



Projeto Brasil 6G Fase III

Atividade 3.2 - Aplicações de Posicionamento e Mapeamento com LiDAR - Parte 2



Histórico de Atualizações:

Versão	Data	Autor(es)	Notas
1	15/07/2026	Ana Luísa Lyra Pavanelli - Inatel Felipe A. P. de Figueiredo - Inatel Letícia Carneiro de Souza - Inatel Lucas Silva Souza - Inatel Mayara de Oliveira Paula - Inatel Matheus Ferreira Silva - Inatel Samuel B. Mafra - Inatel	Elaboração de conteúdo
2	31/07/2026	Francisco M. Portelinha Júnior - Inatel Luciano Leonel Mendes - Inatel Vanessa Mendes Rennó - Inatel	Revisão de texto

Lista de Figuras

1	Visão geral da metodologia utilizada	5
2	Local de captura: Quadra (<i>Gym</i>)	7
3	Local de captura: Laboratório (<i>Office</i>)	7
4	Etapas de processamento	8
5	Nuvem de pontos gerada sem movimento na resolução 1024x20	9
6	Nuvem de pontos gerada em movimento na resolução 1024x20	10
7	Arquitetura funcional proposta para a plataforma integrada de sensoriamento LiDAR, processamento embarcado e comunicação via TV White Space aplicada à agricultura inteligente no contexto do Brasil 6G.	16
8	Diagrama em blocos da plataforma UAV-LiDAR desenvolvida.	17
9	Plataforma UAV-LiDAR desenvolvida para aquisição de dados LiDAR utilizando arquitetura embarcada baseada em Raspberry Pi.	18
10	Geração dos modelos DTM, DSM e CHM a partir da nuvem de pontos LiDAR processada.	20
11	Fluxograma do <i>pipeline</i> de processamento das nuvens de pontos LiDAR.	20
12	Área experimental utilizada nas campanhas de aquisição de dados LiDAR em Santa Rita do Sapucaí, Minas Gerais, Brasil. Fonte da imagem de satélite: Google Earth.	20
13	Distribuição espacial simulada da nuvem de pontos LiDAR considerando um ângulo de inclinação (<i>pitch</i>) de 15°, utilizado durante as campanhas experimentais.	21
14	Visualização da nuvem de pontos obtida diretamente a partir dos dados LiDAR armazenados no arquivo <i>.pcap</i> durante a campanha experimental.	22
15	Modelos derivados gerados a partir do processamento das nuvens de pontos LiDAR da área experimental: (a) DTM, (b) DSM e (c) CHM.	23
16	Mapa de calor representando a altura estimada da vegetação do cafezal, em metros, obtida a partir do CHM derivado dos dados LiDAR.	24
17	Comparação entre as alturas da vegetação medidas em campo e as estimativas obtidas a partir do CHM gerado com dados LiDAR.	24
18	Comparação entre os mapas de calor gerados: (a) resultado obtido antes das otimizações computacionais; (b) resultado obtido após a implementação do <i>pipeline</i> acelerado com CUDA®.	28
19	Comparação entre as configurações de aquisição LiDAR utilizando janelas angulares horizontais (<i>azimuth window</i>) de: (a) 360°; (b) 120°.	29
20	Imagens aéreas dos cenários: (a) ambiente urbano nas dependências do Inatel; (b) ambiente rural em lavoura de café. As linhas indicam o percurso utilizado para avaliação da taxa de transmissão em função da distância. Fonte da imagem de satélite: Google Maps.	30
21	Fluxograma do processamento dos dados, desde a aquisição das nuvens de pontos LiDAR até a obtenção de indicadores agronômicos e ambientais.	33
22	Área experimental utilizada nas campanhas de aquisição de dados LiDAR em Santa Rita do Sapucaí, Minas Gerais, Brasil. Fonte da imagem de satélite: Google Earth.	34
23	Plataforma UAV-LiDAR desenvolvida para aquisição de dados LiDAR utilizando arquitetura embarcada baseada na NVIDIA® Jetson Orin™ NX.	34

24	Mapa de calor representando a altura estimada da vegetação do cafezal, em metros, obtida a partir do CHM derivado dos dados LiDAR.	35
25	Seleção da ROI e subsequente segmentação individual dos cafeeiros utilizando o algoritmo <i>Watershed</i> controlado por marcadores.	36
26	Validação estatística das estimativas de altura obtidas por meio do sistema UAV-LiDAR.	37
27	Perfil agrônômico obtido para a região de interesse (ROI), contendo os parâmetros estruturais estimados a partir dos dados LiDAR.	38

Lista de Tabelas

1	Resultados de armazenamento e compressão dos dados LiDAR.	8
2	Eficiência de representação das nuvens de pontos.	9
3	Resultados da aquisição LiDAR e geração da nuvem de pontos.	11
4	Média do tempo gasto para o processo por cenário.	11
5	Métricas de desempenho para a conversão de arquivos <i>pcap-to-las</i> nas plataformas PC e Jetson.	26
6	Métricas de desempenho para o processamento do CHM nas plataformas PC e Jetson.	26
7	Comparação do tempo de processamento do <i>pipeline</i> embarcado antes e após a aceleração por GPU utilizando CUDA [®]	27
8	Taxa de transmissão Wi-Fi em função da distância para diferentes adaptadores e ambientes de teste.	31
9	Resumo quantitativo do conjunto de dados LiDAR sintético.	40
10	Distribuição de classes no conjunto de dados LiDAR sintético.	41
11	Custo computacional inicial para $B = 2$ e $N = 1024$ pontos por amostra.	42
12	Expressões empíricas para estimativa da memória de treinamento em GiB.	43
13	Número de configurações utilizadas no ajuste e erro residual das expressões empíricas de memória.	43

Acrônimos

6G Sexta Geração de Rede Móvel Celular

AGB *Above-Ground Biomass*

BCE *Binary Cross-Entropy*

CHM *Canopy Height Model*

CPU *Central Processing Unit*

DGCNN *Dynamic Graph Convolutional Neural Network*

DSM *Digital Surface Model*

DTM *Digital Terrain Model*

GPU *Graphics Processing Unit*

IA *Inteligência Artificial*

IAF *Índice de Área Foliar*

ICP *Iterative Closest Point*

IMU *Inertial Measurement Unit*

IPCC *Intergovernmental Panel on Climate Change*

KISS *Keep it Small and Simple*

LiDAR *Light Detection and Ranging*

MAE *Mean Absolute Error*

NIRS *Near-Infrared Spectroscopy*

PDAL *Point Data Abstraction Library*

R² *Coefficient of Determination*

RGB *Red, Green, Blue*

RMSE *Root Mean Square Error*

ROI *Region of Interest*

SDK *Software Development Kit*

SLAM *Simultaneous Localization and Mapping*

SMRF *Simple Morphological Filter*

ToF *Time-of-Flight*

TVWS *TV White Space*

UAV *Unmanned Aerial Vehicle*

Sumário

1	Introdução	1
2	Análise da Qualidade de Captura de Nuvens de Pontos e Comparação de Desempenho do Algoritmo de Compressão LASZip em Diferentes Ambientes	3
2.1	Contextualização	3
2.2	Trabalhos Relacionados	3
2.3	Metodologia	5
2.3.1	Sensor LiDAR Ouster OS1-128	6
2.3.2	Definição de Ambiente	6
2.3.3	Configuração do Sensor	6
2.3.4	Aquisição de Dados	6
2.3.5	Processamento	6
2.3.6	Análise e Comparação	8
2.3.7	Tempo de Processamento e Volume dos Arquivos	10
2.3.8	Influência do Ambiente	11
2.4	Direções Futuras	12
3	Integração de Sistemas UAV-LiDAR e Conectividade TV White Space para Agricultura de Precisão	13
3.1	Contextualização	13
3.2	Estado da Arte	14
3.3	Arquitetura do Sistema Proposto	15
3.4	Desenvolvimento do Sistema UAV-LiDAR	17
3.4.1	Implementação Inicial Baseada em Raspberry Pi	18
3.4.1.1	Metodologia de Aquisição e Processamento de Dados	18
3.4.1.2	Validação Experimental em Lavoura de Café	20
3.4.2	Evolução da Arquitetura Computacional do Sistema	25
3.4.2.1	Comparação entre Plataformas de Processamento	25
3.4.2.2	Implementação do Processamento Embarcado na NVIDIA® Jetson Orin™ NX	27
3.4.3	Avaliação Preliminar da Comunicação Wi-Fi	29
3.5	Avaliação de Ferramentas Complementares para Análise de Dados LiDAR	31
3.5.1	Metodologia de Aquisição e Processamento de Dados	32
3.5.2	Validação Experimental em Lavoura de Café	34
3.6	Direções Futuras	39
4	Criação de um Conjunto de Dados LiDAR Sintético com BlenSor	40
4.1	Contextualização e Descrição Quantitativa do Conjunto de Dados	40
4.2	Desenvolvimento Atual	41
4.3	Estudo Detalhado de Memória e Custo Computacional	42
4.4	Próximas Atividades	44
5	Conclusões	46

1 Introdução

O sensoriamento remoto baseado em tecnologia *Light Detection and Ranging* (LiDAR) tem se consolidado como uma importante ferramenta para aquisição de informações tridimensionais do ambiente com elevada precisão e resolução espacial. Por meio da emissão de pulsos laser e da medição do tempo de retorno dos sinais refletidos pelos objetos, sensores LiDAR são capazes de gerar nuvens de pontos detalhadas que representam a geometria de terrenos, estruturas e elementos da vegetação. Essas características tornam a tecnologia particularmente atrativa para aplicações que demandam modelagem tridimensional, posicionamento, mapeamento e extração de informações estruturais do ambiente. Entretanto, o potencial dessa tecnologia depende não apenas da qualidade dos dados adquiridos, mas também da capacidade de armazená-los, processá-los, transmiti-los e utilizá-los de forma eficiente. O elevado volume de informações gerado pelos sensores LiDAR, aliado à crescente demanda por aplicações inteligentes em áreas como agricultura, telecomunicações, robótica e monitoramento ambiental, impõe desafios significativos relacionados ao desenvolvimento de arquiteturas capazes de integrar sensoriamento, computação em borda e conectividade de alta capacidade.

Nesse contexto, a Atividade 3.2 da Fase III do Projeto Brasil 6G investiga o emprego da tecnologia LiDAR como elemento habilitador de aplicações avançadas suportadas pelas futuras redes Sexta Geração de Rede Móvel Celular (6G). As pesquisas desenvolvidas abrangem diferentes etapas do ciclo de utilização dos dados LiDAR, desde a aquisição e o processamento das nuvens de pontos até sua transmissão, análise e aplicação em sistemas inteligentes. Dessa forma, este relatório reúne os principais avanços obtidos nessas frentes de pesquisa, evidenciando soluções voltadas ao uso eficiente de dados tridimensionais em cenários de posicionamento, mapeamento e monitoramento inteligente.

Inicialmente, o Capítulo 2 apresenta uma avaliação experimental utilizando um sensor LiDAR Ouster OS1-128 com o objetivo de analisar a influência dos parâmetros de aquisição na qualidade das nuvens de pontos geradas. Para isso, foram realizados experimentos em diferentes ambientes internos e externos, considerando múltiplas configurações de resolução horizontal, frequência de varredura e modos de operação estático e em movimento. Após a aquisição, os dados foram submetidos a um *pipeline* de processamento envolvendo a reconstrução das nuvens de pontos, a conversão dos formatos de armazenamento e a compressão dos dados. Os resultados obtidos permitem analisar o impacto dessas configurações na densidade das nuvens de pontos, no volume de dados gerado, no tempo de processamento e na qualidade da reconstrução tridimensional, além de avaliar a eficiência do processo de compressão em cenários com diferentes características geométricas e níveis de complexidade. Essas análises fornecem subsídios para a definição de configurações mais adequadas para aplicações de mapeamento móvel, aquisição tridimensional e armazenamento eficiente de nuvens de pontos.

O Capítulo 3 aborda sua aplicação em uma arquitetura integrada para monitoramento agrícola baseada em sistemas *Unmanned Aerial Vehicle* (UAV)-LiDAR. A solução proposta combina sensoriamento remoto, computação em borda e conectividade sem fio, integrando um sensor LiDAR embarcado em um UAV, processamento local baseado na plataforma NVIDIA® Jetson Orin™ NX e mecanismos de comunicação utilizando Wi-Fi e *TV White Space* (TVWS). Essa arquitetura possibilita a aquisição, o processamento e a transmissão de dados tridimensionais da vegetação, viabilizando a extração de informações agronômicas relevantes para o acompanhamento das culturas. Além da descrição da plataforma desenvolvida, são apresentados resultados experimentais envolvendo a caracterização de lavouras de café, incluindo a geração de modelos tridimensionais e mapas de altura, a validação de estimativas agronômicas

derivadas dos dados LiDAR e a avaliação de diferentes ferramentas e metodologias para análise e visualização de nuvens de pontos.

Complementando essas frentes experimentais, o Capítulo 4 apresenta o desenvolvimento de um conjunto de dados sintéticos LiDAR utilizando o simulador BlenSor. Essa iniciativa busca suprir a necessidade de bases de dados anotadas para o treinamento e a avaliação de modelos de aprendizado profundo aplicados à percepção tridimensional. Para isso, são geradas cenas sintéticas contendo pessoas e animais, acompanhadas de anotações espaciais que permitem estruturar tarefas de classificação multirrótulo em nível de cena e de classificação em nível de objeto. O capítulo também descreve as etapas de normalização, reamostragem e aumento geométrica das nuvens de pontos, bem como um estudo detalhado do custo computacional e do consumo de memória durante o treinamento em *Graphics Processing Unit* (GPU). Dessa forma, o conjunto sintético complementa as demais frentes do relatório ao fornecer uma base controlada e reproduzível para o desenvolvimento e a validação de métodos de percepção tridimensional voltados a aplicações inteligentes em redes 6G.

Por fim, o Capítulo 5 reúne as principais conclusões do relatório, sintetizando os resultados alcançados em cada frente de pesquisa, as contribuições técnicas obtidas no âmbito da Atividade 3.2 do Projeto Brasil 6G e as perspectivas para a continuidade dos trabalhos.

2 Análise da Qualidade de Captura de Nuvens de Pontos e Comparação de Desempenho do Algoritmo de Compressão LASZip em Diferentes Ambientes

Este capítulo apresenta a metodologia adotada para a realização de um estudo comparativo sobre as etapas de aquisição, conversão e compressão de dados LiDAR, desenvolvido no contexto do Projeto Brasil 6G. O objetivo é avaliar a influência dos parâmetros de captura e das características do ambiente na qualidade das nuvens de pontos geradas, bem como analisar o desempenho das etapas de processamento e armazenamento dos dados. Para isso, são descritos os critérios de definição dos cenários experimentais, as configurações de aquisição utilizadas e o *pipeline* empregado desde a captura dos dados até a geração dos arquivos comprimidos. Por fim, é apresentada a utilização do algoritmo LASZip para compressão das nuvens de pontos, permitindo avaliar sua eficiência na redução do volume de armazenamento sem comprometer a representação dos dados.

2.1 Contextualização

Os sensores LiDAR vêm sendo amplamente utilizados em aplicações de mapeamento tridimensional, robótica móvel, veículos autônomos e monitoramento ambiental devido à sua capacidade de gerar representações espaciais precisas do ambiente. Entretanto, a qualidade das nuvens de pontos produzidas depende diretamente dos parâmetros de operação do sensor e das características do ambiente de aquisição. Configurações distintas de resolução horizontal e frequência de varredura influenciam a densidade de pontos, o volume de dados gerado e o nível de detalhamento da cena reconstruída. Além disso, fatores como o movimento do sensor e a complexidade geométrica do ambiente podem afetar significativamente a qualidade dos resultados obtidos. Diante desse cenário, torna-se necessário avaliar experimentalmente o impacto dessas variáveis para identificar configurações adequadas para aplicações de mapeamento tridimensional e sistemas móveis de aquisição de dados.

2.2 Trabalhos Relacionados

Esta seção apresenta os principais trabalhos encontrados na literatura relacionados a sistemas LiDAR, aquisição e processamento de nuvens de pontos, características dos sensores e sua influência na qualidade dos dados gerados. Além disso, são discutidos os desafios associados à utilização de sensores LiDAR em diferentes ambientes e aplicações, destacando aspectos relevantes para a avaliação experimental realizada neste trabalho.

Baseados no princípio *Time-of-Flight* (ToF), os sensores LiDAR realizam medições de distância por meio da emissão de pulsos laser e da medição do tempo de retorno dos sinais refletidos pelos objetos da cena. Essa abordagem permite a reconstrução precisa de ambientes tridimensionais, mesmo sob condições de iluminação adversas. Nos últimos anos, a evolução dos sensores de alta resolução, como os modelos da família Ouster OS1, possibilitou a geração de nuvens de pontos cada vez mais densas e detalhadas, ampliando as aplicações dessa tecnologia em tarefas de percepção, localização, navegação e reconstrução espacial [1, 2, 3].

O conteúdo deste capítulo foi desenvolvido pelos pesquisadores *Lucas Silva Souza* e *Samuel Baraldi Mafrá*.

Além da aquisição geométrica, avanços recentes têm explorado a integração entre dados LiDAR e técnicas de Inteligência Artificial (IA) para a interpretação automática do ambiente. O *framework* TexLiDAR utiliza representações panorâmicas obtidas por sensores LiDAR, combinando imagens de distância, refletividade e intensidade com modelos multimodais para realizar a detecção de objetos e a descrição semântica de cenas em um contexto de 360° [1]. Esses avanços evidenciam o potencial dos sensores LiDAR modernos não apenas para a reconstrução geométrica, mas também para a compreensão semântica do ambiente.

