

Brasil 6G

Projeto Brasil 6G Fase III

Atividade 3.2 - Aplicações de Posicionamento e Mapeamento com LiDAR - Parte 1



Histórico de Atualizações:

Versão	Data	Autor(es)	Notas
1	15/07/2025	Carlos Eduardo da Silva Inácio - Inatel Felipe A. P. de Figueiredo - Inatel Joanna Manjarres - UFRJ José F. de Rezende - UFRJ Letícia Carneiro de Souza - Inatel Luis Gustavo da Silva - Inatel Matheus Ferreira Silva - Inatel Samuel B. Mafra - Inatel	Elaboração de conteúdo
2	15/07/2025	Francisco M. Portelinha Júnior - Inatel Luciano Leonel Mendes - Inatel Vanessa Mendes Rennó - Inatel	Revisão de texto

Lista de Figuras

1	Fluxograma da metodologia.	6
2	Classificação de sistemas LiDAR.	12
3	Arquitetura do sistema de monitoramento agrícola ALS utilizando LiDAR embarcado em drone conectado à rede 6G via TVWS em área remota.	13
4	Ilustração do processo de aquisição de dados por um sistemas LiDAR ALS e os respectivos modelos gerados: MDS e MDT.	15
5	Sistema LiDAR ALS aplicado à estimação de altura da plantação.	16
6	Sistema LiDAR ALS embarcado em drone detectando obstáculos em área agrícola com destaque para objetos identificados entre as linhas de cultivo.	17
7	Simulação de varredura LiDAR usando o BlenSor.	19
8	Processo de geração de uma cena rotulada.	20
9	Representação da resolução do termômetro das coordenadas.	26
10	Desempenho da rede WiSARD variando o endereçamento da memória com entradas de coordenadas e resolução igual 8.	27
11	Mapa de calor do desempenho da acurácia com entradas de coordenadas da rede WiSARD.	27
12	Episódio 8 do LiDAR quantizado do <i>dataset</i> s008 mais o receptor como um termômetro.	28
13	Episódio 8 do LiDAR quantizado do <i>dataset</i> s008.	28
14	Avaliação de desempenho dos dados LiDAR 2D em função do endereçamento das memórias RAM.	29
15	Avaliação de desempenho do modelo WiSARD usando a técnica de limite de variância em dados LiDAR 2D.	29
16	Modelo de rede neural usado em [1] para entrada LiDAR.	29
17	Modelo de rede neural usado em [2] para entrada LiDAR.	30
18	Comparação de desempenho de acurácia entre o modelo proposto WISARD e as técnicas de aprendizado de máquina propostas pelos autores [1], e [2] usando as entradas unimodais (coordenadas e dados LiDAR) e multimodais (coordenadas + LiDAR).	31
19	Comparação de desempenho de <i>throughput ratio</i> entre o modelo proposto WISARD e as técnicas de aprendizado de máquina propostas pelos autores [1], e [2] usando as entradas unimodais (coordenadas e dados LiDAR) e multimodais (coordenadas + LiDAR).	31
20	Comparação dos tempos de treinamento entre o modelo proposto e as técnicas de aprendizado de máquina da literatura dos autores [1], e [2] usando as entradas unimodais (coordenadas e dados LiDAR) e multimodais (coordenadas + LiDAR).	32
21	Desempenho da rede WiSARD em tempos de treinamento usando as entradas unimodais (coordenadas e dados LiDAR) e multimodais (coordenadas + LiDAR).	32

Lista de Tabelas

1	Grupo de dados LiDAR para testes.	6
2	Tamanho do arquivo após a compactação em Mega Bytes (MB)	9
3	Taxa de compressão média por Algoritmo	9
4	Tempo de compressão (em segundos)	9
5	Comparação de trabalhos relacionados.	24
6	Comparação dos resultados alcançados pelos trabalhos da revisão bibliográfica.	25
7	Especificações do termômetro para as coordenadas.	26
8	Impacto da resolução do termômetro sobre o tamanho da entrada.	27
9	Parâmetros usados pelos autores do <i>baseline</i> B. Salehi [1] e J. Ruseckas [2] no modelo LiDAR.	30

Acrônimos

5G Quinta Geração de Rede Móvel Celular

6G Sexta Geração de Rede Móvel Celular

ALS *Airborne Laser Scanner*

ASPRS *American Society for Photogrammetry and Remote Sensing*

BEV *Bird's-eye View*

BS *Base Station*

CNN *Convolutional Neural Network*

CPU *Central Processing Unit*

DNN *Deep Neural Network*

FEC *Forward Error Correction*

GFDM *Generalized Frequency Division Multiplexing*

GPS *Global Positioning System*

GPU *Graphic Processing Unit*

GUI *Graphical User Interface*

IA *Inteligência Artificial*

IoT *Internet of Things*

ITU *International Telecommunications Unit*

KNN *K-Nearest Neighbors*

LiDAR *Light Detection and Ranging*

MDE *Modelos Digital de Elevação*

MDS *Modelo Digital da Superfície*

MDT *Modelo Digital do Terreno*

MIMO *Multiple Input Multiple Output*

ML *Machine Learning*

MLS *Mobile Laser Scanner*

MLP *Multilayer Perceptron*

mmWave *Millimeter Wave*

NZ *NanoZip*

OOB *Out-of-Band*

PBR *Physically Based Rendering*

PCD *Point Cloud Data*

ResNet *Residual Neural Network*

RMSE *Root Mean Square Error*

RNSP *Rede Neural Sem Peso*

SVC *Support Vector Classifier*

SVM *Support Vector Machine*

TLS *Terrestrial Laser Scanner*

ToF *Time-of-Flight*

TVWS *TV White Space*

UAV *Unmanned Aerial Vehicle*

UE *User Equipment*

UV *ultravioleta*

WiSARD *Wilkes, Stonham and Aleksander Recognition Device*

Sumário

1	Introdução	1
1.1	Organização do Relatório	3
2	Um Estudo Comparativo de Algoritmos para Compressão de Dados LiDAR	4
2.1	Contextualização	4
2.2	Trabalhos Relacionados	4
2.3	Metodologia	5
2.3.1	Conjunto de Dados	6
2.3.2	Algoritmos de Compressão de Dados	6
2.3.3	Métricas de Desempenho	8
2.3.4	Análise de Integridade	8
2.4	Resultados Numéricos	8
2.5	Discussões e Trabalhos Futuros	10
3	Integração de Sistemas LiDAR ALS e Conectividade TV White Space para Agricultura de Precisão	11
3.1	Classificação de Sistemas LiDAR	11
3.2	Arquitetura do Sistema Proposto	12
3.3	Requisitos de Projeto	13
3.4	Aplicações Potenciais	14
3.4.1	Mapeamento do Solo	14
3.4.2	Estimativa de Altura das Plantações	15
3.4.3	Detecção de Obstáculos	16
3.5	Direções futuras	17
4	Criação de um Conjunto de Dados LiDAR Sintético com BlenSor	18
4.1	Contextualização	18
4.2	Geração dos Dados LiDAR com o BlenSor	19
4.3	Próximas atividades	21
5	Seleção de Feixe Usando Dados LiDAR	22
5.1	Contextualização	22
5.2	Trabalhos Relacionados	23
5.3	Metodologia usada na Rede Neural Sem Peso	25
5.3.1	Pré-processamento das Coordenadas	25
5.3.2	Pré-processamento dos Dados LiDAR	27
5.4	Proposta de Avaliação	28
5.4.1	Descrição dos Métodos de <i>baseline</i>	28
5.4.2	Comparação dos Modelos	29
5.5	Trabalhos Futuros	31
6	Conclusões	33

1 Introdução

O sensoriamento remoto (*remote sensing*) tem sido amplamente empregado no monitoramento e na análise de características da superfície terrestre [3, 4]. Essa tecnologia viabiliza a coleta de dados em larga escala, com alta resolução e precisão, permitindo o acompanhamento contínuo de alterações no ambiente. Suas aplicações são fundamentais em áreas como gestão ambiental, planejamento urbano e previsão de desastres naturais [5]. Dentre as diversas tecnologias utilizadas para tal, destaca-se o *Light Detection and Ranging* (LiDAR) como uma ferramenta promissora, especialmente em aplicações voltadas à agricultura de precisão e às telecomunicações [6, 7]. Devido à sua acurácia, resolução e versatilidade, o LiDAR apresenta um grande potencial para aprimorar processos de tomada de decisão e otimizar o uso de recursos.

Originalmente desenvolvido para aplicações militares e geológicas, o LiDAR é uma técnica de sensoriamento remoto baseada na emissão de pulsos de laser e na medição do tempo decorrido até o retorno desses pulsos após atingirem uma superfície [8]. Como essa medição se fundamenta na velocidade da luz, uma constante física bem conhecida, é possível calcular com alta precisão a distância entre o sensor emissor e o objeto refletor. Ao emitir pulsos de luz em intervalos regulares, o LiDAR registra sucessivas reflexões, possibilitando a construção de modelos tridimensionais detalhados da superfície observada [9], com amplas aplicações em sensoriamento remoto.

Dentre as principais vantagens dos sensores LiDAR, destaca-se sua independência em relação à luz ambiente. Como essa tecnologia baseia-se na emissão ativa de pulsos de laser, ela pode ser utilizada de forma eficaz tanto durante o dia quanto à noite, além de apresentar bom desempenho sob diferentes condições climáticas [10]. Em contraste, sensores como câmeras RGB (vermelho, verde e azul) e multiespectrais dependem da luz solar incidente, sendo sensíveis a variações de iluminação que podem comprometer, por exemplo, a acurácia na medição de características da vegetação [8]. Além disso, sensores LiDAR oferecem alta precisão — geralmente na ordem de milímetros a centímetros —, superando significativamente a acurácia de sensores ultrassônicos e câmeras RGB [6, 11]. Outro diferencial importante do LiDAR é sua capacidade de penetrar parcialmente a vegetação e outros obstáculos, permitindo a obtenção de informações estruturais em diferentes camadas, algo que sensores multiespectrais ou RGB frequentemente não conseguem captar [12]. No entanto, a adoção em larga escala do LiDAR ainda enfrenta desafios, principalmente devido ao grande volume de dados gerados nas varreduras tridimensionais. A alta densidade de pontos resulta em arquivos extensos, com informações detalhadas como coordenadas espaciais e intensidade de retorno, exigindo soluções robustas para armazenamento, processamento e manutenção da integridade dos dados. Diante desse cenário, torna-se essencial o uso de estratégias eficazes de gerenciamento desses dados, que permitam otimizar a utilização do LiDAR em diversas aplicações. Em particular, técnicas de compressão de dados desempenham um papel fundamental para viabilizar o uso em tempo real e em contextos com restrições de recursos computacionais e de comunicação.

No setor agrícola, o uso de sensoriamento remoto com tecnologia LiDAR tem impulsionado a adoção da agricultura de precisão. Essa abordagem baseia-se na integração de tecnologias avançadas de comunicação e análise de dados para viabilizar a tomada de decisões automatizadas [13]. Entre suas aplicações estão o controle preciso da irrigação, da aplicação de fertilizantes, pesticidas, sementes e outros insumos, resultando em maior produtividade, redução de desperdícios e mitigação de impactos ambientais [6]. Diferentemente de sensores como radar, sonar e câmeras hiperespectrais ou RGB, que possuem limitações quanto ao alcance e nível de detalhamento, o LiDAR destaca-se por seu alto grau de acurácia e capacidade de coleta de dados

estruturais tridimensionais, sendo uma ferramenta chave para a automação no campo [8]. A tecnologia permite a integração de informações tanto da vegetação quanto do ambiente circundante, oferecendo uma visão abrangente para a otimização do manejo agrícola. Por exemplo, ao capturar com precisão a topografia do terreno, o LiDAR facilita a identificação de características físicas que influenciam diretamente a eficiência do plantio, como declividades, áreas de acúmulo de água e variações no relevo [7]. Outra vantagem importante do LiDAR é sua capacidade de realizar coleta de dados em tempo real, possibilitando a análise imediata de atributos das plantas durante as operações agrícolas. Essa característica é essencial para tomadas de decisão dinâmicas, especialmente em cenários que demandam respostas rápidas [14]. Em contrapartida, muitas outras técnicas, como a fotogrametria, requerem processamento posterior, o que pode atrasar a disponibilidade das informações e limitar sua aplicabilidade em tempo real [9, 6]. O LiDAR também apresenta elevada versatilidade quanto às plataformas de operação, podendo ser embarcado em dispositivos portáteis, veículos terrestres, tratores autônomos, *Unmanned Aerial Vehicles* (UAVs) (como drones) e aeronaves tripuladas [15, 16]. Essa flexibilidade torna a tecnologia escalável e adaptável a diferentes perfis de propriedades, permitindo ampla cobertura geográfica com elevado nível de detalhamento estrutural tridimensional.

Apesar do crescente interesse em aplicações baseadas em LiDAR para tarefas de detecção e classificação, ainda há uma escassez de conjuntos de dados públicos voltados para pessoas, animais e vegetação. A maioria dos repositórios disponíveis concentra-se em cenários urbanos voltados à condução autônoma, como os *datasets* KITTI [17], nuScenes [18], SemanticKITTI [19] e Waymo Open Dataset [20]. Esses conjuntos fornecem milhares de cenas anotadas com infraestrutura viária e tráfego, mas não contemplam adequadamente as variações espaciais e de refletividade associadas a alvos biológicos. Considerando o papel estratégico do LiDAR no sensoriamento remoto e na agricultura de precisão, torna-se fundamental o desenvolvimento e a disponibilização de conjuntos de dados específicos que contemplem pessoas, animais e vegetação. Tais *datasets* são essenciais para o treinamento de modelos de aprendizado de máquina com maior robustez e capacidade de generalização, especialmente em cenários voltados à segurança, ao monitoramento ambiental e às aplicações agrícolas automatizadas.

Além das aplicações consolidadas na agricultura, os sensores LiDAR vêm ganhando destaque em outras áreas tecnológicas. Um exemplo promissor é sua aplicação emergente em redes de telecomunicações, particularmente em sistemas *Multiple Input Multiple Output* (MIMO) operando na faixa de *Millimeter Wave* (mmWave). Nesses sistemas, o LiDAR é utilizado para mapear o ambiente em três dimensões, fornecendo informações espaciais detalhadas que, quando combinadas com técnicas de Inteligência Artificial (IA), possibilitam a execução mais eficiente de tarefas como *precoding* e seleção de feixes (*beam selection*). Essa abordagem tem o potencial de reduzir significativamente a dependência da estimativa tradicional do canal de comunicação sem fio via sinais piloto, ao mesmo tempo em que aproveita o conhecimento contextual do ambiente para otimizar o desempenho da comunicação. Dessa forma, o LiDAR se consolida não apenas como uma tecnologia de sensoriamento de alta precisão, mas também como um componente estratégico no avanço das tecnologias de conectividade de próxima geração, como a Sexta Geração de Rede Móvel Celular (6G).

Inserido nesse contexto multidisciplinar, o presente relatório, desenvolvido no âmbito da Fase 3 do Projeto Brasil 6G, mais especificamente na Atividade 3.2: Aplicações de Posicionamento e Mapeamento com LiDAR, tem como objetivo central explorar, desenvolver e validar aplicações baseadas em sensores LiDAR voltadas a contextos agrícolas, industriais e de telecomunicações avançadas. São abordados temas relacionados ao uso eficiente dos dados coletados, à compressão de grandes volumes de informação e à aplicação de técnicas inovadoras voltadas à otimização de

redes móveis de próxima geração. Para alcançar esse objetivo, a investigação está estruturada em quatro linhas principais e complementares de pesquisa, detalhadas nas Seções 2 a 5 deste relatório.

1.1 Organização do Relatório

A Seção 2 apresenta um estudo comparativo de algoritmos de compressão de dados LiDAR, etapa essencial para o enfrentamento do elevado volume de informações gerado por sensores em operações de campo. O estudo contempla tanto técnicas tradicionais quanto abordagens baseadas em aprendizado profundo, com o objetivo de identificar soluções que conciliem alto desempenho de compressão, preservação da integridade dos dados e viabilidade computacional. Esse equilíbrio é particularmente crítico em cenários que exigem processamento em tempo real e operam sob restrições de largura de banda.

Complementando esse esforço, a Seção 3 propõe uma arquitetura prática de sistema LiDAR embarcado em drones, direcionada à coleta e transmissão de dados em áreas agrícolas remotas. A solução utiliza conectividade baseada em *TV White Space* (TVWS) e recursos de computação de borda, possibilitando a integração com redes 6G. Essa configuração garante baixa latência, maior cobertura geográfica e interoperabilidade com sistemas inteligentes de agricultura. A proposta contempla, ainda, aplicações potenciais desse sistema, como o mapeamento detalhado do solo, a estimativa da altura das culturas e a detecção de obstáculos, funcionalidades essenciais para a automação de processos agrícolas, a melhoria da produtividade e a gestão eficiente dos recursos naturais.

A Seção 4 descreve o processo de criação de um conjunto de dados sintético LiDAR por meio do simulador *BlenSor*, uma ferramenta fundamental para a validação de algoritmos de detecção e classificação em contextos onde há escassez de dados reais, como na identificação de pessoas, animais ou vegetação. Essa iniciativa tem como objetivo ampliar a disponibilidade de dados com realismo e precisão, viabilizando o treinamento de modelos robustos e generalizáveis em tarefas voltadas à segurança, ao monitoramento ambiental e à automação de processos agrícolas.

