

Brasil 6G

Projeto Brasil 6G

Contribuições em Tecnologias de Posicionamento e Sensoriamento para Redes 6G Utilizando LiDAR (Meta 4)



UNIVERSIDADE FEDERAL DO RIO DE JANEIRO



Histórico de Atualizações:

Versão	Data	Autor(es)	Notas
1	03/01/2024	Egídio Raimundo Neto Matheus Ferreira Silva	Elaboração de conteúdo
2	19/02/2024	Arismar Cerqueira Sodré Júnior	Revisão de texto

Lista de Figuras

1	Sensor LiDAR Típico e seus principais componentes. Adaptado de [140].	9
2	Esquemático de medida de distância por ToF.	10
3	(a) Aplicação em ambientes públicos internos. (b) Aplicações Industriais em ambientes internos.	21
4	Diagrama em Blocos da Arquitetura do Sistema Proposto.	22
5	Slamtec LiDAR RPLiDAR S2 utilizado na implementação do sistema [ref].	23
6	Ambiente de testes e a divisão em 16 quadrantes.	26
7	Dados dos sensores LiDAR antes do processamento para divisão em 16 quadrantes. (a) LiDAR 1. (b) LiDAR 2. (c) LiDAR 3. (d) LiDAR 4.	27
8	Dados dos sensores LiDAR antes do processamento para divisão em 64 quadrantes. (a) LiDAR 1. (b) LiDAR 2. (c) LiDAR 3. (d) LiDAR 4.	27
9	Dados dos sensores LiDAR após o processamento para divisão em 16 quadrantes. (a) LiDAR 1. (b) LiDAR 2. (c) LiDAR 3. (d) LiDAR 4.	27
10	Dados dos sensores LiDAR após o processamento para divisão em 64 quadrantes. (a) LiDAR 1. (b) LiDAR 2. (c) LiDAR 3. (d) LiDAR 4.	27
11	Dados dos sensores LiDAR combinados para o caso de 16 quadrantes.	28
12	Dados dos sensores LiDAR combinados para o caso de 64 quadrantes.	29
13	Laboratório didático utilizado para validação e análise de desempenho do sistema de sensoriamento e posicionamento proposto, os sensores LiDAR e suas posições no espaço.	29
14	Exemplo da criação dos rótulos por meio de uma interface criada para este processo com 16 quadrantes.	30
15	Exemplo da criação dos rótulos por meio de uma interface criada para este processo com 64 quadrantes.	31

Lista de Tabelas

1	Especificação das camadas de Rede Neural Artificial (RNA) utilizada para o processo de treinamento.	25
2	Avaliação do desempenho da RNA utilizando dados combinados, Cenário de Testes 1.	32
3	Avaliação do desempenho da RNA utilizando dados não combinados, Cenário de Testes 2.	32
4	Comparação dos resultados em termos de precisão para os dois cenários de testes.	33
5	Comparação dos resultados em termos de recall para os dois cenários de testes. .	33
6	Comparação dos resultados em termos de F1 Score para os dois cenários de testes.	34
7	Avaliação do desempenho da RNA utilizando dados combinados, Cenário de Testes 1.	34
8	Avaliação do desempenho da RNA utilizando dados não combinados, Cenário de Testes 2.	35
9	Comparação dos resultados em termos de precisão para os dois cenários de testes.	35
10	Comparação dos resultados em termos de recall para os dois cenários de testes. .	36
11	Comparação dos resultados em termos de F1 Score para os dois cenários de testes.	36

Acrônimos

1G primeira geração de sistemas de comunicações móveis

2D bidimensional

2G segunda geração de sistemas de comunicações móveis

3G terceira geração de sistemas de comunicações móveis

3D tridimensional

4G quarta geração de sistemas de comunicações móveis

5G quinta geração de sistemas de comunicação móveis

6G sexta geração de sistemas de comunicações móveis

AMPS Advanced Mobile Phone System

AoA Angle of Arrival

AGVs Automated Guided Vehicles

B5G Beyond 5G

BLE Bluetooth Low Energy

CDMA Code-Division Multiple Access

CNN Convolutional Neural Network

CPS Cyber Physical Systems

CSI Channel State Information

DL Deep Learning

DL Deep Learning

eMBB enhanced Mobile Broadband

EI Edge Intelligence

GNSS Global Navigation Satellite Systems

GPS Global Positioning System

GSM Global System for Mobiles

IA Inteligência Artificial

IMT International Mobile Telecommunications

IMUs Inertial Measurement Units

IoE Internet of Everything

IoT Internet of Things

IPS Indoor Positioning System

IPS Indoor Positioning Systems

ITU-R União Internacional de Telecomunicações - Setor de Radiocomunicação

ITU-T União Internacional de Telecomunicações - Setor de Padronização de Telecomunicações

LBS Location Based Services
LiDAR Light Detecting And Ranging
LIS Large Intelligent Surfaces
LOS Line of Sight
LTE Long Term Evolution
MIMO Multiple-Input Multiple-Output
ML Machine Learning
ML Machine Learning
mMTC massive Machine Type Communication
NLOS Non-Line of Sight
NLOS Non-Line of Sight
NMT Nordic Mobile Telephone
NOMA Non-Orthogonal Multiple Access
OFDM Orthogonal Frequency Division Multiplexing
RA Realidade Aumentada
RA Realidade Aumentada
RF radiofrequência
RIS Reconfigurable Intelligent Surface
RNA Rede Neural Artificial
RFID Radio Frequency Identification
RFID Radio-Frequency Identification
RL Reinforcement Learning
RM Realidade Mista
RSSI Received Signal Strength Indication
RSSI Received Signal Strength Indicator
RV Realidade Virtual
RV Realidade Virtual
SLAM Simultaneous Localization And Mapping
SLAM Simultaneous Localization And Mapping
SLAM Simultaneous Localization And Mapping
TD-SCDMA Time Division - Synchronous Code Division Multiple Access
TDoA Time Difference of Arrival
TDoA Time Difference of Arrival
TH Telepresença Holográfica
TIC tecnologias de informação e comunicação

ToF Time of Flight

ToA Time of Arrival

ToA Time of Arrival

UAVs Unmanned Aerial Vehicles

uRLLC Ultra-Reliable Low Latency Communication

UWB Ultra Wideband

UWB Ultra-Wideband

WCDMA Wide-Band Code-Division Multiple Access

Wi-Fi Wireless-Fidelity

WLAN Wireless Local Area Network

XR Extended Reality

Sumário

1	Introdução	1
2	Contextualização e Revisão Bibliográfica	4
2.1	Revisão da Literatura	4
2.2	Sistemas de Posicionamento	7
2.2.1	Técnicas de Estimção de Distância	7
2.2.2	Técnicas de Estimção de Localizao	8
2.2.3	Tecnologias de Acesso Utilizadas para Localizao Indoor	8
2.3	LiDAR	9
3	Sensoriamento e Posicionamento em Redes 6G: Aplicaes, Desafios e Oportunidades	13
3.1	Estado da Arte	13
3.2	Casos de Uso	14
3.2.1	Desenvolvimento Sustentvel	14
3.2.2	Telepresena Imersiva	14
3.2.3	Zonas de Confiana Locais para Humanos e Mquinas	14
3.2.4	Twinning Massivo	15
3.2.5	Robos para Robos Colaborativos	15
3.3	Desafios	15
3.3.1	Limitaes e Defeitos do Hardware	15
3.3.2	Canais de Propagao Severos	15
3.4	Oportunidades	16
3.5	Aplicaes de Posicionamento e Sensoriamento com uso de Light Detecting And Ranging (LiDAR)	16
3.5.1	Veiculos Autnomos	16
3.5.2	Geografia e Mapeamento	17
3.5.3	Florestas e Agricultura	17
3.5.4	Cincia Ambiental e Conservao	18
3.5.5	Aplicaes Costeiras e Marinhas	18
3.5.6	Simultaneous Localization And Mapping (SLAM)	19
3.5.7	Sistemas de Sensoriamento e Posicionamento de Robos e Veiculos No Tripulados	19
3.5.8	Sistemas de Estimativa da Marcha humana	19
4	Sistema de Sensoriamento e Posicionamento de Pedestres em Ambientes Internos Utilizando LiDAR e RNA	21
4.1	Aplicaes e Arquitetura do Sistema	21
4.2	Materiais e Mtodos	22
4.2.1	LiDAR 2D	22
4.2.2	Rede Neural Artificial	23
5	Testes e Resultados	26
5.1	Metodologia de Testes	26
5.1.1	Ambiente de Testes e Experimentos	28
5.2	Resultados	30

5.2.1	Experimentos com 16 quadrantes	30
5.2.2	Experimentos com 64 quadrantes	32
5.2.3	Análise dos Resultados	34
6	Conclusão	37

1 Introdução

Egidio Raimundo Neto
 egidio.neto@inatel.br

A indústria de comunicações móveis tem suas origens na primeira geração de sistemas de comunicações móveis (1G) analógicos, representados pelo Advanced Mobile Phone System (AMPS) nos Estados Unidos e pelo Nordic Mobile Telephone (NMT) na Europa, que inicialmente ofereceram o serviço de chamadas de voz móveis por volta do ano de 1980. Desde então, uma nova geração de comunicações móveis foi introduzida no mercado aproximadamente a cada dez anos. Os sistemas AMPS foram substituídos pela segunda geração de sistemas de comunicações móveis (2G) que consiste em redes celulares digitais de segunda geração por volta de 1990. Apesar de vários sistemas concorrentes, o Global System for Mobiles (GSM) [1] alcançou um grande sucesso comercial e permitiu que mais de um bilhão de pessoas desfrutasse da conveniência trazida pela voz móvel, mensagens de texto curtas e serviços de dados de baixa taxa. Explorando uma tecnologia revolucionária chamada Code-Division Multiple Access (CDMA), a terceira geração de sistemas de comunicações móveis (3G), representados pelo Wide-Band Code-Division Multiple Access (WCDMA), Time Division - Synchronous Code Division Multiple Access (TD-SCDMA), foram desenvolvidos e implantados pela primeira vez em 2001 para suportar acesso a dados de alta velocidade com uma taxa de vários megabits por segundo [2]. Em dezembro de 2009, as redes comerciais de Long Term Evolution (LTE) foram lançadas nas capitais escandinavas de Estocolmo e Oslo, proporcionando o primeiro serviço de banda larga móvel que se tornou a quarta geração de sistemas de comunicações móveis (4G) do mundo. O sistema 4G, que é potencializado por uma combinação genial de Multiple-Input Multiple-Output (MIMO) e Orthogonal Frequency Division Multiplexing (OFDM), impulsionou a proliferação de smartphones, fomentando a indústria da internet móvel, que movimentava trilhões de dólares por ano [3]. Diferentemente das gerações anteriores, que se concentravam apenas em melhorar as capacidades de rede, a quinta geração de sistemas de comunicação móveis (5G) expande os serviços de comunicação móvel de humanos para coisas e também de consumidores para indústrias verticais. A escala potencial de assinaturas móveis é substancialmente ampliada, passando de apenas bilhões da população mundial para quase incontáveis interconexões entre humanos, máquinas e coisas. O 5G suporta o enhanced Mobile Broadband (eMBB) para fornecer taxas de dados de pico de até 10 Gbps. Além disso, a Ultra-Reliable Low Latency Communication (uRLLC) minimiza os atrasos para até 1 ms, enquanto a massive Machine Type Communication (mMTC) suporta mais de 100 vezes mais dispositivos por unidade de área em comparação com o 4G. A confiabilidade e disponibilidade de rede esperadas são superiores a 99,999% [4]. A softwarização de rede é uma tecnologia proeminente do 5G que possibilita a dinamicidade, programabilidade e abstração das redes [5]. As capacidades do 5G habilitaram novas aplicações, como Realidade Virtual (RV), Realidade Aumentada (RA), Realidade Mista (RM), Internet of Things (IoT), Indústria 4.0 e veículos autônomos [6–8].

Atualmente, o 5G ainda está em processo de implantação em todo o mundo, mas a academia e a indústria já estão com atenção voltada para além do 5G, também conhecida como Beyond 5G (B5G), ou para a sexta geração de sistemas de comunicações móveis (6G), a fim de atender as futuras demandas por tecnologias de informação e comunicação (TIC) até 2030, neste sentido vários trabalhos pioneiros sobre as redes 6G já foram iniciados [9]. Um grupo de foco chamado Tecnologias para a Rede 2030 dentro do setor de padronização da União Internacional de Telecomunicações - Setor de Padronização de Telecomunicações (ITU-T) foi estabelecido em julho de 2018. O grupo pretende estudar as capacidades das redes para 2030 e além, quando se

espera que suporte cenários inovadores e visionários, como comunicações holográficas, inteligência ubíqua, Internet Tátil, experiência multissensorial e gêmeo digital [10]. Em sua reunião em fevereiro de 2020, o setor de União Internacional de Telecomunicações - Setor de Radiocomunicação (ITU-R) decidiu iniciar o estudo sobre tendências tecnológicas futuras para a evolução futura das International Mobile Telecommunications (IMT) [11].

Desenvolvimentos recentes em comunicações introduziram muitos novos conceitos, como Edge Intelligence (EI), comunicação além de sub 6GHz para faixa de THz, Non-Orthogonal Multiple Access (NOMA) e Large Intelligent Surfaces (LIS), [12,13]. Esses conceitos estão evoluindo para se tornarem tecnologias plenamente desenvolvidas que podem impulsionar futuras gerações de redes de comunicação. Por outro lado, aplicações como Telepresença Holográfica (TH), Unmanned Aerial Vehicles (UAVs), Extended Reality (XR), Smart Grid 2.0, Indústria 5.0, turismo espacial e em alto mar são esperadas para emergir como aplicações principais das futuras redes de comunicação. No entanto, os requisitos dessas aplicações, como taxas de dados ultra altas, acesso em tempo real a recursos computacionais poderosos, latência extremamente baixa, localização e detecção precisas, e confiabilidade e disponibilidade extremamente altas, superam as capacidades de rede prometidas pelo 5G [14,15]. O IoT, que é habilitado pelo 5G, está até crescendo para se tornar a Internet of Everything (IoE), que pretende conectar um número massivo de sensores, dispositivos e também os Cyber Physical Systems (CPS) além das capacidades do 5G. Isso inspirou a comunidade de pesquisa a vislumbrar as redes de comunicação móvel 6G. Espera-se que o 6G aproveite os desenvolvimentos de novas tecnologias de comunicação, suporte totalmente aplicações emergentes, conecte um número massivo de dispositivos e forneça acesso em tempo real a recursos computacionais e de armazenamento poderosos.

Dentro do contexto das aplicações apresentadas, a localização e posicionamento preciso de pessoas e objetos será um ponto crucial para o bom desempenho das mesmas. O posicionamento preciso em tempo real é a chave para habilitar Location Based Services (LBS). Embora o Global Positioning System (GPS) seja amplamente utilizado para localização em ambientes externos, a usabilidade do GPS não é satisfatória em ambientes internos confinados. Ao contrário dos ambientes externos, os ambientes internos são muito complexos, com formas e tamanhos variados e com a presença ou ausência de objetos estacionários e móveis. Esses fatores alteram significativamente tanto a propagação do sinal de radiofrequência (RF) em linha de visão, Line of Sight (LOS), quanto fora da linha de visão, Non-Line of Sight (NLOS), causando atenuação imprevisível, dispersão, sombreamento e pontos cegos que degradam significativamente a precisão do posicionamento interno. No entanto, devido à alta demanda por LBS, uma atenção significativa tem sido dada ao desenvolvimento de Indoor Positioning Systems (IPS). Técnicas de medição típicas baseadas em Received Signal Strength Indicator (RSSI) [16], Time of Arrival (ToA) [17], Time Difference of Arrival (TDoA) [18], Angle of Arrival (AoA) [19] e informações de Channel State Information (CSI) [20] têm sido propostas usando várias tecnologias de acesso, como Wireless-Fidelity (Wi-Fi) [21], Bluetooth [22], Ultra-Wideband (UWB) [23] e etiquetas de Radio-Frequency Identification (RFID) [24] para posicionamento interno. A maioria das técnicas de medição requer pelo menos três nós âncora conhecidos para calcular a localização do alvo desconhecido. Todas essas abordagens sofrem com uma série de desafios, incluindo baixa precisão, alta complexidade computacional e falta de confiabilidade, enquanto a maioria dos dispositivos de posicionamento requer grande capacidade de processamento. Além disso, a capacidade de manter grandes bancos de dados (para sistemas de posicionamento interno em larga escala) enquanto garante segurança e privacidade, e suporta a heterogeneidade de dispositivos a um custo razoável, são outros desafios na localização interna [25]. Nos úl-

timos anos, a Inteligência Artificial (IA) e os algoritmos de Machine Learning (ML) têm se mostrado potenciais para a localização interna [26–29]. A principal vantagem das abordagens de IA/Machine Learning (ML) é a sua capacidade de tomar decisões eficazes usando dados observados sem a necessidade de uma formulação matemática precisa.

Os recentes avanços na tecnologia LiDAR revolucionaram muitas indústrias, tornando-a mais confiável e precisa para várias aplicações, como direção autônoma, interação humano-robô e mais [30,31]. Os dados tridimensional (3D) do LiDAR fornecem uma representação abrangente do ambiente em 360 graus, que pode ser utilizada por robôs ou carros autônomos para tomar decisões informadas. As aplicações do LiDAR 3D são extensas, incluindo direção autônoma [31], silvicultura [30], treinamento médico [32], implantações em cidades inteligentes [33], sensoriamento remoto [34] e Simultaneous Localization And Mapping SLAM 3D [35–37]. Além disso, sensores estáticos podem ser usados em conjunto com robôs móveis ou sistemas, tornando-os mais eficientes e eficazes. Ao montar o LiDAR 3D em um local adequado, diferentes robôs móveis podem acessar os dados e tomar decisões informadas. Essa abordagem pode reduzir significativamente o custo de implantar múltiplos sensores LiDAR 3D em cada robô móvel ou sistema, tornando-o mais viável e acessível. O LiDAR bidimensional (2D) é utilizado para obter informações de profundidade em várias aplicações, como direção autônoma e rastreamento humano por robôs [38–40]. Os sensores LiDAR 2D são acessíveis e precisos, e as nuvens de pontos 2D não são computacionalmente caras para processar. A principal limitação do LiDAR 2D é que ele percebe apenas um plano do ambiente, o que dificulta a detecção de pessoas com alta confiança. No entanto, vale ressaltar que os sensores LiDAR 3D são caros, o que torna desafiador montá-los em múltiplos robôs móveis ou sistemas. O uso de dados de sensores LiDAR e câmera para auxiliar as comunicações sem fio é uma área relativamente nova que ganhou atenção recentemente. Em [41], um problema de seleção de feixe em ondas milimétricas, millimeter Wave (mmWave) baseado em aprendizado profundo em um cenário veicular foi explorado para um sistema de downlink com beamforming analógico. Os autores focam na solução da classificação de LOS versus NLOS do canal atual e na seleção dos pares de feixe para beamforming a partir de um codebook predefinido e mostram o potencial do uso de dados de sensores LiDAR para auxiliar procedimentos de comunicação em mmWave. Os autores em [42] consideram um problema semelhante ao de [41] usando dados LiDAR e de posição para um cenário veicular para um canal de downlink em mmWave.

Este relatório apresenta as principais contribuições ao estado da arte desenvolvidas pelos pesquisadores do projeto Brasil 6G. As contribuições são voltadas para posicionamento e Mapeamento utilizam LiDAR. O relatório é composto por 06 Capítulos, sendo que o Capítulo 2 aborda o contexto das redes 6G e a importância dos sistemas de posicionamento e mapeamento para estas redes. O Capítulo 3 apresenta as possíveis aplicações, os desafios da utilização de LiDARs de forma massiva nestas redes e as oportunidades e ganhos de desempenho que esta tecnologia pode possibilitar. Complementarmente, o Capítulo 4 descreve o desenvolvimento do sistema de processamento e Tratamento dos dados provenientes do LiDAR. O Capítulo 5 apresenta a metodologia de testes, os testes realizados e os resultados obtidos. Por fim, as conclusões do relatório são apresentadas no Capítulo 6.