Embora a evolução tecnológica tenha ampliado significativamente as aplicações dos sensores LiDAR, sua utilização em tarefas de mapeamento e reconstrução tridimensional depende da precisão geométrica e da confiabilidade das medições realizadas. Por esse motivo, diversos trabalhos têm conduzido avaliações experimentais para validar o desempenho de sensores comerciais em diferentes cenários de operação. Entre esses estudos, Males *et al.* demonstraram que o sensor Ouster OS1-32 apresenta desvios da ordem de milímetros em ambientes internos quando comparado a um laser *scanner* terrestre de referência, evidenciando sua capacidade de produzir reconstruções tridimensionais com elevada fidelidade geométrica [4].

As características do sensor exercem influência direta sobre a qualidade e o volume dos dados gerados. Fatores como o número de canais, a resolução horizontal, a frequência de varredura, o alcance máximo e a arquitetura de escaneamento influenciam diretamente a densidade da nuvem de pontos e o nível de detalhamento da representação tridimensional. Em geral, sensores com maior número de canais produzem nuvens de pontos mais densas, permitindo a identificação de estruturas mais complexas. Entretanto, esse ganho vem acompanhado por um aumento no volume de dados gerado e, conseqüentemente, dos requisitos computacionais para armazenamento e processamento [5].

A arquitetura de varredura também representa um fator importante na qualidade dos dados adquiridos. Sensores LiDAR rotativos oferecem cobertura completa de 360° e produzem padrões de varredura estruturados, enquanto sensores *solid-state* ou do tipo *dome* apresentam padrões de escaneamento não repetitivos e campos de visão mais limitados. Estudos comparativos demonstram que essas diferenças influenciam a consistência espacial, a densidade da cobertura e a resolução temporal dos dados adquiridos, tornando necessária a seleção da arquitetura de sensoriamento mais adequada para cada aplicação [6].

Outro fator fundamental está relacionado ao ambiente onde a aquisição é realizada. Em ambientes internos, a presença de paredes, móveis e estruturas geométricas bem definidas favorece reconstruções com elevada precisão, embora superfícies reflexivas e regiões com poucos elementos possam representar desafios para os algoritmos de mapeamento e localização [4]. Em contrapartida, ambientes externos apresentam desafios adicionais devido às maiores distâncias de aquisição, às irregularidades do terreno e, principalmente, às oclusões causadas por elementos como árvores e vegetação densa. Sistemas LiDAR portáteis associados a algoritmos de *Simultaneous Localization and Mapping* (SLAM) têm demonstrado bons resultados em aplicações como inventário florestal e monitoramento ambiental em tempo real, permitindo a extração de parâmetros, como o diâmetro das árvores, durante a própria aquisição dos dados [5].

Além das características do ambiente, o movimento do sensor representa um desafio adicional para sistemas de mapeamento móvel. Durante a aquisição dinâmica, variações na trajetória da plataforma e inconsistências temporais podem comprometer a qualidade da reconstrução tridimensional. Para minimizar esses efeitos, sistemas modernos empregam algoritmos de SLAM, capazes de estimar simultaneamente a posição do sensor e reconstruir o ambiente ao longo da trajetória percorrida. Dessa forma, os avanços em algoritmos de localização, simulação e processamento têm contribuído para tornar as aplicações de mapeamento móvel cada vez mais

precisas e robustas [3].

Apesar dos avanços observados na literatura, grande parte dos estudos concentra-se em aspectos específicos do *pipeline* LiDAR, como a avaliação individual de sensores, o desenvolvimento de algoritmos de SLAM ou aplicações voltadas para cenários específicos. Entretanto, ainda existem poucos trabalhos que realizam uma análise experimental abrangente da influência conjunta dos parâmetros de aquisição, das características do ambiente e das condições de operação sobre a qualidade das nuvens de pontos geradas por sensores LiDAR de alta resolução.

Dessa forma, este trabalho propõe uma avaliação experimental utilizando um sensor Ouster OS1-128 em diferentes ambientes internos, considerando múltiplas configurações de resolução horizontal, frequência de varredura e modos de aquisição estático e dinâmico. O objetivo é analisar como esses fatores influenciam a densidade da nuvem de pontos, o volume de dados gerado e a qualidade da reconstrução tridimensional, contribuindo para a definição de configurações mais adequadas para aplicações de mapeamento móvel e aquisição de dados tridimensionais.

2.3 Metodologia

Diversas etapas foram realizadas para a condução da avaliação experimental das configurações de aquisição LiDAR. Inicialmente, foram definidos os ambientes de teste e as configurações operacionais do sensor, de modo a possibilitar uma análise comparativa entre diferentes condições de captura. Em seguida, as aquisições foram realizadas utilizando um sensor Ouster OS1-128, considerando diferentes combinações de resolução horizontal, frequência de varredura e modos de operação estático e dinâmico. Após a coleta dos dados, os arquivos brutos foram submetidos a um *pipeline* de processamento composto pelas etapas de armazenamento, reconstrução da nuvem de pontos e compressão dos dados. Os conjuntos de dados gerados foram então analisados por meio de métricas quantitativas, incluindo número de pontos, tamanho dos arquivos, taxa de compressão e tempo de processamento. Além da análise quantitativa, foi realizada uma avaliação qualitativa das nuvens de pontos obtidas, considerando aspectos como densidade de pontos, cobertura espacial da cena, presença de oclusões, nível de detalhamento geométrico e consistência da reconstrução em diferentes ambientes. Por fim, os resultados obtidos para cada configuração foram comparados, permitindo identificar a influência dos parâmetros de aquisição e das características do ambiente sobre a qualidade dos dados gerados. A Figura 1 apresenta uma visão geral das etapas que compõem a metodologia proposta.




Figura 1: Visão geral da metodologia utilizada

2.3.1 Sensor LiDAR Ouster OS1-128

Para a realização dos experimentos, foi utilizado um sensor LiDAR Ouster OS1-128, amplamente empregado em aplicações de mapeamento tridimensional, robótica móvel e veículos autônomos. O equipamento opera com base no princípio ToF, realizando medições de distância por meio do cálculo do tempo necessário para que os pulsos de laser emitidos retornem ao sensor após serem refletidos pelos objetos presentes no ambiente. O sensor possui 128 canais de varredura e oferece diferentes configurações de resolução horizontal e frequência de rotação, permitindo adequar a aquisição às necessidades de cada aplicação. Além das informações geométricas, o dispositivo também fornece atributos radiométricos, como refletividade, intensidade do sinal e resposta no infravermelho próximo, *Near-Infrared Spectroscopy* (NIRS), possibilitando uma representação mais completa do ambiente observado. Neste trabalho, o sensor LiDAR foi utilizado para a aquisição de nuvens de pontos em diferentes ambientes e condições de operação, permitindo avaliar a influência dos parâmetros de captura na qualidade dos dados gerados.

2.3.2 Definição de Ambiente

A primeira etapa da metodologia de captura consistiu na definição dos ambientes utilizados nos experimentos. Foram selecionados cenários internos com diferentes características geométricas, níveis de oclusão e densidades de objetos, permitindo avaliar a influência do ambiente na qualidade das nuvens de pontos geradas pelo sensor LiDAR.

Para esta etapa inicial do estudo, foram selecionados dois cenários internos: um ginásio (*Gym*), caracterizado por um ambiente amplo, com grandes espaços livres e poucos elementos próximos ao sensor, e um laboratório/escritório (*Office*), composto por um ambiente mais compacto, com elevada presença de móveis, equipamentos e superfícies próximas. As Figuras 2 e 3 apresentam os ambientes onde foram realizadas as capturas.

2.3.3 Configuração do Sensor

Após a definição dos ambientes, foram estabelecidas as configurações de aquisição do sensor LiDAR. Diferentes combinações de resolução horizontal e frequência de varredura foram avaliadas, bem como os modos de operação estático e dinâmico, permitindo analisar o impacto desses parâmetros sobre os dados gerados.

2.3.4 Aquisição de Dados

As aquisições foram realizadas em todos os ambientes selecionados, utilizando as configurações definidas previamente. Os dados capturados pelo sensor foram armazenados no formato *.pcap*, preservando integralmente as informações transmitidas durante o processo de coleta.

2.3.5 Processamento

Os dados adquiridos foram submetidos a um *pipeline* de processamento responsável pela conversão dos arquivos brutos, reconstrução da trajetória do sensor e geração das nuvens de pontos tridimensionais. Posteriormente, os arquivos foram convertidos para os formatos *.las* e *.laz*, permitindo sua utilização em etapas posteriores de análise e armazenamento. A Figura 4 apresenta detalhadamente as etapas de conversão, processamento, geração da nuvem de pontos e compressão dos dados.



Figura 2: Local de captura: Quadra (*Gym*)




Figura 3: Local de captura: Laboratório (*Office*)

A Tabela 1 demonstra a média do tamanho inicial, final, a taxa de compressão e o tempo necessário para comprimir em cada um dos cenários analisados, enquanto a Tabela 2 demonstra a eficiência média no armazenamento das informações em milhares de pontos por Megabits.



Figura 4: Etapas de processamento

Tabela 1: Resultados de armazenamento e compressão dos dados LiDAR.

Cenário	.pcap (MB)	.las (MB)	.laz (MB)	Compressão	.laz (s)
1024x10 <i>Gym</i> Estático	456.14	1224.74	61.78	0.95	11.26
2048x10 <i>Gym</i> Estático	911.88	2359.05	119.47	0.95	19.49
1024x20 <i>Gym</i> Estático	911.89	2333.69	126.69	0.95	20.36
1024x10 <i>Gym</i> Movimento	456.11	1142.26	65.31	0.94	10.45
2048x10 <i>Gym</i> Movimento	758.17	1789.77	90.36	0.95	15.26
1024x20 <i>Gym</i> Movimento	895.53	2079.13	113.90	0.95	18.67
1024x10 <i>Office</i> Estático	456.11	1210.54	46.55	0.96	9.61
2048x10 <i>Office</i> Estático	911.88	2332.23	80.90	0.97	17.66
1024x20 <i>Office</i> Estático	911.91	2327.09	92.45	0.96	18.52
1024x10 <i>Office</i> Movimento	456.12	1212.98	46.38	0.96	9.84
2048x10 <i>Office</i> Movimento	909.45	2336.85	79.98	0.97	17.77
1024x20 <i>Office</i> Movimento	912.01	2314.50	90.42	0.96	18.53

2.3.6 Análise e Comparação

As nuvens de pontos geradas foram avaliadas por meio de métricas quantitativas e qualitativas. Foram analisados aspectos como número de pontos, tamanho dos arquivos, densidade da nuvem de pontos, cobertura da cena e qualidade da reconstrução em diferentes ambientes e configurações de aquisição. Os resultados obtidos foram comparados entre os diferentes ambientes, configurações do sensor e modos de aquisição. Essa comparação permitiu identificar a influência dos parâmetros operacionais e das características do ambiente na qualidade dos dados LiDAR gerados.

Os testes experimentais foram realizados com o objetivo de avaliar a influência das diferentes configurações de aquisição do sensor LiDAR em ambientes com características distintas. Em ambos os ambientes, foram realizadas aquisições utilizando três configurações do sensor: 1024×10 Hz, 1024×20 Hz e 2048×10 Hz. Além disso, cada configuração foi avaliada em duas condições de operação: sensor estático e sensor em movimento. Para reduzir possíveis variações causadas pelo processo de aquisição, cada condição experimental foi repetida três vezes,

Tabela 2: Eficiência de representação das nuvens de pontos.

Cenário	Pontos/. <i>las</i>	Pontos/. <i>laz</i>
1024x10 <i>Gym</i> Estático	30840.48	611388.07
2048x10 <i>Gym</i> Estático	30840.48	612642.44
1024x20 <i>Gym</i> Estático	30840.47	570311.74
1024x10 <i>Gym</i> Movimento	30840.46	539300.23
2048x10 <i>Gym</i> Movimento	30840.45	611612.08
1024x20 <i>Gym</i> Movimento	30840.47	563138.07
1024x10 <i>Office</i> Estático	30840.38	802011.21
2048x10 <i>Office</i> Estático	30840.44	889127.61
1024x20 <i>Office</i> Estático	30840.48	776267.56
1024x10 <i>Office</i> Movimento	30840.44	806573.44
2048x10 <i>Office</i> Movimento	30840.48	901149.59
1024x20 <i>Office</i> Movimento	30840.48	789379.69

resultando em um conjunto de dados representativo para análise estatística. Todas as capturas tiveram duração de aproximadamente 30 segundos, sendo os dados inicialmente armazenados no formato *.pcap*. Posteriormente, os arquivos passaram pelo *pipeline* de processamento, envolvendo a reconstrução da nuvem de pontos, conversão para o formato *.las* e compressão para o formato *.laz*. Durante esse processo, foram registrados parâmetros relacionados ao volume de dados, quantidade de pontos gerados, tempo de processamento e eficiência da compressão.

As Figuras 5 e 6 mostram as nuvens de pontos geradas na resolução 1024x20 no laboratório (*Office*) tanto em movimento quanto de forma estática.




Figura 5: Nuvem de pontos gerada sem movimento na resolução 1024x20

A quantidade de pontos gerados apresentou uma forte relação com a configuração utilizada no sensor. As configurações com maior taxa de aquisição, como 2048x10 Hz e 1024x20 Hz, produziram aproximadamente o dobro de pontos quando comparadas à configuração 1024x10 Hz, resultado esperado devido ao aumento da resolução horizontal ou da frequência de varredura.

Nas aquisições estáticas, os resultados apresentaram elevada repetibilidade, com pouca va-




Figura 6: Nuvem de pontos gerada em movimento na resolução 1024x20

riação entre as três repetições realizadas em cada cenário. No ambiente *Gym*, a configuração 1024×10 Hz apresentou uma média de aproximadamente 37,8 milhões de pontos, enquanto as configurações 2048×10 Hz e 1024×20 Hz geraram cerca de 72,8 milhões e 72,0 milhões de pontos, respectivamente. De maneira semelhante, no ambiente *Office*, foram observadas médias de 37,3 milhões, 71,9 milhões e 71,8 milhões de pontos para as mesmas configurações.

Nas aquisições em movimento, observou-se uma redução no número de pontos em alguns testes, especialmente no ambiente *Gym*. Esse comportamento pode estar relacionado às variações na trajetória percorrida pelo sensor, à velocidade de deslocamento e ao desempenho dos algoritmos de reconstrução durante o processo de mapeamento. Ainda assim, as configurações de maior densidade mantiveram um volume significativamente superior de informações quando comparadas à configuração de menor resolução.

Por outro lado, a movimentação do sensor pode reduzir regiões de oclusão e permitir a observação de superfícies que não seriam visíveis a partir de uma única posição estática. Dessa forma, as aquisições dinâmicas podem proporcionar uma representação mais completa da geometria tridimensional dos objetos, embora a qualidade final da reconstrução também dependa da trajetória realizada e da precisão dos algoritmos empregados no processamento.

2.3.7 Tempo de Processamento e Volume dos Arquivos

O aumento da quantidade de pontos impactou diretamente o tempo necessário para o processamento dos dados e o tamanho dos arquivos gerados. As configurações de 2048×10 Hz e 1024×20 Hz produziram arquivos *.pcap* próximos de 900 MB, enquanto a configuração de 1024×10 Hz gerou arquivos com aproximadamente 456 MB.

A conversão dos dados para o formato *.las* também apresentou maior tempo de execução nas configurações com maior densidade de pontos. Considerando as médias dos experimentos, as aquisições estáticas realizadas em 1024×10 Hz demandaram cerca de 43 segundos, enquanto as configurações de 2048×10 Hz e 1024×20 Hz atingiram aproximadamente 66 e 86 segundos, respectivamente. Nas aquisições em movimento, o tempo de processamento foi ainda maior devido à necessidade de reconstrução da trajetória do sensor, alcançando valores médios de aproximadamente 128 segundos para a configuração de 2048×10 Hz e 102 segundos para a de 1024×20 Hz.

Em relação ao armazenamento, os arquivos *.las* apresentaram tamanhos variando de aproximadamente 1,2 GB, na configuração de 1024×10 Hz, para valores superiores a 2,3 GB nas demais configurações. Após a compressão para o formato *.laz*, observou-se uma redução significativa no espaço ocupado, com taxas médias de compressão entre 94% e 97%, evidenciando a elevada eficiência da compressão sem perdas aplicada às nuvens de pontos.

Informações mais detalhadas sobre os experimentos são apresentadas nas Tabelas 3 e 4, que resumem, respectivamente, o número médio de pontos gerados (em milhões), o tempo de conversão para cada cenário e o tempo total necessário para todas as etapas do processamento, desde a captura dos dados até a geração da nuvem de pontos comprimida.

Tabela 3: Resultados da aquisição LiDAR e geração da nuvem de pontos.

Cenário	Pacotes	Pontos (Mpts)	Conversão <i>.las</i> (s)
1024x10 <i>Gym</i> Estático	22203.67	37.77	44.16
2048x10 <i>Gym</i> Estático	41403.33	72.75	70.42
1024x20 <i>Gym</i> Estático	41403.33	71.97	87.10
1024x10 <i>Gym</i> Movimento	22202.33	35.23	77.70
2048x10 <i>Gym</i> Movimento	34908.67	55.20	139.85
1024x20 <i>Gym</i> Movimento	40661.00	64.12	92.38
1024x10 <i>Office</i> Estático	22202.00	37.33	42.60
2048x10 <i>Office</i> Estático	41403.33	71.93	62.36
1024x20 <i>Office</i> Estático	41404.33	71.77	84.31
1024x10 <i>Office</i> Movimento	22202.33	37.41	59.38
2048x10 <i>Office</i> Movimento	41301.00	72.07	116.68
1024x20 <i>Office</i> Movimento	41409.33	71.38	111.85

Tabela 4: Média do tempo gasto para o processo por cenário.