A Seção 5 é dedicada à seleção de feixes em comunicações mmWave, com base na integração de dados provenientes de sensores LiDAR. Essa seção investiga o uso da arquitetura Rede Neural Sem Peso (RNSP) (*Wilkes, Stonham and Aleksander Recognition Device* (WiSARD)) como uma alternativa eficiente e de baixo custo computacional para acelerar o processo de *beamforming* em sistemas de Quinta Geração de Rede Móvel Celular (5G) e 6G. A abordagem proposta combina informações de localização obtidas via *Global Positioning System* (GPS) com mapas tridimensionais gerados por sensores LiDAR, a fim de prever com alta acurácia a direção ótima do feixe, mantendo baixa latência, um requisito essencial para aplicações de comunicação em tempo real. São apresentadas análises comparativas com modelos *baseline* da literatura, utilizando o conjunto de dados sintético *Raymobtime* como referência para avaliação de desempenho.

Por fim, a Seção 6 apresenta as conclusões gerais do relatório, sintetizando os principais resultados obtidos nas diferentes frentes de investigação. Além de consolidar os avanços alcançados, a seção discute as contribuições do trabalho para o avanço do uso do LiDAR em aplicações multidisciplinares e aponta perspectivas e recomendações para pesquisas futuras.

2 Um Estudo Comparativo de Algoritmos para Compressão de Dados LiDAR

Esta seção descreve a metodologia adotada para o estudo comparativo de algoritmos de compressão de dados LiDAR, desenvolvido no contexto do Projeto Brasil 6G. São detalhados os critérios de seleção dos conjuntos de dados utilizados nos experimentos, os algoritmos de compressão avaliados, as métricas de desempenho consideradas, bem como os procedimentos aplicados para análise da integridade dos arquivos após os processos de compressão e descompressão.

2.1 Contextualização

A alta densidade de pontos coletados em levantamentos LiDAR resulta na produção de grandes volumes de dados, frequentemente organizados em múltiplos arquivos de grande porte. Cada ponto registrado armazena informações detalhadas, como coordenadas espaciais, intensidade de retorno e, em alguns casos, atributos espectrais, o que aumenta substancialmente o tamanho dos arquivos gerados. A fragmentação desses dados em numerosos arquivos tem como objetivo facilitar o processamento e a análise modular das informações. No entanto, essa prática também impõe uma série de desafios relacionados ao armazenamento, à manipulação e à garantia da integridade dos dados. Entre as principais dificuldades estão a exigência por infraestrutura computacional robusta, os riscos aumentados de perda ou corrupção de arquivos e a complexidade na organização, rastreabilidade e gestão de diferentes versões de dados [21].

Diante das exigências computacionais substanciais associadas ao processamento de dados LiDAR e da necessidade de preservar um nível ótimo de detalhamento, a aplicação de técnicas de compressão de dados deve considerar, criteriosamente, os recursos computacionais envolvidos nos processos de compressão e descompressão, garantindo, simultaneamente, a preservação da integridade dos dados ao longo de todo o ciclo [22].

Nesse contexto, torna-se crucial discutir não apenas os benefícios proporcionados pelo LiDAR, mas também os desafios inerentes ao gerenciamento dos grandes volumes de dados que ele gera. A compreensão desses aspectos é fundamental para a adoção de estratégias eficazes de armazenamento, processamento e análise, contribuindo assim para o uso otimizado dessa tecnologia em diversos contextos de pesquisa e aplicação [23].

2.2 Trabalhos Relacionados

O artigo [23] apresenta uma análise comparativa entre algoritmos especializados e de propósito geral para compressão sem perdas de dados LiDAR aerotransportados. O estudo avalia três algoritmos de compressão específicos para LiDAR (LASzip, LASComp e LiDAR Compressor) e três algoritmos de compressão de propósito geral (7-Zip, WinZip e WinRAR), utilizando conjuntos de dados reais de nuvens de pontos LiDAR da cidade de Washington, DC.

Os algoritmos foram comparados com base na taxa de compressão, no tempo de compressão e na métrica de bits por ponto. Os resultados demonstram que o LASzip, um algoritmo específico para dados LiDAR, apresentou o melhor desempenho global, alcançando uma taxa média de compressão de 16,63% em relação ao tamanho original do arquivo e um tempo médio

O conteúdo deste capítulo foi desenvolvido pelos pesquisadores *Lucas S. Souza, Rafaella L. Dias, Matheus F. Silva, Samuel B. Mafra e Felipe A. P. de Figueiredo.*

de compressão de 16,65 segundos. Entre os algoritmos de propósito geral, o WinRAR obteve desempenho superior ao LiDAR *Compressor* em termos de taxa de compressão, com média de 20,24% do tamanho original. No entanto, de forma geral, os algoritmos específicos para LiDAR superaram os de propósito geral em eficiência de compressão.

A referência [24] propõe uma nova estrutura para compressão e transmissão de nuvens de pontos geradas por sensores LiDAR em cenários automotivos, utilizando segmentação semântica para orientar o processo. Nessa abordagem, a nuvem de pontos é segmentada em grupos semanticamente consistentes, os quais são posteriormente comprimidos e transmitidos individualmente. Os parâmetros de compressão são ajustados dinamicamente com base na importância relativa de cada grupo para a aplicação-alvo. A estrutura emprega algoritmos de compressão com perdas, o que implica que os dados descomprimidos podem não ser réplicas exatas dos originais. No entanto, o estudo enfatiza a preservação do conteúdo semântico, assegurando que as informações críticas para a aplicação permaneçam intactas. O método CACTUS, proposto pelos autores, concentra-se especificamente na adaptação dinâmica dos parâmetros de compressão, de modo a manter a integridade semântica dos segmentos de dados considerados prioritários.

A referência [25] apresenta uma abordagem inovadora para a compressão de nuvens de pontos tridimensionais geradas por sensores LiDAR, amplamente utilizados em veículos autônomos e sistemas de mapeamento robótico. O método emprega aprendizado profundo por meio de um *autoencoder* convolucional que, diferentemente das abordagens tradicionais, dispensa estruturas de discretização e opera diretamente sobre dados brutos de nuvens de pontos. O codificador é responsável por aprender um conjunto compacto de descritores de características locais, formando uma representação latente da entrada, enquanto o decodificador reconstrói a geometria densa da nuvem por meio de uma nova operação de deconvolução. Essa arquitetura contribui para a redução de erros de quantização e minimiza a sobrecarga de memória, resultando em um modelo de compressão mais preciso e eficiente em termos de recursos computacionais. Os resultados iniciais demonstram que o *autoencoder* proposto supera técnicas convencionais de compressão no que se refere à qualidade de reconstrução, mesmo em taxas de bits equivalentes. A abordagem alcança elevadas taxas de compressão em ambientes externos de grande escala, reduzindo significativamente os requisitos de armazenamento e viabilizando uma transmissão de dados mais eficiente.

2.3 Metodologia

Várias etapas foram seguidas para a condução do estudo comparativo de algoritmos para compressão de dados LiDAR. Inicialmente, os dados foram padronizados a fim de garantir consistência e permitir a comparabilidade dos resultados entre os diferentes métodos. Em seguida, os algoritmos de compressão selecionados foram aplicados aos arquivos padronizados. Os dados coletados durante o processo de compressão, bem como as características dos arquivos comprimidos, foram analisados para o estabelecimento das métricas de desempenho. Por fim, os arquivos que apresentaram os melhores resultados de compressão foram descomprimidos, e sua integridade foi verificada por meio da comparação com os arquivos originais. A Figura 1 ilustra esse processo.

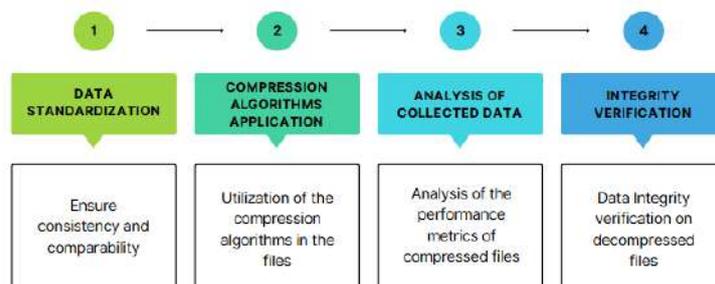


Figura 1: Fluxograma da metodologia.

2.3.1 Conjunto de Dados

Para a realização das compressões, foram utilizados dados provenientes de conjuntos de dados reais de nuvens de pontos obtidos por sistemas LiDAR aerotransportados sobre a cidade de Washington, DC (Distrito de Colúmbia) [26]. Cada conjunto representa uma nuvem de pontos LiDAR, isto é, uma coleção composta por milhões de pontos tridimensionais (x, y, z) que descrevem a superfície terrestre, edificações, vegetação e demais objetos capturados durante o sobrevoo de um sistema LiDAR aerotransportado (*Airborne Laser Scanner (ALS)*) [26].

Os dados encontram-se no formato padrão LAS, definido pela *American Society for Photogrammetry and Remote Sensing (ASPRS)*. Cada ponto, além das coordenadas espaciais (x, y, z) , geralmente inclui atributos adicionais, como a intensidade do retorno do laser, a classificação do objeto (por exemplo, solo, vegetação, edificações), o número do pulso, a marca temporal, entre outros metadados relevantes. Essas informações são essenciais para aplicações em sensoriamento remoto, modelagem tridimensional, geração de Modelos Digital de Elevação (MDE), entre diversas outras finalidades [26]. A Tabela 1 apresenta o tamanho, em bytes, de cada conjunto de dados utilizado no estudo.

Tabela 1: Grupo de dados LiDAR para testes.

	Nome do Arquivo	Tamanho do Arquivo (Bytes)
1	1120.las	1.236.304.420
2	1121.las	1.087.954.270
3	1122.las	1.101.359.710
4	1317.las	1.106.791.720
5	1318.las	849.407.590
6	1319.las	1.006.267.960

2.3.2 Algoritmos de Compressão de Dados

A compressão de dados é o processo de redução do tamanho de arquivos com o objetivo de otimizar a eficiência de armazenamento e viabilizar uma transmissão mais rápida e econômica das informações. Esse processo geralmente envolve a minimização de redundâncias e a aplicação de esquemas alternativos de codificação. As técnicas de compressão são comumente classificadas em dois grupos: com perdas (*lossy*) e sem perdas (*lossless*). Os métodos com perdas não preservam integralmente os dados originais, resultando em arquivos descomprimidos

que diferem do conteúdo original devido à eliminação irreversível de informações. Em contraste, os algoritmos de compressão sem perdas mantêm a fidelidade completa dos dados, permitindo a reconstrução exata do arquivo original após a descompressão. No contexto de aplicações com LiDAR, a compressão sem perdas é fortemente recomendada, considerando o volume expressivo de dados e a natureza crítica das informações contidas nos arquivos no formato LAS (.las) [23].

O sr2 (lançado em 3 de agosto de 2007) é um compressor de ranqueamento de símbolos projetado com foco em alta velocidade de processamento, em detrimento de elevadas taxas de compressão. Trata-se de um compressor para arquivo único, que utiliza aproximadamente 6 MB de memória durante sua execução. Sua modelagem baseia-se na análise dos últimos três bytes observados, empregando um contexto de ordem 4 para esses casos, com base na ordem de aparecimento. Para todos os demais bytes, é utilizado um contexto de ordem 1, com codificação aritmética [27].

LASzip é uma biblioteca de compressão sem perdas desenvolvida por Martin Isenburg para a codificação eficiente de dados LiDAR no formato LAS (.las) para sua versão comprimida (.laz), alcançando reduções de tamanho de arquivo que geralmente variam entre 80% e 93%, sem comprometer a integridade dos dados. Os arquivos resultantes no formato .laz permanecem totalmente compatíveis com *softwares* que suportam a especificação LAS, desde que possuam suporte à descompressão. Embora tenha sido originalmente projetado para integração com o pacote de ferramentas LAsTools, o LASzip é atualmente uma biblioteca *open-source* e pode ser compilado e executado em diversos sistemas operacionais, incluindo Windows, Linux e macOS. Sua alta eficiência de compressão decorre do processamento baseado em blocos e da codificação por componente, na qual diferentes campos dos dados, como coordenadas dos pontos, intensidade, classificação e tempo GPS (métrica que registra o momento de emissão dos feixes de laser), são comprimidos individualmente. Para isso, são utilizadas técnicas como codificação delta, codificação por comprimento de execução e codificação de entropia (como codificação aritmética ou de Huffman). Esses métodos permitem ao LASzip explorar as redundâncias espaciais e de atributos presentes nos dados LiDAR, garantindo fidelidade total após a descompressão [28].

O *NanoZip* (NZ) é um compactador baseado em linha de comando e *Graphical User Interface* (GUI), desenvolvido por Sami Runsas, que incorpora uma variedade de algoritmos experimentais de compressão estatística e por dicionário, projetados para maximizar a eficiência na compactação de dados. A ferramenta oferece suporte tanto à execução *single-threaded* quanto *multi-threaded*, permitindo o aproveitamento eficiente de processadores modernos com múltiplos núcleos [29, 30].

O BSC é uma ferramenta de compressão de arquivos sem perdas desenvolvida por Ilya Grebnov, baseada em algoritmos de ordenação por blocos que viabilizam uma compressão paralela eficiente em sistemas com múltiplos núcleos. Sua arquitetura permite a compressão simultânea de blocos de dados independentes, otimizando o desempenho em ambientes com *Central Processing Units* (CPUs) *multi-core* [31].

O 7-Zip é um *software* de compressão de arquivos de código aberto desenvolvido por Igor Pavlov, amplamente reconhecido por sua alta eficiência de compressão por meio do formato nativo 7z, que utiliza os algoritmos LZMA e LZMA2. Além do formato 7z, o programa oferece suporte a uma ampla variedade de outros formatos, incluindo XZ, BZIP2, GZIP, TAR, ZIP e WIM. Embora sua interface gráfica esteja disponível exclusivamente para o sistema operacional Windows, versões baseadas em linha de comando também são fornecidas para Linux e macOS [32].

2.3.3 Métricas de Desempenho

Diversas características foram analisadas para avaliar o desempenho de cada algoritmo de compressão, incluindo o tempo de compressão, o tamanho do arquivo resultante e a taxa de compressão. Esta última é calculada conforme a seguinte fórmula

$$\text{compression_ratio} = \left(1 - \frac{\text{size_after}}{\text{size_before}} \right) \times 100, \quad (1)$$

em que *size_before* representa o tamanho original do arquivo antes da compressão, enquanto *size_after* corresponde ao tamanho do arquivo após a aplicação do algoritmo de compressão. O resultado, expresso em porcentagem, indica a taxa de compressão obtida, ou seja, a proporção de redução do tamanho em relação ao arquivo original.

2.3.4 Análise de Integridade

Um procedimento de validação de integridade foi realizado em duas etapas, com o objetivo de garantir que os processos de compressão e posterior descompressão não tenham introduzido alterações nos dados originais.

Na primeira etapa, inspeções visuais foram realizadas por meio de *softwares* especializados em visualização de nuvens de pontos, a fim de avaliar qualitativamente possíveis diferenças perceptíveis entre os arquivos originais e os descomprimidos. Essa análise visava identificar distorções visuais, perdas estruturais ou alterações na distribuição espacial e nos valores dos campos escalares.

Na etapa seguinte, foram realizadas verificações de integridade utilizando a função *hash* criptográfica MD5. Essa função gera uma impressão digital única para cada arquivo, possibilitando uma comparação precisa em nível binário. A correspondência exata dos valores MD5 entre os arquivos originais e descomprimidos indica que o conteúdo permaneceu inalterado ao longo de todo o ciclo de compressão, confirmando assim a natureza sem perdas do processo. Em casos de divergência nos valores *hash*, os resultados foram analisados para identificar se as discrepâncias eram decorrentes de variações nas estratégias de compressão (como o uso de formatos de *streaming* ou modificações em metadados) ou de perdas efetivas de dados nas nuvens de pontos.

2.4 Resultados Numéricos

Para o processo de compressão, bem como para a avaliação das taxas de compressão e tempos de processamento, foram utilizados os algoritmos de uso geral WinZip, 7-Zip e Gzip, por meio do *software* 7-Zip Manager (comumente conhecido apenas como 7-Zip), além do algoritmo LASzip, específico para compressão de dados no formato LAS. Adicionalmente, foram incluídos na comparação os algoritmos Nanozip, BSC e sr2.

Os testes foram realizados em um computador Dell Inc. Inspiron 14 5440, equipado com 32 GB de RAM, processador Intel Core i7-150U (12 núcleos), gráficos integrados Intel RPL-U e uma *Graphic Processing Unit* (GPU) NVIDIA GeForce MX570 A. O sistema operacional utilizado foi o Ubuntu 24.04.2 LTS.

Os resultados obtidos com os seis algoritmos de compressão, em termos de taxa de compressão (calculada com base na Equação (1)), para o conjunto de dados de teste, são apresentados nas Tabelas 2 e 3.