2 Contextualização e Revisão Bibliográfica

Egidio Raimundo Neto, Arismar Cerqueira Sodré Junior
 egidio.neto@inatel.br, arismar@inatel.br

Este capítulo tem como objetivo apresentar uma revisão da literatura sobre sistemas de Sensoriamento e posicionamento utilizando LiDAR em redes 6G, descrever os principais fundamentos sobre sistemas de posicionamento e a tecnologia LiDAR.

2.1 Revisão da Literatura

As redes de comunicação na era 6G são previstas para utilizar a enorme largura de banda disponível em frequências mais altas, variando de mmWave a THz. No entanto, comunicar nessas bandas é extremamente desafiador, pois elas sofrem de alta dispersão devido aos seus comprimentos de onda menores em comparação com as frequências sub 6 GHz convencionalmente usadas. Para combater isso, feixes ultra estreitos são usados e, à medida que a largura dos feixes diminui, os bloqueios aleatórios ao caminho de linha de visada podem degradar abruptamente a qualidade do enlace [43]. Especificamente, o bloqueio ocorrendo com movimentos dinâmicos dos humanos no ambiente tem sido relatado como um fator significativo de degradação da qualidade do enlace [44]. Uma solução para minimizar esse efeito adverso da degradação da qualidade do enlace é prever tais bloqueios, permitindo que o transmissor aja proativamente fazendo uma transferência para um transmissor com disponibilidade de linha de visada ou evitando transmitir durante a duração do bloqueio. Prever tais eventos é necessária uma visão holística do ambiente de comunicação. A detecção do ambiente através de modalidades heterogêneas surge como uma tecnologia promissora para capturar a dinâmica do ambiente de comunicação, implicando informações sobre a dispersão, auxiliando assim nos procedimentos de comunicação, como posicionamento, gerenciamento de feixe e previsão de bloqueio. Câmeras, LiDARs e radares são sensores potenciais que podem ser usados para tal detecção ambiental. Particularmente, os sensores LiDAR são uma escolha interessante para capturar a estrutura 2D ou 3D do ambiente de comunicação, o que também elimina as preocupações com a privacidade em contraste com as câmeras. O uso de LiDARs para tais fins de monitoramento é muitas vezes restringido custo elevado dos sensores. No entanto, desenvolvimentos recentes na tecnologia LiDAR reduziram o preço para algumas centenas de dólares, o que permite que uma infinidade de aplicações aproveite o potencial dos LiDARs. Além disso, o alcance desses sensores se torna adequado para capturar o ambiente de comunicação, uma vez que as redes 6G convergem para células minúsculas em termos de distância de cobertura devido à alta perda de percurso nas frequências mais altas. Além disso, algoritmos para processar dados para gerar insights preditivos, especialmente para dados de visão, evoluíram significativamente no passado recente com o crescimento contínuo das técnicas de Deep Learning (DL). As soluções iniciais para os desafios de bloqueio em mmWave focaram na múltipla conectividade, onde um usuário mantém simultaneamente múltiplos links com várias estações base [45–48].

Modelos de ML foram usados com sucesso para prever proativamente bloqueios futuros em [49–54]. Em particular, os autores em [49] desenvolveram uma rede neural recorrente que usou a sequência de feixes das últimas instâncias para prever proativamente bloqueios futuros de linha de visada. Em [55], propõe-se utilizar dados de sensores LiDAR para prever proativamente bloqueios de enlace. Uma vez que o LiDAR fornece alta resolução para os objetos e não é afetado pela luz do dia em comparação com a câmera. O LiDAR também foi usado para auxiliar outras tarefas de comunicação, como previsão e rastreamento de feixe [42,56,57].

Nota-se que uma linha de trabalho relevante como o ML poderia ser aproveitado para estimar ou prever os canais em ondas milimétricas ou seus parâmetros como ângulos de chegada ou partida, atraso, e outros [51,58–60]. A linha de trabalho de estimativa de canal não aborda as questões de previsão de bloqueio. Por exemplo, ela não prevê proativamente se um bloqueio acontecerá no futuro e quando acontecerá. Também é importante diferenciar entre a previsão de bloqueio futuro e a previsão ou identificação do status atual de bloqueio, que também foi estudada em artigos recentes [61–63]. Por exemplo, os trabalhos [62] e [63] aproveitaram ML/DL para identificar se o sinal recebido atual corresponde a um enlace LOS ou NLOS. Além disso, [61] utilizou dados de câmera junto com canais sub-6 GHz para identificar enlaces em mmWave atualmente bloqueados. Em [64] soluções de aprendizado ML que aprendem padrões especiais do sinal recebido e dos dados sensoriais, os quais chamamos de assinaturas, são utilizados para inferir bloqueios futuros para avaliar as abordagens propostas, foi construído um grande conjunto de dados do mundo real que compreende medições coexistentes de LiDAR e comunicação em ondas milimétricas em cenários veiculares externos. Também foi apresentado um algoritmo eficiente de remoção de ruído de dados LiDAR que aplica pré-processamento aos dados do LiDAR.

Nos últimos anos, houve um progresso significativo no desenvolvimento de algoritmos de SLAM baseados em imagens e LiDAR eficientes, consistentes e robustos, que emergiram como as principais abordagens [65–71]. Esses métodos utilizam uma combinação de sensores de câmera e LiDAR para criar mapas de alta qualidade dos ambientes, combinados com estimadores de pose precisos. Com o uso de técnicas de DL para extração de características e localização, a precisão e robustez desses algoritmos melhoraram significativamente. Além disso, avanços recentes em métodos de otimização, como a otimização de grafos de pose não linear, aprimoraram a consistência e eficiência dos algoritmos. No geral, esses desenvolvimentos levaram à adoção crescente de algoritmos de SLAM baseados em imagem [72] e LiDAR [73] em várias aplicações do mundo real dentro das comunidades de robótica e veículos autônomos. Mais importante ainda, a capacidade de reconhecimento de cena é um aspecto importante de qualquer algoritmo de SLAM, pois informações precisas de localização relacionadas a marcos detectados podem ser aproveitadas como referências absolutas. No entanto, em métodos de localização por rádio, é mais difícil reconhecer lugares revisitados através da extração de características dos marcos, como nas abordagens de SLAM por imagem [72], e trabalhos futuros são previstos nessa direção [74].

A estimativa da posição de uma plataforma móvel é uma parte importante de muitos sistemas autônomos, sendo especificamente apontada como um desafio para a indústria de mineração subterrânea [75]. Em uma mina subterrânea, não há cobertura dos Global Navigation Satellite Systems (GNSS) e o ambiente dinâmico e severo exige o mínimo de infraestrutura possível. Portanto, um sistema de localização autossuficiente é preferido [76]. Os veículos autônomos comerciais existentes em minas estão equipados com LiDARs 2D, odometria e Inertial Measurement Units (IMUs) [76–79], e fundem as informações das diferentes fontes de dados por meio de algoritmos de filtragem para determinar a posição do veículo em um mapa. Fazer a correspondência de todos os raios laser de uma varredura LiDAR individualmente com um mapa predefinido é computacionalmente caro, e métodos para selecionar subconjuntos dos raios disponíveis sem perder a precisão da estimativa são desenvolvidos em [80]. No entanto, esses métodos são sensíveis a outliers nos dados e imperfeições no mapa. Como alternativa, podem ser usados algoritmos de correspondência direta de varreduras que buscam uma transformação que alinhe duas nuvens de pontos. Para isso, o algoritmo de ponto mais próximo iterativo é o padrão de fato e muitas variações foram desenvolvidas [81]. A comunidade de visão computa-

cional construiu com sucesso um arsenal de métodos de extração de características exatamente com o propósito de obter associações de dados robustas em dados ruidosos com baixo esforço computacional [82]. Inspirados por isso, métodos de extração de características especificamente adaptados para dados de laser 2D foram desenvolvidos nas últimas décadas [83–85], os quais também se mostraram eficazes em ambientes internos limpos.

Já a estimativa da marcha humana é útil em várias aplicações e recebeu atenção extensiva por décadas. Ela pode ser usada para identificação humana [86,87], diagnóstico clínico [88], interação humano-robô [89,90], esportes [91] e navegação humana [92]. Para estimar a marcha humana, várias técnicas são apresentadas. Elas podem ser divididas em dois grupos: com fixação no corpo e sem fixação no corpo. No grupo com fixação no corpo, o sistema de câmera óptica Vicon [93], que captura marcadores infravermelhos fixados no corpo, é um sistema de referência com alta precisão. Outro método estima o movimento do corpo usando IMUs fixadas em diferentes partes do corpo [94,95]. Na técnica sem fixação no corpo, um sistema de câmera sem marcadores pode capturar e estimar a marcha humana usando métodos de processamento de imagem digital [96,97]. O sensor LiDAR também pode ser usado [98]. O sistema GAITRite, baseado em sensores de placa de força no chão, é conhecido como o padrão de ouro deste grupo [99]. Embora os métodos forneçam parâmetros de marcha altamente precisos, eles requerem alto custo operacional e esforços de instalação complicados. O sistema de sensores vestíveis é leve e de baixo custo. No entanto, um grande problema da estimativa da marcha humana baseada em IMU é o erro de acumulação, que pode afetar significativamente a estimativa de posição.

Um LiDAR 2D, que tem algumas vantagens de não necessitar de marcadores externos e instalação simples, tem sido usado em veículos autônomos [100,101], navegação de robôs móveis [102,103] e rastreamento da marcha humana [90,104–109]. Comparado a um LiDAR 3D, um LiDAR 2D é menos caro tanto em termos de preço quanto de custo computacional. O LiDAR pode ser colocado em uma plataforma móvel, como robôs móveis ou andadores inteligentes, para rastrear a marcha humana durante a caminhada [90,104]. Alguns sensores adicionais, como IMU e codificadores, precisam ser instalados nesses sistemas para estimar a orientação da plataforma móvel. Nos trabalhos apresentados em [105–107] um LiDAR 2D de 360 graus é colocado no chão para rastrear a canela humana durante a caminhada. O sistema requer apenas um único LiDAR, por isso é simples de instalar em qualquer lugar. No entanto, um sistema de LiDAR único tem a desvantagem de alcance de rastreamento limitado. Devido ao pequeno raio da perna humana e à resolução angular grosseira do LiDAR de baixo custo, o alcance de rastreamento da perna humana é de apenas alguns metros. Em [108] um método de rastreamento da marcha humana usando um sistema de múltiplos LiDARs 2D. Esses LiDARs são colocados à mesma altura no chão para escanear as pernas humanas durante a caminhada. O uso de múltiplos LiDARs apresenta o problema de calibração para encontrar as informações relativas entre eles. Assim, muitos esforços foram feitos para calibrar o sistema com precisão. Diferente do sistema de múltiplos LiDARs 3D que pode encontrar os pontos correspondentes dos dados de varredura em espaços 3D e determinar diretamente os parâmetros de calibração extrínsecos, o sistema de múltiplos LiDARs 2D é mais difícil. Um dos métodos mais populares usa um sensor adicional, como uma câmera [109,110] ou odômetro [111], como uma ponte. Em [112] os autores calibram a rede estacionária de múltiplos LiDARs 2D combinando as trajetórias de pessoas em movimento. Embora isso não exija um sensor adicional ou marcador externo, a precisão é afetada pelos erros de estimativa da trajetória humana e pelo posicionamento dos LiDARs. Outro método é calibrar o sistema de múltiplos LiDARs em um robô móvel usando alguns marcadores específicos, como planos ortogonais [113], um triedro [114]

ou um corredor em forma de cuboide [115]. A linha reta é ajustada aos dados de varredura no plano do marcador para cada LiDAR, e os pontos de interseção são usados para estimar os parâmetros de calibração. Portanto, esses sistemas exigem que os LiDARs sejam colocados em planos diferentes e geralmente são usados em robôs móveis.

Portanto esta revisão da literatura aponta para o potencial da utilização dos sensores LiDAR 2D devido ao seu menor custo quando comparado com os sensores LiDAR 3D. Além disso o uso de LiDAR ao invés de câmeras preserva a identidade e a privacidade das pessoas. Também vale ressaltar que a utilização de LiDAR para sensoriamento, posicionamento, localização e também aplicações de SLAM vem sendo propostas. Neste contexto IA, ML e DL vem sendo utilizados como ferramentas para aprimorar a precisão destes sistemas.

2.2 Sistemas de Posicionamento

Um IPS é um sistema livre de GPS que estima a posição de objetos ou pessoas em um ambiente confinado de maneira contínua. Tipicamente, ele possui duas fases: a fase de medição de distância e a fase de estimativa de posição. Na fase de medição de distância, um IPS estima a distância entre o alvo e os nós âncora, cujas posições são conhecidas previamente, usando uma técnica de medição de distância adequada. Em seguida, o IPS usa essas observações de distância para estimar a localização do alvo usando diferentes métodos de localização e posicionamento. A subseção a seguir apresenta as principais técnicas convencionais utilizadas para este fim.

2.2.1 Técnicas de Estimação de Distância

Esta subseção apresenta técnicas de estimação de distância legadas, já amplamente utilizadas em sistemas de comunicação. Serão abordadas as técnicas baseadas em RSSI, ToA, TDoA, AoA e CSI.

O RSSI é, em geral, o parâmetro mais fácil de medir, no entanto, resulta na medição de distância mais imprecisa, especialmente em ambientes internos devido a efeitos como desvanecimento, sombreamento, refração, dispersão e reflexões. No entanto, devido à flutuação do RSSI em ambientes internos, é quase impossível alcançar uma localização precisa usando métodos baseados em modelo em ambientes eletromagnéticos complexos. Portanto, o uso de diferentes filtros, como o Filtro de Kalman [116], e outras técnicas de ML tem sido utilizado para mitigar as flutuações do RSSI.

A técnica ToA é baseada no tempo de chegada, portanto utiliza o tempo de propagação do sinal para calcular a distância entre o alvo e o nó âncora. Em geral, o ToA é muito mais preciso do que a abordagem da técnica baseada em RSSI. No entanto, o tempo de processamento e a sincronização afetam a medição da distância no ToA [117].

A técnica TDoA utiliza a diferença nos tempos de propagação do sinal entre o nó alvo e um número de nós âncora para determinar a posição do nó alvo [118]. Nesta técnica, pelo menos três nós âncora são necessários para calcular a localização do alvo na interseção dos hiperboloides. O TDoA pode abordar a questão do erro de sincronização até certo ponto, pois leva em conta apenas a sincronização dos transmissores [119]. No entanto, a propagação do sinal NLOS degrada significativamente o desempenho dos sistemas baseados em ToA ou TDoA. Portanto, na literatura, um número de métodos de identificação e mitigação de NLOS foram propostos para melhorar a precisão da localização baseada em ToA ou TDoA [120].

A técnica AoA é baseada no ângulo de chegada, e utiliza o ângulo que o sinal faz com um arranjo de antenas para estimar a posição [121]. Esta é uma técnica de medição de distância

aprimorada. Como tanto as medições do ângulo quanto da distância são utilizadas, idealmente dois nós âncora são suficientes para a estimativa de posição [122]. No entanto, uma desvantagem deste método é a necessidade de arranjos de antenas, o que o torna complexo e de custo mais elevado [123]. Este método também pode empregar a diferença de tempo de chegada do sinal em elementos de antena individuais, mas isso requer hardware ainda mais complexo e calibração precisa.

A CSI também é uma técnica de medição de distância aprimorada. A CSI pode ser usada para obter uma estimativa precisa do sinal recebido em toda a largura de banda do sinal. A técnica apresenta um desempenho melhor que o RSSI, onde apenas um único valor de amplitude para o sinal recebido é obtido. Geralmente, o CSI necessita de múltiplas antenas e a resposta de frequência do canal vista por cada antena precisa ser estimada. O CSI pode fornecer tanto a magnitude quanto a fase da resposta do canal e é adequado para esquemas de localização baseados em distância e livres de distância [20].

2.2.2 Técnicas de Estimação de Localização

Esta subseção apresenta técnicas de estimação de localização legadas, já amplamente utilizadas em sistemas de comunicação. Serão abordadas as técnicas baseadas em multilateração e trilateração, triangulação e fingerprinting. A trilateração é uma técnica para estimar a posição de um nó desconhecido com a ajuda de três ou mais nós conhecidos e as respectivas distâncias associadas [124]. A trilateração é um caso especial de multilateração, onde apenas três nós conhecidos são utilizados. A técnica de triangulação pode ser usada para estimativa da localização quando o ângulo de chegada é conhecido. É menos complexa e possui precisão moderada [125], exigindo pelo menos dois nós âncora. A precisão da localização nesta técnica depende fortemente da precisão da estimativa do ângulo de chegada. Aumentar o número de nós âncora pode aprimorar o desempenho da localização.

O fingerprinting, impressão digital, é um método de posicionamento interno amplamente utilizado que utiliza várias tecnologias de acesso sem fio, como Wi-Fi, Bluetooth Low Energy (BLE) e ZigBee [126–128]. O método de localização baseado em impressão digital envolve duas fases, o treinamento na fase off-line e o teste na fase online. Durante a fase de treinamento, dados de RSSI ou CSI são coletados em pontos de acesso para diferentes posições internas conhecidas, chamadas de pontos de referência, e um mapa de rádio é construído com os dados medidos para cada posição registrada. Durante a fase online, a posição em tempo real do nó alvo é estimada comparando os dados medidos nos pontos de acesso para o nó alvo e o mapa de rádio criado na fase de treinamento. Este método oferece alta precisão se mais dados offline forem coletados com precisão para construir o mapa de rádio. No entanto, construir o mapa de rádio para implantação em grandes áreas requer um esforço considerável. Além disso, para redes dinâmicas, quando as posições dos nós, mesmo um único nó, são alteradas ou excluídas inesperadamente, o banco de dados offline deve ser recriado.

2.2.3 Tecnologias de Acesso Utilizadas para Localização Indoor

Esta subseção apresenta tecnologias de acesso legadas, já amplamente utilizadas em sistemas de comunicação. Serão abordadas as tecnologias Wi-Fi, RFID, UWB e BLE. O Wi-Fi é o mais utilizado para IPS devido à disponibilidade ubíqua de sistemas Wi-Fi [129]. Ele pode fornecer uma faixa de cobertura bastante ampla, no entanto, o consumo de energia dos sistemas Wireless Local Area Network (WLAN) é comparativamente mais alto [130]. Tipicamente, os métodos de localização baseados em Wi-Fi são trilateração ou baseados em impressão digital. Técnicas de

medição AoA, ToA e RSSI são usadas para métodos baseados em trilateração [131]. Medidas de RSSI e CSI são geralmente usadas para gerar o mapa de impressões digitais. O RSSI é mais atraente porque as informações de RSSI podem ser facilmente coletadas de um ponto de acesso comum sem a necessidade de outros equipamentos [132]. No entanto, a flutuação do RSSI frequentemente leva a uma degradação severa do desempenho. Na literatura, muitos métodos de aprendizado de máquina foram encontrados para mitigar o impacto das flutuações do RSSI [128,133,134].

O RFID é uma tecnologia muito econômica [135]. Em geral, a tecnologia de posicionamento baseada em RFID é resistente a fatores ambientais e pode ser usada em quase qualquer aplicação. O método de posicionamento baseado em impressão digital, que utiliza medições de RSSI, pode ser usado para sistemas de posicionamento interno baseados em RFID [136]. Uma vez que o UWB é uma tecnologia de rádio de curto alcance que transmite pulsos curtos em uma larga banda, ele é menos sensível aos efeitos de múltiplos percursos e oferece alta precisão. Sistemas de localização baseados em tecnologia UWB alcançam uma precisão de centímetros, o que é consideravelmente melhor do que BLE ou Wi-Fi. O principal desafio em sistemas IPS baseados em UWB é o efeito de NLOS. O sinal NLOS reduz significativamente a precisão da localização. Técnicas de ML têm recebido muita atenção em pesquisas na literatura para distinguir e mitigar o efeito NLOS [137]. O Bluetooth tem sido considerado um concorrente do Wi-Fi devido à ampla adaptabilidade do BLE pela maioria dos smartphones [170]. O BLE pode fornecer uma faixa de cobertura de 70 a 100 metros com alta eficiência energética [138]. Nos últimos anos, a impressão digital baseada em RSSI do BLE ganhou muita atenção na comunidade de pesquisa.

2.3 LiDAR

LIDAR é uma sigla para Light Detection and Ranging, Detecção e Medição por Luz. Ele se enquadra na categoria de sensor de Time of Flight (ToF) [139]. O LIDAR mede a distância de um objeto emitindo sinais de luz de um laser para o objeto e capturando o tempo de viagem [140]. Um sensor LIDAR típico e seus principais elementos são mostrados na Figura 1.