Cenário	Tempo Total (s)
1024x10 <i>Gym</i> Estático	85.42
2048x10 <i>Gym</i> Estático	119.91
1024x20 <i>Gym</i> Estático	137.46
1024x10 <i>Gym</i> Movimento	118.15
2048x10 <i>Gym</i> Movimento	185.11
1024x20 <i>Gym</i> Movimento	141.05
1024x10 <i>Office</i> Estático	82.21
2048x10 <i>Office</i> Estático	110.02
1024x20 <i>Office</i> Estático	133.24
1024x10 <i>Office</i> Movimento	99.22
2048x10 <i>Office</i> Movimento	164.45
1024x20 <i>Office</i> Movimento	160.38

2.3.8 Influência do Ambiente

A comparação entre os ambientes analisados demonstrou que as características da cena influenciam diretamente a distribuição dos pontos e a eficiência do processamento. O ambiente

Office, por apresentar maior quantidade de objetos próximos ao sensor e maior riqueza de referências geométricas, manteve resultados mais consistentes entre as aquisições estáticas e em movimento, com menor variação na quantidade de pontos reconstruídos.

Em contrapartida, o ambiente *Gym* apresentou diferenças mais expressivas entre os modos de captura, principalmente durante as aquisições em movimento. Nessas condições, foram observadas reduções na quantidade de pontos reconstruídos e maior variabilidade nos tempos de processamento, indicando que ambientes amplos e com menor quantidade de referências geométricas representam um desafio adicional para os algoritmos de reconstrução e estimativa de trajetória.

Esses resultados evidenciam que o desempenho do sistema LiDAR depende não apenas da configuração de aquisição adotada, mas também das características do ambiente e da dinâmica da captura. Dessa forma, a seleção dos parâmetros de operação deve considerar, além da densidade de pontos desejada, a complexidade geométrica da cena e os recursos computacionais disponíveis para o processamento das nuvens de pontos.

2.4 Direções Futuras

Como continuidade deste trabalho, pretende-se ampliar as campanhas de aquisição de nuvens de pontos, contemplando diferentes cenários de operação. Entre eles, destacam-se ambientes com elevada presença de árvores e vegetação, bem como ambientes amplos contendo grande quantidade de objetos e superfícies que podem influenciar o funcionamento do sensor LiDAR, como espelhos e vidros. A expansão do conjunto de dados permitirá aumentar o espaço amostral das análises e proporcionar uma compreensão mais abrangente do desempenho do algoritmo LASZip em diferentes condições de utilização do LiDAR para mapeamento e reconstrução tridimensional de ambientes.

Outra frente de desenvolvimento consiste na robotização do processo de aquisição, substituindo a movimentação manual do sensor por uma plataforma robótica. Essa abordagem permitirá padronizar a trajetória e a velocidade de deslocamento durante as capturas, reduzindo a variabilidade introduzida pelo operador humano e possibilitando a realização de experimentos mais controlados e reprodutíveis. Além disso, espera-se ampliar o alcance das campanhas experimentais e obter bases de dados mais consistentes para a avaliação comparativa das diferentes configurações de aquisição.

3 Integração de Sistemas UAV-LiDAR e Conectividade TV White Space para Agricultura de Precisão

Este capítulo apresenta a continuidade das atividades relacionadas ao desenvolvimento de uma arquitetura baseada em sistemas LiDAR embarcados em drones, voltada para o monitoramento agrícola no contexto do Projeto Brasil 6G. São descritas as etapas de aquisição, processamento e análise dos dados LiDAR, bem como as otimizações implementadas para redução do tempo de processamento e aumento da eficiência computacional da plataforma. Adicionalmente, são apresentadas avaliações preliminares da integração do sistema com infraestruturas de comunicação Wi-Fi, além de estudos complementares envolvendo ferramentas de análise de nuvens de pontos. Esses desenvolvimentos constituem a base da arquitetura proposta para integração com a infraestrutura de comunicação TVWS, prevista no Projeto Brasil 6G. Ressalta-se, entretanto, que os resultados referentes à integração entre a plataforma UAV-LiDAR e a rede TVWS são apresentados no relatório técnico da Atividade 4.4 – Demonstrações das Soluções Desenvolvidas no Projeto Brasil 6G. Essas atividades visam estabelecer os fundamentos para o desenvolvimento de uma solução integrada capaz de combinar sensoriamento remoto, processamento em borda e conectividade de longa distância para aplicações de agricultura de precisão.

3.1 Contextualização

A agricultura de precisão vem demandando, de forma crescente, soluções tecnológicas capazes de realizar o monitoramento detalhado das culturas agrícolas, permitindo maior eficiência no manejo, aumento da produtividade e otimização do uso de recursos [7]. Nesse contexto, técnicas de sensoriamento remoto embarcado em UAVs têm recebido destaque devido à sua capacidade de aquisição rápida e flexível de dados em campo, possibilitando a obtenção de informações espaciais de alta resolução sobre o estado da vegetação [8].

Entre as diferentes tecnologias de sensoriamento remoto aplicadas à agricultura de precisão, os sistemas baseados em LiDAR apresentam vantagens importantes em relação às abordagens convencionais baseadas exclusivamente em imagens *Red, Green, Blue* (RGB) ou multiespectrais [9]. Diferentemente de sensores passivos, os sistemas LiDAR realizam medições ativas utilizando pulsos laser para reconstrução tridimensional do ambiente, permitindo estimar parâmetros estruturais da vegetação com elevada precisão, mesmo sob diferentes condições de iluminação [10, 11]. A utilização de plataformas UAV-LiDAR possibilita a geração de produtos derivados tridimensionais, como modelos digitais de terreno (*Digital Terrain Model* (DTM)), modelos digitais de superfície (*Digital Surface Model* (DSM)) e modelos de altura do dossel (*Canopy Height Model* (CHM)), amplamente empregados em aplicações agrícolas envolvendo estimativa de altura de plantas, biomassa, volume vegetativo, índice de área foliar e monitoramento do desenvolvimento das culturas [10, 12].

Apesar do elevado potencial dessas tecnologias, sistemas UAV-LiDAR ainda apresentam desafios importantes relacionados principalmente ao elevado volume de dados gerados durante as operações de voo. Sensores LiDAR modernos são capazes de produzir milhões de pontos por segundo, resultando em arquivos de grande dimensão e elevada demanda computacional para o armazenamento, a transferência e o processamento das nuvens de pontos [13]. Em muitas aplicações, o processamento é realizado de forma *offline* em estações computacionais externas

O conteúdo deste capítulo foi desenvolvido pelas pesquisadoras *Letícia Carneiro de Souza*, *Ana Luísa Lyra Pavanelli* e *Mayara de Oliveira Paula*.

após o término dos voos, aumentando significativamente a latência entre a aquisição dos dados e a obtenção das informações agrícolas de interesse [14, 15]. Nesse cenário, arquiteturas baseadas em computação em borda (*edge computing*) surgem como uma alternativa promissora para reduzir a latência operacional dos sistemas UAV-LiDAR, permitindo que parte do processamento das nuvens de pontos seja executada diretamente em plataformas computacionais embarcadas no próprio drone [9]. Essa abordagem possibilita reduzir o volume de dados transmitidos através dos enlaces sem fio, uma vez que apenas produtos derivados ou parâmetros agrícolas extraídos precisam ser enviados para estações remotas de monitoramento.

Além dos desafios computacionais, aplicações UAV-LiDAR embarcadas também dependem de soluções eficientes de conectividade sem fio para transmissão de dados em ambientes agrícolas, especialmente em regiões rurais onde a infraestrutura tradicional de comunicação é limitada ou inexistente. Nesse contexto, tecnologias baseadas em TVWS apresentam potencial significativo para aplicações agrícolas devido à elevada cobertura, maior alcance de comunicação e melhor capacidade de propagação quando comparadas a tecnologias convencionais de curto alcance, como Wi-Fi operando em frequências mais elevadas [16, 17].

As faixas de frequência associadas ao TVWS correspondem a canais não utilizados da televisão digital terrestre, normalmente localizados abaixo de 1 GHz. Devido às menores frequências de operação, sinais TVWS apresentam menores perdas de propagação e maior capacidade de penetração em obstáculos naturais, como vegetação e irregularidades do terreno, características particularmente relevantes em cenários agrícolas de grande extensão territorial. Dessa forma, sistemas baseados em TVWS podem viabilizar enlaces sem fio de longa distância com menor infraestrutura de comunicação, permitindo a transmissão de informações agrícolas processadas entre plataformas UAVs, estações de solo e centros remotos de monitoramento [18, 19].

3.2 Estado da Arte

Nos últimos anos, o uso de sensores LiDAR embarcados em UAVs tem recebido crescente atenção em aplicações de agricultura de precisão, principalmente devido à capacidade de reconstrução tridimensional da vegetação e obtenção de parâmetros estruturais com elevada resolução espacial. Entre esses parâmetros, a altura das plantas destaca-se por sua relação com o crescimento, vigor e produtividade das culturas, motivando diversos estudos baseados em CHMs. Neste contexto, Ten Harkel *et al.* utilizaram CHMs derivados de dados UAV-LiDAR para estimar a altura de culturas de batata, beterraba açucareira e trigo de inverno, obtendo *Coefficient of Determination* (R^2) entre 0,68 e 0,82 e valores de *Root Mean Square Error* (RMSE) variando de 3,9 cm a 7,4 cm [15]. Resultados semelhantes foram reportados por Luo *et al.* para culturas de milho e soja, com R^2 de 0,649 e 0,403 e RMSE de 23,7 cm e 8,6 cm, respectivamente [20].

Em outro estudo, Liu *et al.* obtiveram erros relativos entre 3,86% e 12,73% na estimativa da altura de plantas de algodão utilizando a média dos cinco pontos mais altos da nuvem de pontos para representar a altura da cultura [21]. Em cultivos de arroz, Phan e Takahashi estimaram a altura das plantas a partir da diferença entre os percentis 1 e 95 da nuvem de pontos, alcançando R^2 de 0,85 e RMSE de 0,07 m [22]. Em lavouras de milho, Zhou *et al.* alcançaram R^2 de 0,96 e RMSE de 0,13 m na estimativa da altura de plantas submetidas a diferentes níveis de acamamento por meio de CHMs [23]. Resultados semelhantes foram observados por Hu *et al.*, que investigaram a capacidade de recuperação do milho após acamamento e reportaram R^2 de 0,95 e 0,98, com RMSE de 0,06 m e 0,13 m em diferentes estágios de desenvolvimento da cultura [24].

O potencial do LiDAR também tem sido explorado para estimativa de outros parâmetros

estruturais da vegetação. Lei *et al.* utilizaram processamento baseado em *voxels* para estimar o Índice de Área Foliar (IAF) de plantas de milho em diferentes camadas do dossel, obtendo erros normalizados de 10,8%, 12,4% e 42,8% para as regiões superior, intermediária e inferior, respectivamente [25]. Para a cultura do sorgo, Maimaitijiang *et al.* obtiveram R^2 de 0,975 e RMSE de 5,2 cm na estimativa da altura das plantas, além de utilizarem modelos baseados em *Random Forest* para estimativa de IAF, reportando R^2 variando entre 0,42 e 0,95 [26]. Xu *et al.* investigaram diferentes técnicas de modelagem para predição da biomassa fresca de cana-de-açúcar, alcançando R^2 de até 0,97 e RMSE de 1,33 kg/m² [27]. Sofonia *et al.* utilizaram métricas extraídas de nuvens de pontos para estimativa da altura da cana-de-açúcar, obtendo R^2 de 0,91 e 0,93 para diferentes métricas de altura [28], enquanto Shendryk *et al.* empregaram parâmetros derivados do LiDAR para estimativa de biomassa da mesma cultura [29]. Em trabalhos envolvendo sorgo, Masjedi *et al.* exploraram diferentes algoritmos de aprendizado de máquina e a fusão de dados RGB, hiperespectrais e LiDAR para estimativa de biomassa, reportando R^2 de até 0,89 [30].

Em relação à cultura do café, uma das principais commodities agrícolas do Brasil e de grande relevância econômica para o país [31], os estudos envolvendo sistemas UAV-LiDAR ainda são relativamente escassos. Isso se deve, em parte, à maior complexidade estrutural dos cafezais, caracterizados por plantas arbustivas perenes, copas irregulares e, frequentemente, cultivadas em áreas com relevo acidentado. Essas características tornam mais desafiadoras as etapas de aquisição, processamento e interpretação das nuvens de pontos, além de dificultarem a extração de parâmetros estruturais com elevada precisão. Entre os poucos trabalhos encontrados na literatura, destaca-se o estudo desenvolvido por Bento *et al.*, que empregou um sistema UAV-LiDAR para o mapeamento da altura das plantas e análise da variabilidade da compactação do solo em lavouras cafeeiras [32]. Os resultados demonstraram o potencial da tecnologia para caracterização estrutural da cultura e monitoramento agrícola.

Esses resultados demonstram que o UAV-LiDAR constitui uma ferramenta consolidada para a obtenção de parâmetros agronômicos em diferentes tipos de culturas. Entretanto, a maior parte dos estudos concentra-se no desenvolvimento de metodologias para extração e análise de parâmetros agronômicos derivados das nuvens de pontos, dedicando menor atenção à avaliação de arquiteturas computacionais embarcadas, técnicas de aceleração do processamento e soluções de conectividade capazes de suportar o transporte dos dados LiDAR gerados durante as operações de voo.

3.3 Arquitetura do Sistema Proposto

Com base nas lacunas identificadas na literatura, foi proposta uma arquitetura integrada para monitoramento agrícola baseada em UAV-LiDAR e conectividade TVWS. Diferentemente da maioria dos trabalhos encontrados, que se concentram principalmente na extração de parâmetros agronômicos a partir de nuvens de pontos processadas *offline*, a arquitetura proposta considera também aspectos relacionados à aquisição, processamento embarcado e transmissão dos dados. A Figura 7 apresenta a arquitetura funcional proposta para a plataforma desenvolvida no contexto do Projeto Brasil 6G. A arquitetura é composta por quatro módulos principais: sensoriamento LiDAR embarcado no UAV, processamento embarcado em borda, comunicação utilizando TVWS e processamento remoto para geração de informações agronômicas avançadas. Neste relatório, entretanto, o foco está no desenvolvimento e na avaliação dos módulos de sensoriamento, processamento embarcado e comunicação local, enquanto a implementação e a validação da integração com a infraestrutura TVWS são apresentadas no relatório técnico da

Atividade 4.4 – Demonstrações das Soluções Desenvolvidas no Projeto Brasil 6G.

Inicialmente, o sistema realiza a aquisição de dados tridimensionais de alta densidade utilizando um sensor LiDAR integrado ao UAV. Os dados capturados, juntamente com as informações inerciais provenientes da *Inertial Measurement Unit* (IMU), são enviados para a unidade computacional embarcada responsável pelas etapas de aquisição, filtragem, normalização e processamento dos dados. O processamento embarcado é executado diretamente na plataforma computacional instalada no UAV, permitindo a geração local de produtos intermediários, como reconstrução da nuvem de pontos, modelos digitais e estimativas iniciais da estrutura da vegetação, reduzindo significativamente o volume de dados transmitidos e aumentando a autonomia operacional do sistema. A comunicação entre o UAV e a estação terrestre é realizada por meio de um enlace Wi-Fi, responsável pela transferência local dos dados processados.

No contexto da arquitetura proposta, os dados são encaminhados através de enlaces TVWS entre a estação terrestre do UAV e a estação remota, possibilitando transmissão de longa distância em áreas rurais com baixa disponibilidade de infraestrutura convencional de conectividade. A utilização de TVWS apresenta características adequadas para aplicações agrícolas distribuídas, incluindo elevada cobertura, baixo custo de implantação e maior capacidade de propagação em ambientes abertos. Na etapa de processamento remoto, são executadas rotinas avançadas de processamento e análise dos dados, permitindo a extração de parâmetros relevantes para aplicações de agricultura de precisão, tais como altura da vegetação, biomassa, IAF, volume e outros indicadores agrônômicos derivados das nuvens de pontos tridimensionais.




Figura 7: Arquitetura funcional proposta para a plataforma integrada de sensoriamento LiDAR, processamento embarcado e comunicação via TV White Space aplicada à agricultura inteligente no contexto do Brasil 6G.

3.4 Desenvolvimento do Sistema UAV-LiDAR

O desenvolvimento do sistema UAV-LiDAR foi realizado de forma incremental, visando a implementação progressiva das funcionalidades de aquisição, armazenamento, processamento embarcado e transmissão de dados para aplicações de sensoriamento remoto agrícola. Inicialmente, as etapas de processamento eram executadas de forma *offline* em estação computacional externa, sendo posteriormente migradas para execução diretamente na plataforma embarcada. As diferentes etapas de desenvolvimento tiveram como objetivo validar a viabilidade operacional da plataforma em cenários reais, além de permitir a evolução da capacidade computacional e da autonomia do sistema ao longo das campanhas experimentais realizadas.