Tabela 2: Tamanho do arquivo após a compactação em Mega Bytes (MB)

Arquivo	7-Zip	Zip	GZip	LASzip	NZ	BSC	sr2
1120.las	294	421	421	194	224	384	388
1121.las	255	367	367	167	195	338	339
1122.las	254	366	366	166	194	341	341
1317.las	257	374	374	167	195	345	347
1318.las	201	290	290	133	157	265	265
1319.las	234	339	339	153	179	317	316

Tabela 3: Taxa de compressão média por Algoritmo

	Algoritmo	Taxa de Compressão Média
1	7-Zip	76,61%
2	Zip	66,24%
3	GZip	66,23%
4	Nanozip	82,08%
5	BSC	68,83%
6	LASzip	84,67%
7	sr2	68,75%

Os resultados de tempo de processamento obtidos com os seis algoritmos, utilizando o conjunto de dados de teste, são apresentados na Tabela 4.

Observou-se que os algoritmos apresentaram desempenhos distintos tanto em termos de taxa de compressão quanto de tempo de processamento. O algoritmo LASzip se destacou pela maior eficiência na redução do tamanho dos arquivos, alcançando uma taxa média de compressão de 84,67%, superando todos os demais métodos avaliados. Esse desempenho reforça a adequação de algoritmos especializados em dados LiDAR, como o LASzip, para compressão sem perdas, uma vez que exploram a estrutura específica dos arquivos no formato LAS. O Nanozip obteve a segunda melhor taxa de compressão, com 82,08%, superando algoritmos de uso geral, como o 7-Zip (76,61%), o Zip (66,24%) e o Gzip (66,23%).

Tabela 4: Tempo de compressão (em segundos)

Arquivo	7-Zip	Zip	GZip	LASzip	NZ	BSC	sr2
1120.las	60	90	93	34	72	23	67
1121.las	55	81	79	17	98	20	25
1122.las	87	83	80	15	35	21	27
1317.las	62	81	89	18	83	20	26
1318.las	56	61	60	25	30	15	19
1319.las	69	75	73	23	82	17	23
Média	64,83	78,50	79,00	22	66,7	19,33	31

Em relação ao tempo de compressão, o algoritmo BSC demonstrou ser o mais rápido, com um tempo médio de 19,33 segundos — aproximadamente 3,4 vezes mais rápido que o 7-Zip (64,83 segundos) e 4,1 vezes mais rápido que o Nanozip (66,7 segundos). No entanto, essa alta velocidade veio acompanhada de uma taxa de compactação moderada (68,83%), inferior à alcançada pelo LASzip e pelo próprio Nanozip. O algoritmo sr2 apresentou um desempenho intermediário, equilibrando parcialmente tempo e eficiência: obteve um tempo médio de compressão de 31 segundos e uma taxa de compactação de 68,75%, semelhante à do BSC.

A análise em nível de arquivo reforçou essas tendências: para o arquivo 1120.las, o LASzip atingiu um tamanho de 185 MB (redução de 85%), enquanto o 7-Zip atingiu 280 MB (76,6%). O BSC compactou o mesmo arquivo para 366 MB (68,8%) em apenas 23 segundos, em comparação com 60 segundos do 7-Zip. Esses resultados evidenciam uma relação inversa entre eficiência de compressão e velocidade de processamento, destacando a necessidade de escolhas estratégicas conforme as prioridades da aplicação: armazenamento otimizado (como no caso do LASzip e Nanozip) ou maior rapidez de execução (como proporcionado pelo BSC).

2.5 Discussões e Trabalhos Futuros

A análise comparativa de algoritmos de compressão para dados de nuvem de pontos LiDAR evidencia que a escolha do método ideal está diretamente relacionada às prioridades da aplicação. O LASzip destacou-se como a solução mais eficiente em termos de armazenamento, alcançando uma taxa média de compressão de 84,67% (reduzindo os arquivos para 16,33% do tamanho original), sendo, portanto, especialmente indicado para cenários em que a economia de armazenamento é essencial, como em sistemas de *Internet of Things* (IoT), drones com restrições de largura de banda ou arquivamento de longo prazo. Em contraste, o BSC demonstrou o melhor desempenho em velocidade de processamento, comprimindo os dados de 3 a 4 vezes mais rápido do que outras alternativas (tempo médio de 19,33 segundos), tornando-se a opção mais adequada para aplicações em tempo real, como mapeamento ou navegação autônoma.

Embora o LASzip e o Nanozip tenham superado as ferramentas de uso geral em termos de eficiência, a compatibilidade do BSC com sistemas baseados em Linux (por exemplo, Ubuntu e Raspberry Pi) amplia sua aplicabilidade em dispositivos embarcados, drones e soluções de IoT, permitindo implantações diretas em campo. Importante destacar que o estudo confirmou a integridade sem perdas de todos os algoritmos analisados, por meio de somas de verificação MD5 e inspeções visuais, assegurando a fidelidade dos dados em aplicações que exigem alta precisão, como modelagem topográfica ou monitoramento ambiental.

O LASzip permanece como o algoritmo com melhor desempenho em taxa de compressão, enquanto o BSC se sobressai em velocidade de execução. O Nanozip apresenta um desempenho equilibrado entre os dois aspectos, embora sem superar o LASzip em eficiência. Já os algoritmos de uso geral (como o 7-Zip) oferecem um compromisso intermediário, mas se mostram menos otimizados para as estruturas de dados específicas do LiDAR.

Trabalhos futuros devem investigar a compressão adaptativa orientada por aprendizado de máquina, como o uso de autocodificadores, com o objetivo de priorizar dinamicamente segmentos semanticamente relevantes dos dados LiDAR (por exemplo, infraestrutura urbana versus vegetação), mantendo níveis aceitáveis de fidelidade em contextos com perdas. Adicionalmente, é recomendável o desenvolvimento de métodos leves de compressão otimizados para ambientes de borda, capazes de atender às restrições severas de energia e processamento em tempo real típicas de dispositivos IoT e sistemas embarcados em drones, garantindo implantação eficiente em cenários com recursos limitados.

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

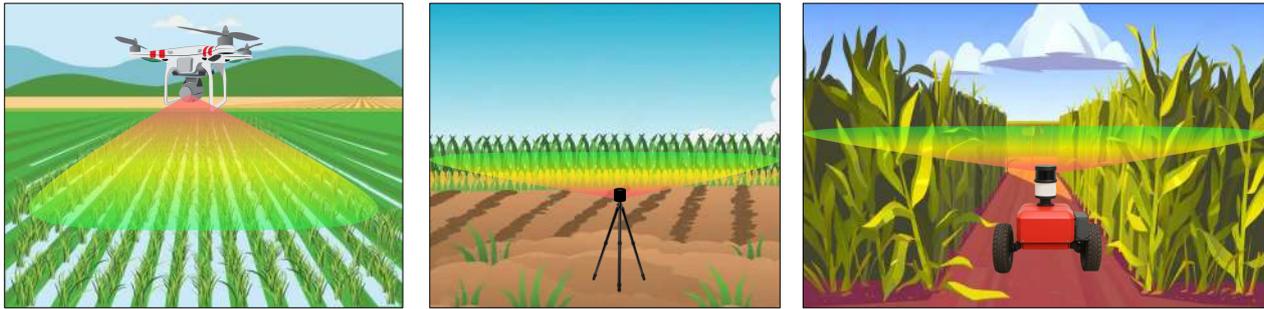
Esta seção apresenta a proposta de uma arquitetura baseada em sistemas LiDAR embarcados em drones, voltada para o monitoramento agrícola no contexto do projeto Brasil 6G. São descritos os requisitos técnicos e operacionais considerados na implementação da solução, bem como as aplicações potenciais que poderão ser exploradas a partir dos dados adquiridos. O objetivo é estabelecer uma base técnica sólida para orientar as etapas subsequentes da pesquisa, considerando tanto os desafios inerentes ao ambiente agrícola quanto as oportunidades proporcionadas pelo uso de sensores LiDAR de alta precisão.

3.1 Classificação de Sistemas LiDAR

Os sistemas LiDAR aplicados à agricultura podem ser classificados em três categorias, conforme ilustrado na Figura 2, de acordo com a forma como são transportados durante a varredura [6]. A primeira categoria é o LiDAR aéreo (ALS), no qual o sistema é instalado em veículos aéreos não tripulados (UAVs). A segunda é o LiDAR terrestre (*Terrestrial Laser Scanner* (TLS)), que utiliza uma base fixa para escaneamento, como um tripé. Nesse caso, são necessárias várias medições em diferentes posições para formar uma nuvem de pontos completa. Por fim, o LiDAR móvel (*Mobile Laser Scanner* (MLS)) oferece maior versatilidade, podendo ser acoplado a diferentes plataformas, como tratores, veículos terrestres, mochilas ou até mesmo ser carregado manualmente por um operador em movimento [8]. Os sistemas TLS e MLS têm se tornado populares por oferecerem maior resolução espacial, o que permite uma caracterização mais detalhada e precisa das culturas em comparação aos sistemas ALS [33]. No entanto, os sistemas TLS ainda enfrentam limitações para aplicação em tarefas rotineiras, devido à necessidade frequente de realocação dos sensores. Embora os sistemas MLS minimizem essa desvantagem, continuam sendo limitados pela velocidade de operação necessária para gerar nuvens de pontos de forma eficiente [9].

Os sistemas ALS representam uma solução economicamente viável para a agricultura de precisão e têm sido aplicados com sucesso em diversas atividades, como o monitoramento de culturas, a modelagem do terreno e a avaliação de risco de inundação em diferentes contextos agrícolas. Conforme relatado em [34], sistemas ALS permitem a realização de análises direcionadas e a tomada de decisão automatizada no setor agrícola, incluindo estimativas de produtividade, detecção precoce de doenças e gestão eficiente da irrigação. Em outro estudo, foi demonstrado que sistemas ALS são capazes de capturar informações detalhadas sobre as condições das culturas, a saúde das plantas e infestações por pragas [35]. Aslan *et al.* concluíram que os sistemas ALS são especialmente úteis para o mapeamento de áreas agrícolas, estimativa de produtividade e otimização de recursos [36]. Outros estudos utilizaram ALS embarcado em UAVs para fins de mapeamento e navegação, demonstrando também capacidades eficazes de desvio de obstáculos [37, 38]. Turner *et al.* utilizaram dados de sistemas ALS para mapear a rugosidade da superfície do solo, evidenciando que as estimativas feitas com esse sistema foram mais precisas e confiáveis do que aquelas obtidas por medições em solo [39]. A visão aérea (*Bird's-eye View* (BEV)) é outra técnica popular para visualizar nuvens de pontos em sistemas LiDAR aéreos (ALS). Essa abordagem simula a perspectiva de uma ave em voo. Por exemplo,

O conteúdo deste capítulo foi desenvolvido pelos pesquisadores *Letícia Carneiro de Souza, Luis Gustavo da Silva e Carlos Eduardo da Silva Inácio.*



ALS – Airborne Laser Scanner TLS – Terrestrial Laser Scanner MLS – Mobile Laser Scanner

Figura 2: Classificação de sistemas LiDAR.

Itakura e Hosoi utilizaram BEV para contar árvores com um sistema ALS [40]. Além disso, esse tipo de LiDAR pode ser empregado na estimativa da altura das plantas [41, 42], na análise de propriedades do solo [43, 44] e no monitoramento da saúde de árvores [45, 46]. Apesar de seus benefícios, os sistemas LiDAR do tipo ALS podem apresentar algumas limitações operacionais que podem impactar sua eficiência. Em UAVs, a autonomia é restrita pela vida útil das baterias, o que limita o tempo de voo e a área coberta. A capacidade de armazenamento a bordo também pode limitar a quantidade de dados capturados em um único voo. Além disso, os UAVs têm limitações quanto à carga útil e são sensíveis às condições climáticas [6].

3.2 Arquitetura do Sistema Proposto

A Figura 3 apresenta a arquitetura de um sistema de monitoramento agrícola voltado para áreas remotas, o qual utiliza um módulo LiDAR embarcado em um UAV, como um drone. O módulo LiDAR é composto por um sensor (OS1, Ouster) responsável pela varredura tridimensional do terreno, um módulo GPS para obtenção precisa da localização geográfica dos dados capturados, além de uma interface e um *gateway* que viabilizam a coleta e o envio dos dados. Além disso, a alimentação elétrica do sistema é feita por uma bateria embarcada.

Durante o voo sobre a área de interesse, o LiDAR realiza o mapeamento do ambiente, coletando dados de relevo, vegetação e estruturas da área agrícola. Os dados adquiridos são transmitidos localmente via Wi-Fi para um *User Equipment* (UE) localizado na própria área rural. Esse dispositivo está acoplado a uma unidade de processamento, responsável por realizar tarefas de pré-processamento, como filtragem, compressão ou análises iniciais dos dados coletados. Essa abordagem permite a redução da quantidade de dados a serem transmitidos pela rede, além de viabilizar respostas mais rápidas para decisões locais por meio de computação de borda (*edge computing*).

A UE conecta-se a uma *Base Station* (BS) utilizando a rede de acesso TVWS, a qual é especialmente vantajosa em regiões remotas. TVWS refere-se a faixas de frequência não utilizadas dentro do espectro destinado à radiodifusão televisiva, geralmente situadas entre 470 MHz e 698 MHz [47]. Essas faixas apresentam características muito favoráveis à comunicação sem fio em áreas rurais, como maior alcance de propagação, melhor penetração em vegetação e menor atenuação em comparação com bandas mais altas, como as utilizadas por redes móveis convencionais ou mmWave [48]. Essa conexão estabelece o enlace de longa distância necessário para levar os dados até a infraestrutura central da rede 6G. A BS encaminha os dados ao núcleo da rede, onde estão localizados os servidores e as aplicações remotas. O núcleo da rede também se conecta à Internet, o que permite a integração do sistema com plataformas externas

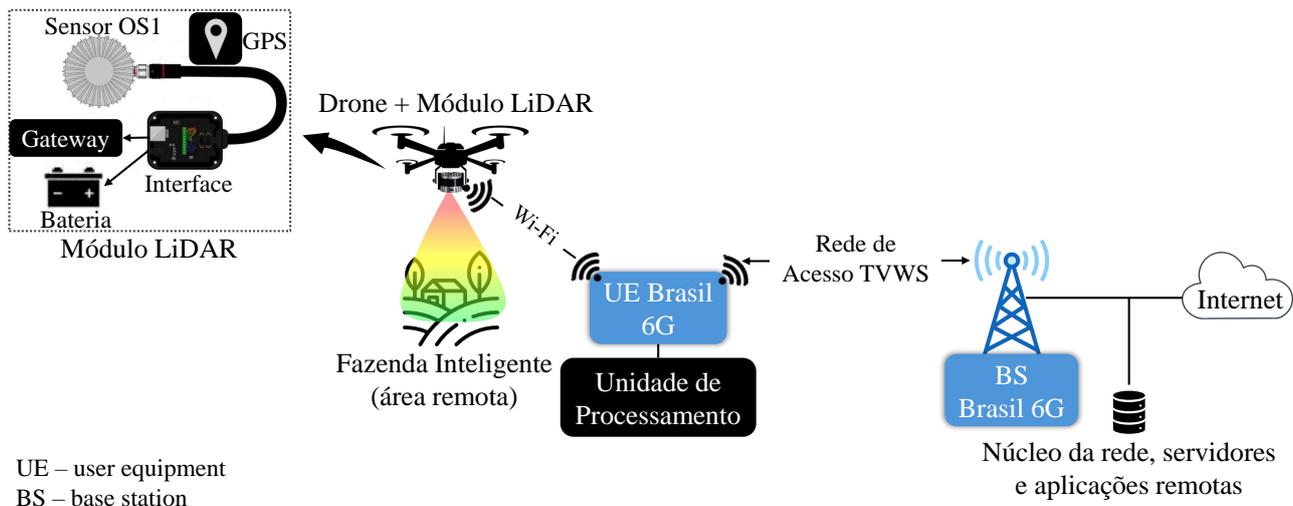


Figura 3: Arquitetura do sistema de monitoramento agrícola ALS utilizando LiDAR embarcado em drone conectado à rede 6G via TVWS em área remota.

de gestão agrícola, painéis de visualização e outros serviços baseados em nuvem.

Para viabilizar essa comunicação de longa distância sobre o espectro TVWS, utiliza-se um transceptor projetado para oferecer conectividade acessível e escalável em áreas rurais e remotas, explorando canais ociosos de TV de forma oportunista por meio de técnicas de rádio cognitivo. Dessa forma, é possível detectar dinamicamente a atividade de usuários primários, realocando automaticamente o canal em uso quando necessário, sem intervenção humana. Na camada física, o transceptor adota a forma de onda *Generalized Frequency Division Multiplexing* (GFDM), que permite a utilização de filtros de conformação por subportadora, reduzindo emissões *Out-of-Band* (OOB) e dispensando filtros de rádiofrequência adicionais. Além disso, a arquitetura inclui codificação *Forward Error Correction* (FEC) e MIMO, o que garante robustez na comunicação e adaptabilidade às condições do canal. As BSs equipadas com esse transceptor podem alcançar raios de cobertura de até 50 km, representando uma solução eficaz para a extensão de serviços de banda larga a regiões com infraestrutura limitada, como áreas agrícolas conectadas a sistemas de sensoriamento e monitoramento remoto [49].

3.3 Requisitos de Projeto

Com base na arquitetura apresentada na Figura 3, são definidos a seguir os principais requisitos do sistema proposto para monitoramento agrícola remoto, utilizando um drone equipado com o módulo LiDAR.