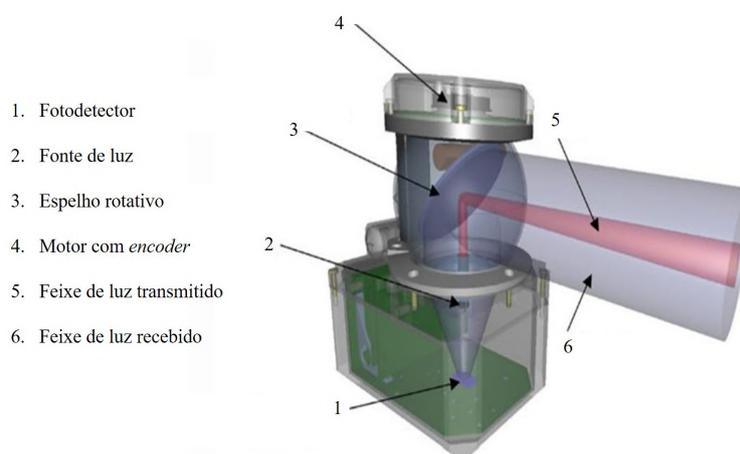


Figura 1: Sensor LiDAR Típico e seus principais componentes. Adaptado de [140].

O sensor é composto por uma fonte de luz na faixa de infravermelho, um espelho rotativo, um motor com encoder para medida de ângulo, e um fotodiodo. A equação para medir a

distância percorrida por uma partícula de luz refletida de e para um objeto é definida pela Equação 1.

$$d = \frac{c \cdot \Delta t}{2} \quad (1)$$

Onde, d é a distância em metros, c é a velocidade da luz em metros por segundo, Δt é o tempo de voo. Esta equação ajuda a quantificar estimativas individuais sobre a atmosfera, bem como a avaliar a geometria e a eficiência de estruturas [141]. Ao medir o tempo que a luz leva para viajar de o sensor LiDAR até um objeto e retornar, e sabendo a velocidade constante da luz, é possível calcular a distância até o objeto. A divisão por 2 é necessária porque o tempo de voo inclui a ida e a volta da luz. Em um LiDAR um laser pulsado emite um pulso de forma única ou contínua em direção ao alvo. Ao emitir um pulso de laser, um circuito de temporização interno é acionado instantaneamente. Um temporizador mede o tempo entre a chegada do pulso de laser ao alvo e o seu retorno ao receptor a partir do alvo, assim, a distância do alvo é obtida. O esquemático de medição de distância por TOF é mostrado na Figura 2.

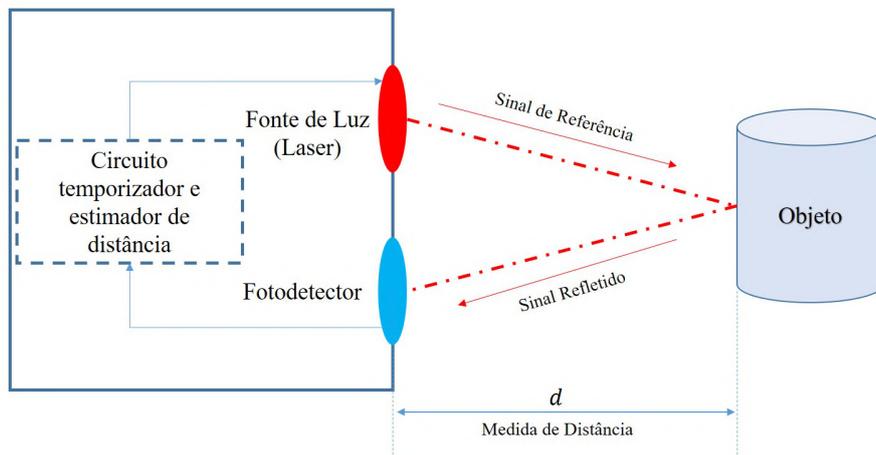


Figura 2: Esquemático de medição de distância por ToF.

O intervalo de tempo Δt é calculado no temporizador pela diferença de tempo do pulso de luz desde a emissão até o alvo e o retorno ao receptor a partir do alvo. O Δt é calculado pelo produto entre número de pulsos do clock n , contados entre o instante da transmissão e da recepção do sinal, e do intervalo de pulso de clock τ . Equação 2 apresenta o cálculo em função destas variáveis.

$$d = \frac{c \cdot n \cdot \tau}{2} \quad (2)$$

O cálculo da distância pode ainda ser determinado em função da frequência de pulso de clock do circuito sendo esta frequência igual a $1/\tau$, ou ainda em função de λ que apresenta a base de distância de cada pulso dada por $c/2f$, como descrito na Equação 3.

$$d = \frac{c \cdot n}{2 \cdot f} = \lambda \cdot n \quad (3)$$

O princípio de funcionamento específico é descrito da seguinte forma: [142] primeiramente, mirando no alvo, inicia-se a emissão de luz para o alvo pelo sistema de emissão de luz; ao mesmo tempo, o sinal de emissão coletado pelo amostrador é usado como o sinal de abertura

do contador e o contador começa a contar. O oscilador de clock efetivamente insere o pulso do clock no contador. O sinal de eco retornado pelo alvo passa difusamente pela atmosfera e entra no sistema óptico receptor, convertendo-se em pulso elétrico pelo detector fotoelétrico, amplificado pelo amplificador, que serve como o sinal de fechamento do contador, e o contador para de contar. O número de pulsos do clock que entra no contador durante a abertura e fechamento do mesmo é calculado para obter a distância do alvo d . O método de medição de distância TOF é principalmente aplicado em medição topográfica, alcance tático de front-end, rastreamento de mísseis guiados, medição de distância por LiDAR a laser e medições de distância entre satélites artificiais, terra e lua, etc. Os fatores que afetam a precisão da medição de distância são principalmente a borda de subida do pulso de laser, a largura de banda do canal receptor, relação sinal-ruído do detector e a precisão do intervalo de tempo.

Sensores podem ser divididos quando às dimensões espaciais de medida entre 2D e 3D. Os sensores LiDAR 2D registram parâmetros X e Y usando um único eixo de feixes [143]. Sensores LiDAR 3D funcionam da mesma forma que suas versões 2D, mas medições adicionais em torno do eixo Z são necessárias para coletar dados verdadeiramente tridimensionais. Os dados do terceiro eixo são geralmente coletados usando vários lasers em ângulos diferentes ou projeções longitudinais. Sensores LiDAR 3D têm maior precisão e resolução do que as versões 2D, mas são significativamente mais caros. O LiDAR 3D é ideal para visualização e análise detalhada de estruturas tecnológicas, como o raio de curvatura.

Os sensores LiDAR podem ainda ser divididos entre mecânicos/rotativos e os de estado sólido. O LiDAR mecânico é difícil de incorporar em um pequeno computador devido ao seu grande volume e massa. Por exemplo, manter um LiDAR mecânico para inspeções de edifícios [144] reduz drasticamente os ciclos de vida de drones de vigilância. É por isso que um LiDAR mecânico não pode ser integrado em um dispositivo portátil devido ao seu tamanho massivo. A recente implementação do LiDAR de estado sólido oferece uma opção de baixo custo e compacta para sistemas LiDAR SLAM. Um LiDAR de estado sólido é uma estrutura inteiramente baseada em um microprocessador e não possui componentes mecânicos [145]. Como resultado, em oposição ao LiDAR mecânico, tanto o tamanho quanto a massa podem ser grandemente reduzidos. Além disso, ao substituir uma base mecânica rotativa, o LiDAR de estado sólido é resistente a vibrações. Em termos de confiabilidade, diz-se que o LiDAR de estado sólido tem uma precisão de 1-2 cm e um alcance visível de centenas de metros. As técnicas atuais para sensores LiDAR mecânicos foram principalmente desenvolvidas e que coletam dados de objetos próximos girando um dispositivo a laser de alta frequência.

O LiDAR está entre os muitos mecanismos perceptivos populares em robótica devido à sua extrema precisão, ampla cobertura e longa longevidade. A maioria dos radares ativos tem um comprimento de onda de 2–30 cm, enquanto os LiDARs operam com um comprimento de onda de 300–2000 nm [146]. Esta é uma diferença de cinco magnitudes que pode ter implicações sérias para aplicações de vigilância. Devido ao espaçamento mais próximo dos feixes de laser, os LiDARs têm trilhas menores e melhores resoluções angulares e temporais do que o Radar. O radar de baixa onda é suscetível a gotas de água e neve caindo, enquanto o LiDAR usa esses aspectos para detectar e medir quantidades moleculares atmosféricas, como oxigênio e conteúdo de água líquida [141].

Em termos de reconhecimento de dados e aplicação, o LiDAR avançou a partir de uma variedade de outras tecnologias e sensores que não eram suficientemente sensíveis. O LiDAR provou ser uma ferramenta poderosa para uma variedade de problemas, incluindo a varredura entre árvores, fornecendo um sistema de mapeamento 3D suave, preciso e direto que produz resultados precisos e fáceis de entender [147]. Essas características diferenciam o LiDAR de

outras alternativas, como técnicas fotográficas, que tinham dificuldade em detectar elevações do solo. Os LiDARs modernos também podem operar 24 horas por dia, o que lhes dá uma vantagem significativa em relação a sensores como câmeras, que são quase inúteis na escuridão ou neblina [141]. A robusta versatilidade do LiDAR, bem como sua grande faixa de alcance de até 200 m permitem que ele identifique facilmente alvos. Além disso, o custo desses sensores 3D de maior desempenho foi bastante reduzido com o advento e adoção da tecnologia de estado sólido, tornando-o mais adequado para uma multiplicidade de aplicações [73].

3 Sensoriamento e Posicionamento em Redes 6G: Aplicações, Desafios e Oportunidades

Egidio Raimundo Neto, Arismar Cerqueira Sodré Junior
 egidio.neto@inatel.br, arismar@inatel.br

3.1 Estado da Arte

As redes sem fio 5G alcançaram melhorias significativas em termos de atraso, taxas de dados, eficiência espectral, mobilidade e no número de dispositivos de usuários sempre conectados [148]. Atualmente, há uma mudança em direção a uma sociedade digital com sistemas de gerenciamento automatizados remotos em vários setores de negócios e indústrias. Portanto, o 5G marcou o início de uma verdadeira sociedade digital. No entanto, o rápido desenvolvimento RA, RV, mídia tridimensional, IA e a IoE levou a um volume massivo de tráfego [148]. Além disso, as futuras redes móveis devem ser sistemas ultra grandes e altamente complexos. Portanto, as tarefas de otimização e configuração manuais, usadas nas redes móveis existentes, não seriam mais adequadas para as redes móveis de próxima geração [149]. Por fim, os novos serviços emergentes exigiriam taxas de dados muito altas, atrasos muito baixos e alta confiabilidade, que excederiam significativamente os objetivos primários das redes 5G [150]. Portanto, muitas iniciativas de pesquisa de rede 6G ganharam atenção significativa tanto na academia quanto na indústria [151]. As redes móveis e sem fio 6G proporcionariam uma grande cobertura de rede, o que permitiria aos usuários se comunicarem em todos os lugares com taxas de dados de usuário muito altas devido à grande largura de banda THz disponível e à IA. A IA seria o principal motor no design e na otimização da arquitetura da rede 6G, bem como nos protocolos, operações e 6G. As redes 6G, juntamente com a IA, forneceriam suporte a serviços inteligentes ubíquos aos usuários, o que excederia o tráfego de dados móveis usado hoje. A eficiência energética na rede 6G deve ser muito mais aprimorada do que na rede 5G. Isso se deve ao fato de que a rede 6G e os dispositivos 6G exigiriam um consumo de energia muito maior do que o 5G, aumentado por um fator de 1000 ou até 10000, uma vez que operariam em bandas de frequência de terahertz (de 0,1 THz a 10 THz), e deveriam fornecer suporte para uma capacidade de tráfego muito alta (10 Gbps/m³) e um número ultra grande de nós sem fio conectados de forma ubíqua. Portanto, novas técnicas de captação de energia estão sendo investigadas para LiDAR com a questão da eficiência energética [151]. Finalmente, a rede 6G utilizaria satélites de telecomunicações e satélites de imageamento da Terra para fornecer cobertura global, serviços de localização, transmissão e conectividade à Internet. Além disso, o aprimoramento do fatiamento dinâmico de rede, redes SDN aprimoradas e a virtualização aprimorada das funções de rede proporcionariam uma gestão de rede dinâmica e programaticamente eficiente no 6G [152]. Em localização, algoritmos classificadores são principalmente utilizados para extrair características dos sinais. No entanto, em cenários de ambiente complexo onde a extração de características é difícil e os dados têm alta dimensionalidade, o DL é muito promissor para melhorar a precisão de localização [153]. O DL é conhecido por sua capacidade de computação distribuída e análise de um grande volume de dados não rotulados e não categorizados. A maior vantagem dos algoritmos de DL é sua capacidade de extrair características diretamente dos dados sem extração manual de características [154]. Isso elimina a necessidade de expertise de domínio e extração de características essenciais. Extração de características e classificação são realizadas por um algoritmo de DL conhecido como Convolutional Neural Network (CNN) [155]. Muitas das abordagens de posicionamento interno são vulneráveis a erros de posicionamento global. O

problema de localização global ocorre quando a posição inicial do alvo é desconhecida para o IPS durante a inicialização. Em tal situação desafiadora, Reinforcement Learning (RL) prova ser a melhor técnica a ser usada. Como o RL permite que o agente alcance um objetivo de longo prazo interagindo com o ambiente, baseado no processo de recompensa e penalidade, e é capaz de resolver problemas causados pela instabilidade do sinal de rádio. Portanto, técnicas de RL são capazes de construir o mapa e otimizar sua ação continuamente [156]. A ideia principal do algoritmo de DL é assemelhar-se ao processo de percepção em um cérebro com uma rede neural profunda [157–159].

3.2 Casos de Uso

3.2.1 Desenvolvimento Sustentável

O desenvolvimento sustentável abrange casos de uso 6G que tratam do desenvolvimento sustentável da sociedade e, ao mesmo tempo, reduzem o impacto ambiental de diferentes indústrias. Um desses casos de uso é fornecer assistência médica para todos, independentemente da localização geográfica. A assistência médica remota é um desses facilitadores, que requer uma precisão de localização bastante fina (por exemplo, implantação de drones para coleta de amostras médicas). A latência requerida, neste caso, é bastante relaxada, e uma disponibilidade moderada é suficiente para garantir o serviço. Outros exemplos de casos de uso são o sensoriamento remoto e o monitoramento das condições meteorológicas, o acompanhamento da biodiversidade ao redor do globo e o rastreamento de ativos, todos os quais têm requisitos de precisão e latência [160].

3.2.2 Telepresença Imersiva

O sensoriamento e posicionamento podem melhorar a telepresença imersiva para interações aprimoradas. Esta família de casos de uso inclui reconhecimento de gestos para interações humano-máquina e RA. O reconhecimento de gestos requer uma precisão de alcance e angular bastante fina. Dependendo do caso de uso específico, a AR pode ter diferentes requisitos. Por exemplo, enquanto a RA para fornecer serviços contextuais, como uma experiência em um shopping, requer uma precisão de localização e angular moderada, a AR para posicionar um objeto no mundo real requer precisões de localização de nível centimétrico e orientações precisas [160].

3.2.3 Zonas de Confiança Locais para Humanos e Máquinas

Segurança da informação e fornecimento de zonas de confiança locais para humanos e máquinas também é um caso de uso potencial. Uma parte desta família inclui casos de uso com requisitos muito rigorosos de localização e orientação, disponibilidade e latência, como a telecirurgia, localizando microrrobôs dentro do corpo humano e posicionando equipamentos médicos no corpo. Outra parte da família inclui o rastreamento e monitoramento de pacientes, uma infraestrutura de sensores web para apoiar dispositivos sem capacidade de sensoriamento, posicionamento cooperativo para apoiar dispositivos com pouca ou nenhuma cobertura de rede, e fornecendo cobertura local temporária quando a cobertura da infraestrutura de rede planejada não está disponível, o que pode operar com precisão de localização mais relaxada [160].

3.2.4 Twinning Massivo

Fornecer um gêmeo digital eficiente de objetos e eventos no domínio digital pode abrir um leque de novas possibilidades. Um caso de uso possível está na manufatura, onde configurar e usar ferramentas industriais pode ser feito remotamente. Esse tipo de caso de uso requer resolução de localização e alcance na ordem de centímetros. Além disso, esse caso de uso requer uma boa resolução de velocidade na ordem de uma fração de metro por segundo para objetos em movimento. Outra área onde o twinning pode fornecer valor é em cidades inteligentes imersivas, onde, em um cenário, obter um gêmeo digital em tempo real da cidade pode ajudar a otimizar utilidades. Outro cenário nesta área é o monitoramento de tráfego. O caso de uso da cidade inteligente requer precisão de localização de nível de metro a submetro e requisitos de latência e disponibilidade bastante relaxados. Por outro lado, o gêmeo digital de um prédio inteligente, onde a localização de cada interruptor de energia, lâmpada, aquecedor, etc., é importante para a interação efetiva, requer posicionamento mais preciso enquanto tolera atrasos mais longos e menos disponibilidade. O requisito mais rigoroso é a alta exigência de escalabilidade [160].

3.2.5 Robôs para Robôs Colaborativos

Outro caso de uso inclui soluções que podem habilitar robôs colaborativos (cobots), como posicionamento de cobot, obtenção de mapas do ambiente de cobots, sensoriamento de objetos por cobots e o posicionamento fino de veículos ao redor de cobots. Alguns casos de uso de posicionamento nesta família, como localizar cobots, requerem posições muito precisas, até o nível de centímetros, e também requisitos de baixa latência. Aplicações de sensoriamento, como o mapeamento ambiental de robôs, têm requisitos rigorosos de precisão de localização de sensoriamento, bem como resolução de velocidade e resolução angular [160].

3.3 Desafios

3.3.1 Limitações e Defeitos do Hardware

Os problemas de hardware têm efeitos mais severos no posicionamento e sensoriamento do que na comunicação. A precisão do alcance degrada principalmente devido a erros de temporização, enquanto a precisão da estimativa de ângulo é degradada por imperfeições da antena. Exemplos de imperfeições do hardware incluem ruído de fase, acoplamento mútuo, distorção não linear e deficiências seletivas de frequência. Enquanto algumas das deficiências do hardware podem ser compensadas por meio de calibração outras, como o ruído de fase, devem ser compensadas dinamicamente durante a operação. Para atender às demandas de baixa latência, uma larga banda é necessária, mas isso está sujeito a limitações do hardware. Além disso, um grande volume de dados requer mais armazenamento e recursos computacionais que, por sua vez, podem limitar o desempenho melhorado por essas características [160].

3.3.2 Canais de Propagação Severos

Dependendo da relação entre o comprimento de onda e o tamanho dos objetos, o canal de rádio pode exibir características variáveis. Em sub-6 GHz, o canal tem uma relação muito complexa com o ambiente, e pequenos movimentos levam a grandes flutuações de potência devido ao desvanecimento em pequena escala. Em bandas de ondas milimétricas, a penetração de obstáculos é reduzida, e reflexão e dispersão tornam-se fenômenos mais importantes. Um canal mais esparsa permite uma maior resolvabilidade de multipercuro, e larguras de banda

maiores e grandes arranjos de antenas possibilitam um posicionamento preciso. A 100 GHz e acima, principalmente, o multipercorso devido a objetos metálicos será visível, seja na forma de pontos de incidência móveis e âncoras virtuais ou objetos menores agindo como pontos estáticos. Além disso, o deslocamento Doppler aumentará grandemente nas frequências mm-wave superiores. Nessas frequências, o estado do canal muda mais rapidamente, exigindo atualizações mais frequentes, o que demanda uma melhor consistência espacial dos modelos de canal desenvolvidos para que amostras consecutivas da resposta impulsiva do canal sejam acumuladas ao longo do tempo. A caracterização das dispersões angular, de atraso e Doppler devido a objetos estendidos, absorção molecular, ganhos de enlace e comportamento sob mobilidade são desafios importantes a serem abordados, por exemplo, através de evidências medidas e modelos de canal [160].

