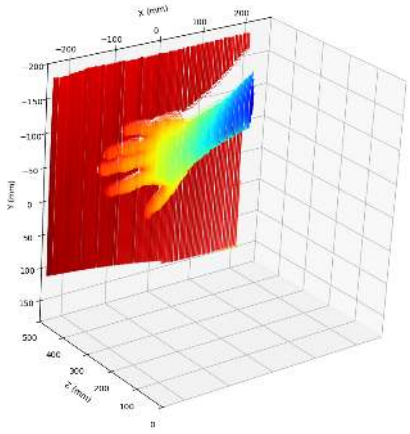


(c) Reconstrução pelo modelo de aprendizado de máquina

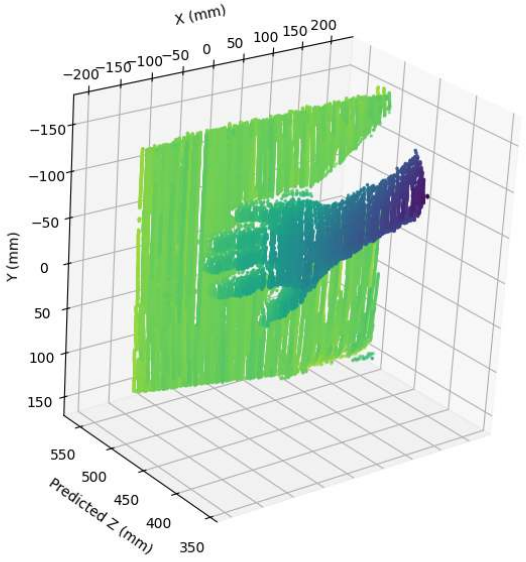
Figura 5 – Análise das diferenças entre os processos com uma caixa. Fonte: Autoria própria.



(a) Mão em análise



(b) Reconstrução pelo modelo geométrico



(c) Reconstrução pelo modelo de aprendizado de máquina

Figura 6 – Análise das diferenças entre os processos com uma mão. Fonte: Autoria própria

2.8 LIMITAÇÕES DA ABORDAGEM BASEADA EM APRENDIZADO DE MÁQUINA

Apesar de sua capacidade de modelar relações complexas e compensar erros sistemáticos do sistema físico, a abordagem baseada em aprendizado de máquina apresenta limitações relevantes que devem ser consideradas. Diferentemente do modelo geométrico,

cuja formulação é fundamentada em princípios físicos bem definidos, o desempenho do modelo de regressão depende fortemente da qualidade e diversidade do conjunto de dados utilizado durante o treinamento.

Uma limitação fundamental está relacionada à dependência do domínio experimental. O modelo é treinado a partir de dados obtidos em condições específicas, como configuração geométrica do sistema, faixa de profundidades, características ópticas da câmera e propriedades de refletância da superfície observada. Alterações nessas condições — por exemplo, mudanças no alinhamento mecânico, na intensidade do laser, no tipo de superfície ou na faixa de distâncias analisada — podem resultar em degradação significativa da acurácia, uma vez que o modelo não possui garantias explícitas de generalização fora do domínio de treinamento.

Além disso, o modelo de aprendizado de máquina não impõe restrições físicas explícitas sobre a solução estimada. Como consequência, podem ocorrer previsões inconsistentes do ponto de vista geométrico, especialmente em regiões onde os dados são escassos ou ruidosos. Embora técnicas de filtragem e suavização possam atenuar esse efeito, não há garantia formal de que as estimativas de profundidade respeitem as relações projetivas do sistema óptico. Dessa forma, superfícies com geometria mais complexa tendem a apresentar maior degradação nos resultados, o que é ilustrado na Figura 7.

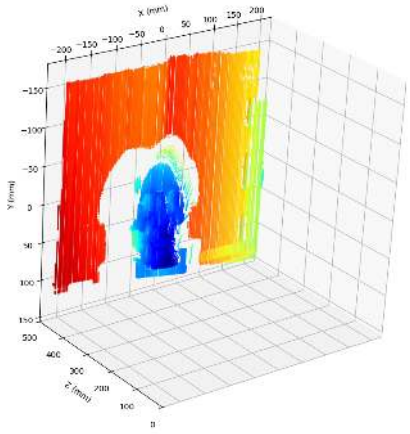
Outro aspecto limitante refere-se à necessidade de um processo de aquisição de dados cuidadoso e potencialmente custoso. A construção do conjunto de treinamento exige múltiplos experimentos controlados, com posicionamento preciso de alvos em distâncias conhecidas e repetibilidade das condições de captura.