- O sistema deve ser capaz de coletar dados da vegetação e do terreno por meio de um módulo LiDAR embarcado no drone;
- O módulo LiDAR deve conter o sensor LiDAR (OS1, Ouster), uma placa de interface, um *gateway*, um módulo GPS e uma bateria;
- O sensor LiDAR deve ser conectado à placa de interface, à qual fornece a alimentação elétrica necessária e possui interface gigabit Ethernet;
- O *gateway* deve armazenar os dados adquiridos localmente por meio de interface gigabit Ethernet e transmiti-los ao UE utilizando uma interface Wi-Fi;

- É necessário o uso de um módulo GPS acoplado ao sistema embarcado, garantindo a correta associação dos dados obtidos às suas respectivas coordenadas geográficas;
- É necessário o uso de uma bateria de 12 ou 24 V para alimentação do módulo LiDAR e *gateway*;
- A bateria deve ter uma duração mínima de 30 minutos, a qual corresponde a autonomia de voo do drone utilizado (Agras MG-1P, DJI);
- O peso do módulo LiDAR não deve ultrapassar 24,8 kg, o qual é o limite máximo suportado pelo drone;
- A UE deve integrar uma interface Wi-Fi para receber os dados transmitidos pelo módulo LiDAR embarcado no drone;
- A unidade de processamento da UE deve ser compatível com o sistema operacional Linux para processar os dados recebidos, incluindo análise preliminar, filtragem e processamento utilizando *softwares* comerciais e métodos como Modelo Digital da Superfície (MDS) e Modelo Digital do Terreno (MDT);
- A UE deve se comunicar com a BS utilizando o espectro TVWS, o qual possibilita a conectividade da área agrícola isolada;
- A BS deve encaminhar os dados processados para o núcleo da rede, possibilitando seu armazenamento, visualização e análise em servidores e aplicações remotas.

3.4 Aplicações Potenciais

A capacidade dos sistemas LiDAR ALS de gerar modelos tridimensionais de alta resolução do terreno e da vegetação permite captar informações detalhadas sobre a estrutura das plantas e características do relevo e do solo. Esses dados viabilizam análises detalhadas da topografia e da estrutura das plantações, além de diagnósticos sobre o crescimento das culturas, a variabilidade do solo e a distribuição das plantas. Também permitem identificar com precisão problemas de saúde, como doenças ou deficiências nutricionais, e apoiar a tomada de decisões relacionadas ao controle da irrigação. Essa caracterização é essencial para a implementação de práticas eficientes de agricultura de precisão. Dessa forma, serão analisadas as aplicações potenciais da arquitetura do sistema proposta, ilustrada na Figura 3, implementada no contexto da agricultura de precisão, com ênfase em suas contribuições para o desenvolvimento de práticas agrícolas mais eficientes e sustentáveis, descritas a seguir.

3.4.1 Mapeamento do Solo

A combinação do LiDAR com técnicas precisas de georreferenciamento permite a criação de mapas de solo de alta resolução. Ao analisar variações na elevação e na inclinação da superfície a partir do LiDAR, pode-se identificar e mapear diferentes tipos de solo e sua distribuição espacial dentro de uma área agrícola [6]. Dessa forma, MDTs e MDSs de alta resolução podem ser criados a partir dos dados adquiridos, o que permite uma classificação precisa do solo e possibilita práticas de controle direcionadas, como a fertilização em taxa variável e a irrigação localizada [50]. O sensor LiDAR opera emitindo pulsos de laser em alta frequência em direção ao solo e medindo o tempo que cada pulso leva para retornar ao sensor após refletir em diferentes

superfícies. Esse processo resulta em um conjunto tridimensional de dados conhecido como nuvem de pontos, no qual cada ponto possui coordenadas geográficas (x, y, z). A densidade e precisão dessa nuvem permitem capturar com alto nível de detalhe tanto a topografia do terreno quanto objetos sobre a superfície, como vegetação ou estruturas. A partir dessa nuvem de pontos, é possível gerar diferentes tipos de modelos digitais de elevação.

A Figura 4 exemplifica o funcionamento de um sistema LiDAR ALS e a geração dos modelos MDS e MDT. O MDS inclui todos os elementos presentes na área analisada, como copas de árvores, edificações e outros obstáculos. Já o MDT representa exclusivamente o relevo natural do solo obtido por meio da filtragem dos pontos que correspondem à vegetação ou construções. As nuvens de pontos LiDAR são geralmente disponibilizadas no formato de arquivo .las. Esse formato compactado é mais eficiente no armazenamento e no gerenciamento dos milhões de pontos comumente presentes nos dados do LiDAR.

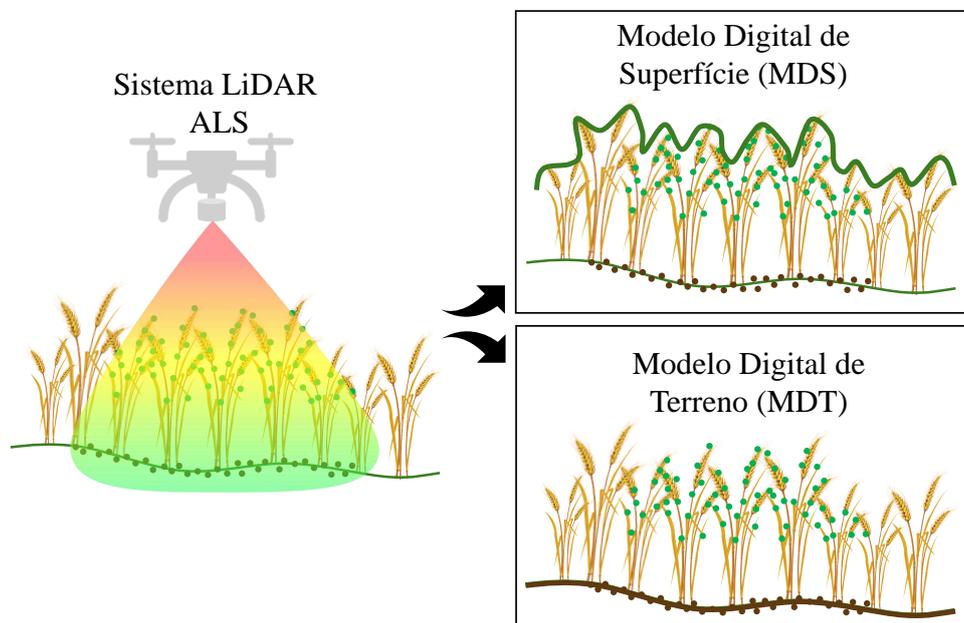


Figura 4: Ilustração do processo de aquisição de dados por um sistemas LiDAR ALS e os respectivos modelos gerados: MDS e MDT.

3.4.2 Estimativa de Altura das Plantações

A altura das plantações é um parâmetro diretamente relacionado ao crescimento e saúde das plantas e à estimativa de produtividade [51, 52]. Tradicionalmente, essa variável é obtida por meio de medições manuais em campo, as quais são demoradas, trabalhosas e inviáveis para grandes áreas [53, 54]. Na agricultura de precisão, os sistemas de sensoriamento remoto surgem como uma alternativa eficiente para a medição de altura das plantações, pois permitem a aquisição de informações da vegetação de forma rápida e precisa, em diferentes períodos de tempo e em larga escala [52]. Dentre as tecnologias aplicadas, os sistemas LiDAR ALS são amplamente utilizados na reconstrução tridimensional da vegetação, pois permitem a coleta de dados sobre grandes áreas com alta densidade de pontos e precisão métrica [52, 55, 56, 57]. Além da coleta dos dados, o processamento das informações obtidas pelo LiDAR ALS é fundamental para a estimativa precisa da altura das plantações.

Por serem montados em plataformas aéreas, como drones, os sistemas ALS conseguem gerar modelos digitais de superfície e da plantação, possibilitando a extração precisa da altura das plantas com base na diferença entre o topo da vegetação e o terreno, conforme ilustrado na Figura 5. Inicialmente, realiza-se a filtragem dos pontos para separar o retorno do solo da vegetação, permitindo a geração do MDT e do MDS. A altura das plantas é então calculada pela diferença entre o MDS e o MDT [53, 58]. A resolução espacial e a precisão dos dados dependem da altitude de voo e da densidade dos pontos coletados. Estudos demonstram que a estimativa da altura com LiDAR ALS pode alcançar *Root Mean Square Error* (RMSE) inferiores a 0,05 metros em culturas de trigo, viabilizando análises precisas para monitoramento do crescimento e planejamento agrícola [8].

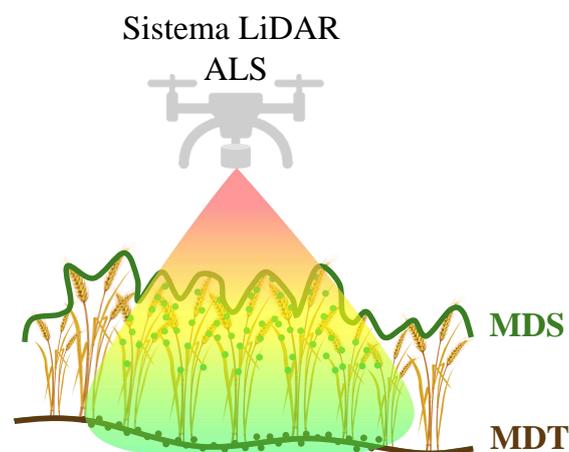


Figura 5: Sistema LiDAR ALS aplicado à estimativa de altura da plantação.

3.4.3 Detecção de Obstáculos

A detecção de obstáculos em campos agrícolas é muito importante para a navegação e para as operações realizadas por máquinas agrícolas, especialmente para máquinas autônomas [59]. Os ambientes agrícolas são complexos e não estruturados, com quatro tipos comuns de obstáculos: obstáculos positivos (por exemplo, árvores e postes), obstáculos negativos (como buracos e valas), obstáculos móveis (como veículos e pessoas) e terrenos difíceis (como encostas e áreas alagadas) [60]. Além disso, as características dos obstáculos variam conforme o tipo de plantação, a curvatura do terreno e outros fatores, e os veículos agrícolas atuais apresentam dificuldades na detecção precisa desses obstáculos.

A tecnologia LiDAR oferece uma solução ao realizar a detecção de obstáculos em tempo real nesses ambientes desafiadores [8]. A maioria das aplicações utiliza sensores LiDAR embarcados em veículos terrestres, como tratores e robôs agrícolas, para realizar a detecção de obstáculos ao nível do solo [61, 62]. No entanto, também é possível empregar sistemas LiDAR ALS montados em drones para essa finalidade, especialmente em tarefas de mapeamento prévio do terreno ou em operações em larga escala, oferecendo uma visão abrangente da área e permitindo a identificação de obstáculos antes da entrada dos veículos no campo [6].

A Figura 6 ilustra a aplicação de um sistema LiDAR ALS na identificação de obstáculos em ambientes agrícolas. Os dados gerados pelos sensores LiDAR podem ser processados por algoritmos de IA e aprendizado de máquina, permitindo não apenas a detecção, mas também

a classificação automática dos obstáculos com base em sua forma, tamanho ou padrão de movimento.



Figura 6: Sistema LiDAR ALS embarcado em drone detectando obstáculos em área agrícola com destaque para objetos identificados entre as linhas de cultivo.

3.5 Direções futuras

Tendo em vista os avanços obtidos na definição da arquitetura e dos requisitos do sistema de monitoramento agrícola baseado em LiDAR embarcado em drones e conectado via TVWS, os próximos passos da pesquisa concentram-se na implementação prática da solução proposta. Essa etapa permitirá validar, em condições reais de operação, a integração entre os módulos de sensoriamento remoto, comunicação e processamento embarcado.

A fase de implementação compreenderá a montagem do protótipo completo, a validação do *hardware*, a realização de testes em campo e a avaliação de parâmetros como confiabilidade da transmissão e latência da comunicação. Espera-se, com isso, demonstrar a viabilidade de aplicações em tempo real e viabilizar a integração dos dados adquiridos para visualização, análise e suporte à decisão em aplicações reais.

A execução em campo permitirá ainda avaliar aspectos operacionais relevantes, como a autonomia de voo, a capacidade de cobertura da solução, a robustez da conexão sob diferentes condições ambientais, bem como o desempenho do sistema nas aplicações específicas descritas na Subseção 3.4.

4 Criação de um Conjunto de Dados LiDAR Sintético com BlenSor

Esta seção descreve a metodologia utilizada para a geração de um conjunto de dados sintéticos LiDAR no contexto do Projeto Brasil 6G. São detalhados os procedimentos realizados com o uso do simulador BlenSor, com ênfase na criação de amostras realistas e devidamente anotadas, destinadas ao desenvolvimento e à validação de algoritmos de detecção e classificação.

4.1 Contextualização

O BlenSor é um ambiente de simulação de sensores tridimensionais integrado diretamente à plataforma Blender, que permite a geração de dados de alcance (*range data*) com elevado grau de realismo físico e ampla flexibilidade de configuração [63]. Seu principal objetivo é fornecer aos pesquisadores das áreas de detecção de obstáculos, segmentação de nuvens de pontos, rastreamento de objetos e reconstrução de superfícies um *framework* unificado, que abstrai as complexidades inerentes à modelagem e implementação de sensores. Dessa forma, o BlenSor possibilita que o foco dos estudos permaneça no desenvolvimento, teste e validação de algoritmos, otimizando o ciclo de pesquisa e experimentação.

A arquitetura do BlenSor é baseada em um *plugin* que expande a interface gráfica do Blender, adicionando painéis de configuração dedicados a diversos tipos de sensores, como LiDAR rotativo, LiDAR de linha e câmeras *Time-of-Flight* (ToF), entre outros. Essa integração dispensa a necessidade de edição de arquivos externos ou utilização de *scripts* adicionais, facilitando a configuração e execução das simulações. Internamente, o BlenSor utiliza um mecanismo de *ray-casting* eficiente, capaz de lançar simultaneamente milhares de raios, simulando com precisão efeitos físicos relevantes, como reflexões múltiplas, atenuação por distância e retroespalhamento (*backfolding*), o que contribui para a geração de dados sintéticos com elevado realismo.

O princípio de simulação adotado pelo BlenSor baseia-se em técnicas de traçado de raios (*ray tracing*), modelando de forma física o tempo de voo da luz, a intensidade do sinal refletido e os ruídos inerentes a cada unidade de detecção. Cada feixe de laser ou pixel de uma câmera ToF é simulado por meio do lançamento de um raio, com o cálculo do ponto de interseção com os objetos da cena e a adição de componentes de ruído sistemático e aleatório. Além disso, são incorporados modelos de refletividade dependentes das propriedades do material e da distância ao sensor. Esse nível de detalhamento permite a reprodução fidedigna de características observadas em sensores comerciais, como os modelos Velodyne HDL-64E e Ibeo LUX, incluindo funcionalidades como ajuste do limiar de detecção e interpolação linear da sensibilidade.

O BlenSor oferece suporte à simulação de múltiplos tipos de sensores, tais como:

- LiDAR Rotativo: simula *scanners* com varredura de 360°, compostos por unidades de laser distribuídas verticalmente. Permite configurar parâmetros como taxa de varredura, número de linhas e distribuição angular entre os feixes.
- LiDAR de Linha: modela sensores híbridos que combinam emissores fixos com espelhos rotativos, permitindo a variação simultânea dos ângulos de *yaw* e *pitch*, o que resulta em padrões de escaneamento complexos e realistas.
- Câmera ToF: gera mapas de profundidade em alta resolução, modelando o *backfolding* e refletividade especular incidente na captação de cada pixel.

O conteúdo deste capítulo foi desenvolvido pelos pesquisadores *Matheus F. Silva* e *Felipe A. P. de Figueiredo*.

Todos esses sensores podem ser ajustados quanto a parâmetros como ruído, alcance máximo, resolução angular e propriedades ópticas dos materiais presentes na cena.

Para exportação dos dados simulados, o BlenSor oferece duas modalidades principais de saída: i) nuvens de pontos tridimensionais, contendo as coordenadas (x, y, z) , ângulos de varredura, distâncias com e sem ruído, e identificadores dos objetos atingidos; ii) mapas de profundidade em ponto flutuante de alta resolução, compatíveis com ferramentas de processamento 2.5D.

Toda a configuração da cena, incluindo os parâmetros do sensor e o ambiente simulado, é mantida de forma integrada em um único arquivo `.blend`.

4.2 Geração dos Dados LiDAR com o BlenSor

O conjunto de dados foi gerado utilizando o simulador BlenSor. Para compor as cenas simuladas, uma variedade de modelos tridimensionais foi importada, abrangendo oito classes-alvo: *Pessoa*, *Cachorro*, *Gato*, *Grandes Felinos* (incluindo leopardo, onça-pintada e outros felinos de grande porte), *Vaca*, *Cavalo*, *Porco* e *Lobo*. Em cada cena, o BlenSor emulou varreduras a laser, gerando dados em formato de nuvem de pontos (*Point Cloud Data* (PCD)). Esses dados foram exportados como conjuntos de coordenadas (x, y, z) , representando com precisão a geometria tridimensional dos objetos simulados.