3.4 Oportunidades

Como um dos principais facilitadores em 6G, uma Reconfigurable Intelligent Surface (RIS) pode refletir uma onda eletromagnética que chega em uma determinada direção à uma direção desejada por meio de células refletoras passivas programáveis e um controlador, o que implica custos de implantação e operacionais menores do que uma estação base ou um repetidor. Sob condições de bloqueio de linha de visada LOS, RISs podem criar enlaces NLOS controláveis para melhorar a cobertura e a qualidade da comunicação. Em aplicações de posicionamento e sensoriamento, RISs com localizações conhecidas podem aumentar a precisão fornecendo medições geométricas adicionais. Por meio de um design sob medida dos deslocamentos de fase da RIS, o desempenho de posicionamento e sensoriamento pode ser significativamente aprimorado quando há conhecimento prévio das localizações do usuário final/alvo.

Os futuros serviços de posicionamento e sensoriamento dependerão de uma rede de comunicação ubiquamente disponível e seu hardware, evitando assim a implantação de infraestrutura paralela dispendiosa. Devido a compromissos inerentes, a otimização conjunta de forma de onda para posicionamento, comunicações e sensoriamento requer uma consideração cuidadosa de requisitos conflitantes, como taxa de dados, precisão e largura do lóbulo principal e níveis de lóbulos laterais da função de ambiguidade. Além disso, formas de onda de comunicação/sensoriamento conjuntas devem ser robustas a imperfeições de hardware em altas frequências, necessitando do design simultâneo de hardware de transceptor multifuncional e formas de onda. Em cenários 6G, algoritmos que podem aproveitar tanto dados quanto conhecimento de domínio serão chave para alcançar desempenho extremo de posicionamento/sensoriamento.

3.5 Aplicações de Posicionamento e Sensoriamento com uso de LiDAR

A tecnologia LiDAR possui uma ampla gama de aplicações em diversos campos devido à sua capacidade de medir distâncias com precisão, iluminando um alvo com luz de um laser e medindo a reflexão com um sensor. Desta forma, existe uma gama de aplicações que podem ser desenvolvidas combinando o uso de LiDAR com outras tecnologias e também IA

3.5.1 Veículos Autônomos

Os sensores LiDAR são cruciais para o desenvolvimento de veículos autônomos. Eles fornecem informações em alta resolução e 3D sobre o ambiente ao redor do veículo, permitindo que o veículo tome decisões informadas sobre navegação e evitação de obstáculos. O campo da mobilidade autônoma tem visto avanços significativos através de pesquisas inovadoras focadas

na interpretação e manipulação de dados LiDAR para veículos autônomos. Em [161] os autores desenvolveram um decodificador LiDAR tridimensional destinado a veículos autônomos em cidades inteligentes, concentrando-se em melhorar a velocidade e eficiência da decodificação para a reconstrução de ambientes 3D. Este trabalho é complementado pela pesquisa apresentada em [162], que propõe um algoritmo para o processamento de fluxos de dados LiDAR em veículos autônomos, utilizando camadas convolucionais 3D para a percepção dinâmica de cenas 3D. Além disso, [163] e [161] descrevem a implementação de localização baseada em mapas usando correspondência de nuvem de pontos para veículos autônomos, destacando a precisão e eficiência para a condução autônoma. Juntos, esses estudos fornecem insights valiosos sobre o desenvolvimento de tecnologias LiDAR para a navegação e percepção de veículos autônomos, representando passos importantes para a realização de sistemas de transporte autônomos eficientes e seguros.

3.5.2 Geografia e Mapeamento

O LiDAR é amplamente utilizado em geografia para mapeamento e levantamentos topográficos. Ele pode penetrar copas de árvores para medir o solo abaixo, tornando-se inestimável para a criação de mapas topográficos detalhados e para entender as mudanças no terreno. A aplicação de tecnologias de sensoriamento remoto, incluindo LiDAR, tem revolucionado diversas áreas de estudo, desde a arqueologia até as ciências da Terra, proporcionando novas oportunidades para pesquisa, análise e interpretação. O trabalho apresentado em [164] destaca o papel crucial do sensoriamento remoto em avançar a arqueologia, geografia e ciências da Terra, abrindo novos caminhos para a exploração e compreensão de nosso mundo. Paralelamente, os autores em [165] os avanços nas tecnologias de UAVs e sensores, incluindo LiDAR, para a detecção de mudanças nas ciências da Terra, enfatizando o potencial para análises detalhadas da evolução geomórfica em uma escala fina. Além disso, o trabalho apresentado em [166] mostra o uso de dados LiDAR do ICESat-2 da NASA para o estudo de dunas de areia eólicas, demonstrando melhorias significativas nos detalhes topográficos de alta resolução e facilitando a educação geológica e o mapeamento de campo. Esses estudos coletivamente ilustram o impacto transformador do sensoriamento remoto e do LiDAR em ampliar nossa compreensão e capacidade de monitorar a Terra e seu ambiente em constante mudança.

3.5.3 Florestas e Agricultura

Na silvicultura, o LiDAR é usado para medir alturas de árvores, estrutura de copas e biomassa. Essas informações são cruciais para o manejo de florestas, avaliação de estoques de carbono e planejamento de colheitas. Na agricultura, o LiDAR ajuda na agricultura de precisão mapeando topografias de campos, otimizando a irrigação e monitorando o status das culturas. A agricultura de precisão tem se beneficiado enormemente dos avanços na aplicação da tecnologia LiDAR, permitindo uma gestão agrícola mais eficiente e sustentável. Em [167] os autores fornecem uma revisão abrangente dos sistemas LiDAR aplicados à agricultura de precisão, destacando o uso de scanners a laser terrestres, móveis e aéreos em diversas atividades, como estimativa de métricas de culturas, digitalização de árvores e plantas, além de suporte ao planejamento e tomada de decisão. Complementando este trabalho em [168] os autores discutem as capacidades de captura de dados não destrutivos do LiDAR na agricultura, abordando aplicações em paisagismo, topografia, estrutura de árvores, estimativa de biomassa e propondo direções futuras para pesquisa. Além disso, em [169] os autores realizam um levantamento sobre o uso significativo da tecnologia LiDAR para análise 3D de culturas terrestres, identificando

áreas de aplicação, espécies de culturas, tecnologias de scanner e discutindo o equilíbrio entre os custos econômicos e a aquisição de informações agronomicamente relevantes. Juntos, esses estudos destacam o impacto transformador do LiDAR na agricultura de precisão, oferecendo insights valiosos para o desenvolvimento futuro de práticas agrícolas mais informadas e eficazes.

3.5.4 Ciência Ambiental e Conservação

As pesquisas destacadas abordam inovações significativas no uso de dados LiDAR para aplicações florestais, demonstrando a versatilidade e eficácia dessa tecnologia em diferentes contextos. Em [170] avaliam a utilização de dados LiDAR de baixa densidade disponíveis gratuitamente para capturar a variabilidade em características de árvores e de povoamentos, incluindo biomassa acima do solo, no Vale Aluvial do Baixo Mississippi. O estudo descobriu que os modelos LiDAR capturaram mais variabilidade no nível da árvore do que no nível do povoamento e que a inclusão do tipo de solo geralmente melhorou os modelos. Por outro lado, em [171] os autores exploram a integração do LiDAR do iPhone com fotogrametria de UAV quadricóptero e de asa fixa para aplicações florestais, concentrando-se na criação de Modelos Digitais de Elevação e Modelos de Altura de Dossel para avaliar as condições florestais. Este estudo destaca a eficiência e os benefícios econômicos do uso do LiDAR do iPhone e da fotogrametria no mapeamento florestal e na gestão de inventário. Juntos, esses trabalhos ilustram o potencial transformador do LiDAR e da fotogrametria na melhoria das práticas de monitoramento e gestão florestal, oferecendo métodos inovadores para a estimativa de biomassa e a avaliação de condições florestais com precisão e eficiência.

3.5.5 Aplicações Costeiras e Marinhas

Em zonas costeiras, o LiDAR é usado para mapeamento de linhas de costa, monitoramento de erosão costeira e mapeamento do leito marinho. Apóia a gestão de recursos costeiros e o planejamento de estruturas de defesa costeira. Trabalhos ilustram a aplicação inovadora de dados LiDAR na engenharia costeira e no monitoramento costeiro, destacando a eficácia dessa tecnologia em fornecer soluções detalhadas para desafios ambientais e de engenharia. [172] documentam o uso de dados LiDAR em projetos de engenharia costeira, ressaltando sua capacidade para mapeamento em larga escala de projetos costeiros com alta resolução espacial. Eles discutem o papel da Digital Coast da National Oceanographic and Atmospheric Administration como um ponto de acesso principal para dados LiDAR nos EUA, apresentando exemplos de projetos de engenharia que utilizam LiDAR para estudos de viabilidade, design, monitoramento e análise de emergência. em [173] os autores revisam o uso de dados de nuvem LiDAR 3D de Varredura a Laser Terrestre (TLS) para monitoramento costeiro, focando na extração de características lineares, localização e categorização de fraturas, e aplicação da técnica de efeito de linha, integrando TLS 3D LiDAR com o Sistema de Informação Geográfica para gestão eficiente da linha costeira e prevenção de erosão. Em [174] os autores exploram o uso de dados LiDAR topo-batimétricos e aprendizado de máquina de floresta aleatória para classificar pedras em ambientes marinhos costeiros, cobrindo a zona de transição entre terra e água e oferecendo dados de alta resolução da batimetria em zonas costeiras, mostrando potencial para mapeamento de habitats no leito marinho. Esses estudos coletivamente destacam o potencial transformador do LiDAR e das tecnologias relacionadas no avanço do monitoramento costeiro e da engenharia costeira, fornecendo ferramentas precisas para a análise e gestão de ambientes costeiros.

3.5.6 SLAM

Um progresso significativo no desenvolvimento de algoritmos de SLAM baseados em imagens e LiDAR eficientes, consistentes e robustos, que emergiram como as principais abordagens [65–71] tem sido apresentado nos últimos anos. Esses métodos utilizam uma combinação de sensores de câmera e LiDAR para criar mapas de alta qualidade dos ambientes, combinados com estimadores de pose precisos. Com o uso de técnicas de DL para extração de características e localização, a precisão e robustez desses algoritmos melhoraram significativamente. Além disso, avanços recentes em métodos de otimização, como a otimização de grafos de pose não linear, aprimoraram a consistência e eficiência dos algoritmos. No geral, esses desenvolvimentos levaram à adoção crescente de algoritmos de SLAM baseados em imagem [72] e LiDAR [73] em várias aplicações do mundo real dentro das comunidades de robótica e veículos autônomos. Mais importante ainda, a capacidade de reconhecimento de cena é um aspecto importante de qualquer algoritmo de SLAM, pois informações precisas de localização relacionadas a marcos detectados podem ser aproveitadas como referências absolutas. No entanto, em métodos de localização por rádio, é mais difícil reconhecer lugares revisitados através da extração de características dos marcos, como nas abordagens de SLAM por imagem [72], e trabalhos futuros são previstos nessa direção [74].

3.5.7 Sistemas de Sensoriamento e Posicionamento de Robôs e Veículos Não Tripulados

A estimativa da posição de uma plataforma móvel é uma parte importante de muitos sistemas autônomos, sendo especificamente apontada como um desafio para a indústria de mineração subterrânea [75]. Em uma mina subterrânea, não há cobertura dos GNSS e o ambiente dinâmico e severo exige o mínimo de infraestrutura possível. Portanto, um sistema de localização autossuficiente é preferido [76]. Os veículos autônomos comerciais existentes em minas estão equipados com LiDARs 2D, odometria e IMUs [76–79], e fundem as informações das diferentes fontes de dados por meio de algoritmos de filtragem para determinar a posição do veículo em um mapa. Fazer a correspondência de todos os raios laser de uma varredura LiDAR individualmente com um mapa predefinido é computacionalmente caro, e métodos para selecionar subconjuntos dos raios disponíveis sem perder a precisão da estimativa são desenvolvidos em [80]. No entanto, esses métodos são sensíveis a outliers nos dados e imperfeições no mapa. Como alternativa, podem ser usados algoritmos de correspondência direta de varreduras que buscam uma transformação que alinhe duas nuvens de pontos. Para isso, o algoritmo de ponto mais próximo iterativo é o padrão de fato e muitas variações foram desenvolvidas [81]. A comunidade de visão computacional construiu com sucesso um arsenal de métodos de extração de características exatamente com o propósito de obter associações de dados robustas em dados ruidosos com baixo esforço computacional [82]. Inspirados por isso, métodos de extração de características especificamente adaptados para dados de laser 2D foram desenvolvidos nas últimas décadas [83–85], os quais também se mostraram eficazes em ambientes internos limpos.

3.5.8 Sistemas de Estimativa da Marcha humana

Já a estimativa da marcha humana pode ser considerada útil em várias aplicações e recebeu atenção extensiva por décadas. Ela pode ser usada para identificação humana [86,87], diagnóstico clínico [88], interação humano-robô [89,90], esportes [91] e navegação humana [92]. Para estimar a marcha humana, várias técnicas são apresentadas. Elas podem ser divididas em dois

grupos: com fixação no corpo e sem fixação no corpo. No grupo com fixação no corpo, o sistema de câmera óptica Vicon [93], que captura marcadores infravermelhos fixados no corpo, é um sistema de referência com alta precisão. Outro método estima o movimento do corpo usando IMUs fixadas em diferentes partes do corpo [94,95]. Na técnica sem fixação no corpo, um sistema de câmera sem marcadores pode capturar e estimar a marcha humana usando métodos de processamento de imagem digital [96,97]. O sensor LiDAR também pode ser usado [98]. O sistema GAITRite, baseado em sensores de placa de força no chão, é conhecido como o padrão de ouro deste grupo [99]. Embora os métodos forneçam parâmetros de marcha altamente precisos, eles requerem alto custo operacional e esforços de instalação complicados. O sistema de sensores vestíveis é leve e de baixo custo. No entanto, um grande problema da estimativa da marcha humana baseada em IMU é o erro de acumulação, que pode afetar significativamente a estimativa de posição.

4 Sistema de Sensoriamento e Posicionamento de Pedestres em Ambientes Internos Utilizando LiDAR e RNA

Egidio Raimundo Neto, Arismar Cerqueira Sodré Junior
 egidio.neto@inatel.br, arismar@inatel.br

Este capítulo tem como objetivo reportar um Sistema de Sensoriamento e Posicionamento de Pedestres em Ambientes Internos utilizando LiDAR e RNA desenvolvido por pesquisadores do Projeto Brasil 6G.

4.1 Aplicações e Arquitetura do Sistema

O presente projeto visa abordar os desafios associados ao posicionamento e detecção em ambientes internos. Ao desenvolver um sistema robusto que integra os dados coletados de sensores LiDAR, este trabalho tem como objetivo aumentar a precisão e confiabilidade do posicionamento e sensoriamento em ambientes internos. A Figura 3 (a) apresenta um cenário de ambiente público interno onde as posições de pessoas e objetos obtidas do sistema de sensores LiDAR são usadas pela estação base 6G para realizar o controle de RIS e de arranjo de antenas. No mesmo contexto, a Figura 3 (b) apresenta um cenário interno de uma indústria. Em ambos os casos, o objetivo é melhorar o desempenho do sistema de comunicação, bem como disponibilizar as informações de posicionamento e localização para outras aplicações verticais.

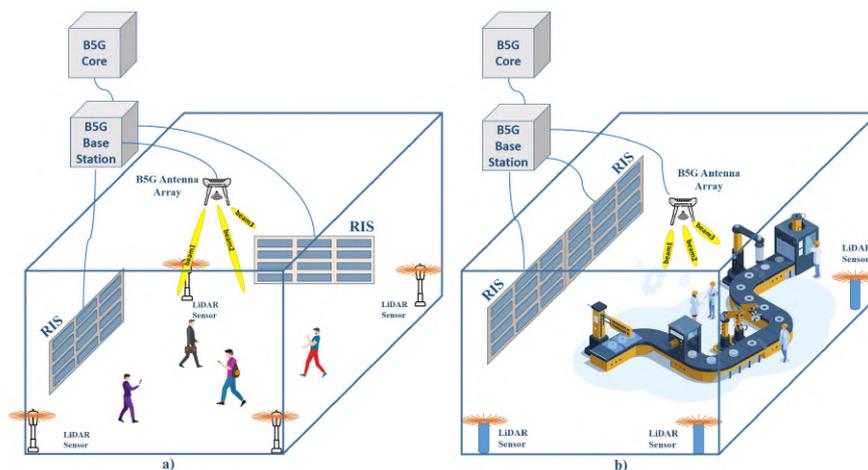


Figura 3: (a) Aplicação em ambientes públicos internos. (b) Aplicações Industriais em ambientes internos.

A arquitetura do sistema proposto de detecção e posicionamento é apresentada na Figura 4. Sensores LiDAR são estrategicamente implantados pelo ambiente alvo para a detecção de pedestres. Os dados coletados desses sensores LiDAR são transmitidos em tempo real para uma estação base 6G através de uma rede de acesso sem fio. Posteriormente, esses dados são enviados para o núcleo 6G, onde são utilizados para determinar a localização dos pedestres dentro do ambiente. Inicialmente, os dados brutos do sensor passam por um processo de transformação, no qual coordenadas polares são convertidas em coordenadas cartesianas dentro de uma área de interesse pré-definida. Após esta fase de pré-processamento, uma estratégia de fusão de dados é estabelecida. Esta estratégia determina se os dados de múltiplos sensores devem ser combinados

ou processados como entradas separadas para a RNA . Baseado na configuração de entrada definida para a RNA , as coordenadas cartesianas dos pontos detectados são usadas para determinar a presença de objetos em cada quadrante e esses vetores são usados como entrada da RNA . A saída da RNA é um vetor de mesma dimensão dos vetores de entrada, indicando a presença detectada de pedestres em vários quadrantes da área de interesse pré-definida. Esses dados posicionais dos indivíduos estão então disponíveis para outros componentes do núcleo 6G , para realizar o Controle RIS, Controle de Arranjo de Antenas e Aplicações de Emergência, como por exemplo ações com equipes de resgate durante cenários de desastre.

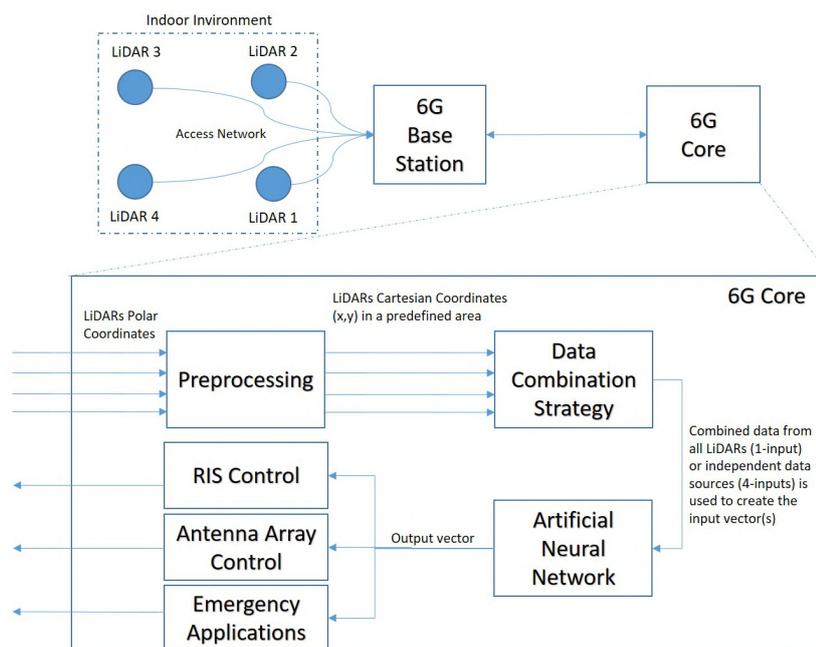


Figura 4: Diagrama em Blocos da Arquitetura do Sistema Proposto.