Adicionalmente, embora o LightGBM apresente boa interpretabilidade quando comparado a modelos de caixa-preta mais complexos, como redes neurais profundas, a relação entre as variáveis de entrada e a profundidade estimada ainda não é diretamente interpretável em termos físicos. Isso dificulta a análise detalhada da propagação de erros e a identificação de falhas específicas do sistema, especialmente quando comparado ao modelo geométrico clássico.

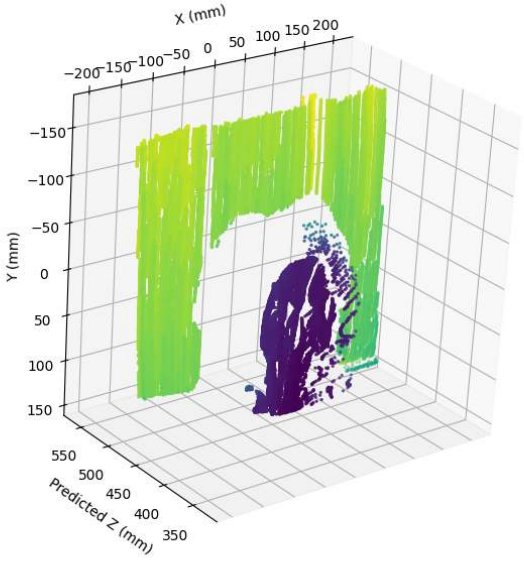
Por fim, a abordagem puramente baseada em aprendizado de máquina não explora, em sua forma atual, o conhecimento prévio disponível sobre a geometria do sistema. A ausência de mecanismos que incorporem explicitamente restrições físicas pode limitar a robustez do método em condições adversas, motivando investigações futuras sobre estratégias híbridas que combinem modelos analíticos e técnicas de aprendizado de máquina.



(a) Caveira analisada



(b) Reconstrução pelo modelo geométrico



(c) Reconstrução pelo modelo de aprendizado de máquina

Figura 7 – Análise das diferenças entre os processos com uma caveira. Fonte: autoria própria

2.9 INTERFACE GRÁFICA

Foi desenvolvida uma interface gráfica para operação do sistema de triangulação a laser, atuando como camada de interação entre o operador e os módulos de hardware e software responsáveis pela aquisição dos dados. A interface foi implementada em Python utilizando a biblioteca *CustomTkinter*, priorizando usabilidade, confiabilidade operacional e reprodutibilidade experimental.

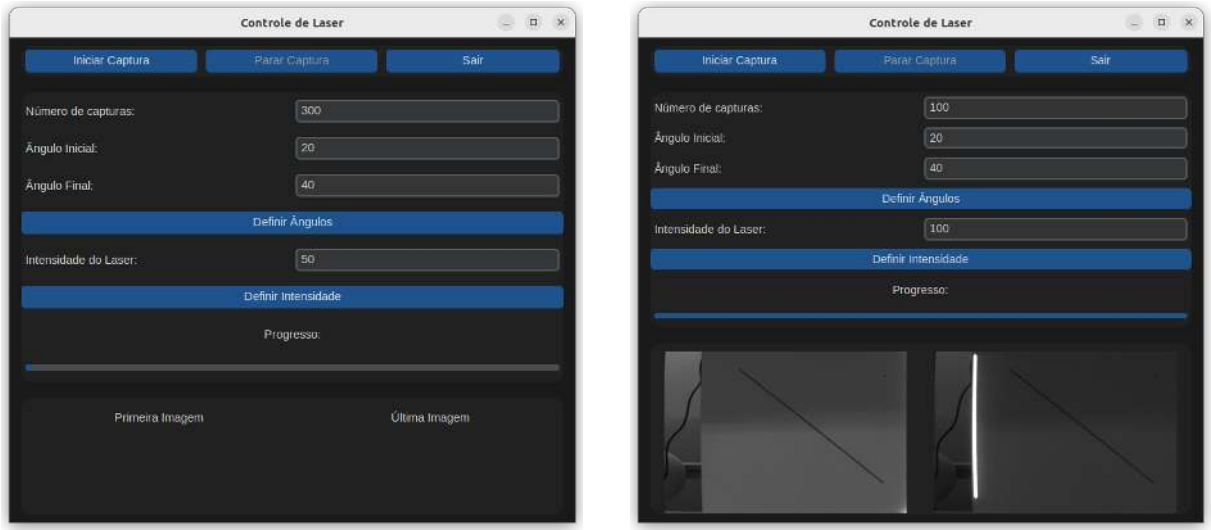
A aplicação segue uma arquitetura modular, na qual a interface gráfica coordena a comunicação entre os módulos de controle da câmera, do microcontrolador e do gerenciamento de dados, mantendo baixo acoplamento entre os componentes do sistema.