Os modelos tridimensionais utilizados foram adquiridos no *marketplace TurboSquid*, um dos maiores repositórios de ativos profissionais voltados para aplicações em jogos, efeitos visuais e visualização arquitetônica [64]. Em particular, foi utilizado o conjunto pago “Animal Collection” (ID 1499359), publicado em janeiro de 2020, que reúne mais de 40 espécies com geometrias de alta resolução (aproximadamente 1,5 milhão de polígonos), mapeamento ultravioleta (UV)

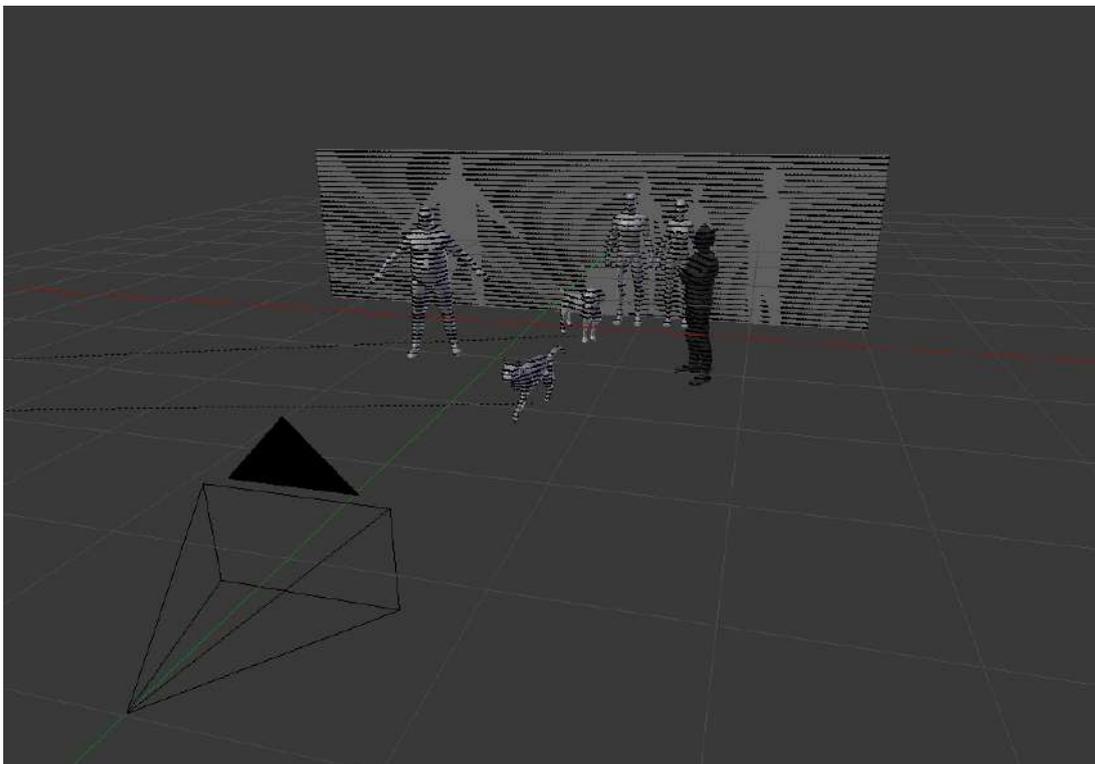


Figura 7: Simulação de varredura LiDAR usando o BlenSor.

completo, texturas baseadas em *Physically Based Rendering* (PBR) e *rigs* detalhados para animação [65]. Dentre as espécies disponíveis, foram selecionadas especificamente: Cachorro, Gato, Grandes Felinos (Leopardo e Onça-Pintada), Vaca, Cavalo, Porco e Lobo. Os modelos de pessoas foram obtidos a partir de projetos *open source* gratuitos, selecionados por apresentarem malhas limpas, coordenadas UV devidamente desdobradas e texturas básicas adequadas à simulação.

Cada objeto presente na cena foi anotado com uma caixa delimitadora alinhada aos eixos (*axis-aligned bounding box*). As etiquetas consistem nas coordenadas do centro da caixa (x_c, y_c, z_c), na largura w , altura h , comprimento l , e no ângulo de rotação de guinada θ_y , correspondente à rotação em torno do eixo y do sistema de coordenadas do sensor. A Figura 7 ilustra a simulação de uma cena no BlenSor, destacando a leitura gerada por um sensor LiDAR a partir de múltiplos objetos tridimensionais.

Os dados gerados pelo BlenSor são submetidos a um processo de compressão com o objetivo de reduzir o tamanho dos arquivos, otimizando o armazenamento e a transferência. Inicialmente, as colunas numéricas em ponto flutuante são convertidas para uma representação de precisão reduzida, simulando o formato BFloat16, que preserva aproximadamente três a quatro dígitos significativos. Em seguida, as colunas inteiras são ajustadas para tipos de dados com menor ocupação de memória, enquanto os valores de refletividade são compactados em um tipo de 8 bits. Após essa etapa de otimização, o conjunto de dados é serializado em um arquivo *pickle* comprimido por *gzip*, proporcionando compactação adicional e assegurando compatibilidade com ferramentas de processamento subsequentes. Em média, esse processo resulta em arquivos com tamanho mais de 600 vezes menor em comparação aos dados brutos originalmente exportados.

A Figura 8 ilustra o fluxo de trabalho completo para a geração e compressão de uma cena rotulada no BlenSor.

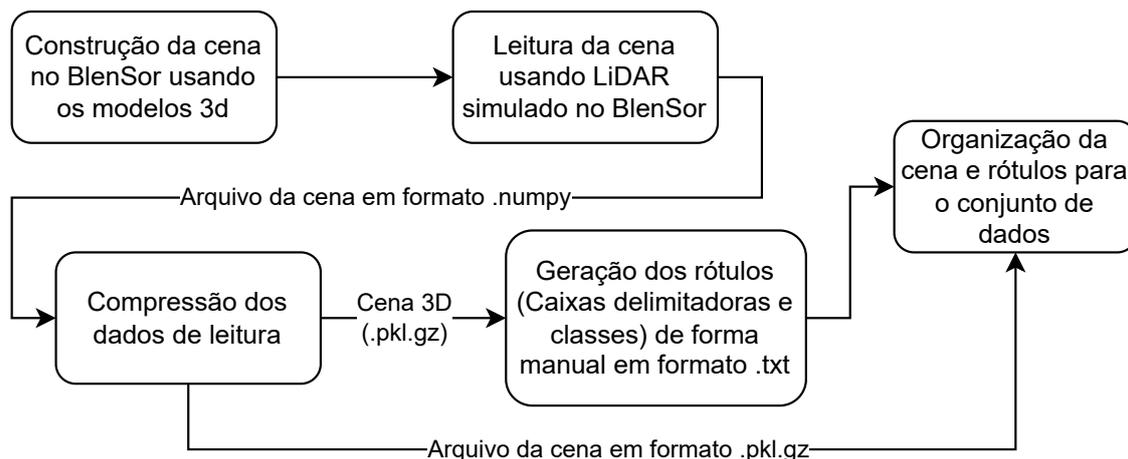


Figura 8: Processo de geração de uma cena rotulada.

Após a geração dos *scans* sintéticos no BlenSor, serão aplicadas técnicas de *data augmentation* diretamente nas nuvens de pontos e em suas respectivas anotações, com o objetivo de aumentar a diversidade do conjunto de dados e melhorar a robustez dos modelos de aprendizado. Dentre os métodos empregados, destaca-se o *flip* ao longo dos eixos x ou z , que inverte simetricamente a cena, ajustando tanto os pontos quanto a orientação das caixas. A escala não

uniforme permite simular variações de tamanho dos objetos ao alongar ou comprimir as nuvens de pontos em cada eixo independentemente. A técnica de *dropout* de pontos remove aleatoriamente uma fração dos pontos, emulando falhas de retorno do sensor. O *occlusion* aplica uma máscara cúbica aleatória na cena, eliminando pontos dentro desse volume e simulando obstruções físicas. A distorção elástica introduz deslocamentos suaves nos pontos por meio de ruído espacial suavizado, representando imperfeições estruturais ou ruído mecânico do sensor. Além disso, o recorte aleatório (*random crop*) seleciona sub-regiões da nuvem de pontos, descartando partes externas, enquanto o *resample* ajusta a densidade do PCD, tanto por subamostragem quanto por superamostragem. Também são aplicadas transformações rígidas, como rotações arbitrárias em torno dos eixos x , y ou z e translações espaciais, além do *jitter*, que adiciona ruído gaussiano de baixa magnitude, simulando incertezas de medição. Essas operações não apenas aumentam a variabilidade espacial das amostras, como também promovem invariância a transformações geométricas e robustez a ruídos característicos de sensores reais.

Um dos principais entraves identificados nesse fluxo de trabalho é a natureza altamente manual do processo de criação das cenas e das anotações. Cada ambiente sintético precisa ser montado individualmente, exigindo o posicionamento manual dos modelos tridimensionais, o ajuste de suas orientações e propriedades de material, bem como a calibração dos parâmetros de varredura para cada sensor virtual. Na etapa seguinte, é necessário validar e corrigir manualmente as caixas delimitadoras de cada objeto, assegurando que as dimensões, o centroide e a rotação estejam consistentes com a cena renderizada. Esse processo de configuração e etiquetagem, que deve ser repetido para cada amostra, demanda tempo e recursos humanos, tornando a geração de grandes volumes de dados rotulados um desafio em termos de escalabilidade e produtividade.

4.3 Próximas atividades

A pesquisa encontra-se em andamento, e a próxima fase será voltada à ampliação do volume de dados por meio da implementação de *pipelines* automatizados para geração de novas amostras, bem como da aplicação de técnicas de *data augmentation* sobre as nuvens de pontos. Essas estratégias visam aumentar a diversidade e a representatividade do conjunto de dados, fortalecendo a generalização dos modelos criados.

Em complemento, será desenvolvida uma interface em *Python* para automatizar os processos de criação e edição de anotações. Essa ferramenta será projetada para auxiliar o usuário na geração de caixas delimitadoras, além de oferecer funcionalidades para validação em lote dos rótulos. A interface permitirá o ajuste interativo de parâmetros de anotação e a exportação de conjuntos de *labels* em formatos padronizados, reduzindo significativamente o esforço manual envolvido no processo.

O conjunto resultante apresentará maior diversidade e robustez, fornecendo uma base sólida para a avaliação e o refinamento de algoritmos de detecção e classificação em cenários simulados.

5 Seleção de Feixe Usando Dados LiDAR

Esta seção descreve a metodologia adotada para a seleção de feixe (*beam selection*) em comunicações mmWave, com base em dados provenientes de sensores LiDAR, no contexto do Projeto Brasil 6G. Foi empregada a arquitetura WiSARD como uma solução leve e eficiente para a previsão da melhor direção de feixe, com o objetivo de reduzir a latência e a complexidade computacional do processo de *beamforming*. São apresentados os dados utilizados no estudo, incluindo informações de localização obtidas por GPS e mapas tridimensionais gerados por LiDAR, além dos procedimentos de pré-processamento aplicados. A avaliação da abordagem proposta considera métricas de desempenho padrão e realiza uma comparação com modelos de referência disponíveis na literatura, utilizando como base o conjunto de dados *Raymobtime*.

5.1 Contextualização

As comunicações em mmWave, que operam na faixa de 30 a 300GHz, oferecem amplo espectro para aplicações de banda larga. No contexto do 5G, a *International Telecommunications Unit* (ITU) alocou as faixas de 28–38 GHz e 70–90 GHz durante a Conferência Mundial de Radiocomunicações de 2019 (WRC-19) [66]. Entretanto, sistemas mmWave enfrentam desafios significativos relacionados à descoberta e seleção de feixes (*beam discovery* e *beam selection*), especialmente na ausência de informações contextuais fora de banda de operação. Duas abordagens predominam nesse processo:

- i) Varredura exaustiva: transmissor e receptor avaliam todos os pares possíveis de feixes (Tx-Rx) para identificar a melhor combinação de direcionamento;
- ii) Busca hierárquica: inicia-se com feixes largos, que são progressivamente refinados até se alcançar feixes estreitos com maior ganho direcional.

Atualmente, os padrões celulares adotam a varredura exaustiva como abordagem padrão para seleção de feixes. No entanto, com o aumento no número de antenas previsto para os sistemas móveis de próxima geração, essa estratégia torna-se gradualmente inviável, devido à elevada complexidade computacional e à latência associada ao processo. Nesse contexto, técnicas de aprendizado de máquina têm se consolidado como alternativas promissoras para a otimização de tais processos em redes móveis. Sua capacidade de generalização permite lidar de forma mais eficiente com a complexidade da seleção de feixes, especialmente em cenários desafiadores e dinâmicos, contribuindo para a redução do tempo de varredura e o aumento da eficiência espectral.

Neste estudo, investiga-se o uso de RNSP, em particular a arquitetura WiSARD, como alternativa para o processo de seleção de feixe em sistemas mmWave. A abordagem proposta considera informações contextuais provenientes de dados GPS e de sensores LiDAR.

A proposta inicial foi apresentada na Seção 10 do relatório técnico "Tecnologias Habilitadoras e Estudo Exploratório de Algoritmos para Camada Física e de Enlace para Redes 6G", elaborado na Fase II do Projeto Brasil 6G, onde se investigou o uso de dados LiDAR para prever bloqueios de canal em cenários veiculares. Nesse trabalho, foram abordados o estado da arte sobre o uso de dados contextuais unimodais e multimodais na seleção de feixe, o funcionamento de RNSPs com ênfase na arquitetura WiSARD, a metodologia de pré-processamento dos dados

O conteúdo deste capítulo foi desenvolvido pelos pesquisadores *Joanna Manjarres* e *José F. de Rezende*.

de entrada aplicados à rede e a aplicação na predição de bloqueios, além da constatação de que o uso de informações contextuais (como posição, imagens, sensores inerciais ou LiDAR) pode reduzir a sobrecarga nos enlaces, aumentando a eficiência espectral e diminuindo a latência.

Com base nesses resultados, o presente estudo objetiva aprimorar o pré-processamento dos dados de entrada para a arquitetura WiSARD. O desempenho da abordagem foi avaliado por meio de comparações com técnicas tradicionais de aprendizado supervisionado, incluindo *K-Nearest Neighbors* (KNN), Árvores de Decisão, *Support Vector Classifier* (SVC) e *Random Forest*, bem como com modelos previamente reportados na literatura.

Entre as principais motivações para a utilização da arquitetura WiSARD na seleção de feixe, destacam-se o baixo tempo de inferência, fator crítico para decisões em tempo real em cenários dinâmicos, o reduzido consumo de memória e baixa complexidade computacional, que viabilizam a implementação em dispositivos embarcados com recursos limitados, sem a necessidade de GPUs ou aceleradores dedicados, e a robustez à quantização e ao ruído nos dados, uma vez que a WiSARD opera naturalmente com entradas binarizadas. Tais características tornam essa arquitetura uma candidata promissora para integração em sistemas 6G, que exigem resposta rápida, confiabilidade e eficiência energética.

5.2 Trabalhos Relacionados

A literatura recente tem investigado amplamente o uso de técnicas de aprendizado de máquina (*Machine Learning* (ML)) como apoio à tarefa de seleção de feixes em sistemas de comunicações móveis. Tabela 5 apresenta um panorama dos principais estudos nessa área, organizados em três categorias, conforme o tipo de informação contextual utilizada como entrada para os modelos:

- Grupo I: trabalhos que utilizam múltiplas fontes de informação, como sinais de piloto, imagens capturadas por câmeras, dados de sensores (por exemplo, radar) e informações de localização via GPS;
- Grupo II: estudos que integram dados provenientes de sensores LiDAR com outras fontes contextuais, como GPS ou imagens, ampliando a riqueza da informação disponível para a seleção de feixes;
- Grupo III: pesquisas que se concentram exclusivamente no uso de dados de sensores LiDAR para a tarefa de seleção de feixes.

A tabela também resume as principais técnicas de ML aplicadas, as configurações de antenas adotadas e os conjuntos de dados utilizados em cada estudo. Observa-se que as *Deep Neural Networks* (DNNs) são amplamente empregadas, devido à sua capacidade de lidar com dados de alta dimensionalidade e capturar padrões complexos. Além dessa arquitetura, destacam-se a *Convolutional Neural Network* (CNN), eficaz na extração de características espaciais a partir de dados 2D ou 3D, e a *Multilayer Perceptron* (MLP). Além disso, técnicas mais tradicionais, como *Support Vector Machine* (SVM), Árvores de Decisão, *Random Forest* e KNN, também são utilizadas, especialmente em cenários com restrições de complexidade computacional ou com conjuntos de dados reduzidos.

Com o objetivo de resumir os resultados obtidos nos trabalhos que utilizaram o *dataset Raymobtime*, a Tabela 6 apresenta o desempenho alcançado pelas diferentes técnicas implementadas.

Embora as abordagens recentes apresentem precisão aceitável na tarefa de seleção de feixes, a limitação mais recorrente está no alto custo computacional e na complexidade do treinamento. Essas técnicas geralmente requerem grandes volumes de dados, além de processos de treinamento que podem ser lentos e instáveis.

Até a data deste trabalho, não foi identificada na literatura uma comparação justa e padronizada entre diferentes métodos, especialmente no que diz respeito ao desempenho computacional. Este estudo propõe realizar uma comparação entre abordagens com parametrizações semelhantes, treinadas e testadas sob as mesmas condições, visando analisar tanto a acurácia quanto a eficiência computacional. Com base na análise dos trabalhos revisados, foram selecionadas como modelos *baseline* as abordagens propostas por [1] e [2], que servirão de referência para a comparação de desempenho desenvolvida neste estudo.