4.2 Materiais e Métodos

4.2.1 LiDAR 2D

O RPLiDAR S2 é um LiDAR baseado em ToF de alto desempenho e tamanho compacto desenvolvido pela SLAMTEC, e sua típica onda de laser é de 905 nm. Ele possui um alcance angular de 360°, um alcance de medição de 30 metros e uma precisão de medição de $\pm 30\text{mm}$. O dispositivo tem uma alta frequência de amostragem de 32.000 amostras/s e uma velocidade de rotação de 10 rpm. As dimensões do RPLiDAR S2 são 77x77x38,85mm, tornando-o pequeno e compacto, ideal para integração em sistemas robóticos, veículos e também ser fixado em ambientes internos sem causar impacto visual. Utilizando a tecnologia Direct Time of Flight (DToF) da SLAMTEC, o RPLiDAR S2 oferece uma resolução de alcance consistente e a capacidade de detectar vários tipos de materiais, incluindo objetos mais escuros e superfícies reflexivas. Esta tecnologia mantém a precisão mesmo em distâncias maiores. O LiDAR é altamente compatível, suportando modos de comunicação serial e em rede, e compartilha a mesma porta de interface que a série A de RPLiDARs, facilitando a integração fácil em sistemas existentes. Ele atende ao padrão de segurança a laser Classe 1, garantindo que seja seguro para os olhos humanos. O RPLiDAR S2 tem uma ampla gama de aplicações, incluindo navegação e mapeamento de

robôs, detecção de obstáculos para Automated Guided Vehicles (AGVs), monitoramento de estacionamentos, percepção ambiental e movimento autônomo de veículos não tripulados de baixa velocidade, toque multiponto e interação homem-máquina, e detecção de obstáculos em UAVs [175]. A Figura 5 apresenta um dos sensores utilizados no projeto.



Figura 5: Slamtec LiDAR RPLiDAR S2 utilizado na implementação do sistema [ref].

O procedimento de processamento de dados é composto por duas etapas principais: aquisição de dados e análise de dados. A aquisição de dados envolve o sensor LiDAR emitindo pulsos de luz laser para medir distâncias. Neste projeto, os sensores foram posicionados em ambientes internos a uma altura de 1,3 metro acima do chão. O controle do sensor e o registro de dados são realizados por meio de código C++, que utiliza um pipe nomeado como meio de comunicação entre processos. Um código em Python, posteriormente, lê os dados dos pipes nomeados em tempo real para processamento. A análise de dados envolve o processamento e a análise dos dados LiDAR coletados para determinar a posição e a forma do objeto. Medidas de distância e ângulo são convertidas de coordenadas polares para cartesianas e armazenadas em um vetor.

4.2.2 Rede Neural Artificial

A entrada para a rede neural é derivada de dados LiDAR, inicialmente coletados como pares de coordenadas (x, y) . As coordenadas cartesianas dos pontos detectados são usadas para determinar a presença de objetos em cada quadrante e esses vetores são usados como entrada da RNA. Cada elemento do vetor de entrada corresponde a um quadrante específico da grade mapeada, com o valor '1' indicando a presença de pontos detectados naquele quadrante e '0' em caso de pontos não detectados. Os rótulos são as informações fornecidas junto com os dados de entrada, representando a classificação correta para cada conjunto de leituras em termos de sua localização nos quadrantes da grade. Cada elemento do vetor de rótulos corresponde a um quadrante específico dentro de uma grade mapeada, com o valor '1' indicando a presença de um pedestre naquele quadrante e '0' a ausência. Esses rótulos são fundamentais para o treinamento supervisionado, servindo como verdade básica contra a qual a rede ajusta seus pesos e vieses para otimizar as previsões. Da mesma forma, os elementos do vetor de saída da rede correspondem a um quadrante específico dentro de uma grade mapeada, com o valor '1' indicando a presença de leituras de pedestres naquele quadrante e '0' a ausência. A rede é estruturada em várias camadas com funções de ativação específicas, refletindo uma complexidade cuidadosamente equilibrada. A Camada de Entrada é composta por um número de neurônios

igual ao número de quadrantes na grade, 16 ou 64; as outras camadas são descritas da seguinte forma:

1. Primeira Camada Oculta: Esta camada tem 128 neurônios, uma escolha que reflete o equilíbrio entre capacidade computacional e complexidade suficiente para capturar uma ampla gama de padrões nos dados. A função de ativação ReLU é usada aqui por sua eficácia em adicionar não-linearidade ao modelo, permitindo que a rede aprenda padrões complexos e variados nos dados de entrada.

2. Segunda Camada Oculta: Contém 64 neurônios, seguindo a lógica de uma arquitetura "funil", onde a redução progressiva no número de neurônios ajuda a consolidar padrões aprendidos e a reduzir a complexidade do modelo, facilitando a generalização para novos dados. A função ReLU continua a ser usada para manter a não-linearidade.

3. Camada de Saída: Composta por um número de neurônios igual ao número de quadrantes na grade, 16 ou 64, esta camada usa a função de ativação sigmoide. Esta escolha é ideal para classificação binária, transformando as saídas da rede em probabilidades que variam de 0 a 1, interpretadas como a probabilidade da presença da leitura em cada quadrante específico.

Para o processo de treinamento, camadas de dropout foram inseridas após cada camada oculta, com uma taxa de 0.2, ajudando a mitigar o risco de overfitting. Elas funcionam desativando aleatoriamente um conjunto de neurônios durante o treinamento, forçando a rede a aprender padrões mais robustos e generalizáveis. Dividir os dados em 80 por cento para treinamento e 20 por cento para teste equilibra a necessidade de uma amostra substancial para treinamento com uma quantidade adequada para validação e teste. O modelo é compilado com a função de perda de entropia cruzada binária e otimizado com o algoritmo Adam, que é um otimizador eficiente para a maioria dos casos de uso de redes neurais. O desempenho do modelo é avaliado usando métricas de precisão, recall e F1score. Essas métricas fornecem uma visão holística do desempenho da rede, equilibrando a capacidade de identificar corretamente leituras positivas (precisão) e a capacidade de capturar uma alta proporção dos positivos reais (recall) [176]. A Tabela 1 apresenta as especificações das camadas da ANN para o processo de treinamento.

Tabela 1: Especificação das camadas de RNA utilizada para o processo de treinamento.

Camada	Neuônios	Função de Ativação	Funcionalidade	Observações
Entrada	n° de Quadrantes	-	Recebe os vetores binários de entrada e de rótulos	Vetores representam presença/ausência em quadrantes
1a. Camada Escondida	128	ReLU	Captura padrões de dados mais complexos	-
Camada de Dropout	-	-	Evita o overfitting	Taxa de 0.2
2a. Camada Escondida	64	ReLU	Consolidação de padrões aprendidos	-
Camada de Dropout	-	-	Evita o overfitting	Taxa de 0.2
Camada de Saída	n° de Quadrantes	Sigmoid	Produz probabilidades de classificação por quadrante	Vetores representam presença/ausência em quadrantes

5 Testes e Resultados

Egídio Raimundo Neto, Matheus Ferreira Silva
 egidio.neto@inatel.br, matheus.ferreira@get.inatel.br

5.1 Metodologia de Testes

Para a operacionalização do sistema proposto, foi estabelecido um ambiente de teste baseado em laboratório. Esse ambiente envolveu o posicionamento estratégico de quatro sensores LiDAR, cada um localizado em um vértice de uma grade quadrada de 4x4 metros. Apesar da capacidade de alcance de 30 metros de cada sensor, o foco foi restrito a esta grade. A grade foi subdividida em 16 ou 64 quadrantes respectivamente de 1x1 metro e 0,5x0,5 metro, numerados sequencialmente de zero a 15 ou de zero a 63. A Figura 6 ilustra a divisão em 16 quadrantes.

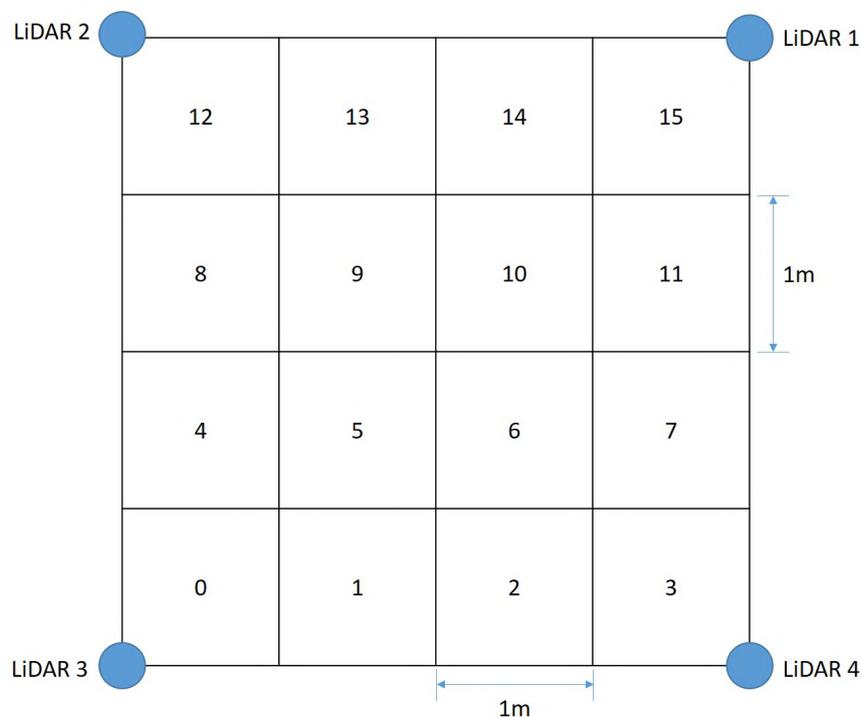


Figura 6: Ambiente de testes e a divisão em 16 quadrantes.

A aquisição de dados dos LiDARs, apresentada em pares de coordenadas, passou por uma fase de pré-processamento. Esta fase garantiu a utilização apenas daquelas amostras que estavam dentro da área pré-definida e converteu cada ponto de interesse para o treinamento da RNA em procedimentos experimentais subsequentes. A Figura 7 ilustra o processo preliminar de aquisição de dados de cada sensor LiDAR antes do pré-processamento para divisão em 16 quadrantes e a Figura 8 apresenta os mesmos dados para divisão em 64 quadrantes.

Após o pré-processamento, o conjunto de dados é refinado para incluir apenas aqueles pontos de dados que estão localizados dentro da área de interesse pré-definida, aumentando assim a eficiência do sistema, como mostrado na Figura 9 e na Figura 10 para as divisões em 16 e 64 quadrantes respectivamente.

Finalmente, a Figura 11 e Figura 12 demonstram o formato de apresentação dos dados LiDAR combinados após o processamento. É crucial destacar que a eficácia do sistema foi

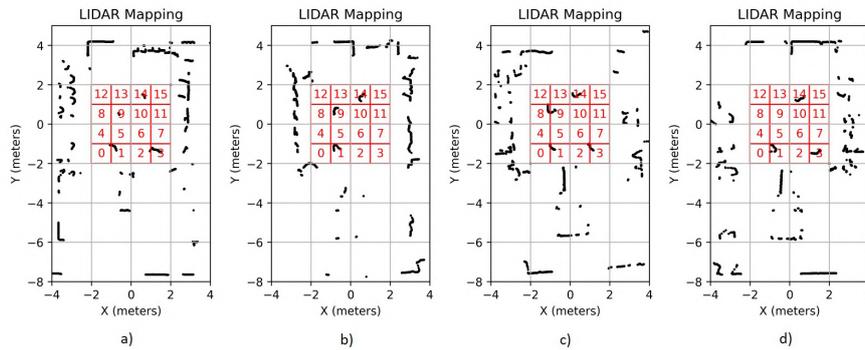


Figura 7: Dados dos sensores LiDAR antes do processamento para divisão em 16 quadrantes. (a) LiDAR 1. (b) LiDAR 2. (c) LiDAR 3. (d) LiDAR 4.

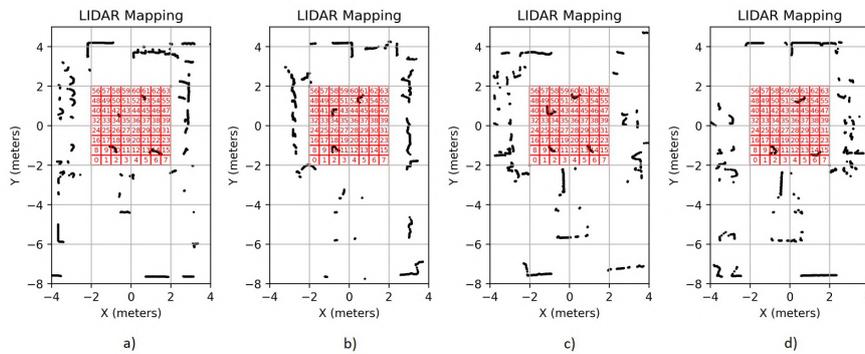


Figura 8: Dados dos sensores LiDAR antes do processamento para divisão em 64 quadrantes. (a) LiDAR 1. (b) LiDAR 2. (c) LiDAR 3. (d) LiDAR 4.

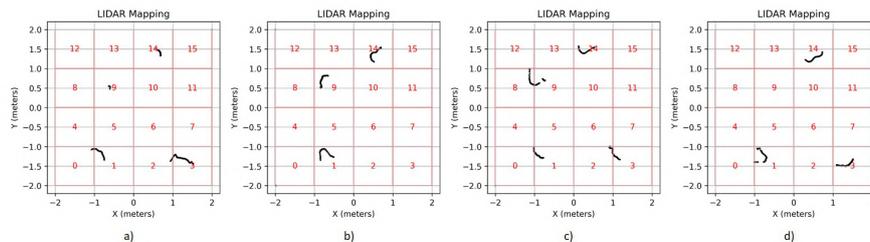


Figura 9: Dados dos sensores LiDAR após o processamento para divisão em 16 quadrantes. (a) LiDAR 1. (b) LiDAR 2. (c) LiDAR 3. (d) LiDAR 4.

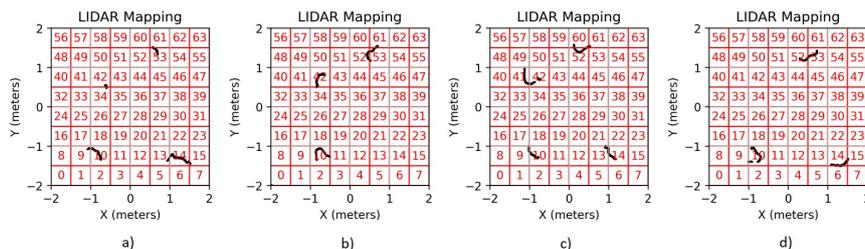


Figura 10: Dados dos sensores LiDAR após o processamento para divisão em 64 quadrantes. (a) LiDAR 1. (b) LiDAR 2. (c) LiDAR 3. (d) LiDAR 4.

sistematicamente avaliada em uma variedade de cenários, empregando dados combinados ou não combinados de 1 a 4 LiDARs e considerando a divisão da área de interesse em 16 ou 64 quadrantes.

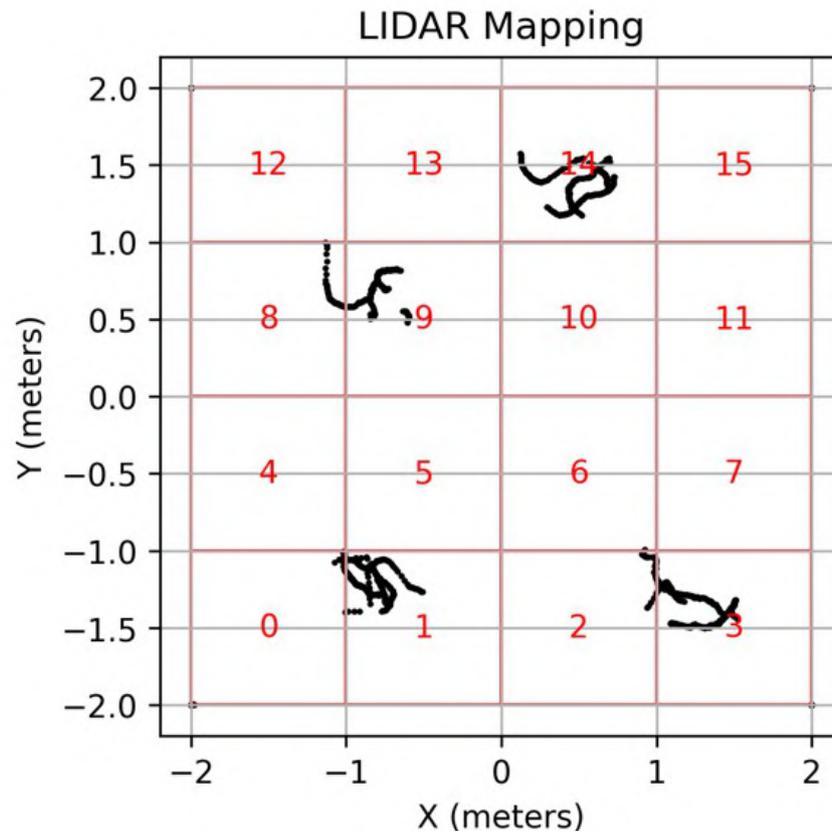


Figura 11: Dados dos sensores LiDAR combinados para o caso de 16 quadrantes.

5.1.1 Ambiente de Testes e Experimentos

Os experimentos e análises de desempenho foram conduzidos em um laboratório de ensino do Inatel, conforme mostrado na Figura 13, incluindo as localizações precisas de cada sensor LiDAR no ambiente. Durante a coleta de dados, 2000 amostras foram coletadas de forma sincronizada de cada sensor LiDAR. Quatro pedestres alteraram aleatoriamente suas posições a cada 20 amostras com o objetivo de emular variadas condições ambientais.

Para facilitar o processo de rotulação, permitindo a criação de vetores que representam o estado de cada quadrante para cada amostra, foi desenvolvida uma interface dedicada. A Figura 14 ilustram exemplos onde os quadrantes 1, 3, 9 e 14 estão marcados, indicando a presença de indivíduos nestes quadrantes. Para o caso de 16 quadrantes.

A Figura 15 ilustram exemplos onde os quadrantes 10, 13, 14, 41, 42, 52 e 53 estão marcados, indicando a presença de indivíduos nestes quadrantes. Para o caso de 64 quadrantes.

Os parâmetros de avaliação do sistema incluem: precisão, indicando a proporção de quadrantes corretamente identificados ocupados por pessoas em relação ao total de identificações positivas, crucial em cenários onde minimizar falsos positivos é importante; recall (sensibilidade), medindo a capacidade do sistema de identificar corretamente todos os quadrantes ocu-

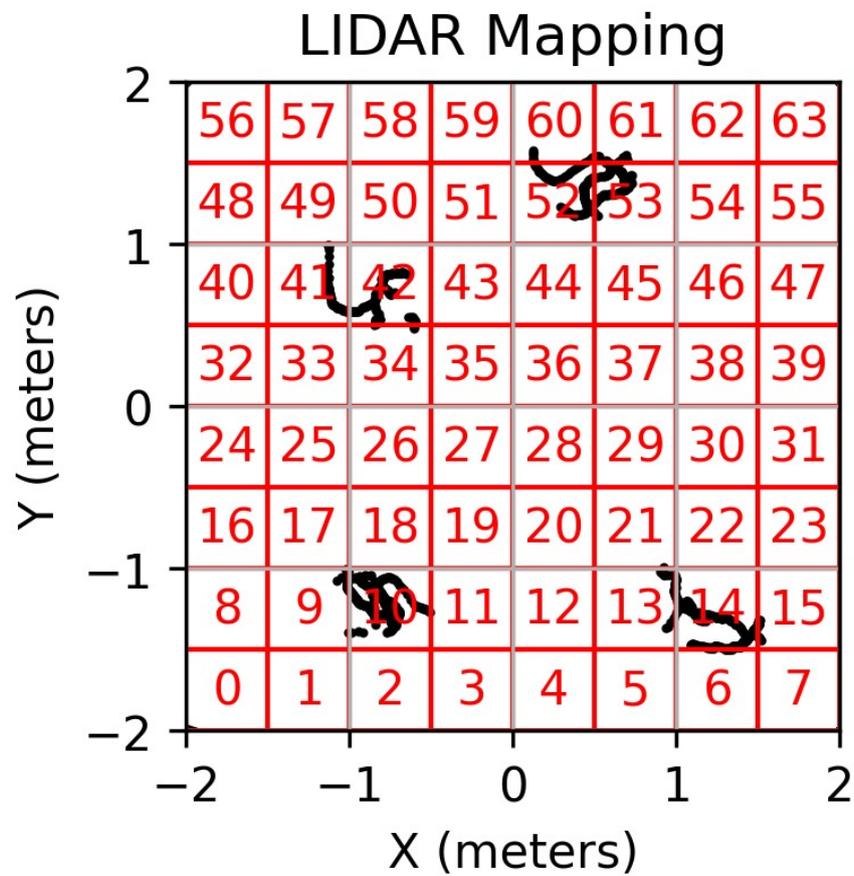


Figura 12: Dados dos sensores LiDAR combinados para o caso de 64 quadrantes.