A Figura 8 apresenta o diagrama em blocos funcional do sistema UAV-LiDAR desenvolvido ao longo do projeto. O UAV utilizado foi a plataforma multirrotor DJI Agras MG-1P, selecionada devido à sua elevada capacidade de carga útil e adequação para aplicações de sensoriamento remoto agrícola. A plataforma suporta peso máximo de decolagem de até 24,8 kg e opera com velocidades de voo de aproximadamente 12–15 m/s, apresentando autonomia de voo estacionário entre 9 e 20 minutos, dependendo das condições operacionais e da carga embarcada. O sistema de sensoriamento foi composto por um sensor LiDAR Ouster OS1-128, capaz de fornecer cobertura horizontal de 360° e campo de visão vertical de até 45°. O sensor permite a aquisição de nuvens de pontos de alta densidade utilizando 128 canais, alcançando taxas de aquisição de até 2,6 milhões de pontos por segundo. Além disso, o OS1-128 apresenta alcance máximo de medição de até 120 m e precisão aproximada de ± 3 cm. O sensor LiDAR integra ainda uma IMU de três eixos, responsável pelo fornecimento de dados sincronizados de acelerômetro e giroscópio, utilizados para auxiliar nas etapas de alinhamento temporal e estabilização das nuvens de pontos. O sensor opera utilizando fonte laser Classe 1 em comprimento de onda de 865 nm, permitindo operação segura em aplicações externas.




Figura 8: Diagrama em blocos da plataforma UAV-LiDAR desenvolvida.

A arquitetura embarcada também foi composta por uma unidade computacional responsável pela aquisição, armazenamento e processamento dos dados LiDAR, além de um módulo de comunicação Wi-Fi utilizado para transmissão local de dados entre o UAV e a estação terrestre. Uma interface dedicada foi empregada para fornecer alimentação regulada ao sensor LiDAR e possibilitar a transmissão de dados em alta taxa através de interface Gigabit Ethernet entre o sensor e a unidade computacional embarcada. O sistema também contou com um subsistema de alimentação baseado em baterias embarcadas, responsável pelo suprimento energético dos módulos computacionais e de comunicação durante as operações de voo.

As subseções seguintes apresentam as diferentes etapas de desenvolvimento da plataforma, incluindo as arquiteturas implementadas, campanhas experimentais realizadas e a evolução dos subsistemas de aquisição, processamento e comunicação ao longo do projeto.

3.4.1 Implementação Inicial Baseada em Raspberry Pi

A primeira etapa de desenvolvimento do sistema UAV-LiDAR foi baseada em uma plataforma computacional Raspberry Pi, utilizada para validação inicial da arquitetura embarcada de aquisição e armazenamento de dados LiDAR. A Figura 9 apresenta a plataforma UAV-LiDAR desenvolvida nessa etapa. Essa implementação teve como principal objetivo avaliar a viabilidade operacional da plataforma em aplicações de sensoriamento remoto agrícola, além de validar a integração entre os subsistemas de sensoriamento, armazenamento e comunicação.




Figura 9: Plataforma UAV-LiDAR desenvolvida para aquisição de dados LiDAR utilizando arquitetura embarcada baseada em Raspberry Pi.

A unidade computacional embarcada foi implementada utilizando uma Raspberry Pi 4 Model B equipada com 4 GB de memória RAM e armazenamento de 128 GB em cartão microSD, executando o sistema operacional Linux. A comunicação entre o sensor LiDAR e a plataforma computacional foi realizada através de interface Gigabit Ethernet, permitindo a recepção e armazenamento contínuo dos pacotes de dados provenientes do sensor durante as operações de voo. Nesta etapa, o processamento dos dados adquiridos não era executado embarcado na plataforma. Assim, os dados LiDAR e IMU coletados durante os voos eram armazenados localmente para posterior processamento *offline* em estação computacional externa.

3.4.1.1 Metodologia de Aquisição e Processamento de Dados

Para gerenciamento da aquisição dos dados LiDAR, foi desenvolvido um serviço dedicado responsável pelo controle de todo o *pipeline* de aquisição embarcado. Após a inicialização do sistema, o serviço realiza automaticamente a comunicação com o sensor LiDAR através de interface Gigabit Ethernet, iniciando a recepção contínua dos pacotes LiDAR e IMU. Durante as campanhas experimentais, os dados foram adquiridos em janelas de captura configuráveis, sendo utilizado neste trabalho um intervalo de aquisição de 5 minutos para cada operação de voo. Os pacotes recebidos foram armazenados sequencialmente em arquivos no formato *.pcap*, enquanto os parâmetros de aquisição e metadados do sensor foram registrados automaticamente em arquivos no formato *.json*. A utilização do armazenamento em arquivos *.pcap* permitiu preservar integralmente os dados brutos provenientes do sensor, possibilitando posterior processamento *offline* e reprodutibilidade das etapas de reconstrução e análise. Devido às limitações computacionais da plataforma baseada em Raspberry Pi, as etapas de processamento das nuvens de pontos não foram executadas embarcadas durante as operações de voo. Dessa forma, após a

conclusão das campanhas experimentais, os arquivos contendo os dados LiDAR e IMU eram transferidos para uma estação computacional externa de maior capacidade computacional, responsável pela execução das etapas de reconstrução e processamento das nuvens de pontos.

Após a transferência dos dados adquiridos, as informações provenientes do sensor LiDAR foram submetidas a um *pipeline* de processamento baseado em técnicas de SLAM, responsável pela reconstrução tridimensional do ambiente e pela estimação da trajetória da plataforma durante o voo. O princípio fundamental do processo de SLAM consiste no alinhamento incremental entre nuvens de pontos consecutivas, permitindo simultaneamente a localização do sensor e a construção de um mapa global consistente da área monitorada. Esse processo é realizado através do registro sucessivo das varreduras adquiridas pelo sensor, possibilitando a estimação do movimento relativo da plataforma ao longo da trajetória de voo. Uma das abordagens mais utilizadas para registro de nuvens de pontos é o algoritmo *Iterative Closest Point* (ICP), responsável por estimar iterativamente a transformação rígida entre varreduras consecutivas através da minimização do erro de alinhamento entre os pontos correspondentes [33]. Neste trabalho, a reconstrução SLAM foi realizada utilizando o *framework open-source Keep it Small and Simple* (KISS)-ICP, selecionado devido à sua baixa complexidade computacional e elevada eficiência para aplicações embarcadas [34, 35]. O *framework* realiza o alinhamento sucessivo das nuvens de pontos utilizando técnicas derivadas do ICP, permitindo a reconstrução do ambiente e a estimação da trajetória da plataforma sem dependência direta de sistemas externos de posicionamento de alta precisão.

Após a reconstrução SLAM, as nuvens de pontos foram submetidas a etapas adicionais de filtragem e processamento para extração das informações relacionadas à vegetação. Inicialmente, foi aplicada uma etapa de filtragem de solo utilizando o algoritmo *Simple Morphological Filter* (SMRF), responsável pela identificação dos pontos pertencentes ao terreno. Os parâmetros do filtro foram ajustados empiricamente visando melhorar a separação entre solo e vegetação nas áreas agrícolas analisadas. Os parâmetros utilizados foram: *cell size* igual a 0,5, *window size* igual a 14, *slope threshold* igual a 0,2 e *elevation threshold* igual a 0,45. Em seguida, os pontos classificados como não pertencentes ao solo foram refinados através de uma etapa de agrupamento espacial (*clustering*), permitindo a remoção de ruídos e retornos isolados presentes na nuvem de pontos. Para essa etapa, foram utilizados os parâmetros *min_points* igual a 20 e *tolerance* igual a 0,5. Após a remoção de ruídos, foi realizada a normalização vertical da nuvem de pontos e aplicação de filtros de altura para preservação apenas dos pontos pertencentes ao dossel vegetal. Posteriormente, foram gerados diferentes modelos em formato *raster* utilizados para caracterização da vegetação e análise do ambiente agrícola.

Inicialmente, foi produzido o DTM, obtido a partir dos pontos classificados como solo durante a etapa de filtragem. O DTM representa a superfície do terreno sem a presença da vegetação, sendo responsável por descrever a topografia da área monitorada. Em seguida, foi gerado o DSM, construído a partir dos pontos de maior elevação presentes em cada célula da grade espacial. Diferentemente do DTM, o DSM representa os elementos superiores da cena, incluindo copas das plantas, galhos e demais estruturas acima do solo. A partir desses dois modelos, foi obtido o CHM, calculado através da diferença entre o DSM e o DTM. O CHM fornece uma representação espacial da altura da vegetação, permitindo a extração de parâmetros relevantes para aplicações de agricultura de precisão, como altura das plantas, biomassa e IAF. A Figura 10 ilustra uma representação dos modelos DTM, DSM e CHM a partir da nuvem de pontos adquirida pelo sistema UAV-LiDAR. O fluxo completo de aquisição e processamento desenvolvido neste estágio é apresentado na Figura 11.




Figura 10: Geração dos modelos DTM, DSM e CHM a partir da nuvem de pontos LiDAR processada.




Figura 11: Fluxograma do *pipeline* de processamento das nuvens de pontos LiDAR.

3.4.1.2 Validação Experimental em Lavoura de Café

A área de estudo, ilustrada na Figura 12, consiste em uma plantação de café (*Coffea arabica* L.) localizada em Santa Rita do Sapucaí, Minas Gerais, Brasil (22°12'28.0"S, 45°40'15.2"W). A região encontra-se em altitude entre 820 e 830 m e apresenta clima subtropical de altitude, com temperatura média anual de aproximadamente 21°C e variações mensais típicas entre 11°C e 27°C. A precipitação média anual é de aproximadamente 1416 mm, concentrada predominantemente no período chuvoso entre os meses de outubro e março.

Na área experimental, os cafeeiros encontram-se organizados em linhas de contorno sobre um terreno com inclinação aproximada de 31°, característica que aumenta a complexidade geométrica da cena em comparação a áreas planas. Os dados LiDAR foram adquiridos em 21 de novembro de 2025, enquanto as medidas de referência da altura dos cafeeiros foram realizadas no mesmo dia utilizando fita métrica. Ao todo, foram coletadas 10 amostras em pontos representativos distribuídos ao longo da plantação para posterior comparação com os dados obtidos pelo sistema UAV-LiDAR.




Figura 12: Área experimental utilizada nas campanhas de aquisição de dados LiDAR em Santa Rita do Sapucaí, Minas Gerais, Brasil. Fonte da imagem de satélite: Google Earth.

Outro parâmetro importante analisado durante o desenvolvimento do sistema foi o ângulo de inclinação do sensor LiDAR, representado pelo parâmetro *pitch*. Esse ângulo define a inclinação do sensor em relação ao solo e influencia diretamente a distribuição espacial dos pontos adquiridos ao longo da área imageada. A definição adequada do *pitch* depende simultaneamente das características do sensor, da altura de voo, da velocidade da aeronave e da geometria da área monitorada. A Figura 13 apresenta uma simulação da distribuição espacial da nuvem de pontos considerando um ângulo de inclinação de 15° . Observa-se que a inclinação do sensor altera significativamente a geometria de cobertura da cena, permitindo concentrar maior densidade de pontos na região frontal ao deslocamento da aeronave. Essa estratégia é particularmente relevante em aplicações agrícolas, nas quais se busca maximizar a densidade de amostragem sobre a vegetação e minimizar aquisições desnecessárias de regiões periféricas. Com base nas análises realizadas, adotou-se um ângulo de *pitch* de 15° durante as campanhas experimentais, por apresentar um compromisso adequado entre cobertura da área imageada e densidade espacial de pontos sobre a plantação.




Figura 13: Distribuição espacial simulada da nuvem de pontos LiDAR considerando um ângulo de inclinação (*pitch*) de 15° , utilizado durante as campanhas experimentais.

Os dados adquiridos durante a campanha experimental foram inicialmente armazenados em arquivos no formato *.pcap*, preservando integralmente os pacotes LiDAR e IMU provenientes do sensor embarcado. A Figura 14 apresenta uma visualização da nuvem de pontos obtida diretamente a partir dos dados brutos adquiridos durante o voo experimental, antes das etapas de reconstrução, filtragem e processamento. É possível observar a representação espacial das linhas de cultivo e da topografia da área monitorada, bem como o efeito da inclinação de 15° adotada para o sensor LiDAR durante a aquisição dos dados. Essa visualização evidencia a capacidade do sistema em adquirir informações tridimensionais do ambiente agrícola.

A Figura 15 apresenta os modelos DTM, DSM e CHM gerados a partir do processamento das nuvens de pontos adquiridas durante a campanha experimental na plantação de café e visualizados no *software CloudCompare*. O DTM permitiu a representação da topografia da área monitorada após a remoção dos elementos pertencentes à vegetação, enquanto o DSM representou a superfície superior da cena, incluindo o dossel dos cafeeiros. A partir desses modelos, foi gerado o CHM, responsável por representar espacialmente a altura da vegetação ao longo




Figura 14: Visualização da nuvem de pontos obtida diretamente a partir dos dados LiDAR armazenados no arquivo *.pcap* durante a campanha experimental.

da área experimental. Observa-se que o CHM possibilitou evidenciar a distribuição espacial das alturas dos cafeeiros, permitindo a extração de informações relevantes para aplicações de agricultura de precisão.

A partir do CHM gerado durante o processamento das nuvens de pontos, torna-se possível obter representações espaciais da altura da vegetação ao longo da área monitorada. Esse tipo de representação permite visualizar a distribuição estrutural da cultura agrícola, evidenciando regiões com diferentes alturas de dossel e auxiliando na identificação de variações espaciais presentes na plantação. A Figura 16 apresenta o mapa de calor da altura da vegetação obtido a partir dos dados LiDAR processados. Observa-se que o mapa evidencia claramente a organização das linhas de cultivo do cafezal, permitindo identificar a variabilidade espacial da altura das plantas ao longo da área experimental.

As regiões associadas às maiores alturas da vegetação são representadas em tons de verde, enquanto áreas com menores alturas apresentam uma transição gradual para tons de amarelo e vermelho. Observa-se ainda que as bordas externas da região mapeada concentram predominantemente pontos associados a baixas alturas, correspondentes principalmente às áreas de solo exposto e regiões sem cobertura vegetal significativa. Quando comparados à área experimental apresentada na Figura 12, os resultados demonstram que os padrões estruturais da plantação, incluindo alinhamento, espaçamento e curvatura das linhas de cultivo, foram adequadamente preservados durante as etapas de reconstrução e processamento das nuvens de pontos LiDAR. Esse comportamento evidencia a capacidade do sistema UAV-LiDAR em representar de forma coerente a geometria da cultura agrícola mesmo em terrenos inclinados e com maior complexidade topográfica.

A avaliação quantitativa das estimativas de altura obtidas pelo sistema UAV-LiDAR foi realizada através da comparação entre os valores derivados do CHM e as medições manuais efetuadas em campo. Para essa análise, foram utilizados três indicadores estatísticos amplamente empregados na literatura: coeficiente de determinação (R^2), raiz do erro quadrático médio (RMSE) e erro absoluto médio (*Mean Absolute Error* (MAE)). O R^2 avalia o grau de correlação entre os valores estimados e os valores medidos em campo, indicando a capacidade




Figura 15: Modelos derivados gerados a partir do processamento das nuvens de pontos LiDAR da área experimental: (a) DTM, (b) DSM e (c) CHM.

do modelo em representar a variabilidade observada nos dados de referência. Já o RMSE quantifica a magnitude global dos erros, apresentando maior sensibilidade a discrepâncias elevadas. O MAE, por sua vez, representa a média das diferenças absolutas entre os valores estimados e medidos, fornecendo uma medida mais diretamente interpretável do erro médio do sistema. As respectivas expressões matemáticas utilizadas para cálculo das métricas são [36, 23]

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

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

$$\text{MAE} = \frac{\sum_{i=1}^N |y_i - \hat{y}_i|}{N}, \quad (3)$$

em que N representa o número total de amostras, y_i corresponde à altura medida em campo, $\hat{y}_i$ representa a altura estimada pelo sistema LiDAR e $\bar{y}_i$ corresponde à média das alturas medidas.

A Figura 17 apresenta a comparação entre as alturas obtidas manualmente em campo e os valores estimados a partir do processamento dos dados LiDAR. Cada ponto representa uma posição amostral avaliada durante a campanha experimental, enquanto a linha tracejada indica a condição ideal de concordância 1:1 entre os valores estimados e medidos. As plantas avaliadas




Figura 16: Mapa de calor representando a altura estimada da vegetação do cafezal, em metros, obtida a partir do CHM derivado dos dados LiDAR.




Figura 17: Comparação entre as alturas da vegetação medidas em campo e as estimativas obtidas a partir do CHM gerado com dados LiDAR.

apresentaram alturas variando entre 0 e 4 m, conforme reportado na Figura 16. Os resultados obtidos apresentaram forte tendência linear e elevada concordância entre as estimativas derivadas do sistema UAV-LiDAR e as medições de referência realizadas em campo. O coeficiente de determinação obtido ($R^2 = 0,94$) indica que a maior parte da variabilidade observada nas medições manuais foi adequadamente representada pelas estimativas derivadas do CHM, evidenciando elevada consistência entre os conjuntos de dados. Os resultados obtidos apresentam desempenho compatível com trabalhos reportados na literatura relacionados à estimativa de altura de culturas agrícolas utilizando sistemas LiDAR embarcados em UAVs, nos quais valores de R^2 tipicamente variam entre 0,6 e 0,97, enquanto valores de RMSE geralmente situam-se entre 5 e 25 cm em condições reais de campo [15, 20, 26]. As métricas de erro corroboram esse comportamento. O valor de MAE igual a 12,47 cm indica que o erro médio absoluto entre os valores medidos e estimados permaneceu relativamente reduzido. De forma semelhante, o RMSE de 14,53 cm demonstra que discrepâncias de maior magnitude ocorreram com baixa frequência ao longo das amostras analisadas.