Tabela 5: Comparação de trabalhos relacionados.

Ref.	Tipo de entrada	Técnica de aprendizado	Tipo de antena	Dataset
[67]	GPS	DNN, Depp RL, AdaBoost, Linear SVM, Decision tree, Random Forest	UPA 4X4	Raymobtime
[68]	pilots	DNN	ULA 64X64	Deep MIMO
[68]	pilots	DNN	ULA 64X64	Deep MIMO
[69]	images	DNN	-	Generate
[70]	pilots	IFML	-	-
[71]	pilots	LSTM	-	Deep MIMO
[72]	pilots	DNN	UPA	Generate
[73]	Radar	-	UPA	Generate
[74]	GPS	MLP, CNN	UPA 4X4	Raymobtime
[75]	GPS, images	DNN	ULA 32X8	Raymobtime
[76]	GPS, LiDAR	ViT model	-	Raymobtime
[77]	GPS, LiDAR	CNN	UPA 16X4	Raymobtime
[2]	GPS, LiDAR	MLP	ULA 32X8	Raymobtime
[78]	GPS, LiDAR	DNN	UPA 16X4	Raymobtime
[1]	GPS, LiDAR, images	DNN	ULA 32X8	Raymobtime, NEU
[79]	GPS, LiDAR	Federated, NN	-	Raymobtime
[80]	GPS, LiDAR, images	DNN	ULA 64X8	Raymobtime
[81]	LiDAR, GPS	SVC, KNN, WiSARD, Decision Tree, Random Forest	ULA 32X8	Raymobtime
[82]	LiDAR	3D CNN	-	Raymobtime
[83]	LiDAR	DNN	UPA	Raymobtime
[84]	LiDAR	CNN	-	Raymobtime
[69]	LiDAR	DNN	UPA	Generate

Tabela 6: Comparação dos resultados alcançados pelos trabalhos da revisão bibliográfica.

Técnica	Entrada	Acurácia[%]			Referência
		Top-1	Top-10	Top-20	
Linear SVM		33.2	-	-	
AdaBoost		55.0	-	-	
Decision Tree	GPS	55.5	-	-	[67]
Random Forest		63.2	-	-	
DNN		63.8	-	-	
DQN		67.5	-	-	
DNN	LiDAR	20.5	33.0	49.5	[83]
DL	LiDAR, GPS	42.0	90.0	98.0	[78]
Conv3D	LiDAR	63.3	92.5	-	[82]
KNN		43.0	-	-	
Naive Bayes	GPS	8.70	-	-	[74]
ANN		40.50	-	-	
Lightweight NN	LiDAR, GPS	59.5	-	87.0	[84]
F-DL	LiDAR	46.2	89.9	96.1	[1]
DNN	LiDAR	32.0	80.0	-	[69]
Dense Neural Network	LiDAR	43.0	82.0	85.0	[80]
WiSARD	LiDAR, GPS	71.0	95.0	98.0	[81]

5.3 Metodologia usada na Rede Neural Sem Peso

Para a avaliação da rede WiSARD na tarefa de seleção de feixe, foi utilizado o *dataset Raymobtime*¹, o qual fornece coletas de dados realistas para a simulação de comunicações sem fio. Essa base de dados inclui, além dos resultados de traçado de raios, informações contextuais relevantes, como a posição dos veículos receptores e dados provenientes de sensores LiDAR.

Devido às características da rede WiSARD, as entradas devem ser previamente binarizadas. Para esse fim, foi realizado um processo de pré-processamento específico, tanto para as coordenadas quanto para os dados provenientes do sensor LiDAR, utilizando-se o método do termômetro em ambos os casos. Esse método consiste na construção de uma palavra binária de d bits que simula uma escala ordenada, permitindo representar variáveis contínuas de forma compatível com a estrutura da rede [85]. As metodologias implementadas para esse pré-processamento são apresentadas nas subseções a seguir.

5.3.1 Pré-processamento das Coordenadas

No caso das coordenadas, cada receptor é representado por dois valores decimais correspondentes às posições GPS (x e y). Sendo assim, dado um conjunto de coordenadas para treinamento, foi considerada a diferença entre uma coordenada dada e a coordenada mínima do conjunto, para, finalmente, definir o tamanho da entrada (palavra de d bits) da rede WiSARD,

¹<https://www.lasse.ufpa.br/raymobtime/>

conforme especificado na Tabela 7, adotando-se uma resolução de 1 bit por unidade. Esse procedimento permite representar cada coordenada como um vetor binarizado, compatível com o modelo termométrico exigido pela arquitetura da rede.

Tabela 7: Especificações do termômetro para as coordenadas.

Coord	min	max	Tamanho da entrada
x	745	765	20
y	431	676	245

A resolução desse termômetro é definida como a diferença entre a coordenada da posição do receptor e a coordenada mínima do conjunto de dados. Portanto, para o caso das coordenadas x , se o receptor estiver posicionado na coordenada mínima, a diferença resultante será igual a 0 e, nesse caso, o termômetro conterá apenas um único valor 1 em seu vetor de entrada. Já no caso em que o receptor estiver posicionado na última coordenada, a diferença resultante será igual a 20, e o vetor de entrada será composto por vinte valores 1. A Figura 9 apresenta uma representação dessa proposta.

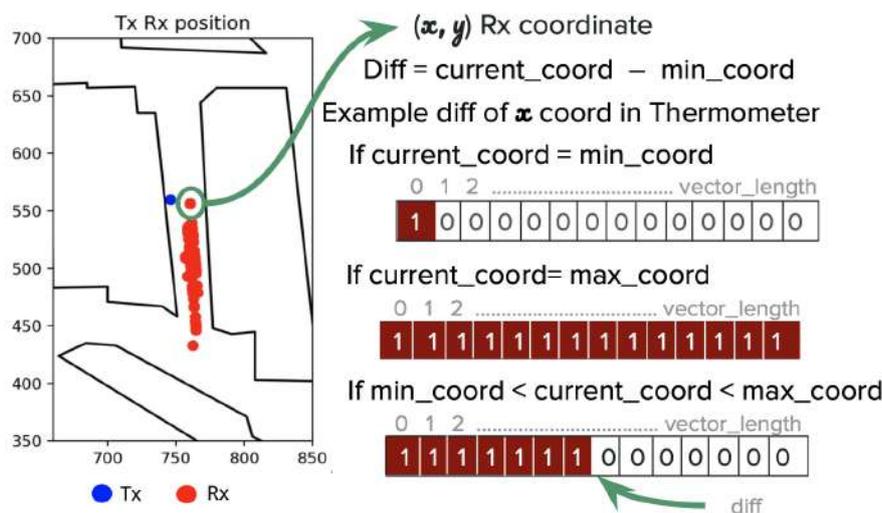


Figura 9: Representação da resolução do termômetro das coordenadas.

Uma vez definida a quantidade de bits que representa a entrada das coordenadas ($d = 265$) e estabelecida a resolução de 1 bit, a Figura 10 apresenta o desempenho da rede WiSARD em função dos diferentes tamanhos de endereçamento de memória avaliados, sendo este um dos principais hiperparâmetros a ser ajustado.

Devido ao aumento observado na acurácia com o crescimento do tamanho da memória, tanto o tamanho da entrada (d) quanto a resolução foram considerados como hiperparâmetros da rede WiSARD. Para isso, foram avaliados dez configurações de termômetros com incrementos lineares, conforme descrito na Tabela 8. A fim de resumir o impacto desses hiperparâmetros no desempenho da rede, a Figura 11 apresenta um mapa de calor que evidencia a melhor acurácia obtida com entradas baseadas em coordenadas, igual a 59,5%, alcançada com tamanho de entrada de 2.120 bits, resolução de 8 bits e endereçamento de memória de 54 bits. Observa-se, contudo, que para tamanhos elevados de entrada, o desempenho da rede se manteve estável, com acurácia em torno de 58%.

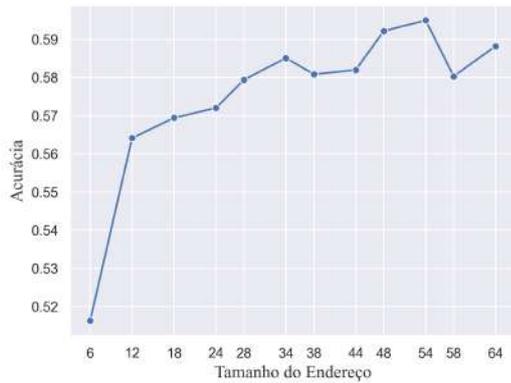


Figura 10: Desempenho da rede WiSARD variando o endereçamento da memória com entradas de coordenadas e resolução igual 8.

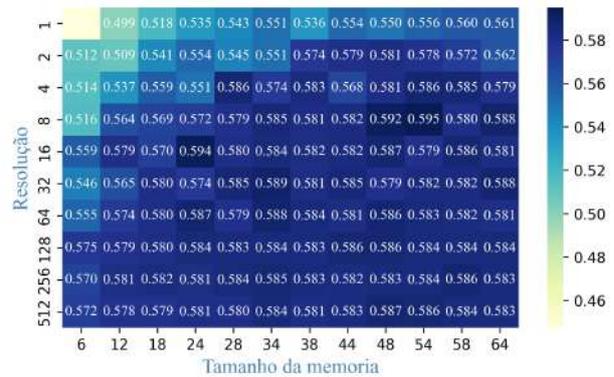


Figura 11: Mapa de calor do desempenho da acurácia com entradas de coordenadas da rede WiSARD.

Tabela 8: Impacto da resolução do termômetro sobre o tamanho da entrada.

Resolução		1	2	4	8	16	32	64	128	256	512
Tamanho da entrada	coord. X	20	40	80	160	320	640	1.280	2.560	5.120	10.240
	coord. Y	245	490	980	1.960	3.920	7.840	15.680	31.360	62.720	125.440

5.3.2 Pré-processamento dos Dados LiDAR

Os dados LiDAR presentes no *dataset Raymobtime* representam a localização do transmissor, dos receptores e de obstáculos na região estudada. Essas informações estão quantizadas na forma de histogramas, nos quais cada elemento corresponde a uma região fixa da área de cobertura. No lado direito da Figura 12, é apresentada uma representação dos dados LiDAR do episódio 8, pertencente ao conjunto s008. Para adequar esses dados às exigências do modelo proposto, foi realizada uma etapa inicial de quantização. Além disso, desenvolveu-se uma abordagem exclusiva de codificação termométrica tridimensional, que incorpora a posição espacial do receptor no ambiente. Esta técnica está ilustrada no lado esquerdo da Figura 12.

A entrada dos dados LiDAR, portanto, incorpora não apenas a localização precisa do receptor, mas também um mapa abrangente que representa todos os obstáculos quantizados presentes na cena. Para simplificar a manipulação e o processamento desses dados no modelo, a matriz tridimensional original foi convertida em uma representação bidimensional, por meio do descarte das informações relativas à altura. Essa transformação está ilustrada na Figura 13.

Além da etapa de quantização, foi avaliada uma técnica de filtragem baseada em limiar de variância. Esse algoritmo descarta atributos cuja variabilidade esteja abaixo de um limite pré-estabelecido, por serem considerados pouco informativos para o modelo. Inicialmente, analisou-se o desempenho da rede WiSARD variando o tamanho do endereço de memória (RAM *size*), conforme ilustrado na Figura 14. Após identificar que o melhor desempenho foi obtido com um tamanho de memória igual a 58, foram testados cinco níveis distintos de limiar de variância, cujos resultados são apresentados na Figura 15.

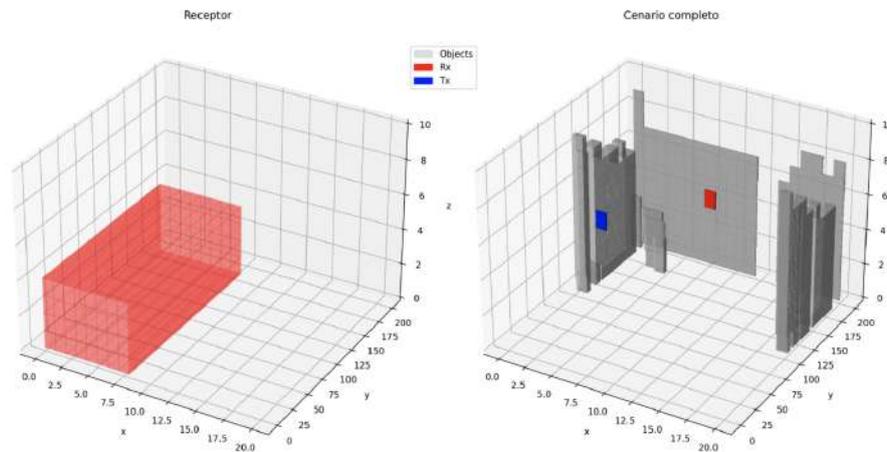


Figura 12: Episódio 8 do LiDAR quantizado do *dataset* s008 mais o receptor como um termômetro.

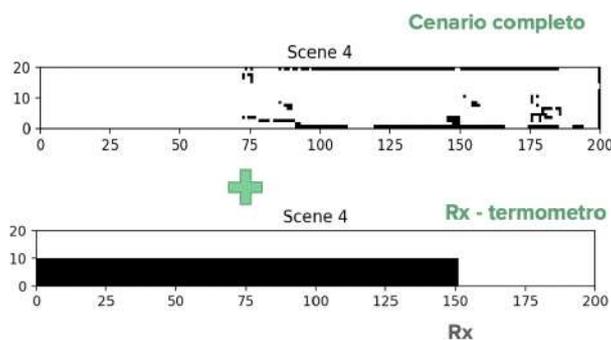


Figura 13: Episódio 8 do LiDAR quantizado do *dataset* s008.

Os resultados obtidos indicaram que o melhor desempenho da rede foi alcançado com o limiar de variância igual a 0,1. No entanto, ao adotar um limiar de 0,15, observou-se uma redução de 17% no tamanho da entrada, com uma perda de acurácia marginal de apenas 0,39%. Diante desse equilíbrio entre a diminuição da complexidade computacional e a preservação do desempenho, optou-se por utilizar o limiar de 0,15 nas avaliações subsequentes. Por fim, as duas matrizes, correspondentes à codificação da localização do receptor e à representação dos obstáculos, são reestruturadas em vetores unidimensionais e, em seguida, concatenadas para formar um único vetor de entrada que encapsula as informações espaciais necessárias ao modelo.

5.4 Proposta de Avaliação

5.4.1 Descrição dos Métodos de *baseline*

Com base na análise apresentada na Seção 5.2, os estudos de J. Ruseckas [2] e B. Salehi [1] foram selecionados como referências de *baseline* para a avaliação da abordagem proposta. A escolha desses trabalhos justifica-se pela adoção de parâmetros experimentais semelhantes aos utilizados neste estudo, além da apresentação de métricas de desempenho robustas, o que os torna apropriados para fins comparativos.

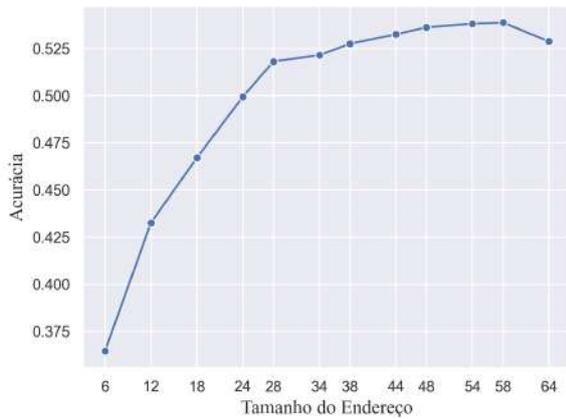


Figura 14: Avaliação de desempenho dos dados LiDAR 2D em função do endereçamento das memórias RAM.

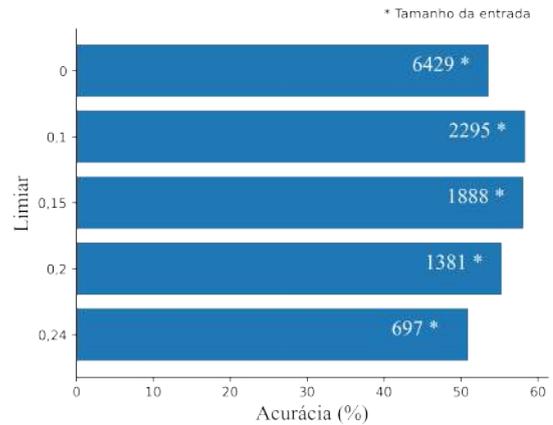


Figura 15: Avaliação de desempenho do modelo WiSARD usando a técnica de limite de variância em dados LiDAR 2D.

Para a entrada baseada em dados LiDAR, ambos os autores projetaram seus modelos utilizando arquiteturas inspiradas na *Residual Neural Network* (ResNet). No entanto, as implementações apresentam diferenças, conforme ilustrado nas Figuras 16 e 17, que destacam elementos como o tipo e o número de camadas, quantidade de neurônios e demais características arquiteturais relevantes. Adicionalmente, os principais hiperparâmetros utilizados em seus experimentos, incluindo tamanho do lote (*batch size*), taxa de aprendizado e número de épocas de treinamento, estão sumarizados na Tabela 9, possibilitando uma comparação consistente e equitativa entre os modelos considerados.