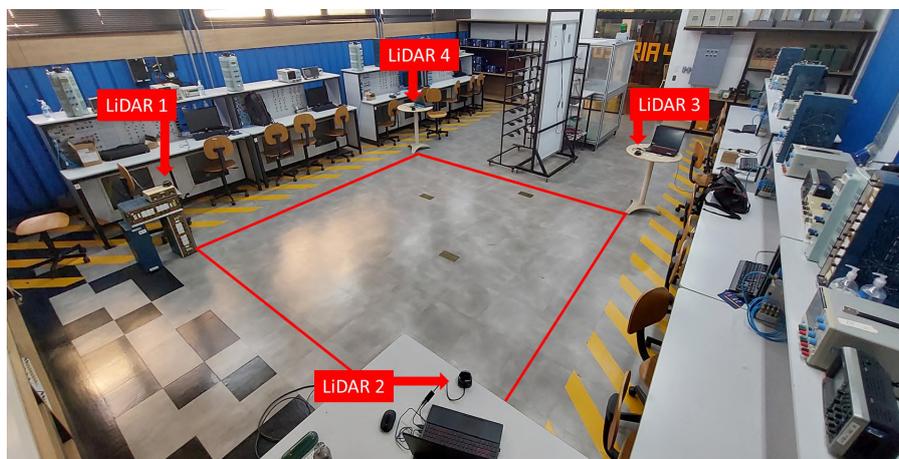


Figura 13: Laboratório didático utilizado para validação e análise de desempenho do sistema de sensoriamento e posicionamento proposto, os sensores LiDAR e suas posições no espaço.

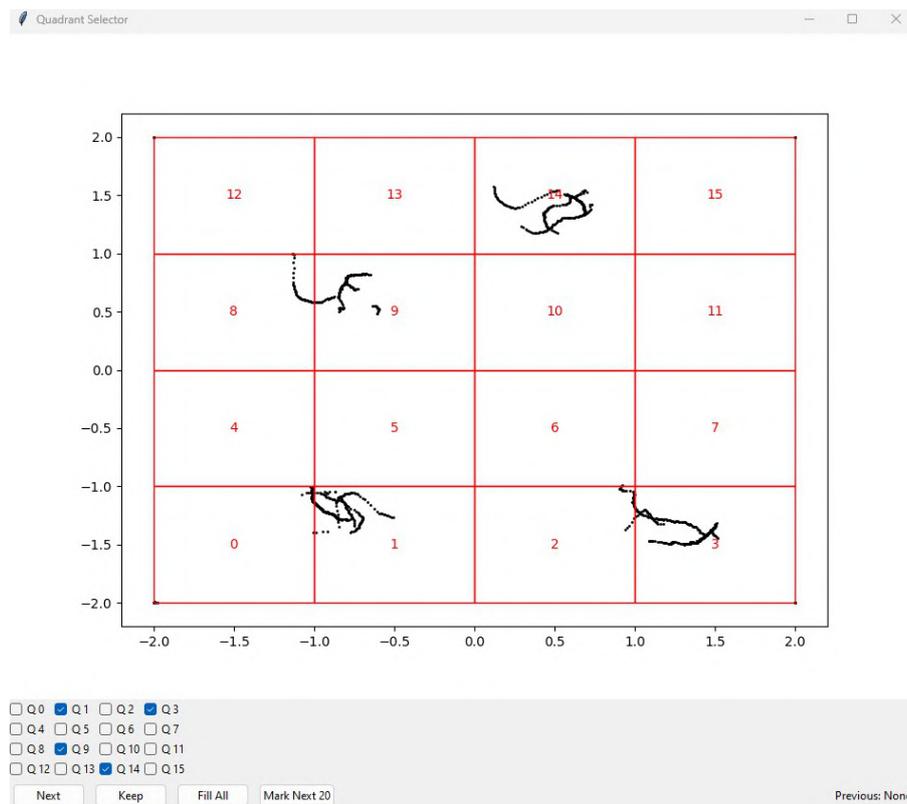


Figura 14: Exemplo da criação dos rótulos por meio de uma interface criada para este processo com 16 quadrantes.

pados, focando na redução de falsos negativos, essencial em situações onde perder qualquer detecção verdadeira é inaceitável; e F1 Score, fornecendo um equilíbrio entre precisão e recall, particularmente valioso em contextos com distribuição desigual de classes.

5.2 Resultados

Esta seção apresenta os resultados obtidos durante os experimentos realizados, serão apresentados resultados obtidos dividindo a área de 16 metros quadrados em 16 e 64 quadrantes e para cada um dos casos serão analisados 2 cenários de teste. O Cenário de Testes 1 considerando uma entrada com dados combinados de diferentes sensores e o Cenário de Teste 2 considerando as entradas dos sensores de forma independente.

5.2.1 Experimentos com 16 quadrantes

No Cenário de Testes 1, o desempenho do sistema foi avaliado usando apenas duas entradas: o vetor de rótulos e o vetor de entrada. Várias condições de teste foram estabelecidas neste cenário. O vetor de entrada foi formulado usando dados exclusivamente do LiDAR 1; dados dos LiDARs 1 e 3; dados dos LiDARs 1, 2 e 3; e, finalmente, dados de todos os quatro LiDARs. A saída do sistema é um vetor indicando quais quadrantes detectaram a presença de pessoas. A Tabela 2 apresenta a avaliação de desempenho do sistema em termos de precisão, recall e F1 Score.

No Cenário de Teste 2, o desempenho do sistema foi avaliado usando múltiplas entradas, onde cada conjunto de dados de coordenadas do LiDAR foi tratado separadamente para criar

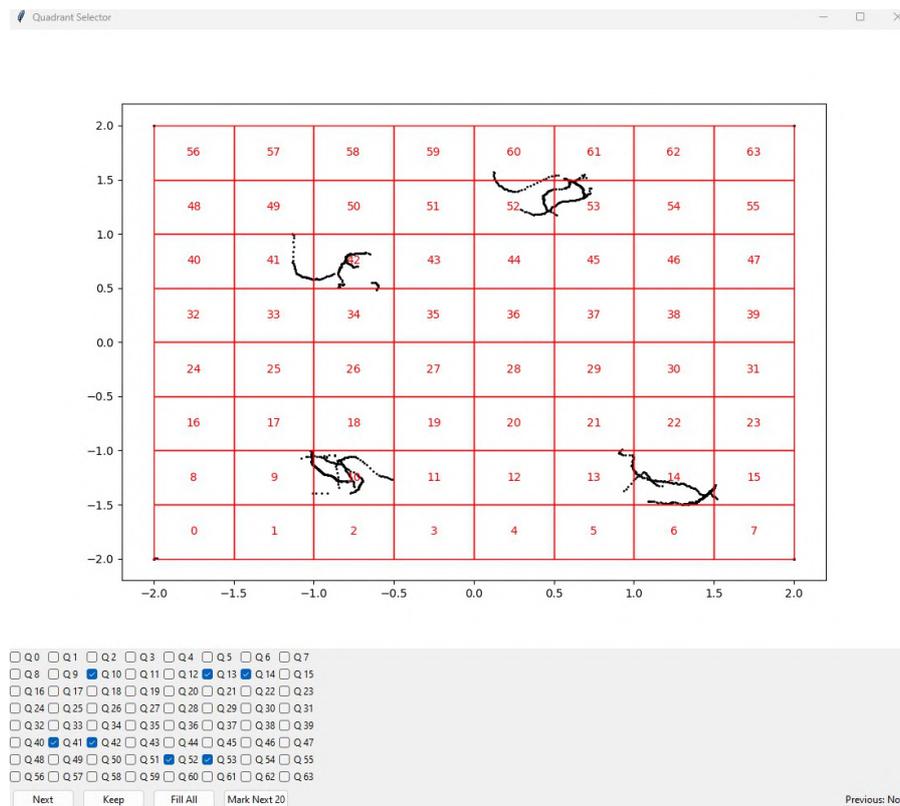


Figura 15: Exemplo da criação dos rótulos por meio de uma interface criada para este processo com 64 quadrantes.

o vetor de entrada, em vez de combiná-los. Isso incluiu o vetor de rótulos como uma entrada e números variados de vetores de entrada: apenas do LiDAR 1 (uma entrada de dados), dos LiDARs 1 e 3 (duas entradas de dados), dos LiDARs 1, 2 e 3 (três entradas de dados) e, finalmente, de todos os quatro LiDARs (quatro entradas de dados). A saída do sistema é um vetor indicando quais quadrantes detectaram a presença de pessoas. A Tabela 3 apresenta a avaliação de desempenho do sistema em termos de precisão, recall e F1 Score.

A avaliação do sistema foi realizada considerando dois cenários de teste. No Cenário 1, usando dados combinados, o sistema exibiu alta precisão, recall e F1 Score; particularmente quando os dados de todos os quatro LiDARs foram combinados. No Cenário 2, tratando cada LiDAR como uma entrada separada, houve uma ligeira diminuição nas métricas de desempenho, mais pronunciada com um número crescente de sensores. A comparação dos cenários sugere que a combinação de dados de múltiplos LiDARs melhora o desempenho, destacando a eficácia da integração de dados na otimização da precisão e eficiência geral do sistema. A análise de precisão na Tabela 4 revela uma clara vantagem da combinação de dados em relação à não combinação. Essa vantagem é notavelmente significativa em configurações com múltiplos LiDARs. As taxas de precisão são mais altas quando todos os quatro LiDARs são combinados, confirmando a eficácia da integração de múltiplas fontes de dados para o aumento da precisão. Por exemplo, a precisão com os LiDARs 1, 2, 3 e 4 combinados é de 99,12%, comparada a 96,21% sem combinação, destacando o impacto da integração de dados na precisão.

As métricas de recall, conforme mostrado na Tabela 5, indicam uma melhoria consistente com a combinação de entradas de dados. A taxa de recall aumenta com o número de LiDARs usados em combinação, demonstrando a capacidade aprimorada do sistema de identificar cor-

Tabela 2: Avaliação do desempenho da RNA utilizando dados combinados, Cenário de Testes 1.

Cenário de Testes 1 (Dados Combinados)	Precisão	Recall	F1 Score
LiDAR 1	99,39%	98,84%	99,06%
LiDARs 1 and 3	98,87%	98,68%	98,72%
LiDARs 1, 2 and 3	99,29%	98,94%	99,06%
LiDARs 1, 2, 3 and 4	99,12%	99,03%	99,05%

Tabela 3: Avaliação do desempenho da RNA utilizando dados não combinados, Cenário de Testes 2.

Cenário de Testes 2 (Entradas Independentes)	Precisão	Recall	F1 Score
LiDAR 1	99,39%	98,84%	99,06%
LiDARs 1 and 3	98,43%	98,04%	98,18%
LiDARs 1, 2 and 3	95,96%	95,25%	95,41%
LiDARs 1, 2, 3 and 4	96,21%	95,45%	95,66%

retamente os quadrantes ocupados quando as fontes de dados são integradas. O recall para os LiDARs 1, 2, 3 e 4 em combinação é de 99,03%, significativamente maior do que 95,45% sem combinação, indicando capacidades de detecção aprimoradas com dados integrados.

As comparações do F1 Score na Tabela 6 destacam o desempenho equilibrado entre precisão e recall em cenários de combinação de dados. Os escores são uniformemente mais altos em configurações com dados combinados, especialmente com a inclusão de mais entradas de LiDAR, destacando a eficiência e precisão globais do sistema em diversas configurações de sensores. Para configurações que usam os todos os LiDARs, o F1 Score atinge 99,05% com combinação, comparado a 95,66% sem combinação, demonstrando um desempenho superior do sistema em cenários de dados combinados.

As avaliações do sistema em dois cenários, conforme detalhado nas tabelas, destacam a eficácia da integração de dados. A Tabela 4 demonstra que a precisão é consistentemente maior com dados combinados, uma tendência mais pronunciada em configurações que utilizam mais LiDARs. A Tabela 5, focada no recall, reflete essa tendência, mostrando taxas de recall aprimoradas com a combinação de dados. Da mesma forma, as comparações do F1 Score na Tabela 6 indicam um desempenho superior em cenários de dados combinados em todas as configurações, destacando a precisão e eficiência aumentadas proporcionadas pela integração de dados de múltiplos LiDARs.

5.2.2 Experimentos com 64 quadrantes

No Cenário de Testes 1, assim como já descrito para a condição de divisão em 16 quadrantes, o desempenho do sistema foi avaliado usando apenas duas entradas: o vetor de rótulos e o vetor de entrada. Várias condições de teste foram estabelecidas neste cenário. O vetor de entrada foi formulado usando dados exclusivamente do LiDAR 1; dados dos LiDARs 1 e 3; dados dos LiDARs 1, 2 e 3; e, finalmente, dados de todos os quatro LiDARs. A saída do sistema é um vetor indicando quais quadrantes detectaram a presença de pessoas. A Tabela 7 apresenta a avaliação de desempenho do sistema em termos de precisão, recall e F1 Score.

Tabela 4: Comparação dos resultados em termos de precisão para os dois cenários de testes.

Entradas de Dados	Dados Combinados	Dados não Combinados
LiDAR 1	99,39%	99,39%
LiDARs 1 and 3	98,87%	98,43%
LiDARs 1, 2 and 3	99,29%	95,96%
LiDARs 1, 2, 3 and 4	99,12%	96,21%

Tabela 5: Comparação dos resultados em termos de recall para os dois cenários de testes.

Entradas de Dados	Dados Combinados	Dados não Combinados
LiDAR 1	98,84%	98,84%
LiDARs 1 and 3	98,68%	98,04%
LiDARs 1, 2 and 3	98,94%	95,25%
LiDARs 1, 2, 3 and 4	99,03%	95,45%

No Cenário de Testes 2, assim como já descrito para a condição de divisão em 16 quadrantes, o desempenho do sistema foi avaliado usando múltiplas entradas, onde cada conjunto de dados de coordenadas do LiDAR foi tratado separadamente para criar o vetor de entrada, ao invés de combiná-los. Isso incluiu o vetor de rótulos como uma entrada e números variados de vetores de entrada: apenas do LiDAR 1 (uma entrada de dados), dos LiDARs 1 e 3 (duas entradas de dados), dos LiDARs 1, 2 e 3 (três entradas de dados) e, finalmente, de todos os quatro LiDARs (quatro entradas de dados). A saída do sistema é um vetor indicando em quais quadrantes foi detectada a presença de pessoas. A Tabela 8 apresenta a avaliação de desempenho do sistema em termos de precisão, recall e F1 Score.

A avaliação do sistema, assim como no caso da divisão em 16 quadrantes, foi realizada considerando dois cenários de teste. No Cenário 1, usando dados combinados, o sistema exibiu alta precisão, recall e F1 Score; particularmente quando os dados de todos os quatro LiDARs foram combinados. No Cenário 2, tratando cada LiDAR como uma entrada separada, houve uma ligeira diminuição nas métricas de desempenho, mais pronunciada com um número crescente de sensores. A comparação dos cenários sugere que a combinação de dados de múltiplos LiDARs melhora o desempenho, destacando a eficácia da integração de dados na otimização da precisão e eficiência geral do sistema. A análise de precisão apresentada na Tabela 9 revela uma clara vantagem da combinação de dados em relação à não combinação. Essa vantagem é notavelmente significativa em configurações com múltiplos LiDARs. As taxas de precisão são mais altas quando todos os quatro LiDARs são combinados, confirmando a eficácia da integração de múltiplas fontes de dados para o aumento da precisão. Por exemplo, a precisão com os LiDARs 1, 2, 3 e 4 combinados é de 99,96%, comparada a 96,678% sem combinação, destacando o impacto da integração de dados na precisão.

As métricas de recall, conforme mostrado na Tabela 10, indicam uma melhoria consistente com a combinação de entradas de dados. A taxa de recall aumenta com o número de LiDARs usados em combinação, demonstrando a capacidade aprimorada do sistema de identificar corretamente os quadrantes ocupados quando as fontes de dados são integradas. O recall para os LiDARs 1, 2, 3 e 4 em combinação é de 99,86%, significativamente maior do que 95,9% sem combinação, indicando capacidades de detecção aprimoradas com dados integrados.

As comparações do F1 Score apresentadas na Tabela 11 destacam o desempenho equilibrado

Tabela 6: Comparação dos resultados em termos de F1 Score para os dois cenários de testes.

Entradas de Dados	Dados Combinados	Dados não Combinados
LiDAR 1	99,06%	99,06%
LiDARs 1 and 3	98,72%	98,18%
LiDARs 1, 2 and 3	99,06%	95,41%
LiDARs 1, 2, 3 and 4	99,05%	95,66%

Tabela 7: Avaliação do desempenho da RNA utilizando dados combinados, Cenário de Testes 1.

Cenário de Testes 1 (Dados Combinados)	Precisão	Recall	F1 Score
LiDAR 1	99,80%	98,74%	99,76%
LiDARs 1 and 3	99,825%	99,608%	99,684%
LiDARs 1, 2 and 3	99,84%	98,93%	99,88%
LiDARs 1, 2, 3 and 4	99,96%	99,86%	99,90%

entre precisão e recall em cenários de combinação de dados. Os escores são uniformemente mais altos em configurações com dados combinados, especialmente com a inclusão de mais entradas de LiDAR, destacando a eficiência e precisão globais do sistema em diversas configurações de sensores. Para configurações que usam todos os sensores LiDAR, o F1 Score atinge 99,90% com combinação, comparado a 96,06% sem combinação, demonstrando um desempenho superior do sistema em cenários de dados combinados.

As avaliações do sistema em dois cenários, conforme detalhado nas tabelas, sublinham a eficácia da integração de dados. A Tabela 9 demonstra que a precisão é consistentemente maior com dados combinados, uma tendência mais pronunciada em configurações que utilizam mais LiDARs. A Tabela 10, focada no recall, reflete essa tendência, mostrando taxas de recall aprimoradas com a combinação de dados. Da mesma forma, as comparações do F1 Score na Tabela 11 indicam um desempenho superior em cenários de dados combinados em todas as configurações, destacando a precisão e eficiência aumentadas proporcionadas pela integração de dados de múltiplos LiDARs.

5.2.3 Análise dos Resultados

O desenvolvimento do sistema contou com o uso de quatro sensores 2D-LiDAR sincronizados, coletando um conjunto de dados de 2000 amostras, divididas em 80% para treinamento e 20% para testes de desempenho. Avaliações experimentais consideraram tanto dados de sensores combinados quanto entradas de dados de sensores independentes para avaliar o desempenho em diferentes cenários, focando em precisão, recall e F1 Score. Os dados combinados de todos os quatro sensores LiDAR como uma única entrada ANN superaram as entradas de dados de sensores individuais. Para o Cenário de Testes 1, considerando a divisão da área de interesse em 16 quadrantes o sistema com dados combinados mostrou 99,12% de precisão, 99,03% de recall e 99,05% de F1 Score, enquanto o sistema com dados não combinados teve um desempenho inferior com 96,21% de precisão, 95,45% de recall e 95,66% de F1 Score. Já para o Cenário de testes 2, considerando a divisão do sistema em 64 quadrantes, o sistema com dados combinados mostrou 99,96% de precisão, 99,86% de recall e 99,90% de F1 Score, enquanto o sistema com

Tabela 8: Avaliação do desempenho da RNA utilizando dados não combinados, Cenário de Testes 2.

Cenário de Testes 2 (Entradas Independentes)	Precisão	Recall	F1 Score
LiDAR 1	99,80%	98,74%	99,76%
LiDARs 1 and 3	99,196%	98,939%	99,004%
LiDARs 1, 2 and 3	95,597%	94,824%	94,986%
LiDARs 1, 2, 3 and 4	96,678%	95,9%	96,06%

Tabela 9: Comparação dos resultados em termos de precisão para os dois cenários de testes.