3.4.2 Evolução da Arquitetura Computacional do Sistema

Embora os resultados obtidos tenham demonstrado a viabilidade da plataforma baseada em Raspberry Pi para aquisição e armazenamento dos dados LiDAR, a arquitetura desenvolvida ainda apresentava limitações relacionadas tanto à capacidade computacional embarcada quanto à transmissão dos dados adquiridos. Durante esta etapa do projeto, o *pipeline* de processamento apresentado na Figura 11 foi executado *offline* em uma estação computacional externa, devido às restrições de processamento e memória da plataforma embarcada utilizada. Dessa forma, os arquivos contendo os dados brutos adquiridos pelo sensor LiDAR precisavam ser transferidos posteriormente para processamento externo.

Além das limitações computacionais, observou-se que os arquivos gerados durante as campanhas experimentais apresentavam elevado volume de dados, especialmente devido ao armazenamento contínuo dos pacotes LiDAR e IMU no formato *.pcap*. Em campanhas típicas de aquisição, os arquivos gerados podiam atingir tamanhos da ordem de 2 GB para 5 minutos de voo, tornando inviável a transmissão integral dos dados brutos através de enlaces Wi-Fi convencionais. Essa limitação evidencia que arquiteturas baseadas exclusivamente na transmissão das nuvens de pontos brutas demandariam elevada largura de banda e apresentariam restrições significativas para aplicações em tempo real utilizando plataformas UAV.

Dessa forma, surgiu a necessidade de evoluir a arquitetura do sistema para uma abordagem baseada em processamento em borda (*edge computing*), na qual parte significativa do *pipeline* de processamento passaria a ser executada diretamente na plataforma embarcada. Essa estratégia possibilita reduzir drasticamente o volume de dados transmitidos, permitindo que apenas informações processadas, mapas derivados ou parâmetros agrícolas de interesse sejam enviados para a estação remota. Nesse contexto, foi realizada a avaliação da plataforma NVIDIA® Jetson Orin™ NX como alternativa computacional para execução embarcada do *pipeline* LiDAR, motivando a evolução da arquitetura do sistema UAV-LiDAR.

3.4.2.1 Comparação entre Plataformas de Processamento

Com o objetivo de avaliar a viabilidade de processamento embarcado, foi realizada uma análise comparativa entre a estação computacional utilizada durante as etapas iniciais do projeto, equipada com NVIDIA® GeForce RTX™ 3060 Laptop, e a plataforma embarcada NVIDIA®

Jetson Orin™ NX, selecionada devido à sua elevada relação desempenho por watt e reduzido fator de forma. O *pipeline* de processamento foi desenvolvido utilizando a biblioteca *open-source Point Data Abstraction Library* (PDAL), um *framework* voltado ao processamento escalável e reproduzível de nuvens de pontos tridimensionais [37]. A biblioteca foi utilizada para implementação das etapas de filtragem, normalização e geração dos modelos derivados das nuvens de pontos LiDAR. Para garantir consistência na avaliação, ambas as plataformas executaram o mesmo fluxo de processamento, utilizando os mesmos algoritmos e configurações de parâmetros. O arquivo utilizado nos testes continha aproximadamente 10,4 milhões de pontos LiDAR.

A análise comparativa foi realizada considerando métricas relacionadas ao tempo total de processamento, utilização computacional, tempo de processamento normalizado por milhão de pontos e consumo energético por milhão de pontos processados. Na plataforma baseada em computador convencional, as métricas de desempenho e potência foram monitoradas utilizando o *software MSI Afterburner* em ambiente Windows. Já na plataforma Jetson Orin™ NX, as métricas foram obtidas utilizando as ferramentas nativas de monitoramento disponíveis no ambiente Linux embarcado. A avaliação foi dividida em duas etapas principais do *pipeline*. A primeira etapa correspondeu à conversão dos arquivos brutos no formato *.pcap* para o formato *.las*, utilizado para armazenamento estruturado das nuvens de pontos. A segunda etapa correspondeu ao processamento subsequente das nuvens de pontos para geração do CHM. Os resultados obtidos para ambas as etapas são apresentados nas Tabelas 5 e 6.

Os resultados demonstraram que o computador convencional apresentou menores tempos de processamento em ambas as etapas avaliadas, refletindo sua maior capacidade computacional bruta. Durante a etapa de conversão *pcap-to-las*, o computador convencional apresentou tempo total de processamento de 4 min e 52 s, enquanto a Jetson Orin™ NX demandou aproximadamente 14 min e 45 s. De maneira semelhante, durante a etapa de processamento para geração do CHM, o computador convencional concluiu o processamento em 11 min e 19 s, enquanto a plataforma embarcada demandou aproximadamente 25 min e 14 s.

Tabela 5: Métricas de desempenho para a conversão de arquivos *pcap-to-las* nas plataformas PC e Jetson.

Plataforma	Tempo total de processamento	Utilização média da CPU	Tempo por milhão de pontos	Energia por milhão de pontos
NVIDIA® GeForce RTX™ 3060 Laptop	4m52s	60-80%	28,11 s/Mpts	1881,79 J/Mpts
NVIDIA® Jetson Orin™ NX	14m45s	80-95%	85,20 s/Mpts	783,21 J/Mpts

Tabela 6: Métricas de desempenho para o processamento do CHM nas plataformas PC e Jetson.

Plataforma	Tempo total de processamento	Utilização média da CPU	Tempo por milhão de pontos	Energia por milhão de pontos
NVIDIA® GeForce RTX™ 3060 Laptop	11m19s	60-70%	65,36 s/Mpts	1992,68 J/Mpts
NVIDIA® Jetson Orin™ NX	25m14s	100%	145,74 s/Mpts	901,03 J/Mpts

Apesar da vantagem em desempenho bruto, o computador convencional apresentou um consumo energético significativamente superior ao observado na plataforma embarcada. Durante a etapa de conversão *pcap-to-las*, o consumo energético normalizado por milhão de pontos processados foi aproximadamente 2,4 vezes maior no computador convencional em comparação à Jetson Orin™ NX. Um comportamento semelhante foi observado durante o processamento para geração do CHM, no qual o consumo energético da plataforma convencional foi aproximadamente 2,2 vezes superior. Dessa forma, embora a Jetson Orin™ NX tenha apresentado um maior tempo de processamento em comparação com o computador convencional, os resultados obtidos demonstraram que a plataforma possui potencial para aplicações de processamento LiDAR embarcado, principalmente devido à sua elevada eficiência energética e reduzido fator de forma.

3.4.2.2 Implementação do Processamento Embarcado na NVIDIA® Jetson Orin™ NX

Embora a plataforma NVIDIA® Jetson Orin™ NX tenha apresentado elevada eficiência energética e características adequadas para aplicações embarcadas, os testes iniciais demonstraram que o tempo necessário para a execução completa do *pipeline* de processamento ainda representava uma limitação importante para aplicações em tempo real ou quase em tempo real. Nesse contexto, visando reduzir a latência do processamento embarcado e aproximar o sistema de uma arquitetura de computação em borda compatível com aplicações UAV-LiDAR em agricultura de precisão, foi realizada uma etapa adicional de otimização baseada em aceleração por GPU utilizando a arquitetura NVIDIA CUDA®.

A implementação foi desenvolvida utilizando o *framework* NVIDIA CUDA® em conjunto com o *Software Development Kit* (SDK) do sensor LiDAR Ouster, que disponibiliza rotinas otimizadas para geração e manipulação de nuvens de pontos utilizando processamento paralelo em C++. Nesta etapa, foi mantido o mesmo *pipeline* ilustrado na Figura 11 e os mesmos algoritmos empregados anteriormente, utilizando as configurações padrão já adotadas durante os experimentos anteriores. Entretanto, diferentemente da implementação inicial baseada exclusivamente em processamento via *Central Processing Unit* (CPU), as operações computacionalmente mais intensivas passaram a ser executadas diretamente na GPU integrada da Jetson Orin™ NX. A utilização da arquitetura CUDA® permitiu explorar paralelismo massivo durante as etapas de processamento das nuvens de pontos, possibilitando que múltiplas operações fossem executadas simultaneamente na GPU embarcada. A Tabela 7 apresenta a comparação entre os tempos de processamento obtidos antes e após a implementação da aceleração baseada em GPU utilizando CUDA®. Observa-se uma redução significativa na latência tanto durante a etapa de conversão dos arquivos brutos *.pcap* quanto durante a geração do CHM, evidenciando o impacto da paralelização em GPU sobre o desempenho do *pipeline* embarcado.

Além da redução significativa do tempo de processamento, também foi possível obter uma representação mais organizada e refinada dos produtos derivados gerados a partir das nuvens

Tabela 7: Comparação do tempo de processamento do *pipeline* embarcado antes e após a aceleração por GPU utilizando CUDA®.

Etapa do <i>pipeline</i>	Sem aceleração CUDA®	Com Aceleração CUDA®	Redução
Conversão <i>pcap-to-las</i>	14m45s	6m44s	54,35%
Geração do CHM	25m14s	5 s	99,67%

de pontos LiDAR. A Figura 18 apresenta uma comparação entre os mapas de calor gerados antes e após a implementação das otimizações computacionais embarcadas. Observa-se que o *pipeline* acelerado produziu uma representação mais limpa e consistente da plantação, reduzindo significativamente a presença de ruídos e melhorando a definição espacial das linhas de cultivo. Além disso, nota-se uma melhor separação entre as regiões correspondentes à vegetação e as áreas de solo exposto, permitindo uma distinção mais clara entre a superfície do terreno e o dossel da cultura. As regiões associadas ao solo passaram a apresentar menor dispersão de pontos, contribuindo para uma representação mais homogênea do terreno. Consequentemente, as áreas vegetadas tornaram-se mais bem delimitadas, possibilitando uma visualização mais precisa das variações de altura ao longo da área monitorada. Esses resultados demonstram que a utilização de aceleração baseada em GPU não apenas reduziu o tempo necessário para geração do CHM, mas também contribuiu para tornar o processamento embarcado mais robusto e adequado para aplicações de agricultura de precisão utilizando plataformas UAV-LiDAR.

Além das otimizações relacionadas ao processamento embarcado utilizando CUDA®, também foram realizadas modificações na configuração de aquisição do sensor LiDAR com o objetivo de reduzir o volume de dados gerados e maximizar a eficiência do sensoramento da área agrícola monitorada. Inicialmente, o sensor operava utilizando uma janela completa de varredura horizontal (*azimuth window*) de 360°, resultando na captura de uma grande quantidade de pontos associados à estrutura do próprio UAV, além de regiões externas à área de interesse agrícola. Como ilustrado na Figura 19, essa configuração produzia nuvens de pontos contendo informações irrelevantes para a aplicação, aumentando significativamente o tamanho dos arquivos *.pcap* e impactando diretamente o tempo de processamento dos dados. Com o objetivo de concentrar a aquisição apenas na região útil da plantação, a janela angular horizontal foi reduzida de 360° para 120°. Dessa forma, observou-se uma redução significativa no tamanho dos arquivos *.pcap*, passando de 2.3 GB na configuração original para 1.6 GB na configuração otimizada, evidenciando a diminuição do volume de dados gerados durante as campanhas ex-




Figura 18: Comparação entre os mapas de calor gerados: (a) resultado obtido antes das otimizações computacionais; (b) resultado obtido após a implementação do *pipeline* acelerado com CUDA®.




Figura 19: Comparação entre as configurações de aquisição LiDAR utilizando janelas angulares horizontais (*azimuth window*) de: (a) 360°; (b) 120°.

perimentais. Essa modificação também permitiu aumentar a resolução angular horizontal do sensor de 512 para 1024 amostras, elevando a densidade espacial da nuvem de pontos na região efetivamente monitorada.

Como etapa final de otimização da plataforma, realizou-se a automação das etapas operacionais do sistema embarcado, visando reduzir a necessidade de intervenção manual durante as operações de voo. Inicialmente, diversas etapas do *pipeline*, incluindo a inicialização do sensor, a captura dos dados, a conversão dos arquivos e a execução do processamento, eram realizadas manualmente por meio de diferentes *scripts* e comandos executados separadamente. Com o avanço do desenvolvimento da arquitetura embarcada, os módulos responsáveis pela aquisição, armazenamento, processamento e geração dos produtos derivados passaram a operar de forma integrada e automática. Dessa forma, após a inicialização do sistema embarcado, o sensor LiDAR é automaticamente configurado e iniciado, permitindo a captura contínua dos pacotes de dados LiDAR e IMU. Em seguida, os arquivos adquiridos são processados automaticamente pelo *pipeline* implementado na plataforma NVIDIA® Jetson Orin™ NX, incluindo as etapas de conversão, reconstrução da nuvem de pontos e geração dos produtos derivados, como o CHM.

A automação do *pipeline* também permitiu reduzir erros operacionais associados à execução manual das etapas de processamento, além de melhorar a repetibilidade dos experimentos realizados durante as campanhas de voo. Adicionalmente, a arquitetura desenvolvida estabeleceu a base para futuras operações com processamento embarcado e transmissão de dados em campo, permitindo que os próximos esforços sejam direcionados à validação integrada da solução em missões reais de monitoramento agrícola. Embora a arquitetura proposta contemple a integração entre a plataforma UAV-LiDAR e a infraestrutura de comunicação TVWS, as atividades apresentadas nesta seção concentraram-se no desenvolvimento e na validação dos módulos de aquisição, processamento embarcado e comunicação local. A implementação e a validação experimental da transmissão de dados por meio de enlaces TVWS constituem a etapa subsequente do projeto e são apresentadas no relatório técnico da Atividade 4.4 – Demonstrações das Soluções Desenvolvidas no Projeto Brasil 6G.

3.4.3 Avaliação Preliminar da Comunicação Wi-Fi

Antes da integração com a infraestrutura TVWS, foram realizados testes preliminares de comunicação Wi-Fi com o objetivo de avaliar a viabilidade da transmissão dos dados gerados pelo sistema UAV-LiDAR até a estação terrestre (*Ground Station*). Esses experimentos busca-

ram avaliar o comportamento da taxa de transmissão em função da distância, fornecendo uma referência inicial para o dimensionamento da comunicação local da arquitetura proposta.

Para os ensaios, foi utilizado um roteador TP-Link TL-WR841HP configurado como ponto de acesso. O equipamento opera na faixa de 2,4 GHz, suporta os padrões IEEE 802.11 b/g/n e disponibiliza taxa nominal de até 300 Mbps, além de incorporar amplificadores de alta potência projetados para ampliar a cobertura sem fio. Inicialmente, os testes foram realizados entre dois computadores utilizando um adaptador Wi-Fi USB genérico conectado ao terminal cliente. As medições foram conduzidas em dois cenários distintos, ilustrados na Figura 20: um ambiente urbano, nas dependências do Inatel, e um ambiente rural, em uma lavoura de café. Em ambos os casos, a taxa de transmissão foi avaliada em função da distância entre o terminal cliente e o ponto de acesso, alcançando até aproximadamente 80 m. Posteriormente, o adaptador genérico foi substituído por um TP-Link TL-WN8200ND, dispositivo compatível com IEEE 802.11n e equipado com duas antenas externas de 5 dBi, permitindo maior sensibilidade de recepção e potência de transmissão quando comparado a adaptadores convencionais. Novos testes de alcance foram então realizados nas dependências do Inatel utilizando a mesma infraestrutura de rede.

As taxas de transmissão, medidas para os diferentes cenários avaliados, são apresentadas na Tabela 8. Os ensaios foram realizados em função da distância entre o terminal cliente e o ponto de acesso, permitindo comparar o desempenho do adaptador Wi-Fi genérico e do adaptador TP-Link TL-WN8200ND em ambientes distintos. Observa-se que a taxa de transmissão apresenta tendência de redução com o aumento da distância em todos os cenários avaliados. Entretanto, diferenças significativas podem ser observadas em função do ambiente de propagação e do *hardware* utilizado. Os testes realizados em ambiente rural apresentaram, em diversas distâncias, desempenho superior ao observado nas dependências do Inatel, possivelmente em razão da menor presença de obstáculos e fontes de interferência eletromagnética. Além disso, a utilização do adaptador TP-Link TL-WN8200ND resultou em ganhos expressivos de desempe-




Figura 20: Imagens aéreas dos cenários: (a) ambiente urbano nas dependências do Inatel; (b) ambiente rural em lavoura de café. As linhas indicam o percurso utilizado para avaliação da taxa de transmissão em função da distância. Fonte da imagem de satélite: Google Maps.

nho quando comparada ao adaptador genérico, principalmente para distâncias superiores a 40 m. A melhoria observada pode ser explicada pelas características de radiofrequência do adaptador TP-Link TL-WN8200ND. Considerando potência de transmissão de até 20 dBm e antenas externas de 5 dBi, a configuração apresenta maior orçamento de enlace quando comparada a adaptadores USB convencionais de baixo ganho. Dessa forma, espera-se que a utilização desse adaptador em ambiente rural possa resultar em taxas de transmissão ainda mais elevadas e em maior alcance operacional. Entretanto, essa hipótese deverá ser confirmada experimentalmente em trabalhos futuros.

Tabela 8: Taxa de transmissão Wi-Fi em função da distância para diferentes adaptadores e ambientes de teste.

Distância (m)	Adaptador Genérico (Inatel) Mbps	Adaptador Genérico (Lavoura de Café) Mbps	TP-Link TL-WN8200ND (Inatel) Mbps
0	63,8	89,6	58,5
10	42,5	92,8	69,2
20	43,9	78,3	70,3
30	42,8	74,1	49,7
40	20,2	54,8	33,9
60	24,6	61	30,6
80	4,5	47,1	29,5

Além dos testes de alcance, foi realizada uma validação funcional da arquitetura de comunicação por meio da transferência de arquivos representativos da aplicação final. Utilizando o adaptador TP-Link TL-WN8200ND, estabeleceu-se uma comunicação baseada no protocolo IP entre os dispositivos da rede, permitindo a transmissão bem-sucedida dos produtos gerados pelo processamento dos dados LiDAR. Nessa etapa, foram transferidos um mapa de calor da plantação e um CHM, demonstrando a capacidade da infraestrutura proposta de encaminhar informações processadas entre o sistema UAV-LiDAR e a estação base terrestre. Como o objetivo desta avaliação foi verificar a viabilidade da comunicação e da transferência dos produtos gerados pela aplicação, não foram realizadas medições de desempenho em função da distância ou da taxa efetiva de transmissão.