Por meio da interface, o operador pode configurar os principais parâmetros da varredura a laser, incluindo o número de imagens a serem adquiridas, os ângulos inicial e final da varredura e a intensidade do laser, controlada por modulação por largura de pulso (PWM). Os valores inseridos são validados em tempo real, reduzindo a probabilidade de erros de configuração.

A aquisição das imagens é realizada de forma assíncrona, utilizando *threads* dedicadas, garantindo que a interface permaneça responsiva durante toda a execução do experimento. Mecanismos de sincronização asseguram a consistência do estado do sistema e a integridade dos dados coletados.

Durante a varredura, a interface fornece feedback visual por meio de uma barra de progresso, permitindo o acompanhamento em tempo real da aquisição. Ao final do processo, a primeira e a última imagens capturadas são exibidas para verificação preliminar da qualidade dos dados.

Os dados experimentais são organizados automaticamente em pastas específicas para cada execução, contendo as imagens adquiridas e seus respectivos metadados, como ângulo de varredura, intensidade do laser e informações temporais. Essa estrutura padronizada facilita a rastreabilidade dos experimentos e o uso posterior dos dados nas etapas de reconstrução tridimensional e treinamento dos modelos de aprendizado de máquina.



(a) Interface gráfica (b) Interface após a captura

Figura 8 – Interface gráfica. Fonte: autoria própria

3 RESULTADOS E DISCUSSÃO

Os resultados obtidos ao longo dos experimentos evidenciam o impacto direto tanto do modelo geométrico de triangulação quanto da abordagem baseada em aprendizado de máquina na qualidade da reconstrução tridimensional. As análises foram conduzidas considerando diferentes configurações de varredura, intensidades do laser e regiões do campo de visão, permitindo uma avaliação abrangente do comportamento do sistema.

3.1 AVALIAÇÃO DO MODELO GEOMÉTRICO

A aplicação direta do modelo geométrico de triangulação mostrou-se eficaz na reconstrução da geometria global dos objetos analisados, especialmente em regiões próximas ao centro do campo de visão, onde os efeitos de distorção óptica e desalinhamento mecânico são menos pronunciados. Nesses casos, observou-se uma boa correspondência entre a profundidade estimada e as dimensões físicas esperadas, indicando que o modelo é conceitualmente consistente e adequado como primeira aproximação do problema.

Entretanto, à medida que os pontos reconstruídos se afastam do eixo óptico da câmera, tornam-se evidentes erros sistemáticos na estimativa da profundidade. Esses desvios manifestam-se principalmente como deformações progressivas na geometria reconstruída, podendo ser atribuídos a incertezas nos parâmetros de calibração, à não idealidade do modelo pinhole e a pequenos erros no ângulo do laser fornecido pelo encoder. A amplificação desses erros em regiões extremas do campo de visão reforça as limitações intrínsecas do modelo puramente geométrico, conforme discutido anteriormente.

3.2 INFLUÊNCIA DA QUALIDADE DA EXTRAÇÃO DA LINHA LASER

A precisão da reconstrução mostrou-se fortemente dependente da qualidade da extração da linha laser nas imagens. A utilização de métodos de extração subpixel, baseados no cálculo do centroide ponderado da intensidade, resultou em uma redução significativa do ruído na nuvem de pontos final, quando comparada a abordagens baseadas apenas em limiarização binária.