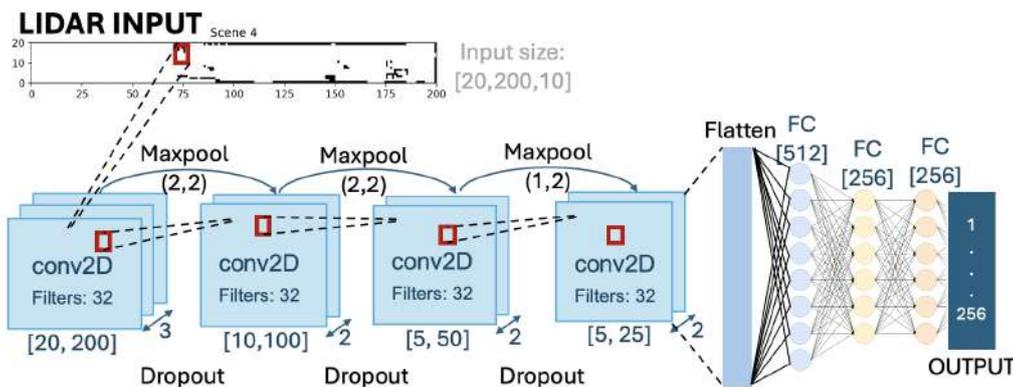


Figura 16: Modelo de rede neural usado em [1] para entrada LiDAR.

5.4.2 Comparação dos Modelos

Com o objetivo de assegurar uma comparação equitativa entre o modelo proposto e as abordagens de referência, foi adotada a mesma metodologia descrita nos trabalhos selecionados como *baseline*. Especificamente, utilizou-se o *dataset Raymobtime*, com o subconjunto s008 destinado ao treinamento e o subconjunto s009 reservado para avaliação. Essa estratégia garante consistência nas medições e permite a comparação direta de métricas fundamentais, como acurácia, taxa de transferência e tempo de processamento. A comparação considerou diferentes

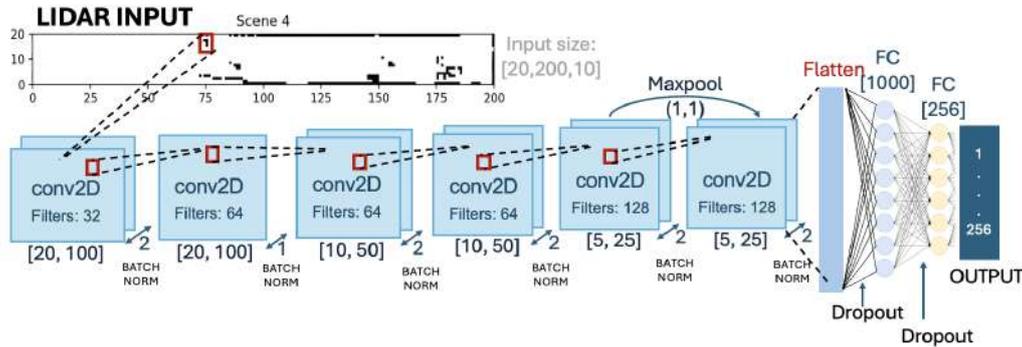


Figura 17: Modelo de rede neural usado em [2] para entrada LiDAR.

Tabela 9: Parâmetros usados pelos autores do *baseline* B. Salehi [1] e J. Ruseckas [2] no modelo LiDAR.

Parametros	B. Salehi	J. Ruseckas
Épocas de treinamento	100	50
Tamanho do Batch	32	32
Taxa de aprendizado	0,0001	Increase according to a coise law for the 30% of leaning duration
Otimizador	Adam β (0.9 , 0.999)	Adam β (min 0.85)
Função de ativação	Categorical cross entropy	
Total params.	2322528 (8.86 MB)	1029476 (3.93 MB)

abordagens de entrada nos modelos, incluindo dados unimodais (coordenadas ou LiDAR) e multimodais (combinação de coordenadas e dados LiDAR).

De forma geral, a rede WiSARD apresentou desempenho competitivo em relação aos modelos de referência, tanto em acurácia (Figura 18) quanto em taxa de transferência (Figura 19). No cenário mais desafiador ($top-k = 1$), o modelo WiSARD com entradas LiDAR superou os modelos de Salehi et al. [1] e Ruseckas et al. [2] em 11,9% e 3,3%, respectivamente. Com dados multimodais, os ganhos foram ainda mais expressivos, atingindo melhorias de 17,49% e 1,29% em relação aos mesmos modelos.

Dada sua consistência em termos de acurácia, a eficiência computacional da rede WiSARD também foi avaliada com base no tempo de treinamento, considerando diferentes tipos de entrada. Os resultados, apresentados nas Figuras 20 e 21, confirmam a leveza computacional da abordagem: o treinamento da WiSARD foi até 99,78% mais rápido em comparação com os modelos *baseline*, evidenciando sua adequação para aplicações em tempo real.

Os testes foram realizados em uma máquina com processador M1 Pro, 16 GB de memória RAM e sistema operacional macOS Ventura (versão 13.6.7).

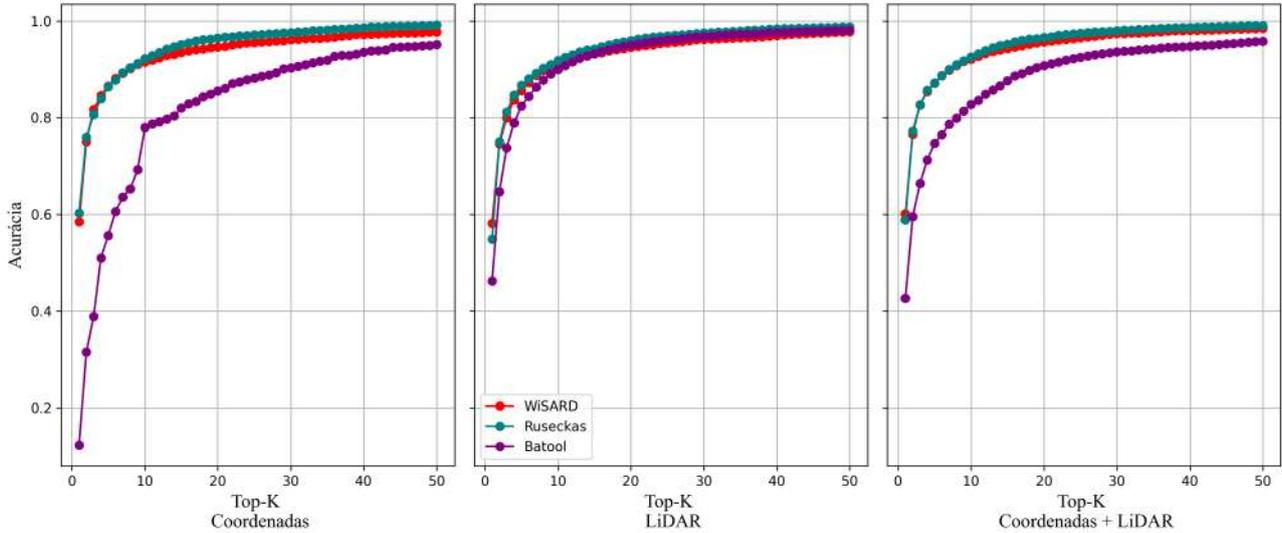


Figura 18: Comparação de desempenho de acurácia entre o modelo proposto WISARD e as técnicas de aprendizado de maquina propostas pelos autores [1], e [2] usando as entradas unimodais (coordenadas e dados LiDAR) e multimodais (coordenadas + LiDAR).

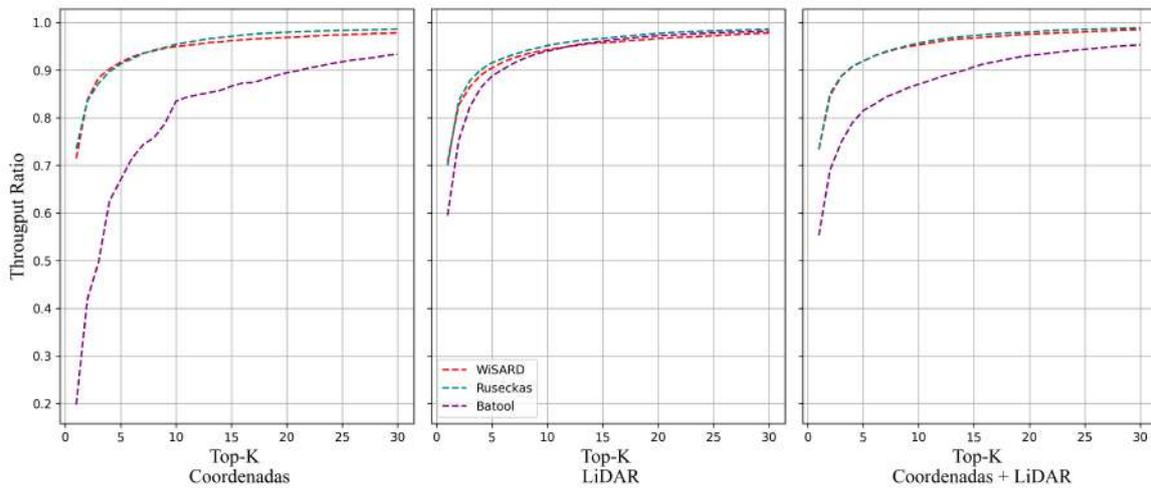


Figura 19: Comparação de desempenho de *throughput ratio* entre o modelo proposto WISARD e as técnicas de aprendizado de maquina propostas pelos autores [1], e [2] usando as entradas unimodais (coordenadas e dados LiDAR) e multimodais (coordenadas + LiDAR).

5.5 Trabalhos Futuros

As propriedades intrínsecas da rede WiSARD, como baixa complexidade computacional, interpretabilidade e capacidade de atualização incremental, tornam-na uma candidata promissora para aplicações em cenários de seleção de feixes. Ao contrário das redes neurais tradicionais, que exigem reprocessamento custoso para se adaptarem a novos dados, a WiSARD possibilita atualizações rápidas e eficientes, o que é essencial em ambientes altamente dinâmicos. Nesse contexto, futuros trabalhos podem investigar sua implementação em novas arquiteturas, com foco na avaliação do tempo de adaptação, uso de recursos e resiliência a variações abruptas no ambiente. Outra direção envolve a integração da WiSARD com abordagens de aprendizado federado e autônomo, visando soluções escaláveis para redes 6G.

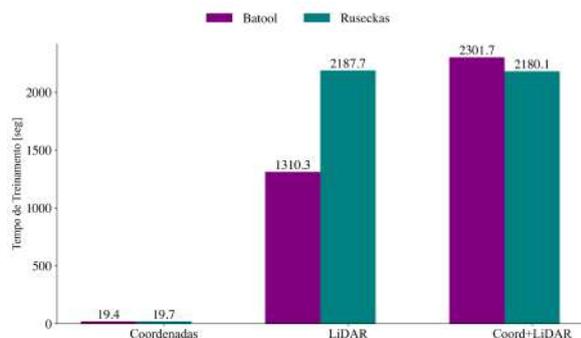


Figura 20: Comparação dos tempos de treinamento entre o modelo proposto e as técnicas de aprendizado de máquina da literatura dos autores [1], e [2] usando as entradas unimodais (coordenadas e dados LiDAR) e multimodais (coordenadas + LiDAR).

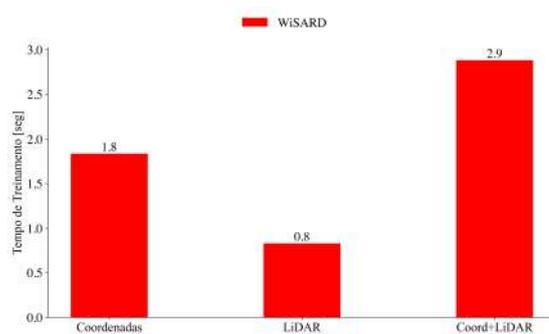


Figura 21: Desempenho da rede WiSARD em tempos de treinamento usando as entradas unimodais (coordenadas e dados LiDAR) e multimodais (coordenadas + LiDAR).

6 Conclusões

Este relatório consolidou os principais avanços obtidos no desenvolvimento de aplicações de posicionamento e mapeamento com sensores LiDAR, no âmbito da Fase 3 do Projeto Brasil 6G, atividade 3.2. As contribuições evidenciam a relevância da tecnologia para cenários como agricultura de precisão, redes móveis emergentes e monitoramento ambiental. As investigações abordaram desafios técnicos associados à compressão de dados, à implementação de sistemas embarcados, à geração de conjuntos sintéticos e à aplicação de técnicas de IA para a otimização de comunicações sem fio. As abordagens desenvolvidas demonstram a versatilidade e o potencial do LiDAR como ferramenta estratégica, contribuindo para o avanço da pesquisa nacional em tecnologias habilitadoras de próxima geração.

Especificamente, o estudo comparativo de algoritmos para compressão de dados de nuvem de pontos LiDAR demonstrou que a escolha do método mais adequado deve levar em conta as prioridades da aplicação, especialmente em termos de taxa média de compressão e velocidade de processamento. Todos os algoritmos analisados preservaram a integridade dos dados, garantindo fidelidade para aplicações sensíveis. Os resultados destacam a relevância de soluções especializadas para compressão sem perdas e indicam caminhos promissores para pesquisas futuras, incluindo o uso de abordagens baseadas em aprendizado de máquina e técnicas de compressão leve, voltadas para dispositivos embarcados e ambientes com recursos restritos.

No contexto de agricultura de precisão, apresentou-se um sistema de monitoramento agrícola baseado em tecnologia LiDAR ALS embarcada em drone, com conectividade viabilizada pela rede 6G por meio do espectro TVWS. Essa proposta estabelece uma base técnica sólida para o desenvolvimento dessa solução no âmbito do projeto Brasil 6G. A arquitetura inclui um módulo LiDAR, responsável pela aquisição de dados detalhados do relevo, vegetação e estruturas da área monitorada durante o voo, e computação de borda para otimizar o processamento e a transmissão dos dados adquiridos. Os requisitos do sistema foram detalhadamente especificados, considerando os desafios associados à conectividade em áreas remotas, à autonomia de voo dos drones e às restrições de peso dos componentes embarcados. Também foram discutidas aplicações técnicas relevantes, como a geração de MDSs e MDTs para mapeamento topográfico detalhado, a estimativa da altura da vegetação e a detecção automatizada de obstáculos. Dessa forma, a proposta apresenta uma solução alinhada aos requisitos operacionais da agricultura de precisão em ambientes remotos conectados por redes 6G. Os trabalhos futuros contemplam a implementação experimental do sistema proposto, com o objetivo de validar sua funcionalidade, desempenho e adequação operacional em ambientes rurais.

No contexto da geração de conjuntos de dados para sensores LiDAR, empregou-se o simulador BlenSor para criar nuvens de pontos realistas, contemplando oito classes de interesse acompanhadas de caixas delimitadoras. Para otimizar o uso de armazenamento e facilitar o manuseio dos dados, foram aplicadas técnicas de compressão, reduzindo significativamente o volume dos arquivos gerados. Embora a configuração inicial das cenas e a validação das anotações exijam intervenção manual substancial, propõe-se o desenvolvimento de *scripts* em Python visando automatizar parcialmente a verificação dos *labels*, com o intuito de reduzir o tempo e o esforço na preparação dos dados. Como direções futuras, planeja-se a aplicação de técnicas de *data augmentation* para ampliar a diversidade da base sintética, bem como a integração desses conjuntos em *pipelines* de treinamento de algoritmos de detecção e classificação baseados em aprendizado de máquina.

No contexto de telecomunicações, foi investigado o uso de sensores LiDAR combinados com técnicas de IA para a seleção de feixes em sistemas mmWave. A arquitetura baseada em RNSPs,

com foco na rede WiSARD, foi apresentada e parametrizada, sendo posteriormente comparada a modelos de *baseline* da literatura. Os resultados demonstraram que a WiSARD apresenta desempenho competitivo em acurácia, com destaque para sua eficiência computacional, em que o tempo de treinamento foi menor em relação aos modelos comparados. Essa vantagem evidencia seu potencial como solução leve, de baixa complexidade e adequada a dispositivos com restrições de *hardware*. Além disso, sua capacidade de incorporar informações contextuais favorece a operação em cenários dinâmicos. Por fim, uma seleção de feixe mais eficiente contribui para a redução do consumo energético e a melhoria da qualidade de enlace, alinhando-se aos objetivos de sustentabilidade das futuras redes móveis.