3.5 Avaliação de Ferramentas Complementares para Análise de Dados LiDAR

Além do desenvolvimento da arquitetura principal de processamento implementada em C++ e CUDA, foram realizadas avaliações exploratórias utilizando o ambiente MATLAB® [version 2025b], com o objetivo de investigar ferramentas adicionais para análise e processamento de dados LiDAR. Para isso, foi empregada a *LiDAR Toolbox*[™], que disponibiliza um conjunto abrangente de algoritmos e funções dedicadas à visualização, filtragem, segmentação e extração de informações a partir de nuvens de pontos tridimensionais. A utilização dessa ferramenta permitiu explorar diferentes abordagens para processamento e interpretação dos dados adquiridos pelo sistema UAV-LiDAR, complementando as análises realizadas na plataforma desenvolvida ao longo do projeto. Embora essas ferramentas não tenham sido incorporadas ao fluxo operacional principal da arquitetura proposta, sua avaliação permitiu identificar funcionalidades potencialmente relevantes para trabalhos futuros, especialmente no desenvolvimento de métodos

avancados para caracterização estrutural da vegetação e extração de parâmetros agrônômicos a partir dos dados LiDAR.

3.5.1 Metodologia de Aquisição e Processamento de Dados

Para essa análise, foi empregada a mesma metodologia de aquisição de dados previamente desenvolvida no projeto, baseada na captura dos pacotes provenientes dos sensores LiDAR e IMU e no armazenamento dos dados em arquivos *.pcap*. Entretanto, nesta etapa, a aquisição foi realizada utilizando a plataforma NVIDIA[®] Jetson Orin[™] NX, desenvolvida ao longo deste projeto para substituir a arquitetura anterior baseada em Raspberry Pi e possibilitar futuras aplicações de processamento em borda. Após a aquisição dos dados, os arquivos *.pcap* foram convertidos para o formato *.las*, permitindo sua importação para o ambiente MATLAB[®]. A aplicação *LiDAR Viewer*[™] do MATLAB[®] é utilizada para determinar empiricamente os parâmetros mais adequados para o algoritmo SMRF. Para as análises realizadas, foram adotados os seguintes parâmetros: *grid resolution* igual a 1, *maximum window radius* de 18, *slope threshold* de 0,15, *elevation threshold* de 0,5 e *elevation scaling factor* igual a 1. Esses parâmetros diferem daqueles utilizados nas análises anteriores, pois foram ajustados especificamente para a nuvem de pontos obtida neste experimento, considerando as características da área analisada e a densidade de pontos adquirida. O ajuste teve como objetivo otimizar a separação entre terreno e vegetação durante a classificação realizada pelo algoritmo SMRF. Dessa forma, embora os valores dos parâmetros tenham sido modificados, a metodologia de processamento permaneceu inalterada, sendo alterada apenas a calibração do algoritmo para as características do conjunto de dados analisado.

Após a classificação dos pontos de terreno, é realizada a normalização topográfica da nuvem de pontos, com o objetivo de evitar que as variações naturais do relevo influenciem as medições agrônômicas. Esse procedimento consiste na geração do DTM a partir dos pontos classificados como solo e na posterior subtração desse modelo da nuvem de pontos original. Como resultado, estabelece-se uma referência plana para a cena, fazendo com que o eixo vertical represente exclusivamente a altura da vegetação em relação ao solo. Em seguida, considerando que o objetivo da análise está voltado para plantas de café, aplica-se um filtro de altura máxima para eliminar elementos não pertencentes à cultura de interesse, como árvores e outras estruturas vegetais. Por fim, o CHM é obtido pela diferença entre o DSM e o DTM.

Para reduzir o volume de dados processados e restringir a análise à região de interesse (*Region of Interest* (ROI)), foi definida manualmente uma área poligonal correspondente à segunda linha da plantação avaliada. Essa abordagem permite isolar apenas as plantas de café de interesse e possibilita a comparação direta dos resultados obtidos com medições realizadas em campo. Embora adequada para a validação experimental, a definição manual da ROI limita a escalabilidade da metodologia. Em aplicações práticas, essa etapa deverá ser automatizada, utilizando técnicas de segmentação ou informações de georreferenciamento, de forma a eliminar a intervenção do operador e permitir o processamento de grandes áreas agrícolas. A etapa seguinte consiste na segmentação individual das plantas para estimar parâmetros como quantidade e altura de cada planta. Inicialmente, são identificados marcadores topológicos no CHM, correspondentes aos máximos locais associados ao ponto mais elevado de cada planta. Após a identificação desses picos, o CHM é invertido matematicamente e submetido a um algoritmo de segmentação do tipo *Watershed* controlado por marcadores. Trabalhos recentes têm demonstrado que a combinação de marcadores topológicos com a segmentação *Watershed* reduz significativamente problemas de subsegmentação em copas sobrepostas [38, 39]. O método si-

mula o preenchimento gradual das regiões mais baixas da superfície invertida até que os níveis simulados de inundação se encontrem. As linhas de interseção resultantes definem os limites físicos entre as plantas, permitindo separar automaticamente as copas dos cafeeiros em entidades individuais passíveis de quantificação e análise.

Após a delimitação geométrica das plantas e a validação das estimativas de altura, foram realizadas estimativas de volume vegetativo e biomassa, com o objetivo de ampliar o conjunto de informações agronômicas extraídas dos dados LiDAR. Inicialmente, o volume individual de cada planta é calculado a partir do CHM, multiplicando-se a área correspondente a cada pixel pelo respectivo valor de altura e somando-se os microvolumes de todos os pixels contidos dentro dos limites segmentados de cada planta. A partir dos volumes obtidos, é possível estimar a biomassa seca aérea total (*Above-Ground Biomass* (AGB)) por meio da aplicação de constantes de calibração específicas para a cultura analisada. Neste trabalho, a biomassa foi estimada por [40]

$$AGB = V_{plant} \cdot 2,85, \quad (4)$$

onde V_{plant} é o volume da planta. Uma informação adicional que pode ser obtida a partir da biomassa é a quantidade de carbono armazenado na vegetação, representada por C . Para essa estimativa, utiliza-se o fator de conversão de 0,47 recomendado pelo *Intergovernmental Panel on Climate Change* (IPCC), conforme apresentado a seguir [40]

$$C = AGB \cdot 0,47. \quad (5)$$

Por fim, os valores de carbono estocado podem ser convertidos em dióxido de carbono equivalente retido (CO_{2e}), permitindo relacionar os dados estruturais obtidos pelo LiDAR com indicadores ambientais associados ao sequestro de carbono. Essa conversão é realizada utilizando o fator 3,667, correspondente à razão entre as massas moleculares do dióxido de carbono e do carbono, dado por [40]

$$CO_{2e} = C \cdot 3,667. \quad (6)$$

Dessa forma, para cada quilograma de carbono armazenado na biomassa vegetal, estima-se que aproximadamente 3,667 kg de CO_2 tenham sido removidos da atmosfera e incorporados à vegetação. A Figura 21 apresenta o fluxo completo de processamento empregado, desde a aquisição dos dados LiDAR até a obtenção dos indicadores agronômicos e ambientais derivados das nuvens de pontos [40].




Figura 21: Fluxograma do processamento dos dados, desde a aquisição das nuvens de pontos LiDAR até a obtenção de indicadores agronômicos e ambientais.

3.5.2 Validação Experimental em Lavoura de Café

A área de estudo, ilustrada na Figura 22, consiste em uma plantação de café (*Coffea arabica* L.) localizada em Santa Rita do Sapucaí, Minas Gerais, Brasil ($22^{\circ}21'11,1''\text{S}$, $45^{\circ}68'07,1''\text{W}$). Na área experimental, os cafeeiros estão dispostos em linhas retas sobre terreno plano. Os dados LiDAR foram adquiridos em 27 de fevereiro de 2026, enquanto as medições de referência da altura das plantas foram realizadas no mesmo dia utilizando fita métrica. Ao todo, foram coletadas 41 amostras na segunda linha da plantação, utilizadas para validação dos resultados obtidos a partir do processamento das nuvens de pontos. A Figura 23 apresenta a configuração experimental utilizada durante a campanha de aquisição, evidenciando a integração entre o sensor LiDAR e a plataforma NVIDIA® Jetson Orin™ NX, responsável pela aquisição, armazenamento e processamento inicial dos dados embarcados.



Figura 22: Área experimental utilizada nas campanhas de aquisição de dados LiDAR em Santa Rita do Sapucaí, Minas Gerais, Brasil. Fonte da imagem de satélite: Google Earth.




Figura 23: Plataforma UAV-LiDAR desenvolvida para aquisição de dados LiDAR utilizando arquitetura embarcada baseada na NVIDIA® Jetson Orin™ NX.

A Figura 24 apresenta um mapa de calor gerado a partir do CHM obtido dos dados LiDAR. Nesse tipo de representação, as diferentes cores indicam a altura estimada da vegetação em relação ao solo, permitindo uma interpretação visual rápida da distribuição espacial das plantas ao longo da área monitorada. As regiões em verde correspondem às maiores alturas, enquanto

os tons em vermelho representam áreas de menor elevação, associadas principalmente ao solo exposto ou à vegetação de menor porte. É possível observar claramente a disposição das linhas de cultivo do cafeeiro, bem como a variabilidade de altura existente entre diferentes plantas e trechos da lavoura. Nota-se também a presença de regiões externas às linhas de cultivo contendo vegetação de maior porte, correspondentes a árvores e outros elementos do ambiente. Esses elementos foram posteriormente removidos por meio da definição da região de interesse e da aplicação dos filtros descritos anteriormente, de forma a restringir as análises às plantas de café. Os resultados obtidos demonstram que o fluxo de processamento implementado foi capaz de transformar a nuvem de pontos tridimensional em uma representação bidimensional de fácil interpretação, preservando as principais características estruturais da plantação e permitindo análises quantitativas da vegetação.




Figura 24: Mapa de calor representando a altura estimada da vegetação do cafezal, em metros, obtida a partir do CHM derivado dos dados LiDAR.

Após a geração do CHM, foi realizada a seleção da região de interesse (ROI), conforme ilustrado na Figura 25. A área selecionada corresponde à segunda linha da plantação, escolhida por possuir medições de referência obtidas em campo. Essa etapa permite reduzir o volume de dados processados e restringir as análises às plantas efetivamente consideradas na validação experimental. Em seguida, foi aplicado o algoritmo *Watershed* controlado por marcadores para realizar a segmentação individual dos cafeeiros. Inicialmente, foram identificados máximos locais no CHM, correspondentes aos pontos de maior altura de cada planta. Esses marcadores foram utilizados como referência para a delimitação automática das copas, permitindo separar indivíduos adjacentes mesmo em regiões com elevada proximidade entre plantas. O resultado da segmentação é apresentado na ampliação mostrada à direita da Figura 25, onde cada região colorida representa uma planta individual identificada pelo algoritmo. Observa-se que o método foi capaz de distinguir adequadamente os diferentes cafeeiros ao longo da linha de cultivo, fornecendo uma base consistente para a extração de parâmetros agrônômicos individualizados,

como altura máxima, volume vegetativo e biomassa. A segmentação individual das plantas constitui uma etapa fundamental do fluxo de processamento, uma vez que permite transformar a nuvem de pontos e os produtos derivados do CHM em informações associadas a cada planta, possibilitando análises mais detalhadas da variabilidade espacial da lavoura.




Figura 25: Seleção da ROI e subsequente segmentação individual dos cafeeiros utilizando o algoritmo *Watershed* controlado por marcadores.

A Figura 26 apresenta a validação estatística das estimativas de altura obtidas a partir do processamento dos dados LiDAR. Foram avaliadas 41 plantas de café individualmente segmentadas, comparando-se as alturas estimadas pelo sistema UAV-LiDAR com as medições de referência realizadas em campo. A Figura 26(a) mostra a comparação direta entre os valores medidos e estimados para cada planta. Observa-se que o perfil de alturas obtido pelo sistema acompanha de forma consistente a tendência observada nas medições de campo ao longo de toda a linha analisada. O RMSE obtido foi de 9,36 cm, indicando boa concordância entre os valores estimados e os dados de referência. A análise de correlação apresentada na Figura 26(b) resultou em um R^2 de 0,74, evidenciando uma correlação significativa entre as alturas medidas e estimadas. Além disso, a reta de regressão obtida apresentou coeficiente angular de 0,95 e intercepto de aproximadamente 7 cm, sugerindo que o método reproduz adequadamente a variação de altura observada na lavoura. As métricas complementares de erro resultaram em RMSE de 0,09 m e MAE de 0,07 m.

A distribuição dos erros residuais, apresentada na Figura 26(c), mostra que a maioria das estimativas permanece concentrada próxima de zero, sem a presença de tendências sistemáticas evidentes de superestimação ou subestimação. Embora algumas plantas apresentem erros superiores a 15 cm, observa-se que a maior parte dos resíduos permanece dentro da faixa de ± 10 cm, corroborando a consistência dos resultados obtidos. De forma geral, os resultados demonstram que a metodologia baseada em UAV-LiDAR foi capaz de estimar a altura dos cafeeiros com precisão compatível com os trabalhos reportados na literatura para cultivos agrícolas. Considerando a complexidade estrutural dos cafeeiros, caracterizados por copas irregulares e sobreposição de ramos, os resultados obtidos indicam o potencial da abordagem para aplicações de monitoramento agrícola e extração automática de parâmetros agrônômicos.




Figura 26: Validação estatística das estimativas de altura obtidas por meio do sistema UAV-LiDAR. (a) Comparação entre as medições de referência realizadas em campo e as alturas estimadas a partir dos dados LiDAR. (b) Resultado da regressão linear e métricas de qualidade do ajuste. (c) Distribuição dos erros residuais associados às plantas de café segmentadas individualmente.

Após a validação das estimativas de altura, foram extraídos parâmetros agronômicos adicionais para cada planta segmentada, incluindo volume vegetativo e biomassa estimada. Os resultados são apresentados na Figura 27, que reúne os principais indicadores estruturais obtidos a partir do processamento das nuvens de pontos LiDAR para as 41 plantas presentes na região de interesse. Os resultados evidenciam a variabilidade estrutural existente entre os diferentes indivíduos da lavoura, refletida nas diferenças observadas entre as alturas máximas, volumes de copa e biomassa estimada. O volume médio individual das plantas foi de $0,93 \text{ m}^3$, enquanto a área média projetada das copas foi de $1,06 \text{ m}^2$. Observa-se ainda que plantas com alturas semelhantes podem apresentar volumes distintos, demonstrando que a altura, isoladamente, não é suficiente para caracterizar completamente o desenvolvimento vegetativo dos cafeeiros.

A partir dos volumes estimados, foi calculada a AGB da região de interesse, resultando em aproximadamente 108,7 kg para o conjunto das 41 plantas analisadas, correspondendo a uma média de 2,65 kg por planta. Utilizando os fatores de conversão adotados, estimou-se um estoque total de carbono de 51,09 kg, equivalente a aproximadamente 187,35 kg de dióxido de carbono equivalente (CO_{2e}) retido pela vegetação. As maiores estimativas de biomassa fo-




Figura 27: Perfil agrônomo obtido para a região de interesse (ROI), contendo os parâmetros estruturais estimados a partir dos dados LiDAR.

ram observadas para as plantas localizadas aproximadamente entre os identificadores 10 e 30, coincidindo com indivíduos que apresentaram maior desenvolvimento vegetativo. Embora os valores de biomassa e carbono apresentados tenham caráter exploratório e dependam dos fatores de calibração adotados, os resultados demonstram a capacidade das ferramentas avaliadas em transformar nuvens de pontos tridimensionais em informações agrônômicas de maior valor agregado, ampliando as possibilidades de utilização dos dados LiDAR em sistemas de monitoramento agrícola. Além da estimativa de altura, a metodologia permite caracterizar aspectos relacionados ao porte vegetativo e ao acúmulo de biomassa, fornecendo informações que podem ser utilizadas em aplicações de agricultura de precisão, monitoramento do desenvolvimento das culturas e avaliação de produtividade.

Embora os resultados obtidos demonstrem o potencial da metodologia para extração de informações agrônômicas a partir de dados UAV-LiDAR, alguns aspectos podem ser aprimorados em trabalhos futuros. As medições de referência utilizadas na validação foram realizadas manualmente em campo, estando sujeitas às incertezas inerentes ao processo de medição. Adicionalmente, as estimativas de biomassa foram obtidas a partir de relações empíricas reportadas na literatura, não sendo acompanhadas por campanhas destrutivas de amostragem para calibração específica da área estudada. Como continuidade deste trabalho, recomenda-se a realização de campanhas experimentais mais abrangentes, incluindo a coleta de parâmetros adicionais, como diâmetro do tronco, dimensões da copa e biomassa de referência. Essas informações poderão contribuir para o desenvolvimento de modelos alométricos específicos para a cultura do café e para o aumento da precisão das estimativas agrônômicas derivadas dos dados LiDAR.