Ainda assim, variações na refletância superficial dos objetos e na intensidade efetiva do laser introduziram flutuações locais na posição estimada da linha. Esses efeitos foram particularmente perceptíveis em superfícies com acabamento especular ou com forte variação de textura, indicando que a etapa de pré-processamento da imagem permanece como uma fonte relevante de incerteza no sistema.

3.3 RESULTADOS DA ABORDAGEM POR APRENDIZADO DE MÁQUINA

A abordagem baseada em aprendizado de máquina demonstrou maior robustez frente a imperfeições do sistema físico, especialmente em cenários onde o modelo geométrico apresentou desempenho limitado. Ao aprender diretamente a relação entre as observações no plano da imagem e a profundidade correspondente, o modelo foi capaz de compensar, ao menos parcialmente, erros sistemáticos decorrentes de desalinhamentos, distorções ópticas residuais e não linearidades do sistema.

Os resultados indicam uma melhora consistente na regularidade da superfície reconstruída e uma redução visível de artefatos geométricos, sobretudo nas regiões periféricas do campo de visão. No entanto, o desempenho do modelo mostrou-se fortemente dependente da qualidade e diversidade do conjunto de dados de treinamento, tornando-o sensível a cenários que diferem significativamente das condições experimentais observadas durante a aquisição dos dados.

3.4 COMPARAÇÃO ENTRE AS ABORDAGENS

A comparação direta entre o modelo geométrico e a abordagem por aprendizado de máquina evidencia um compromisso clássico entre interpretabilidade e capacidade de generalização. Enquanto o modelo geométrico oferece uma relação física explícita entre os parâmetros do sistema e a profundidade estimada, sua precisão é limitada pela fidelidade do modelo e pela qualidade da calibração. Por outro lado, os modelos baseados em aprendizado de máquina apresentam maior flexibilidade e capacidade de adaptação, ao custo de uma menor interpretabilidade e de uma maior dependência dos dados experimentais.

Nesse contexto, os resultados sugerem que uma abordagem híbrida, na qual o modelo geométrico seja utilizado como base ou como fonte de regularização para o aprendizado de máquina, pode representar um caminho promissor para futuras investigações.

3.5 DISCUSSÃO GERAL

De forma geral, os resultados obtidos confirmam que sistemas de triangulação a laser de baixo custo podem alcançar níveis satisfatórios de precisão, desde que acompanhados por um cuidadoso processo de calibração, extração de características e controle experimental. As limitações observadas não invalidam o uso do modelo geométrico, mas destacam a necessidade de estratégias complementares para lidar com as inevitáveis imperfeições do sistema físico real.

Além disso, a análise comparativa reforça o papel do aprendizado de máquina como uma ferramenta poderosa para a compensação de erros sistemáticos, desde que utilizada

de maneira criteriosa e com adequada validação. Esses resultados fornecem uma base sólida para o desenvolvimento de sistemas de reconstrução tridimensional mais robustos, combinando modelos físicos e métodos orientados por dados. (5, 7)

4 CONCLUSÃO

Este trabalho apresentou o desenvolvimento completo de um sistema de triangulação a laser para reconstrução tridimensional, contemplando desde a concepção e integração do hardware experimental até a implementação de algoritmos de processamento de imagens e reconstrução 3D. O sistema desenvolvido mostrou-se funcional e adequado para a aquisição controlada de dados, permitindo a avaliação sistemática de diferentes estratégias de estimativa de profundidade.

Nesse contexto, a investigação de técnicas de aprendizado de máquina supervisionado mostrou-se uma alternativa viável e complementar ao modelo geométrico. A abordagem orientada por dados foi capaz de capturar relações não lineares presentes no sistema físico real, apresentando maior robustez frente a incertezas estruturais e irregularidades experimentais. Embora, nas condições analisadas, o modelo geométrico tenha apresentado maior precisão absoluta, os resultados obtidos com aprendizado de máquina indicam um potencial significativo de melhoria à medida que conjuntos de dados mais amplos e diversificados sejam incorporados ao treinamento.