Referências

- [1] B. Salehi, G. Reus-Muns, D. Roy, Z. Wang, T. Jian, J. Dy, S. Ioannidis, and K. Chowdhury, “Deep learning on multimodal sensor data at the wireless edge for vehicular network,” *IEEE Transactions on Vehicular Technology*, vol. 71, no. 7, pp. 7639–7655, 2022.
- [2] J. Ruseckas, G. Molis, and H. Bogucka, “Mimo beam selection in 5g using neural networks,” *International Journal of Electronics and Telecommunications*, vol. 67, no. 4, 2021.
- [3] N. Victor, P. K. R. Maddikunta, D. R. K. Mary, R. Murugan, R. Chengoden, T. R. Gadekallu, N. Rakesh, Y. Zhu, and J. Paek, “Remote sensing for agriculture in the era of industry 5.0—a survey,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024.
- [4] S. L. Ullo and G. R. Sinha, “Advances in iot and smart sensors for remote sensing and agriculture applications,” *Remote Sensing*, vol. 13, no. 13, p. 2585, 2021.
- [5] S. Khanal, K. Kc, J. P. Fulton, S. Shearer, and E. Ozkan, “Remote sensing in agriculture—accomplishments, limitations, and opportunities,” *Remote sensing*, vol. 12, no. 22, p. 3783, 2020.
- [6] 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.
- [7] S. Debnath, M. Paul, and T. Debnath, “Applications of lidar in agriculture and future research directions,” *Journal of Imaging*, vol. 9, no. 3, p. 57, 2023.
- [8] 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.
- [9] G. Rivera, R. Porras, R. Florencia, and J. P. Sánchez-Solís, “Lidar applications in precision agriculture for cultivating crops: A review of recent advances,” *Computers and electronics in agriculture*, vol. 207, p. 107737, 2023.
- [10] 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.
- [11] N. Borowiec and U. Marmol, “Using lidar system as a data source for agricultural land boundaries,” *Remote Sensing*, vol. 14, no. 4, p. 1048, 2022.
- [12] 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.
- [13] 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.

- [14] X. Cao, Y. Liu, R. Yu, D. Han, and B. Su, “A comparison of uav rgb and multispectral imaging in phenotyping for stay green of wheat population,” *Remote Sensing*, vol. 13, no. 24, p. 5173, 2021.
- [15] S. Holm, R. Nelson, and G. Ståhl, “Hybrid three-phase estimators for large-area forest inventory using ground plots, airborne lidar, and space lidar,” *Remote sensing of environment*, vol. 197, pp. 85–97, 2017.
- [16] J. Wang, Y. Zhang, and R. Gu, “Research status and prospects on plant canopy structure measurement using visual sensors based on three-dimensional reconstruction,” *Agriculture*, vol. 10, no. 10, p. 462, 2020.
- [17] A. Geiger, P. Lenz, and R. Urtasun, “Are we ready for autonomous driving? the kitti vision benchmark suite,” in *2012 IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, 2012, pp. 3354–3361.
- [18] H. Caesar, V. Bankiti, A. H. Lang, S. Vora, Y. Liong, Q. Xu, A. Krishnan, Y. Pan, G. Baldan, and O. Beijbom, “nusenes: A multimodal dataset for autonomous driving,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020, pp. 11 621–11 631.
- [19] J. Behley, M. Garbade, A. Milioto, J. Quenzel, S. Behnke, C. Stachniss, and J. Gall, “Semantickitti: A dataset for semantic scene understanding of lidar sequences,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019, pp. 9297–9307.
- [20] P. Sun, H. Kretschmar, P. Dotiwalla, Y. Chouard, A. Patnaik, J. Tsui, J. Guo, Y. Zhou, H. Chou, V. Caine, J. Taylor, S. Feng, D. Manocha, and H. Lakshminanth, “Scalability in perception for autonomous driving: Waymo open dataset,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020, pp. 2446–2454.
- [21] NOAA Office for Coastal Management. (2025) Lidar 101: An introduction to lidar technology, data, and applications. [Online]. Available: <https://coast.noaa.gov/data/digitalcoast/pdf/lidar-101.pdf>
- [22] G. Rivera, R. Porras, R. Florencia, and J. P. Sánchez-Solís, “Lidar applications in precision agriculture for cultivating crops: A review of recent advances,” *Computers and Electronics in Agriculture*, vol. 207, p. 107737, 2023.
- [23] A. Kotb, S. Hassan, and H. Hassan, “A comparative study among various algorithms for lossless airborne lidar data compression,” in *Proceedings of the 2018 14th International Computer Engineering Conference (ICENCO)*, 2018, pp. 17–21.
- [24] D. Mari, E. Camuffo, and S. Milani, “Cactus: Content-aware compression and transmission using semantics for automotive lidar data,” *Sensors*, vol. 23, no. 12, 2023. [Online]. Available: <https://www.mdpi.com/1424-8220/23/12/5611>
- [25] L. Wiesmann, A. Milioto, X. Chen, C. Stachniss, and J. Behley, “Deep compression for dense point cloud maps,” *IEEE Robotics and Automation Letters*, vol. 6, no. 2, pp. 2060–2067, 2021.

- [26] AWS Open Data, “District of columbia 2015 lidar,” 2025. [Online]. Available: <https://github.com/awslabs/open-data-docs/tree/main/docs/dc-lidar-2015>
- [27] M. Mahoney. (2025) Data compression programs. [Online]. Available: <https://www.mattmahoney.net/dc/#sr2>
- [28] M. Isenburg, “Laszip: Lossless compression of lidar data,” *Photogrammetric Engineering and Remote Sensing*, vol. 79, no. 2, pp. 209–217, 2013.
- [29] M. Mahoney. (2025) Large text compression benchmark. [Online]. Available: <https://www.mattmahoney.net/dc/text.html#1493>
- [30] D. Pukhkaiev, “Energy-efficient benchmarking for energy-efficient software,” 2016.
- [31] I. Grebnov, “libbsc: High performance block-sorting data compression library,” 2025. [Online]. Available: <https://github.com/IlyaGrebnov/libbsc>
- [32] 7-Zip. (2025) 7-zip: Open-source file archiver with high compression ratio. [Online]. Available: <https://www.7-zip.org/>
- [33] L. Wu, X. Zhu, R. Lawes, D. Dunkerley, and H. Zhang, “Comparison of machine learning algorithms for classification of lidar points for characterization of canola canopy structure,” *International Journal of Remote Sensing*, vol. 40, no. 15, pp. 5973–5991, 2019.
- [34] D. Rakesh, N. A. Kumar, M. Sivaguru, K. Keerthivaasan, B. R. Janaki, and R. Raffik, “Role of uavs in innovating agriculture with future applications: A review,” in *2021 International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation (ICAECA)*. IEEE, 2021, pp. 1–6.
- [35] N. Fareed, J. P. Flores, and A. K. Das, “Analysis of uas-lidar ground points classification in agricultural fields using traditional algorithms and pointcnn,” *Remote Sensing*, vol. 15, no. 2, p. 483, 2023.
- [36] M. F. Aslan, A. Durdu, K. Sabanci, E. Ropelewska, and S. S. Gültekin, “A comprehensive survey of the recent studies with uav for precision agriculture in open fields and greenhouses,” *Applied Sciences*, vol. 12, no. 3, p. 1047, 2022.
- [37] L. Dowling, T. Poblete, I. Hook, H. Tang, Y. Tan, W. Glenn, and R. R. Unnithan, “Accurate indoor mapping using an autonomous unmanned aerial vehicle (uav),” *arXiv preprint arXiv:1808.01940*, 2018.
- [38] H. Qin, Z. Meng, W. Meng, X. Chen, H. Sun, F. Lin, and M. H. Ang, “Autonomous exploration and mapping system using heterogeneous uavs and ugvs in gps-denied environments,” *IEEE Transactions on Vehicular Technology*, vol. 68, no. 2, pp. 1339–1350, 2019.
- [39] R. Turner, R. Panciera, M. A. Tanase, K. Lowell, J. M. Hacker, and J. P. Walker, “Estimation of soil surface roughness of agricultural soils using airborne lidar,” *Remote Sensing of Environment*, vol. 140, pp. 107–117, 2014.

- [40] K. Itakura and F. Hosoi, “Automatic individual tree detection and canopy segmentation from three-dimensional point cloud images obtained from ground-based lidar,” *Journal of Agricultural Meteorology*, vol. 74, no. 3, pp. 109–113, 2018.
- [41] 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.
- [42] C. Zhang, W. A. Craine, R. J. McGee, G. J. Vandemark, J. B. Davis, J. Brown, S. H. Hulbert, and S. Sankaran, “High-throughput phenotyping of canopy height in cool-season crops using sensing techniques,” *Agronomy Journal*, vol. 113, no. 4, pp. 3269–3280, 2021.
- [43] R. Cassidy, I. A. Thomas, A. Higgins, J. S. Bailey, and P. Jordan, “A carrying capacity framework for soil phosphorus and hydrological sensitivity from farm to catchment scales,” *Science of the total environment*, vol. 687, pp. 277–286, 2019.
- [44] F. Demelezi, B. Gálya, J. Tamás, I. Demelezi, and A. Nagy, “Evaluation of soil water management properties based on lidar data and soil analyses at farm level,” 2019.
- [45] H. Dhami, K. Yu, T. Xu, Q. Zhu, K. Dhakal, J. Friel, S. Li, and P. Tokekar, “Crop height and plot estimation for phenotyping from unmanned aerial vehicles using 3d lidar,” in *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2020, pp. 2643–2649.
- [46] 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.
- [47] 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.
- [48] 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.
- [49] 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.
- [50] P. Bartmiński, M. Siłuch, and W. Kociuba, “The effectiveness of a uav-based lidar survey to develop digital terrain models and topographic texture analyses,” *Sensors*, vol. 23, no. 14, p. 6415, 2023.
- [51] T. Guo, Y. Fang, T. Cheng, Y. Tian, Y. Zhu, Q. Chen, X. Qiu, and X. Yao, “Detection of wheat height using optimized multi-scan mode of lidar during the entire growth stages,” *Computers and Electronics in Agriculture*, vol. 165, p. 104959, 2019.
- [52] 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.

- [53] W. Yuan, J. Li, M. Bhatta, Y. Shi, P. S. Baenziger, and Y. Ge, “Wheat height estimation using lidar in comparison to ultrasonic sensor and uas,” *Sensors*, vol. 18, no. 11, p. 3731, 2018.
- [54] Y. Miao, C. Peng, L. Wang, R. Qiu, H. Li, and M. Zhang, “Measurement method of maize morphological parameters based on point cloud image conversion,” *Computers and Electronics in Agriculture*, vol. 199, p. 107174, 2022.
- [55] 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.
- [56] 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.
- [57] D. Yin, L. Wang, Y. Lu, and C. Shi, “Mangrove tree height growth monitoring from multi-temporal uav-lidar,” *Remote Sensing of Environment*, vol. 303, p. 114002, 2024.
- [58] X. Zhang, Y. Bao, D. Wang, X. Xin, L. Ding, D. Xu, L. Hou, and J. Shen, “Using uav lidar to extract vegetation parameters of inner mongolian grassland,” *Remote Sensing*, vol. 13, no. 4, p. 656, 2021.
- [59] Z. Doerr, A. Mohsenimanesh, C. Laguë, and N. McLaughlin, “Application of the lidar technology for obstacle detection during the operation of agricultural vehicles.” *Canadian Biosystem Engineering Journal*, vol. 55, 2013.
- [60] G. Reina, A. Milella, R. Rouveure, M. Nielsen, R. Worst, and M. R. Blas, “Ambient awareness for agricultural robotic vehicles,” *Biosystems engineering*, vol. 146, pp. 114–132, 2016.
- [61] C. Periu, A. Mohsenimanesh, C. Laguë, and N. McLaughlin, “Isolation of vibrations transmitted to a lidar sensor mounted on an agricultural vehicle to improve obstacle detection.” *Canadian Biosystem Engineering Journal*, vol. 55, 2013.
- [62] J. Qin, R. Sun, K. Zhou, Y. Xu, B. Lin, L. Yang, Z. Chen, L. Wen, and C. Wu, “Lidar-based 3d obstacle detection using focal voxel r-cnn for farmland environment,” *Agronomy*, vol. 13, no. 3, p. 650, 2023.
- [63] M. Gschwandtner, R. Kwitt, and A. Uhl, “Blensor: Blender sensor simulation toolbox,” in *Advances in Visual Computing: 7th International Symposium (ISVC 2011)*, ser. Lecture Notes in Computer Science, vol. 6938, Las Vegas, Nevada, USA, Sep. 26–28 2011, pp. 199–208.
- [64] TurboSquid, “TurboSquid: 3d models marketplace,” <https://www.turbosquid.com/3d-models>, 2025, accessed: 26 June 2025.
- [65] —, “Animal Collection 3d models (id 1499359),” <https://www.turbosquid.com/3d-models/animal-collection-1499359>, January 2020, accessed: 26 June 2025.

- [66] K. Cuneray, N. Akcam, T. Okan, and G. O. Arican, “28/38 ghz dual-band mimo antenna with wideband and high gain properties for 5g applications,” *AEU-International Journal of Electronics and Communications*, vol. 162, p. 154553, 2023.
- [67] A. Klautau, P. Batista, N. González-Prelcic, Y. Wang, and R. W. Heath, “5g mimo data for machine learning: Application to beam-selection using deep learning,” in *2018 Information Theory and Applications Workshop (ITA)*. IEEE, 2018, pp. 1–9.
- [68] X. Li and A. Alkhateeb, “Deep learning for direct hybrid precoding in millimeter wave massive mimo systems,” in *2019 53rd Asilomar Conference on Signals, Systems, and Computers*. IEEE, 2019, pp. 800–805.
- [69] W. Xu, F. Gao, S. Jin, and A. Alkhateeb, “3d scene-based beam selection for mmwave communications,” *IEEE Wireless Communications Letters*, vol. 9, no. 11, pp. 1850–1854, 2020.
- [70] J. Gui, Y. Liu, X. Deng, and B. Liu, “Network capacity optimization for cellular-assisted vehicular systems by online learning-based mmwave beam selection,” *Wireless Communications and Mobile Computing*, vol. 2021, no. 1, p. 8876186, 2021.
- [71] T. T. Nguyen and K.-K. Nguyen, “A deep learning framework for beam selection and power control in massive mimo-millimeter-wave communications,” *IEEE Transactions on Mobile Computing*, vol. 22, no. 8, pp. 4374–4387, 2022.
- [72] T. S. Cousik, V. K. Shah, T. Erpek, Y. E. Sagduyu, and J. H. Reed, “Deep learning for fast and reliable initial access in ai-driven 6g mm wave networks,” *IEEE Transactions on Network Science and Engineering*, 2022.
- [73] N. González-Prelcic, R. Méndez-Rial, and R. W. Heath, “Radar aided beam alignment in mmwave v2i communications supporting antenna diversity,” in *2016 Information Theory and Applications Workshop (ITA)*. IEEE, 2016, pp. 1–7.
- [74] E. Chatzoglou and S. K. Goudos, “Beam-selection for 5g/b5g networks using machine learning: A comparative study,” *Sensors*, vol. 23, no. 6, p. 2967, 2023.
- [75] G. Reus-Muns, B. Salehi, D. Roy, T. Jian, Z. Wang, J. Dy, S. Ioannidis, and K. Chowdhury, “Deep learning on visual and location data for v2i mmwave beamforming,” in *2021 17th International Conference on Mobility, Sensing and Networking (MSN)*. IEEE, 2021, pp. 559–566.
- [76] S. Gupta, N. Saxena, A. Roy, and A. Ravi, “Efficient mmwave beam selection using vits and gvec: Gps-based virtual environment capture,” in *2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT)*. IEEE, 2023, pp. 1–6.
- [77] Z. Chen, M. Liu, H. Zhao, B. Xu, W. Xun, and H. Zhu, “Enhancing lidar-based mm wave beam selection with augmix augmented cnns,” in *2023 IEEE 23rd International Conference on Communication Technology (ICCT)*. IEEE, 2023, pp. 926–930.
- [78] A. Klautau, N. González-Prelcic, and R. W. Heath, “Lidar data for deep learning-based mmwave beam-selection,” *IEEE Wireless Communications Letters*, vol. 8, no. 3, pp. 909–912, 2019.

- [79] M. B. Mashhadi, M. Jankowski, T.-Y. Tung, S. Kobus, and D. Gündüz, “Federated mmwave beam selection utilizing lidar data,” *IEEE Wireless Communications Letters*, vol. 10, no. 10, pp. 2269–2273, 2021.
- [80] A. Klautau, A. de Oliveira, I. P. Trindade, and W. Alves, “Generating mimo channels for 6g virtual worlds using ray-tracing simulations,” in *2021 IEEE Statistical Signal Processing Workshop (SSP)*. IEEE, 2021, pp. 595–599.
- [81] J. C. Manjarres, D. O. Cardoso, A. Klautau, and J. F. de Rezende, “A wisard network approach for 5g mimo beam selection,” in *International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems*. Springer, 2024, pp. 360–373.
- [82] Y. Zheng, S. Chen, and R. Zhao, “A deep learning-based mmwave beam selection framework by using lidar data,” in *2021 33rd Chinese Control and Decision Conference (CCDC)*. IEEE, 2021, pp. 915–920.
- [83] M. Dias, A. Klautau, N. González-Prelcic, and R. W. Heath, “Position and lidar-aided mmwave beam selection using deep learning,” in *2019 IEEE 20th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*. IEEE, 2019, pp. 1–5.
- [84] M. Zecchin, M. B. Mashhadi, M. Jankowski, D. Gündüz, M. Kountouris, and D. Gesbert, “Lidar and position-aided mmwave beam selection with non-local cnns and curriculum training,” *IEEE Transactions on Vehicular Technology*, vol. 71, no. 3, pp. 2979–2990, 2022.
- [85] A. Kappaun, K. Camargo, F. Rangel, F. Firmino, P. M. V. Lima, and J. Oliveira, “Evaluating binary encoding techniques for wisard,” in *2016 5th Brazilian Conference on Intelligent Systems (BRACIS)*, 2016, pp. 103–108.