3.6 Direções Futuras

Como continuidade deste trabalho, pretende-se realizar a validação da arquitetura completa em condições reais de operação, utilizando o sistema UAV-LiDAR equipado com a plataforma NVIDIA® Jetson Orin™ NX durante missões de voo em lavouras de café. Embora as etapas individuais de aquisição, processamento e comunicação tenham sido avaliadas separadamente, a validação integrada em campo permitirá verificar o desempenho da arquitetura completa durante operações reais, contemplando a aquisição dos dados, processamento embarcado, geração de produtos derivados e transmissão das informações para usuários remotos. Essa etapa também possibilitará quantificar métricas como tempo total de processamento, latência fim a fim, consumo energético da plataforma embarcada e impacto das condições operacionais sobre o desempenho do sistema.

Outra etapa importante consiste na expansão dos experimentos envolvendo a infraestrutura de comunicação baseada em TVWS. Embora testes preliminares documentados no relatório técnico da Atividade 4.4 – Demonstrações das Soluções Desenvolvidas no Projeto Brasil 6G tenham demonstrado a viabilidade da solução em ambiente de laboratório, ainda são necessárias campanhas experimentais adicionais em áreas agrícolas para avaliação do alcance efetivo da comunicação, robustez do enlace, capacidade de transmissão de dados e comportamento do sistema em cenários sujeitos a obstáculos, relevo irregular e diferentes condições ambientais. Esses experimentos complementarão os resultados já obtidos, permitindo uma validação mais abrangente da utilização de TVWS como tecnologia habilitadora para conectividade de longa distância em aplicações de agricultura de precisão.

Do ponto de vista do processamento dos dados LiDAR, pretende-se expandir os algoritmos atualmente empregados para a extração de parâmetros agrônômicos avançados. Além da estimativa de altura das plantas, serão investigadas metodologias para a obtenção de métricas relacionadas ao volume vegetativo, biomassa, IAF, caracterização estrutural das copas e estimativas de estoque de carbono. Também se pretende ampliar as campanhas de validação em campo, incorporando medições adicionais, como diâmetro dos troncos, dimensões das copas e dados de biomassa de referência, visando ao desenvolvimento de modelos específicos para a cultura do café.

Adicionalmente, pretende-se investigar técnicas de processamento em tempo quase real, explorando de forma mais intensiva os recursos computacionais da NVIDIA® Jetson Orin™ NX. O objetivo é reduzir o intervalo entre a aquisição dos dados e a disponibilização das informações agrônômicas, estabelecendo, em trabalhos futuros, metas quantitativas de desempenho, como o tempo máximo admissível para geração do CHM ou o processamento contínuo de blocos de dados durante o voo.

Por fim, pretende-se expandir a aplicação da plataforma para outras culturas agrícolas e cenários de monitoramento remoto, avaliando a adaptabilidade da arquitetura proposta a diferentes tipos de vegetação, padrões de plantio e requisitos operacionais. Espera-se que os avanços futuros contribuam para o desenvolvimento de sistemas inteligentes de monitoramento agrícola capazes de integrar sensoriamento remoto, processamento em borda e conectividade sem fio avançada, alinhando-se aos requisitos das futuras aplicações suportadas pelas redes 6G.

4 Criação de um Conjunto de Dados LiDAR Sintético com BlenSor

Este capítulo apresenta a continuidade das atividades relacionadas à criação de um conjunto de dados sintético LiDAR utilizando o simulador BlenSor. Nesta etapa, além da geração das cenas e das nuvens de pontos, foi consolidado um fluxo computacional para organizar os dados, preparar as anotações, aplicar transformações geométricas e avaliar modelos de aprendizado profundo em tarefas de classificação de cenas e objetos. O objetivo é estabelecer uma base reprodutível para a análise de métodos de percepção tridimensional, mantendo o foco em aplicações com pessoas e animais em ambientes simulados.

4.1 Contextualização e Descrição Quantitativa do Conjunto de Dados

A etapa anterior, reportada no Relatório 1 da Atividade 3.1 da Fase III do Projeto Brasil 6G, concentrou-se na construção inicial das cenas sintéticas no BlenSor, na importação dos modelos tridimensionais e na geração de nuvens de pontos associadas às classes Pessoa, Cachorro, Gato, Grandes Felinos, Vaca, Cavalo, Porco e Lobo. Cada cena foi simulada a partir de varreduras LiDAR, resultando em arquivos de nuvens de pontos e em anotações espaciais associadas aos objetos presentes. Essa base inicial permitiu estabelecer o fluxo de produção dos dados e identificar os principais desafios relacionados à escalabilidade do processo, especialmente aqueles associados à criação manual das cenas e à validação das anotações.

O conjunto atualmente documentado contém 143 cenas, 314 objetos anotados e 1 426 595 pontos no total. As cenas apresentam variação relevante de densidade, com 364 a 97 642 pontos por cena, bem como variação na composição, com 0 a 11 objetos anotados por amostra. Essa diversidade inicial permite avaliar o comportamento dos modelos em cenários com diferentes níveis de ocupação espacial, densidade de pontos e combinação de classes. A Tabela 9 apresenta o resumo quantitativo do conjunto de dados.

Tabela 9: Resumo quantitativo do conjunto de dados LiDAR sintético.

Indicador	Mín.	Média	Mediana	Máx.	Total
Cenas	–	–	–	–	143
Objetos anotados	–	–	–	–	314
Pontos por cena	364	9 976,19	2 984	97 642	1 426 595
Objetos por cena	0	2,20	1	11	314
Pontos em caixas delimitadoras por cena	0	2 546,37	2 072	10 968	364 131

A distribuição das classes é apresentada na Tabela 10. Observa-se que Pessoa é a classe mais frequente, representando 31,53% das anotações e aparecendo em 45 cenas. Em contraste, Porco apresenta a menor frequência, com 15 anotações e ocorrência em 11 cenas. Essa distribuição deve ser considerada na análise experimental, pois classes menos representadas podem exigir métricas por classe, ponderação da função de perda ou estratégias controladas de aumento para reduzir viés de treinamento.

Além da variação natural de densidade e composição das cenas, o repositório prevê a expansão experimental por transformações geométricas e estruturais, incluindo recorte, remoção

Tabela 10: Distribuição de classes no conjunto de dados LiDAR sintético.

ID	Classe	Anotações	Anotações (%)	Cenas	Cenas (%)
0	Pessoa	99	31,53	45	31,47
1	Cachorro	47	14,97	31	21,68
2	Gato	21	6,69	21	14,69
3	Grandes Felinos	46	14,65	20	13,99
4	Vaca	25	7,96	16	11,19
5	Cavalo	29	9,24	13	9,09
6	Porco	15	4,78	11	7,69
7	Lobo	32	10,19	20	13,99

de pontos, deformação elástica, espelhamento, perturbação gaussiana, mosaico, rotação, escala, inserção de contexto ao redor do objeto e translação. Essas variações são tratadas como fatores experimentais controlados, não como novas classes. Consequentemente, as amostras aumentadas devem preservar a identidade da cena de origem, de modo que a divisão entre treinamento, validação e teste seja feita no nível da cena e evite vazamento de informação.

4.2 Desenvolvimento Atual

Nesta etapa, o trabalho passa a ser estruturado como um estudo centrado em dados, no qual o conjunto sintético é utilizado para avaliar o comportamento de modelos de classificação em nuvens de pontos. Diferentemente de uma tarefa de detecção de objetos, uma das formulações de interesse considera a classificação de cena em regime multirrótulo, na qual uma mesma amostra pode conter uma ou mais classes simultaneamente. Essa formulação é adequada ao conjunto gerado, pois as cenas podem incluir diferentes combinações de pessoas e animais, com variações de posição, oclusão parcial, densidade de pontos e distribuição espacial. Contudo, para manter uma comparação mais direta com a literatura e reduzir a complexidade inicial da análise experimental, os treinamentos iniciais serão conduzidos com cenas contendo apenas um objeto por amostra. Após a avaliação de desempenho e do custo computacional nessas condições controladas, será analisada a viabilidade de estender o protocolo para o cenário multirrótulo, no qual a mesma cena poderá conter múltiplas classes simultaneamente.

O fluxo computacional em desenvolvimento contempla a preparação das nuvens de pontos, a normalização das coordenadas, a reamostragem para um número fixo de pontos e a organização das etiquetas. Na formulação multirrótulo, cada cena é representada por um vetor binário de oito posições, em que cada posição indica a presença ou ausência de uma das classes consideradas. Essa representação permite treinar modelos com múltiplas saídas sigmoidais, utilizando uma função de perda baseada em *Binary Cross-Entropy* (BCE), o que é mais apropriado do que uma saída *softmax* quando as classes não são mutuamente exclusivas. Já nos experimentos iniciais com um único objeto por cena, a organização das amostras será feita de modo a permitir uma comparação mais direta com protocolos tradicionalmente empregados na literatura de classificação de nuvens de pontos.

Também foi iniciada a preparação de experimentos em nível de objeto, nos quais cada instância é recortada da cena a partir de sua caixa delimitadora tridimensional. Nesse caso, o problema passa a ser tratado como classificação de objeto individual, permitindo avaliar separadamente a capacidade dos modelos de reconhecer geometrias isoladas. Essa dupla perspectiva,

em nível de cena e em nível de objeto, amplia o potencial de uso do conjunto de dados, pois permite investigar tanto a composição global do ambiente quanto o reconhecimento local das classes simuladas.

A etapa de modelagem considera arquiteturas representativas para aprendizado em nuvens de pontos, incluindo PointNet, PointNet++, *Dynamic Graph Convolutional Neural Network* (DGCNN) e PointMLP. Esses modelos foram selecionados por apresentarem diferentes níveis de complexidade e diferentes formas de explorar a geometria dos pontos. A adaptação para o conjunto sintético em desenvolvimento considera entradas com número fixo de pontos e uma camada de saída compatível com as oito classes do problema. Dessa forma, o mesmo conjunto de dados poderá ser usado para comparar modelos com diferentes características arquiteturais sob um protocolo comum.

4.3 Estudo Detalhado de Memória e Custo Computacional

Como parte da preparação dos experimentos de classificação em nuvens de pontos, foi conduzido um estudo de custo computacional para estimar a viabilidade de treinamento dos modelos PointNet, DGCNN, PointMLP e PointNet++. A análise considerou diferentes tamanhos de lote B e diferentes números de pontos N por amostra. O varrimento utilizou $B \in \{2, 4, 8, 16, 32, 64\}$ e valores de N entre 1024 e 97280 pontos, com passo de 1024 pontos. As medições de pico correspondem à passagem direta dos modelos. Portanto, os valores de memória de treinamento apresentados nesta seção devem ser interpretados como limites inferiores estimados, pois incluem parâmetros, gradientes, estados do otimizador, entradas, ativações e tensores temporários, mas ainda precisam ser validados por medições completas com retropropagação.

A Tabela 11 apresenta o ponto de referência inicial para $B = 2$ e $N = 1024$. Observa-se que o PointNet possui o menor custo de memória estimado para treinamento, atingindo 0,17 GiB, seguido pelo PointNet++, com 0,42 GiB. O DGCNN apresenta custo superior, com 0,65 GiB, devido à construção dinâmica de grafos e aos tensores temporários associados às operações de vizinhança. O PointMLP apresenta o maior custo nesse ponto de operação, com 1,78 GiB estimados para treinamento, principalmente em razão dos agrupamentos locais e dos estágios residuais de alta dimensionalidade.

Tabela 11: Custo computacional inicial para $B = 2$ e $N = 1024$ pontos por amostra.

Modelo	Parâm.	M_{train}	M_{infer}	Pico	MAC	Tempo
PointNet	3,47 M	0,17 GiB	0,07 GiB	0,04 GiB	0,91 G	202,78 ms
DGCNN	1,80 M	0,65 GiB	0,38 GiB	0,14 GiB	5,95 G	325,10 ms
PointMLP	13,23 M	1,78 GiB	0,85 GiB	0,12 GiB	31,41 G	260,21 ms
PointNet++	1,46 M	0,42 GiB	0,21 GiB	0,05 GiB	1,74 G	335,49 ms

Além da medição pontual, foram ajustadas expressões empíricas para estimar a memória de treinamento em função de B e N , conforme apresentado na Tabela 12. As expressões foram obtidas por regressão de mínimos quadrados sobre as configurações executadas com sucesso no varrimento, usando como variável dependente o limite inferior de memória de treinamento reportado pelos *scripts* de análise. O modelo de regressão considerou os termos B , BN e BN^2 , de modo que o termo B capturasse componentes proporcionais ao lote, o termo BN representasse ativações lineares no número de pontos e o termo BN^2 representasse estruturas quadráticas, como matrizes de distância e agrupamentos locais.

Tabela 12: Expressões empíricas para estimativa da memória de treinamento em GiB.

Modelo	Memória estimada de treinamento
PointNet	$\widehat{M}_{\text{train}} = 5,177 \times 10^{-2} + 7,642 \times 10^{-5}B + 5,653 \times 10^{-5}BN$
DGCNN	$\widehat{M}_{\text{train}} = 2,686 \times 10^{-2} + 2,295 \times 10^{-5}B + 2,911 \times 10^{-4}BN + 1,490 \times 10^{-8}BN^2$
PointMLP	$\widehat{M}_{\text{train}} = 1,973 \times 10^{-1} + 2,295 \times 10^{-5}B + 7,684 \times 10^{-4}BN + 2,474 \times 10^{-9}BN^2$
PointNet++	$\widehat{M}_{\text{train}} = 2,185 \times 10^{-2} + 1,976 \times 10^{-1}B + 1,919 \times 10^{-6}BN$

A Tabela 13 resume a qualidade dos ajustes empíricos e deve ser interpretada em conjunto com o procedimento de coleta dos dados. A coluna *Configurações utilizadas no ajuste* indica quantas combinações (B, N) puderam ser efetivamente empregadas na regressão para cada arquitetura. Neste estudo, o varrimento completo considerou $B \in \{2, 4, 8, 16, 32, 64\}$ e valores de N entre 1 024 e 97 280, totalizando até 570 combinações por modelo. Entretanto, nem todas essas combinações produziram uma medição utilizável. Configurações que falharam por falta de memória, interrupção de execução ou impossibilidade de completar a passagem direta não geram um valor numérico confiável para M_{train} e, portanto, não podem ser incluídas diretamente em um ajuste por mínimos quadrados. Por essa razão, a regressão foi construída apenas com as configurações para as quais a execução foi concluída com sucesso e o *script* retornou uma estimativa consistente de memória.

Tabela 13: Número de configurações utilizadas no ajuste e erro residual das expressões empíricas de memória.

Modelo	Configurações utilizadas no ajuste	MAE (GiB)	RMSE (GiB)	R^2
PointNet	495	$< 10^{-6}$	$< 10^{-6}$	1,000
DGCNN	78	$< 10^{-6}$	$< 10^{-6}$	1,000
PointMLP	87	$< 10^{-6}$	$< 10^{-6}$	1,000
PointNet++	471	$< 10^{-5}$	$< 10^{-5}$	1,000

Essa distinção é relevante porque as falhas observadas em configurações extremas não correspondem a observações quantitativas completas, mas sim a uma indicação de que o consumo ultrapassou o limite operacional da GPU. Em termos estatísticos, esses casos podem ser entendidos como observações censuradas à direita, e não como medições numéricas equivalentes às execuções bem-sucedidas. Caso fossem incluídas artificialmente no ajuste, mediante a atribuição de valores arbitrários de memória, as expressões resultantes tenderiam a ficar enviesadas e perderiam interpretação física. Assim, o ajuste foi deliberadamente restrito à região observável do espaço (B, N) , enquanto as falhas foram analisadas separadamente nas tabelas de fronteira de execução e na discussão dos mecanismos dominantes de consumo de memória.

As colunas MAE, RMSE e R^2 quantificam a qualidade do ajuste. O MAE representa o erro absoluto médio e indica, em termos diretos, o desvio médio entre a estimativa e o valor medido, em GiB. O RMSE atribui maior peso a discrepâncias mais elevadas e, por isso, é particularmente útil para identificar a presença de erros localizados mais pronunciados. Já o R^2 expressa a fração da variabilidade observada que é explicada pelo modelo ajustado. Valores próximos de

1 indicam que a expressão empírica reproduz com elevada fidelidade o comportamento medido na faixa de dados considerada.

As diferenças entre as contagens de configurações utilizadas no ajuste também ajudam a interpretar a dificuldade computacional de cada arquitetura. PointNet e PointNet++ apresentaram 495 e 471 configurações, respectivamente, o que mostra que grande parte do varrimento pôde ser executada com sucesso. Em contraste, DGCNN e PointMLP apresentaram apenas 78 e 87 configurações, respectivamente, porque o crescimento mais acelerado do consumo de memória restringiu fortemente a região observável antes da ocorrência de falhas. Portanto, essa diferença não decorre de uma amostragem desigual planejada, mas da própria limitação prática imposta pela escalabilidade de cada modelo. Consequentemente, a Tabela 13 não apenas avalia a qualidade dos ajustes, mas também fornece uma indicação indireta da extensão da região operacional em que cada arquitetura pôde ser medida de forma confiável.

A análise das falhas de memória também permitiu identificar os principais mecanismos responsáveis pelo crescimento de cada arquitetura. No PointNet, o consumo é dominado por ativações de 1024 canais, especialmente em camadas convolucionais compartilhadas e módulos de transformação espacial. Portanto, o PointNet é limitado por ativações largas, mas seu crescimento permanece linear em relação ao número de pontos.

No DGCNN, o gargalo é estruturalmente mais severo. A construção dinâmica de grafos requer matrizes de distância par a par com dimensão aproximada (B, N, N) , além dos tensores associados às operações de vizinhança. Assim, o DGCNN é o modelo mais sensível ao aumento de N , pois seu custo de memória é dominado pelo termo quadrático.