De forma geral, os resultados indicam que a integração entre modelos físicos e técnicas de aprendizado de máquina constitui uma estratégia promissora para sistemas de reconstrução tridimensional, particularmente em aplicações de inspeção subaquática, onde condições ambientais adversas dificultam a modelagem analítica precisa. O sistema desenvolvido contribui diretamente para os objetivos do Projeto VORIS, fornecendo uma plataforma experimental robusta para validação de técnicas ópticas e para a geração de bases de dados destinadas a estudos futuros.

Como trabalhos futuros, destacam-se a exploração de abordagens híbridas que combinem explicitamente restrições geométricas com modelos de aprendizado de máquina, a ampliação da base de dados experimental para diferentes tipos de superfícies e condições de iluminação, bem como a adaptação e validação do sistema em ambientes subaquáticos reais. Essas extensões têm o potencial de elevar significativamente a robustez e a aplicabilidade do sistema proposto em cenários industriais reais.

Por fim, no que se refere à experiência de Iniciação Científica, o desenvolvimento deste trabalho proporcionou um aprofundamento substancial na formação acadêmica e científica do aluno. A participação em todas as etapas do projeto contribuiu para o desenvolvimento de competências técnicas em instrumentação, visão computacional e modelagem matemática, bem como para o aprimoramento do raciocínio científico e da capacidade de resolução de problemas complexos. Além disso, a vivência no ambiente de pesquisa favoreceu o amadurecimento acadêmico, a autonomia intelectual e a compreensão do método científico como processo iterativo de formulação, validação e refinamento

de hipóteses, consolidando bases sólidas para futuras atividades de pesquisa e atuação profissional.

REFERÊNCIAS

1 YANG, Y. et al. Underwater target 3D reconstruction via integrated laser triangulation and multispectral photometric stereo. *Journal of Marine Science and Engineering*, v. 13, n. 2, 2025.

2 LABMETRO – LABORATÓRIO DE METROLOGIA E AUTOMAÇÃO. *Veículo Operado Remotamente para Inspeção Submarina – VORIS*. 2024. Disponível em: <https://www.portalabpg.org.br/12pdpetro/sistema_da_abpg/repositorio/trabalho/59240705082024200.pdf>. Projeto financiado pela FINEP. Trabalho apresentado no 12º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás. Acesso em: 10 jan. 2026.

3 ALIZZIO, D.; BONFANTI, M.; GAROZZO, G. Comparison between 3D reconstruction optical methods applied to bulge-tests through a feed-forward neural network. *Acta IMEKO*, v. 10, n. 4, p. 1–10, 2021. Disponível em: <https://acta.imeko.org/index.php/acta-imeko/article/view/IMEKO-ACTA-10%20%282021%29-04-30>. Acesso em: 10 jan. 2026.

4 ÁLVAREZ, H. Multi camera and multi laser calibration method for 3D reconstruction of revolution parts. *Sensors*, v. 21, n. 7, 2021.

5 LAHIRI, S.; REN, J.; LIN, X. Deep learning-based stereopsis and monocular depth estimation techniques: a review. *Vehicles*, v. 6, n. 1, p. 305–351, 2024.

6 ZHANG, Y. et al. Displacement equation-free laser triangulation ranging with deep learning. *Optics Express*, v. 33, n. 3, p. 4215–4231, 2025.

7 SALVI, J. et al. State of the art in structured light patterns for surface profilometry. *Pattern Recognition*, v. 43, n. 8, p. 2666–2680, 2010.

8 BESL, P. J. Active, optical range imaging sensors. *Machine Vision and Applications*, v. 1, n. 2, p. 127–152, 1988.

9 CUI, B.; TAO, W.; ZHAO, H. High-precision 3D reconstruction for small-to-medium-sized objects utilizing line-structured light scanning: a review. *Remote Sensing*, v. 13, n. 18, 2021.

10 KE, G.; MENG, Q.; FINLEY, T. LightGBM: a highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, v. 30, 2017. Disponível em: <https://proceedings.neurips.cc/paper/2017/file/6449f44a102fde848669bdd9eb6b76fa-Paper.pdf>. Acesso em: 10 jan. 2026.