Entradas de Dados	Dados Combinados	Dados não Combinados
LiDAR 1	99,80%	99,80%
LiDARs 1 and 3	99,825%	99,196%
LiDARs 1, 2 and 3	99,84%	95,597%
LiDARs 1, 2, 3 and 4	99,96%	96,678%

dados não combinados teve um desempenho inferior com 96,21% de precisão, 95,45% de recall e 95,66% de F1 Score. Portanto, a partir das comparações apresentadas neste capítulo, pode-se concluir que a utilização de dados combinados de múltiplos sensores, associada à divisão da área de interesse em 64 quadrantes, apresentou a melhor configuração para o sistema, visto que nesta condição o sistema apresentou resultados expressivos em relação à precisão, recall e F1 Score. Além disso, o uso de múltiplos sensores reduz a possibilidade de que obstruções em algum sensor impactem de forma drástica no desempenho do sistema. E por fim, é possível concluir que o uso de sensores LiDAR 2D e RNAs em conjunto para sensoriamento e posicionamento em ambientes internos apresenta-se como uma potencial solução, sem violar a privacidade das pessoas nos ambientes, livre de interferências eletromagnéticas e com menor custo quando comparado com aplicações que utilizam sensores LiDAR 2D.

Tabela 10: Comparação dos resultados em termos de recall para os dois cenários de testes.

Entradas de Dados	Dados Combinados	Dados não Combinados
LiDAR 1	98,74%	98,74%
LiDARs 1 and 3	99,608%	98,939%
LiDARs 1, 2 and 3	98,93%	94,824%
LiDARs 1, 2, 3 and 4	99,86%	95,9%

Tabela 11: Comparação dos resultados em termos de F1 Score para os dois cenários de testes.

Entradas de Dados	Dados Combinados	Dados não Combinados
LiDAR 1	99,76%	99,76%
LiDARs 1 and 3	99,684%	99,004%
LiDARs 1, 2 and 3	99,88%	94,986%
LiDARs 1, 2, 3 and 4	99,90%	96,06%

6 Conclusão

Egidio Raimundo Neto
 egidio.neto@inatel.br

Este trabalho relatou o desenvolvimento de um Sistema de Detecção e Posicionamento de Pedestres com LiDAR 2D baseado em RNA para aplicações 6G. O sistema proposto visa detectar pedestres e determinar sua localização em ambientes internos. Utilizando os dados de localização desses indivíduos, tais sistemas de comunicação são capazes de gerenciar adequadamente RIS e arranjos de antenas para direcionar o sinal de informação para esses potenciais usuários a fim de aprimorar sua experiência. Além disso, a localização de pedestres em ambientes internos pode beneficiar sistemas de segurança e emergência em edifícios e cidades inteligentes. O Capítulo 1 apresentou a contextualização em torno do tema de pesquisa proposto relacionando a evolução dos sistemas de comunicação móvel; a necessidade de determinar a posição e localização de pessoas em ambientes internos e a importância dos sensores LiDAR neste cenário; bem como a importância da IA neste contexto. Os objetivos da pesquisa foram apresentados. Também foi apresentada uma revisão da literatura de trabalhos relacionados às áreas destacadas acima. E, por fim foram destacadas as contribuições da pesquisa e a estrutura da Tese. O Capítulo 2 destacou a fundamentação teórica do trabalho e de forma objetiva destacou os sistemas 6G; os sistemas de posicionamento legados, bem como a divisão entre técnicas de estimação de distância, técnicas de estimação de localização e as tecnologias de acesso utilizadas em sistemas baseados em RF; a técnica LiDAR seus fundamentos e princípio de funcionamento; e por fim, foi abordado o tema de IA e a utilização de DL por meio de RNAs. No Capítulo 3 foram apresentados potenciais cenários de aplicação e arquitetura do sistema; e os materiais e métodos utilizados no trabalho destacando o sensor LiDAR 2D utilizado e a estrutura da RNA utilizada para implementação do sistema. Na sequência, no Capítulo 4 a análise de desempenho do sistema proposto é apresentada, destacando o setup de experimentos; os cenários de teste baseados no número de quadrantes em que a área foi dividida e como os dados de entrada foram combinados; e por fim, a análise dos resultados obtidos. Os resultados obtidos sugerem que o uso de dados combinados de múltiplos sensores proporciona um desempenho superior em comparação com sistemas não combinados. Como consequência, uma rede de sensores LiDAR conectada a uma rede 6G permite enviar dados de coordenadas para o sistema de detecção e posicionamento da rede central, via uma rede de acesso. O pré-processamento, filtragem e combinação desses dados no núcleo antes de alimentá-los na RNA são cruciais. A partir das comparações apresentadas no Capítulo 4, discutidos pode-se concluir que a utilização de dados combinados de múltiplos sensores, associada à divisão da área de interesse em 64 quadrantes, apresentou a melhor configuração para o sistema, visto que nesta condição o sistema apresentou resultados expressivos em relação à precisão, recall e F1 Score. Além disso, o uso de múltiplos sensores reduz a possibilidade de que obstruções em algum sensor impactem de forma drástica no desempenho do sistema. E por fim, é possível concluir que o uso de sensores LiDAR 2D e RNAs em conjunto para sensoriamento e posicionamento em ambientes internos apresenta-se como uma potencial solução, sem violar a privacidade das pessoas nos ambientes, livre de interferências eletromagnéticas e com menor custo quando comparado com aplicações que utilizam sensores LiDAR 2D. Trabalhos futuros dependem da melhoria das metodologias de teste e análise de desempenho do sistema, como o uso de dados de ambientes maiores, ambientes com obstáculos e obstruções aleatórias, diferentes estruturas de RNA, bem como sensores 3D-LiDAR.

Referências

- [1] J. De Vriendt, P. Laine, C. Lerouge, e X. Xu, “Mobile network evolution: a revolution on the move,” *IEEE Communications Magazine*, v. 40, n. 4, p. 104–111, 2002.
- [2] E. Dahlman, B. Gudmundson, M. Nilsson, e A. Skold, “Umts/imt-2000 based on wideband cdma,” *IEEE Communications Magazine*, v. 36, n. 9, p. 70–80, 1998.
- [3] D. Astely, E. Dahlman, A. Furuskär, Y. Jading, M. Lindström, e S. Parkvall, “Lte: the evolution of mobile broadband,” *IEEE Communications Magazine*, v. 47, n. 4, p. 44–51, 2009.
- [4] P. Popovski, K. F. Trillingsgaard, O. Simeone, e G. Durisi, “5g wireless network slicing for embb, urllc, and mmhc: A communication-theoretic view,” *IEEE Access*, v. 6, p. 55 765–55 779, 2018.
- [5] Desconhecido, *Software Defined Mobile Networks (SDMN): Beyond LTE Network Architecture*. Hoboken, NJ, USA: Wiley, 2015.
- [6] S. Wijethilaka e M. Liyanage, “Realizing internet of things with network slicing: Opportunities and challenges,” in *2021 IEEE 18th Annual Consumer Communications Networking Conference (CCNC)*, 2021, p. 1–6.
- [7] Y. Siriwardhana, C. De Alwis, G. Gür, M. Ylianttila, e M. Liyanage, “The fight against the covid-19 pandemic with 5g technologies,” *IEEE Engineering Management Review*, v. 48, n. 3, p. 72–84, 2020.
- [8] J. G. Andrews, S. Buzzi, W. Choi, S. V. Hanly, A. Lozano, A. C. K. Soong, e J. C. Zhang, “What will 5g be?” *IEEE Journal on Selected Areas in Communications*, v. 32, n. 6, p. 1065–1082, 2014.
- [9] F. H. P. Fitzek e P. Seeling, “Why we should not talk about 6g,” Mar. 2020, [Online]. Available: arXiv:2003.02079.
- [10] “A blueprint of technology, applications and market drivers towards the year 2030 and beyond,” ITU Geneva, Switzerland, document ITU-T FG-NET-2030, May 2019.
- [11] ITU-R Working Party 5D, “Future technology trends for the evolution of imt towards 2030 and beyond,” Liaison Statement, ITU-R Working Party 5D, ITU, Geneva, Switzerland, Tech. Rep., Oct. 2020, available: ITU website.
- [12] W. Saad, M. Bennis, e M. Chen, “A vision of 6g wireless systems: Applications, trends, technologies, and open research problems,” *IEEE Network*, v. 34, n. 3, p. 134–142, 2020.
- [13] F. Fang, Y. Xu, Q.-V. Pham, e Z. Ding, “Energy-efficient design of irs-noma networks,” *IEEE Transactions on Vehicular Technology*, v. 69, n. 11, p. 14 088–14 092, 2020.
- [14] Y. Lu e X. Zheng, “6g: A survey on technologies, scenarios, challenges, and the related issues,” *Journal of Industrial Information Integration*, v. 19, p. 100158, 2020. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2452414X20300339>

- [15] Y. Liu, X. Yuan, Z. Xiong, J. Kang, X. Wang, e D. Niyato, “Federated learning for 6g communications: Challenges, methods, and future directions,” *China Communications*, v. 17, n. 9, p. 105–118, 2020.
- [16] G. Wang, H. Chen, Y. Li, e M. Jin, “On received-signal-strength based localization with unknown transmit power and path loss exponent,” *IEEE Wireless Communications Letters*, v. 1, n. 5, p. 536–539, 2012.
- [17] J. Xiong e K. Jamieson, “Arraytrack: a fine-grained indoor location system,” in *Proceedings of the 10th USENIX Conference on Networked Systems Design and Implementation*, ser. nsdi’13. USA: USENIX Association, 2013, p. 71–84.
- [18] R. Zhang, F. Höflinger, e L. Reindl, “Tdoa-based localization using interacting multiple model estimator and ultrasonic transmitter/receiver,” *IEEE Transactions on Instrumentation and Measurement*, v. 62, n. 8, p. 2205–2214, 2013.
- [19] Y. Zheng, M. Sheng, J. Liu, e J. Li, “Exploiting aoa estimation accuracy for indoor localization: A weighted aoa-based approach,” *IEEE Wireless Communications Letters*, v. 8, n. 1, p. 65–68, 2019.
- [20] Z. Yang, Z. Zhou, e Y. Liu, “From rssi to csi: Indoor localization via channel response,” *ACM Comput. Surv.*, v. 46, n. 2, dec 2013. [Online]. Disponível em: <https://doi.org/10.1145/2543581.2543592>
- [21] Q. Li, W. Li, W. Sun, J. Li, e Z. Liu, “Fingerprint and assistant nodes based wi-fi localization in complex indoor environment,” *IEEE Access*, v. 4, p. 2993–3004, 2016.
- [22] R. C. Luo e T.-J. Hsiao, “Indoor localization system based on hybrid wi-fi/ble and hierarchical topological fingerprinting approach,” *IEEE Transactions on Vehicular Technology*, v. 68, n. 11, p. 10 791–10 806, 2019.
- [23] A. Costanzo, D. Dardari, J. Aleksandravicius, N. Decarli, M. Del Prete, D. Fabbri, M. Fantuzzi, A. Guerra, D. Masotti, M. Pizzotti, e A. Romani, “Energy autonomous uwb localization,” *IEEE Journal of Radio Frequency Identification*, v. 1, n. 3, p. 228–244, 2017.
- [24] M. Liu, H. Wang, Y. Yang, Y. Zhang, L. Ma, e N. Wang, “Rfid 3-d indoor localization for tag and tag-free target based on interference,” *IEEE Transactions on Instrumentation and Measurement*, v. 68, n. 10, p. 3718–3732, 2019.
- [25] F. Zafari, A. Gkelias, e K. K. Leung, “A survey of indoor localization systems and technologies,” *IEEE Communications Surveys Tutorials*, v. 21, n. 3, p. 2568–2599, 2019.
- [26] M. T. Hoang, B. Yuen, X. Dong, T. Lu, R. Westendorp, e K. Reddy, “Recurrent neural networks for accurate rssi indoor localization,” *IEEE Internet of Things Journal*, v. 6, n. 6, p. 10 639–10 651, 2019.
- [27] C. Jiang, J. Shen, S. Chen, Y. Chen, D. Liu, e Y. Bo, “Uwb nlos/los classification using deep learning method,” *IEEE Communications Letters*, v. 24, n. 10, p. 2226–2230, 2020.

- [28] J. Schroeder, S. Galler, K. Kyamakya, e K. Jobmann, “Nlos detection algorithms for ultra-wideband localization,” in *2007 4th Workshop on Positioning, Navigation and Communication*, 2007, p. 159–166.
- [29] M. Zhou, Y. Tang, Z. Tian, L. Xie, e W. Nie, “Robust neighborhood graphing for semi-supervised indoor localization with light-loaded location fingerprinting,” *IEEE Internet of Things Journal*, v. 5, n. 5, p. 3378–3387, 2018.
- [30] M. Pierzchała, P. Giguère, e R. Astrup, “Mapping forests using an unmanned ground vehicle with 3d lidar and graph-slam,” *Computers and Electronics in Agriculture*, v. 145, p. 217–225, 2018. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169917301631>
- [31] Q. Zhu, L. Chen, Q. Li, M. Li, A. Nüchter, e J. Wang, “3d lidar point cloud based intersection recognition for autonomous driving,” in *2012 IEEE Intelligent Vehicles Symposium*, 2012, p. 456–461.
- [32] B. R. VanVoorst, M. Hackett, C. Strayhorn, J. Norfleet, E. Honold, N. Walczak, e J. Schewe, “Fusion of lidar and video cameras to augment medical training and assessment,” in *2015 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI)*, 2015, p. 345–350.
- [33] P. Torres, H. Marques, e P. Marques, “Pedestrian detection with lidar technology in smart-city deployments—challenges and recommendations,” *Computers*, v. 12, n. 3, 2023. [Online]. Disponível em: <https://www.mdpi.com/2073-431X/12/3/65>
- [34] Z. Wang e M. Menenti, “Challenges and opportunities in lidar remote sensing,” *Front. Earth Sci.*, v. 9, p. 713129, 2021.
- [35] M. Ibrahim, N. Akhtar, M. A. A. K. Jalwana, M. Wise, e A. Mian, “High definition lidar mapping of perth cbd,” in *2021 Digital Image Computing: Techniques and Applications (DICTA)*, 2021, p. 01–08.
- [36] L. Lou, Y. Li, Q. Zhang, e H. Wei, “Slam and 3d semantic reconstruction based on the fusion of lidar and monocular vision,” *Sensors*, v. 23, n. 3, 2023. [Online]. Disponível em: <https://www.mdpi.com/1424-8220/23/3/1502>
- [37] Q. Zou, Q. Sun, L. Chen, B. Nie, e Q. Li, “A comparative analysis of lidar slam-based indoor navigation for autonomous vehicles,” *IEEE Transactions on Intelligent Transportation Systems*, v. 23, n. 7, p. 6907–6921, 2022.
- [38] A. Azim e O. Aycard, “Detection, classification and tracking of moving objects in a 3d environment,” in *2012 IEEE Intelligent Vehicles Symposium*, 2012, p. 802–807.
- [39] B. Ravi Kiran, L. Roldao, B. Irastorza, R. Verastegui, S. Suss, S. Yogamani, V. Talpaert, A. Lepoutre, e G. Trehard, “Real-time dynamic object detection for autonomous driving using prior 3d-maps,” in *Proceedings of the European Conference on Computer Vision (ECCV) Workshops*, Munich, Germany, Sep. 2018.
- [40] T.-D. Vu e O. Aycard, “Laser-based detection and tracking moving objects using data-driven markov chain monte carlo,” in *2009 IEEE International Conference on Robotics and Automation*, 2009, p. 3800–3806.

- [41] A. Klautau, N. González-Prelcic, e R. W. Heath, “Lidar data for deep learning-based mmwave beam-selection,” *IEEE Wireless Communications Letters*, v. 8, n. 3, p. 909–912, 2019.
- [42] M. Dias, A. Klautau, N. González-Prelcic, e 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)*, 2019, p. 1–5.
- [43] J. Tan e L. Dai, “Thz precoding for 6g: Applications, challenges, solutions, and opportunities,” 2020.
- [44] G. R. MacCartney, T. S. Rappaport, e S. Rangan, “Rapid fading due to human blockage in pedestrian crowds at 5g millimeter-wave frequencies,” in *2017 IEEE Global Communications Conference (GLOBECOM)*. Singapore: IEEE, Dec. 2017, p. 1–7.
- [45] M. Giordani, M. Mezzavilla, S. Rangan, e M. Zorzi, “Multi-connectivity in 5g mmwave cellular networks,” in *2016 Mediterranean Ad Hoc Networking Workshop (Med-Hoc-Net)*, 2016, p. 1–7.
- [46] M. Polese, M. Giordani, M. Mezzavilla, S. Rangan, e M. Zorzi, “Improved handover through dual connectivity in 5g mmwave mobile networks,” *IEEE Journal on Selected Areas in Communications*, v. 35, n. 9, p. 2069–2084, 2017.
- [47] V. Petrov, D. Solomitckii, A. Samuylov, M. A. Lema, M. Gapeyenko, D. Moltchanov, S. Andreev, V. Naumov, K. Samouylov, M. Dohler, e Y. Koucheryavy, “Dynamic multi-connectivity performance in ultra-dense urban mmwave deployments,” *IEEE Journal on Selected Areas in Communications*, v. 35, n. 9, p. 2038–2055, 2017.
- [48] D. Aziz, J. Gebert, A. Ambrosy, H. Bakker, e H. Halbauer, “Architecture approaches for 5g millimetre wave access assisted by 5g low-band using multi-connectivity,” in *2016 IEEE Globecom Workshops (GC Wkshps)*, 2016, p. 1–6.
- [49] A. Alkhateeb, I. Beltagy, e S. Alex, “Machine learning for reliable mmwave systems: Blockage prediction and proactive handoff,” in *2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, 2018, p. 1055–1059.
- [50] S. Wu, M. Alrabeiah, C. Chakrabarti, e A. Alkhateeb, “Blockage prediction using wireless signatures: Deep learning enables real-world demonstration,” *IEEE Open Journal of the Communications Society*, v. 3, p. 776–796, 2022.
- [51] M. Alrabeiah e A. Alkhateeb, “Deep learning for mmwave beam and blockage prediction using sub-6 ghz channels,” *IEEE Transactions on Communications*, v. 68, n. 9, p. 5504–5518, 2020.
- [52] Z. Ali, A. Duel-Hallen, e H. Hallen, “Early warning of mmwave signal blockage and aoa transition using sub-6 ghz observations,” *IEEE Communications Letters*, v. 24, n. 1, p. 207–211, 2020.
- [53] G. Charan, M. Alrabeiah, e A. Alkhateeb, “Vision-aided 6g wireless communications: Blockage prediction and proactive handoff,” *IEEE Transactions on Vehicular Technology*, v. 70, n. 10, p. 10 193–10 208, 2021.

- [54] U. Demirhan e A. Alkhateeb, “Integrated sensing and communication for 6g: Ten key machine learning roles,” 2022.
- [55] S. Wu, C. Chakrabarti, e A. Alkhateeb, “Lidar-aided mobile blockage prediction in real-world millimeter wave systems,” in *2022 IEEE Wireless Communications and Networking Conference (WCNC)*, 2022, p. 2631–2636.
- [56] M. Zecchin, M. B. Mashhadi, M. Jankowski, D. Gündüz, M. Kountouris, e D. Gesbert, “Lidar and position-aided mmwave beam selection with non-local cnns and curriculum training,” *IEEE Transactions on Vehicular Technology*, v. 71, n. 3, p. 2979–2990, 2022.
- [57] S. Jiang, G. Charan, e A. Alkhateeb, “Lidar aided future beam prediction in real-world millimeter wave v2i communications,” *IEEE Wireless Communications Letters*, v. 12, n. 2, p. 212–216, 2023.
- [58] S. Moon, H. Kim, e I. Hwang, “Deep learning-based channel estimation and tracking for millimeter-wave vehicular communications,” *Journal of Communications and Networks*, v. 22, n. 3, p. 177–184, 2020.
- [59] X. Wei, C. Hu, e L. Dai, “Deep learning for beamspace channel estimation in millimeter-wave massive mimo systems,” *IEEE Transactions on Communications*, v. 69, n. 1, p. 182–193, 2021.
- [60] H. Huang, J. Yang, H. Huang, Y. Song, e G. Gui, “Deep learning for super-resolution channel estimation and doa estimation based massive mimo system,” *IEEE Transactions on Vehicular Technology*, v. 67, n. 9, p. 8549–8560, 2018.
- [61] M. Alrabeiah, A. Hredzak, e A. Alkhateeb, “Millimeter wave base stations with cameras: Vision-aided beam and blockage prediction,” in *2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*, 2020, p. 1–5.
- [62] J.-S. Choi, W.-H. Lee, J.-H. Lee, J.-H. Lee, e S.-C. Kim, “Deep learning based nlos identification with commodity wlan devices,” *IEEE Transactions on Vehicular Technology*, v. 67, n. 4, p. 3295–3303, 2018.
- [63] C. Huang, A. F. Molisch, R. He, R. Wang, P. Tang, B. Ai, e Z. Zhong, “Machine learning-enabled los/nlos identification for mimo systems in dynamic environments,” *IEEE Transactions on Wireless Communications*, v. 19, n. 6, p. 3643–3657, 2020.
- [64] S. Wu, C. Chakrabarti, e A. Alkhateeb, “Proactively predicting dynamic 6g link blockages using lidar and in-band signatures,” *IEEE Open Journal of the Communications Society*, v. 4, p. 392–412, 2023.
- [65] T. Shan, B. Englot, D. Meyers, W. Wang, C. Ratti, e D. Rus, “Lio-sam: Tightly-coupled lidar inertial odometry via smoothing and mapping,” in *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2020, p. 5135–5142.
- [66] H. Casarrubias-Vargas, A. Petrilli-Barceló, e E. Bayro-Corrochano, “EKF-slam and machine learning techniques for visual robot navigation,” in *2010 20th International Conference on Pattern Recognition*, 2010, p. 396–399.