No PointMLP, as falhas são explicadas principalmente pelos tensores de agrupamento local, incluindo operações de amostragem, busca de vizinhos e formação de grupos. Embora o modelo não utilize grafos dinâmicos completos como o DGCNN, o primeiro estágio de agrupamento gera tensores grandes, o que explica seu custo prático elevado mesmo com uma formulação baseada em operações locais.

No PointNet++, o custo principal das camadas de abstração de conjunto permanece relativamente controlado, pois o número de centróides e vizinhos é fixado em cada estágio. Contudo, a implementação ainda pode gerar tensores temporários grandes durante agrupamentos e abstrações globais. Portanto, apesar de sua boa escalabilidade nas estimativas, o PointNet++ ainda requer cautela em lotes elevados.

4.4 Próximas Atividades

As próximas atividades concentram-se na expansão do conjunto de dados, na validação das anotações e na execução dos experimentos de classificação em nuvens de pontos. Inicialmente, será finalizada a automatização da geração de cenas no BlenSor, com posicionamento procedural de instâncias das oito classes consideradas. O gerador deverá controlar a quantidade de objetos por cena, a posição no plano, a rotação em *yaw*, a escala dos modelos e a ocorrência de oclusão parcial.

Em seguida, será executada a validação das anotações. Essa etapa deverá verificar a consistência das caixas delimitadoras, a presença de pontos dentro de cada caixa, a inexistência de objetos totalmente fora do alcance do sensor virtual e a preservação do identificador da cena de origem em amostras aumentadas. Esse controle é necessário para que os conjuntos de treinamento, validação e teste sejam separados no nível da cena, evitando vazamento entre amostras originais e variações geométricas derivadas.

Depois da validação dos dados, serão conduzidos os treinamentos iniciais com cenas con-

tendo apenas um objeto, mantendo $N = 1024$ pontos por amostra. Essa decisão permite uma comparação mais direta com a literatura e reduz a complexidade inicial da avaliação. Após a análise de desempenho e do custo computacional dos modelos treinados nesse cenário controlado, será examinada a viabilidade de avançar para o regime multirrótulo, no qual a mesma cena poderá conter múltiplas classes simultaneamente.

Por fim, o estudo de custo computacional será complementado com medições reais durante o treinamento completo, incluindo passagem direta, retropropagação e atualização do otimizador. As medições deverão registrar o pico de memória para cada combinação de modelo, B e N . Essa etapa permitirá comparar o consumo real com as expressões empíricas ajustadas, reportar o erro de predição em relação ao treinamento completo e atualizar os limites operacionais antes da execução dos experimentos finais.

5 Conclusões

Este relatório consolidou os principais avanços obtidos na Atividade 3.2 da Fase III do Projeto Brasil 6G, dedicada ao desenvolvimento de aplicações de posicionamento e mapeamento baseadas em sensores LiDAR. As pesquisas realizadas abordaram diferentes etapas do ciclo de utilização dos dados tridimensionais, desde sua aquisição e processamento até sua aplicação em sistemas inteligentes e na construção de bases de dados para aprendizado de máquina. Em conjunto, os resultados evidenciam o potencial da tecnologia LiDAR como elemento habilitador de aplicações em áreas como agricultura de precisão, telecomunicações, monitoramento ambiental e robótica, contribuindo para o desenvolvimento de soluções alinhadas aos desafios das futuras redes 6G.

A primeira frente de pesquisa concentrou-se na avaliação experimental do processo de aquisição e processamento de nuvens de pontos, permitindo analisar a influência dos parâmetros de captura e das condições de operação sobre a qualidade dos dados gerados. Os experimentos realizados evidenciaram o impacto da resolução do sensor, da frequência de varredura e do modo de aquisição no volume de dados produzido, no tempo de processamento e na qualidade da reconstrução tridimensional. Além de fornecer diretrizes para a seleção de configurações mais adequadas a diferentes aplicações, esse estudo estabeleceu uma base sólida para estudos futuros, ao caracterizar o desempenho do *pipeline* de aquisição, reconstrução e compressão de dados LiDAR.

Complementarmente, foi desenvolvida uma arquitetura integrada UAV-LiDAR para monitoramento agrícola, combinando sensoriamento remoto, computação em borda e conectividade sem fio. Os avanços obtidos envolveram a integração do sensor LiDAR à plataforma NVIDIA® Jetson Orin™ NX, a implementação de mecanismos de aquisição e processamento embarcado e a realização de campanhas experimentais em lavouras de café. Os resultados demonstraram a capacidade da plataforma em gerar modelos tridimensionais da vegetação e extrair indicadores agrônômicos relevantes, como altura, volume vegetativo, biomassa e estoque de carbono, apresentando boa concordância com as medições de referência realizadas em campo. Adicionalmente, a avaliação de diferentes ferramentas e fluxos de processamento confirmou a viabilidade da utilização de arquiteturas embarcadas para aplicações de agricultura de precisão suportadas por futuras infraestruturas de comunicação.

Complementando essas contribuições, foi iniciada a construção de um conjunto de dados sintéticos LiDAR utilizando o simulador BlenSor, estabelecendo um *pipeline* para geração, preparação e avaliação de nuvens de pontos destinadas ao treinamento de modelos de aprendizado profundo. O trabalho definiu a estrutura inicial do conjunto de dados, contemplando cenas com pessoas e animais, rotinas de normalização, reamostragem e aumento geométrico, além de um estudo detalhado sobre consumo de memória e custo computacional durante o treinamento em GPU. Esses resultados fornecem uma base metodológica consistente para o desenvolvimento de modelos de percepção tridimensional, favorecendo a reprodutibilidade dos experimentos e a avaliação controlada de diferentes arquiteturas de aprendizado.

De forma integrada, as três frentes de pesquisa desenvolvidas demonstram que o uso eficiente da tecnologia LiDAR depende da combinação entre estratégias adequadas de aquisição, processamento, comunicação e análise dos dados. Enquanto a primeira frente estabelece os fundamentos para a obtenção de nuvens de pontos de alta qualidade, a segunda evidencia seu potencial em aplicações reais de monitoramento agrícola e a terceira amplia as possibilidades de desenvolvimento de soluções baseadas em IA por meio da disponibilização de conjuntos de dados sintéticos. Em conjunto, essas contribuições fortalecem a infraestrutura científica e tec-

nológica do Projeto Brasil 6G, criando bases para o desenvolvimento de aplicações inteligentes suportadas por futuras redes móveis.

Como perspectivas para a continuidade desta atividade, destacam-se a ampliação das campanhas experimentais em novos cenários de aquisição, a evolução da plataforma UAV-LiDAR com maior integração às infraestruturas de comunicação desenvolvidas no projeto e a expansão do conjunto de dados sintéticos, incorporando novas classes de objetos, cenários e tarefas de percepção tridimensional. Esses avanços deverão ampliar a robustez das soluções desenvolvidas e contribuir para o desenvolvimento de sistemas cada vez mais eficientes, autônomos e adaptados às demandas das futuras redes 6G.

Referências

- [1] N. Cohen, R. Orfaig, and B.-Z. Bobrovsky, “Texlidar: Automated text understanding for panoramic lidar data,” 2025. [Online]. Available: <https://arxiv.org/abs/2502.04385>
- [2] H. Padusinski, C. Steinhauser, C. Scherl, J. Gaal, and J. Langner, “Point cloud recombination: Systematic real data augmentation using robotic targets for lidar perception validation,” in *2025 IEEE International Automated Vehicle Validation Conference (IAVVC)*, 2025, pp. 1–8.
- [3] A. Mock, “Inverse sensor modeling for 6d mobile robot localization in scene graphs via hardware-accelerated ray tracing,” Ph.D. dissertation, Universität Osnabrück, 2025.
- [4] G.-C. Males, V.-E. Oniga, I. Lavric, A.-M. Loghin, C.-O. Miron, and D. Pădure, “Performance analysis of the ouster os1-32 lidar sensor for indoor mapping,” *Journal of Physics: Conference Series*, vol. 3071, no. 1, p. 012018, aug 2025. [Online]. Available: <https://doi.org/10.1088/1742-6596/3071/1/012018>
- [5] A. Proudman, M. Ramezani, S. T. Digumarti, N. Chebrolu, and M. Fallon, “Towards real-time forest inventory using handheld lidar,” *Robotics and Autonomous Systems*, vol. 157, p. 104240, 2022.
- [6] D. M. K. Felix, X. Yu, J. Zhang, S. Ha, Z. Zou, and T. Westerlund, “Understanding lidar variability: A dataset and comparative study featuring dome-shaped, solid-state, and spinning lidars,” *IEEE Robotics and Automation Letters*, vol. 11, no. 1, pp. 570–577, 2025.
- [7] A. Soussi, E. Zero, R. Sacile, D. Trincherro, and M. Fossa, “Smart sensors and smart data for precision agriculture: a review,” *Sensors*, vol. 24, no. 8, p. 2647, 2024.
- [8] S. K. Phang, T. H. A. Chiang, A. Happonen, and M. M. L. Chang, “From satellite to uav-based remote sensing: A review on precision agriculture,” *Ieee Access*, vol. 11, pp. 127 057–127 076, 2023.
- [9] S. M. Farhan, J. Yin, Z. Chen, and M. S. Memon, “A comprehensive review of lidar applications in crop management for precision agriculture,” *Sensors (Basel, Switzerland)*, vol. 24, no. 16, p. 5409, 2024.
- [10] M. R. Karim, M. N. Reza, H. Jin, M. A. Haque, K.-H. Lee, J. Sung, and S.-O. Chung, “Application of lidar sensors for crop and working environment recognition in agriculture: A review,” *Remote Sensing*, vol. 16, no. 24, p. 4623, 2024.
- [11] H. Yuan, R. S. Bennett, N. Wang, and K. D. Chamberlin, “Development of a peanut canopy measurement system using a ground-based lidar sensor,” *Frontiers in plant science*, vol. 10, p. 203, 2019.
- [12] E. Omia, H. Bae, E. Park, M. S. Kim, I. Baek, I. Kabenge, and B.-K. Cho, “Remote sensing in field crop monitoring: A comprehensive review of sensor systems, data analyses and recent advances,” *Remote Sensing*, vol. 15, no. 2, p. 354, 2023.

- [13] Z. Li, M. E. Hodgson, and W. Li, "A general-purpose framework for parallel processing of large-scale lidar data," *International Journal of Digital Earth*, vol. 11, no. 1, pp. 26–47, 2018.
- [14] E. Hadas, G. Jozkow, A. Walicka, and A. Borkowski, "Apple orchard inventory with a lidar equipped unmanned aerial system," *International Journal of Applied Earth Observation and Geoinformation*, vol. 82, p. 101911, 2019.
- [15] J. ten Harkel, H. Bartholomeus, and L. Kooistra, "Biomass and crop height estimation of different crops using uav-based lidar," *Remote Sensing*, vol. 12, no. 1, p. 17, 2019.
- [16] L. L. Mendes *et al.*, "Enhanced Remote Areas Communications: The Missing Scenario for 5G and Beyond 5G Networks," *IEEE Access*, vol. 8, pp. 219 859–219 880, 2020.
- [17] M. Z. Islam, J. F. O'Hara, D. Shadoan, M. Ibrahim, and S. Ekin, "Tv white space based wireless broadband internet connectivity: A case study with implementation details and performance analysis," *IEEE Open Journal of the Communications Society*, vol. 2, pp. 2449–2462, 2021.
- [18] W. Zhang, J. Yang, G. Zhang, L. Yang, and C. Kiat Yeo, "Tv white space and its applications in future wireless networks and communications: A survey," *IET Communications*, vol. 12, no. 20, pp. 2521–2532, 2018.
- [19] M. S. B. Cunha, J. S. Ferreira, A. R. R. Marins, R. A. B. d. Lima, G. Zorello, and L. L. Mendes, "Impact of regulation on tv white space implementation in brazil: Laboratory and field analyses using 5g-range system," *Sensors*, vol. 25, no. 8, p. 2469, 2025.
- [20] S. Luo, W. Liu, Y. Zhang, C. Wang, X. Xi, S. Nie, D. Ma, Y. Lin, and G. Zhou, "Maize and soybean heights estimation from unmanned aerial vehicle (uav) lidar data," *Computers and Electronics in Agriculture*, vol. 182, p. 106005, 2021.
- [21] K. Liu, X. Dong, and B. Qiu, "Analysis of cotton height spatial variability based on uav-lidar," *International Journal of Precision Agricultural Aviation*, vol. 3, no. 3, 2020.
- [22] A. Phan, K. Takahashi *et al.*, "Estimation of rice plant height from a low-cost uav-based lidar point clouds," *International Journal of Geoinformatics*, vol. 17, no. 2, pp. 89–98, 2021.
- [23] L. Zhou, X. Gu, S. Cheng, G. Yang, M. Shu, and Q. Sun, "Analysis of plant height changes of lodged maize using uav-lidar data," *Agriculture*, vol. 10, no. 5, p. 146, 2020.
- [24] X. Hu, L. Sun, X. Gu, Q. Sun, Z. Wei, Y. Pan, and L. Chen, "Assessing the self-recovery ability of maize after lodging using uav-lidar data," *Remote Sensing*, vol. 13, no. 12, p. 2270, 2021.
- [25] L. Lei, C. Qiu, Z. Li, D. Han, L. Han, Y. Zhu, J. Wu, B. Xu, H. Feng, H. Yang *et al.*, "Effect of leaf occlusion on leaf area index inversion of maize using uav-lidar data," *Remote Sensing*, vol. 11, no. 9, p. 1067, 2019.

- [26] M. Maimaitijiang, V. Sagan, H. Erkbol, J. Adrian, M. Newcomb, D. LeBauer, D. Pauli, N. Shakoor, and T. Mockler, “UAV-based sorghum growth monitoring: A comparative analysis of lidar and photogrammetry,” *ISPRS annals of the photogrammetry, remote sensing and spatial information sciences*, vol. 3, pp. 489–496, 2020.
- [27] J.-X. Xu, J. Ma, Y.-N. Tang, W.-X. Wu, J.-H. Shao, W.-B. Wu, S.-Y. Wei, Y.-F. Liu, Y.-C. Wang, and H.-Q. Guo, “Estimation of sugarcane yield using a machine learning approach based on uav-lidar data,” *Remote Sensing*, vol. 12, no. 17, p. 2823, 2020.
- [28] J. Sofonia, Y. Shendryk, S. Phinn, C. Roelfsema, F. Kendoul, and D. Skocaj, “Monitoring sugarcane growth response to varying nitrogen application rates: A comparison of uav slam lidar and photogrammetry,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 82, p. 101878, 2019.
- [29] Y. Shendryk, J. Sofonia, R. Garrard, Y. Rist, D. Skocaj, and P. Thorburn, “Fine-scale prediction of biomass and leaf nitrogen content in sugarcane using uav lidar and multispectral imaging,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 92, p. 102177, 2020.
- [30] A. Masjedi and M. M. Crawford, “Prediction of sorghum biomass using time series uav-based hyperspectral and lidar data,” in *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*. IEEE, 2020, pp. 3912–3915.
- [31] United States Department of Agriculture, Foreign Agricultural Service (USDA FAS), “Coffee production statistics (2024/2025),” <https://www.fas.usda.gov/data/production/commodity/0711100>, 2025, accessed: 2025-12-02.
- [32] N. L. Bento, G. A. e. S. Ferraz, L. S. Santana, R. d. O. Faria, G. Rossi, and G. Bambi, “Plant Height and Soil Compaction in Coffee Crops Based on LiDAR and RGB Sensors Carried by Remotely Piloted Aircraft,” *Remote Sensing*, vol. 17, no. 8, p. 1445, 2025.
- [33] P. J. Besl and N. D. McKay, “Method for registration of 3-d shapes,” in *Sensor fusion IV: control paradigms and data structures*, vol. 1611. Spie, 1992, pp. 586–606.
- [34] I. Vizzo, T. Guadagnino, B. Mersch, L. Wiesmann, J. Behley, and C. Stachniss, “Kiss-icp: In defense of point-to-point icp—simple, accurate, and robust registration if done the right way,” *IEEE Robotics and Automation Letters*, vol. 8, no. 2, pp. 1029–1036, 2023.
- [35] I. Vizzo, T. Guadagnino, J. Behley, and C. Stachniss, “KISS-ICP: Open-Source Implementation,” <https://github.com/PRBonn/kiss-icp>, 2023.
- [36] T. Liu, S. Zhu, T. Yang, W. Zhang, Y. Xu, K. Zhou, W. Wu, Y. Zhao, Z. Yao, G. Yang *et al.*, “Maize height estimation using combined unmanned aerial vehicle oblique photography and lidar canopy dynamic characteristics,” *Computers and Electronics in Agriculture*, vol. 218, p. 108685, 2024.
- [37] H. Butler, A. Bell, M. P. Gerlek, P. Gadomski, C. Manning, M. Łoskot, B. Couwenberg, N. Barker, P. Ramsey, J. Dark *et al.*, “PDAL Point Data Abstraction Library,” Aug. 2025. [Online]. Available: <https://doi.org/10.5281/zenodo.10884408>

- [38] Y. Liu, D. Chen, S. Fu, P. T. Mathiopoulos, M. Sui, J. Na, and J. Peethambaran, “Segmentation of individual tree points by combining marker-controlled watershed segmentation and spectral clustering optimization,” *Remote Sensing*, vol. 16, no. 4, p. 610, 2024.
- [39] S. Wang, J. Ji, L. Zhao, J. Li, M. Zhang, and S. Li, “Canopy segmentation of overlapping fruit trees based on unmanned aerial vehicle lidar,” *Agriculture*, vol. 15, no. 3, p. 295, 2025.
- [40] I. Change, “Guidelines for national greenhouse gas inventories,” *Intergovernmental Panel on Climate Change (IPCC): Hayama, Kanagawa, Japan*, 2006.