- [67] A. E. Al-Tarras, M. I. Yacoub, M. S. Asfoor, e A. M. Sharaf, “Experimental evaluation of computation cost of fastslam algorithm for unmanned ground vehicles,” in *2019 7th International Conference on Control, Mechatronics and Automation (ICCMA)*, 2019, p. 78–83.
- [68] J. Ren, “An improved binocular lsd slam method for object localization,” in *2020 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA)*. Dalian, China: IEEE, Jun. 2020, p. 30–33.
- [69] R. Mur-Artal, J. M. M. Montiel, e J. D. Tardós, “Orb-slam: A versatile and accurate monocular slam system,” *IEEE Transactions on Robotics*, v. 31, n. 5, p. 1147–1163, 2015.
- [70] W. Yuan, Z. Li, e C.-Y. Su, “Rgb-d sensor-based visual slam for localization and navigation of indoor mobile robot,” in *2016 International Conference on Advanced Robotics and Mechatronics (ICARM)*, 2016, p. 82–87.
- [71] G. Grisetti, R. Kümmerle, C. Stachniss, e W. Burgard, “A tutorial on graph-based slam,” *IEEE Intelligent Transportation Systems Magazine*, v. 2, n. 4, p. 31–43, 2010.
- [72] H. Lategahn, A. Geiger, e B. Kitt, “Visual slam for autonomous ground vehicles,” in *2011 IEEE International Conference on Robotics and Automation*, 2011, p. 1732–1737.
- [73] M. U. Khan, S. A. A. Zaidi, A. Ishtiaq, S. U. R. Bukhari, S. Samer, e A. Farman, “A comparative survey of lidar-slam and lidar based sensor technologies,” in *2021 Mohammad Ali Jinnah University International Conference on Computing (MAJICC)*, 2021, p. 1–8.
- [74] P. T. Karfakis, M. S. Couceiro, e D. Portugal, “Nr5g-sam: A slam framework for field robot applications based on 5g new radio,” *Sensors*, v. 23, n. 11, 2023. [Online]. Disponível em: <https://www.mdpi.com/1424-8220/23/11/5354>
- [75] L. Thrybom, J. Neander, E. Hansen, e K. Landernas, “Future challenges of positioning in underground mines,” *IFAC-PapersOnLine*, v. 48, n. 10, p. 222–226, 2015, 2nd IFAC Conference on Embedded Systems, Computer Intelligence and Telematics CESCIT 2015. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2405896315010022>
- [76] J. Marshall, A. Bonchis, E. Nebot, e S. Scheduling, *Robotics in Mining*. Cham, Switzerland: Springer, 2016.
- [77] J. Paraszczak, A. Gustafson, e H. Schunnesson, “Technical and operational aspects of autonomous lhd application in metal mines,” *Int. J. Mining Reclamation Environ.*, v. 29, n. 5, p. 391–403, 2015.
- [78] J. Marshall, T. Barfoot, e J. Larsson, “Autonomous underground tramming for center-articulated vehicles,” *J. Field Robot.*, v. 25, n. 6, p. 400–421, 2008.
- [79] H. Mäkelä, “Overview of lhd navigation without artificial beacons,” *Robotics and Autonomous Systems*, v. 36, n. 1, p. 21–35, 2001. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0921889001001154>

- [80] K. Nielsen e G. Hendebly, “Sensor management in 2d lidar-based underground positioning,” in *2020 IEEE 23rd International Conference on Information Fusion (FUSION)*, 2020, p. 1–6.
- [81] S. Rusinkiewicz e M. Levoy, “Efficient variants of the icp algorithm,” in *Proceedings Third International Conference on 3-D Digital Imaging and Modeling*, 2001, p. 145–152.
- [82] S. Krig, *Computer Vision Metrics: Survey Taxonomy and Analysis*. Berkeley, CA, USA: Apress, 2014.
- [83] G. D. Tipaldi e K. O. Arras, “Flirt - interest regions for 2d range data,” in *2010 IEEE International Conference on Robotics and Automation*, 2010, p. 3616–3622.
- [84] F. Kallasi, D. L. Rizzini, e S. Caselli, “Fast keypoint features from laser scanner for robot localization and mapping,” *IEEE Robotics and Automation Letters*, v. 1, n. 1, p. 176–183, 2016.
- [85] M. Usman, A. M. Khan, A. Ali, S. Yaqub, K. M. Zuhaib, J. Y. Lee, e C.-S. Han, “An extensive approach to features detection and description for 2-d range data using active b-splines,” *IEEE Robotics and Automation Letters*, v. 4, n. 3, p. 2934–2941, 2019.
- [86] M. S. Nixon, T. Tan, e R. Chellappa, *Human Identification Based on Gait*, ser. Inserir nome da série aqui, se disponível. Springer, 2010, v. 4.
- [87] N. Khamsemanan, C. Nattee, e N. Jianwattanapaisarn, “Human identification from freestyle walks using posture-based gait feature,” *IEEE Transactions on Information Forensics and Security*, v. 13, n. 1, p. 119–128, 2018.
- [88] A. H. Snijders, B. P. van de Warrenburg, N. Giladi, e B. R. Bloem, “Neurological gait disorders in elderly people: Clinical approach and classification,” *Lancet Neurol.*, v. 6, n. 1, p. 63–74, Jan. 2007.
- [89] C. Bayón, O. Ramírez, J. Serrano, M. D. Castillo, A. Pérez-Somarrriba, J. Belda-Lois, I. Martínez-Caballero, S. Lerma-Lara, C. Cifuentes, A. Frizera, e E. Rocon, “Development and evaluation of a novel robotic platform for gait rehabilitation in patients with cerebral palsy: Cpwalker,” *Robotics and Autonomous Systems*, v. 91, p. 101–114, 2017. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0921889016301816>
- [90] A. Yorozu e M. Takahashi, “Estimation of body direction based on gait for service robot applications,” *Robotics and Autonomous Systems*, v. 132, p. 103603, 2020. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0921889020304437>
- [91] A. Mapelli, M. Zago, L. Fusini, D. Galante, A. Colombo, e C. Sforza, “Validation of a protocol for the estimation of three-dimensional body center of mass kinematics in sport,” *Gait Posture*, v. 39, n. 1, p. 460–465, 2014. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0966636213005833>
- [92] Bebek, M. A. Suster, S. Rajgopal, M. J. Fu, X. Huang, M. C. Çavuşoğlu, D. J. Young, M. Mehregany, A. J. van den Bogert, e C. H. Mastrangelo, “Personal navigation via high-resolution gait-corrected inertial measurement units,” *IEEE Transactions on Instrumentation and Measurement*, v. 59, n. 11, p. 3018–3027, 2010.

- [93] P. Merriaux, Y. Dupuis, R. Boutteau, P. Vasseur, e X. Savatier, “A study of vicon system positioning performance,” *Sensors*, v. 17, n. 7, 2017. [Online]. Disponível em: <https://www.mdpi.com/1424-8220/17/7/1591>
- [94] T. Seel, J. Raisch, e T. Schauer, “Imu-based joint angle measurement for gait analysis,” *Sensors*, v. 14, n. 4, p. 6891–6909, 2014. [Online]. Disponível em: <https://www.mdpi.com/1424-8220/14/4/6891>
- [95] R. Caldas, M. Mundt, W. Potthast, F. B. de Lima Neto, e B. Markert, “A systematic review of gait analysis methods based on inertial sensors and adaptive algorithms,” *Gait Posture*, v. 57, p. 204–210, Sep. 2017.
- [96] P. Chattopadhyay, S. Sural, e J. Mukherjee, “Frontal gait recognition from incomplete sequences using rgb-d camera,” *IEEE Transactions on Information Forensics and Security*, v. 9, n. 11, p. 1843–1856, 2014.
- [97] M. Gabel, R. Gilad-Bachrach, E. Renshaw, e A. Schuster, “Full body gait analysis with kinect,” in *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2012, p. 1964–1967.
- [98] C. Benedek, B. Gálai, B. Nagy, e Z. Jankó, “Lidar-based gait analysis and activity recognition in a 4d surveillance system,” *IEEE Transactions on Circuits and Systems for Video Technology*, v. 28, n. 1, p. 101–113, 2018.
- [99] H. B. Menz, M. D. Latt, A. Tiedemann, M. M. S. Kwan, e S. R. Lord, “Reliability of the gaitrite walkway system for the quantification of temporo-spatial parameters of gait in young and older people,” *Gait Posture*, v. 20, n. 1, p. 20–25, 2004.
- [100] H. Gao, B. Cheng, J. Wang, K. Li, J. Zhao, e D. Li, “Object classification using cnn-based fusion of vision and lidar in autonomous vehicle environment,” *IEEE Transactions on Industrial Informatics*, v. 14, n. 9, p. 4224–4231, 2018.
- [101] H. Wang, B. Wang, B. Liu, X. Meng, e G. Yang, “Pedestrian recognition and tracking using 3d lidar for autonomous vehicle,” *Robotics and Autonomous Systems*, v. 88, p. 71–78, 2017. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0921889015302633>
- [102] S. Gatesichapakorn, J. Takamatsu, e M. Ruchanurucks, “Ros based autonomous mobile robot navigation using 2d lidar and rgb-d camera,” in *2019 First International Symposium on Instrumentation, Control, Artificial Intelligence, and Robotics (ICA-SYMP)*, 2019, p. 151–154.
- [103] Y. Xu, Y. S. Shmaliy, Y. Li, X. Chen, e H. Guo, “Indoor ins/lidar-based robot localization with improved robustness using cascaded fir filter,” *IEEE Access*, v. 7, p. 34 189–34 197, 2019.
- [104] S. D. Sierra, J. F. Molina, D. A. Gómez, M. C. Múnera, e C. A. Cifuentes, “Development of an interface for human-robot interaction on a robotic platform for gait assistance: Agora smart walker,” in *2018 IEEE ANDESCON*, 2018, p. 1–7.

- [105] S. Yoon, H.-W. Jung, H. Jung, K. Kim, S.-K. Hong, H. Roh, e B.-M. Oh, “Development and validation of 2d-lidar-based gait analysis instrument and algorithm,” *Sensors*, v. 21, n. 2, 2021. [Online]. Disponível em: <https://www.mdpi.com/1424-8220/21/2/414>
- [106] T. Pallejà, M. Teixidó, M. Tresanchez, e J. Palacín, “Measuring gait using a ground laser range sensor,” *Sensors*, v. 9, n. 11, p. 9133–9146, 2009. [Online]. Disponível em: <https://www.mdpi.com/1424-8220/9/11/9133>
- [107] A. Yorozu, T. Moriguchi, e M. Takahashi, “Improved leg tracking considering gait phase and spline-based interpolation during turning motion in walk tests,” *Sensors*, v. 15, n. 9, p. 22 451–22 472, 2015. [Online]. Disponível em: <https://www.mdpi.com/1424-8220/15/9/22451>
- [108] H. T. Duong e Y. S. Suh, “Human gait estimation using multiple 2d lidars,” *IEEE Access*, v. 9, p. 56 881–56 892, 2021.
- [109] Q. Zhang e R. Pless, “Extrinsic calibration of a camera and laser range finder (improves camera calibration),” in *2004 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) (IEEE Cat. No.04CH37566)*, v. 3, 2004, p. 2301–2306 vol.3.
- [110] H. Yoo, H. J. Moon, S.-H. Kim, e S.-I. Choi, “Multi-target tracking with multiple 2d range scanners,” *IEEE Access*, v. 8, p. 99 990–99 998, 2020.
- [111] J.-L. Blanco, F.-A. Moreno, e J. Gonzalez, “A collection of outdoor robotic datasets with centimeter-accuracy ground truth,” *Auton. Robots*, v. 27, n. 4, p. 327–351, Nov. 2009.
- [112] K. Schenk, A. Kolarow, M. Eisenbach, K. Debes, e H.-M. Gross, “Automatic calibration of a stationary network of laser range finders by matching movement trajectories,” in *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2012, p. 431–437.
- [113] D.-G. Choi, Y. Bok, J.-S. Kim, e I. S. Kweon, “Extrinsic calibration of 2-d lidars using two orthogonal planes,” *IEEE Transactions on Robotics*, v. 32, n. 1, p. 83–98, 2016.
- [114] F. Zhu, Y. Huang, Z. Tian, e Y. Ma, “Extrinsic calibration of multiple two-dimensional laser rangefinders based on a trihedron,” *Sensors*, v. 20, n. 7, 2020. [Online]. Disponível em: <https://www.mdpi.com/1424-8220/20/7/1837>
- [115] D. Yin, J. Liu, T. Wu, K. Liu, J. Hyppä, e R. Chen, “Extrinsic calibration of 2d laser rangefinders using an existing cuboid-shaped corridor as the reference,” *Sensors*, v. 18, n. 12, 2018. [Online]. Disponível em: <https://www.mdpi.com/1424-8220/18/12/4371>
- [116] M. Ben Kilani, A. J. Raymond, F. Gagnon, G. Gagnon, e P. Lavoie, “Rssi-based indoor tracking using the extended kalman filter and circularly polarized antennas,” in *2014 11th Workshop on Positioning, Navigation and Communication (WPNC)*, 2014, p. 1–6.
- [117] I. Sharp e K. Yu, “Indoor toa error measurement, modeling, and analysis,” *IEEE Transactions on Instrumentation and Measurement*, v. 63, n. 9, p. 2129–2144, 2014.
- [118] P. Du, S. Zhang, C. Chen, A. Alphones, e W.-D. Zhong, “Demonstration of a low-complexity indoor visible light positioning system using an enhanced tdoa scheme,” *IEEE Photonics Journal*, v. 10, n. 4, p. 1–10, 2018.

- [119] T. Do e M. Yoo, “Tdoa-based indoor positioning using visible light,” *Photon Netw Commun*, v. 27, p. 80–88, 2014. [Online]. Disponível em: <https://doi.org/10.1007/s11107-014-0428-4>
- [120] I. Guvenc, C.-C. Chong, e F. Watanabe, “Analysis of a linear least-squares localization technique in los and nlos environments,” in *2007 IEEE 65th Vehicular Technology Conference - VTC2007-Spring*, 2007, p. 1886–1890.
- [121] S. Wielandt, B. Thoen, e L. De Strycker, “Experimental evaluation of a single anchor multipath assisted indoor angle of arrival localization system in the 2.4 ghz and 5 ghz band,” in *2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, 2018, p. 1–7.
- [122] B. Yimwadsana, V. Serey, e S. Sanghlaio, “Performance analysis of an aoa-based wi-fi indoor positioning system,” in *2019 19th International Symposium on Communications and Information Technologies (ISCIT)*, 2019, p. 36–41.
- [123] W. Sakpere, M. A. Oshin, e N. B. Mlitwa, “A state-of-the-art survey of indoor positioning and navigation systems and technologies,” *South Afr. Comput. J.*, v. 29, n. 3, p. 145–197, Dec. 2017.
- [124] R. Carotenuto, M. Merenda, D. Iero, e F. G. Della Corte, “An indoor ultrasonic system for autonomous 3-d positioning,” *IEEE Transactions on Instrumentation and Measurement*, v. 68, n. 7, p. 2507–2518, 2019.
- [125] J. Pomárico-Franquiz, S. H. Khan, e Y. S. Shmaliy, “Combined extended fir/kalman filtering for indoor robot localization via triangulation,” *Measurement*, v. 50, p. 236–243, 2014. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263224114000062>
- [126] R. Faragher e R. Harle, “Location fingerprinting with bluetooth low energy beacons,” *IEEE Journal on Selected Areas in Communications*, v. 33, n. 11, p. 2418–2428, 2015.
- [127] M. Uradzinski, H. Guo, X. Liu, e M. Yu, “Advanced indoor positioning using zigbee wireless technology,” *Wireless Pers. Commun.*, v. 97, n. 4, p. 6509–6518, Dec. 2017.
- [128] J. Yan, L. Zhao, J. Tang, Y. Chen, R. Chen, e L. Chen, “Hybrid kernel based machine learning using received signal strength measurements for indoor localization,” *IEEE Transactions on Vehicular Technology*, v. 67, n. 3, p. 2824–2829, 2018.
- [129] M. U. Ali, S. Hur, e Y. Park, “Wi-fi-based effortless indoor positioning system using iot sensors,” *Sensors*, v. 19, n. 7, 2019. [Online]. Disponível em: <https://www.mdpi.com/1424-8220/19/7/1496>
- [130] F. Liu, J. Liu, Y. Yin, W. Wang, D. Hu, P. Chen, e Q. Niu, “Survey on wifi-based indoor positioning techniques,” *IET Communications*, v. 14, n. 9, p. 1372–1383, 2020.
- [131] Z. Li, T. Braun, e D. C. Dimitrova, “A passive wifi source localization system based on fine-grained power-based trilateration,” in *2015 IEEE 16th International Symposium on A World of Wireless, Mobile and Multimedia Networks (WoWMoM)*, 2015, p. 1–9.

- [132] K. Qian, C. Wu, Z. Yang, Y. Liu, e Z. Zhou, “Pads: Passive detection of moving targets with dynamic speed using phy layer information,” in *2014 20th IEEE International Conference on Parallel and Distributed Systems (ICPADS)*, 2014, p. 1–8.
- [133] L. Calderoni, M. Ferrara, A. Franco, e D. Maio, “Indoor localization in a hospital environment using random forest classifiers,” *Expert Systems with Applications*, v. 42, n. 1, p. 125–134, 2015. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0957417414004497>
- [134] F. Zhao, T. Huang, e D. Wang, “A probabilistic approach for wifi fingerprint localization in severely dynamic indoor environments,” *IEEE Access*, v. 7, p. 116 348–116 357, 2019.
- [135] A. Hameed e H. A. Ahmed, “Survey on indoor positioning applications based on different technologies,” in *2018 12th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics (MACS)*, 2018, p. 1–5.
- [136] A. R. J. Jiménez Ruiz, F. Seco Granja, J. Carlos Prieto Honorato, e J. I. Guevara Rosas, “Pedestrian indoor navigation by aiding a foot-mounted imu with rfid signal strength measurements,” in *2010 International Conference on Indoor Positioning and Indoor Navigation*, 2010, p. 1–7.
- [137] R. Murari, “Practical and robust approach for a neural networks based indoor positioning system using ultrawide band,” Thesis, Toronto Metropolitan University, 2021.
- [138] K. Yu, K. Wen, Y. Li, S. Zhang, e K. Zhang, “A novel nlos mitigation algorithm for uwb localization in harsh indoor environments,” *IEEE Transactions on Vehicular Technology*, v. 68, n. 1, p. 686–699, 2019.
- [139] M. Kolakowski, V. Djaja-Josko, e J. Kolakowski, “Static lidar assisted uwb anchor nodes localization,” *IEEE Sensors Journal*, v. 22, n. 6, p. 5344–5351, 2022.
- [140] H. Wang, X. Liu, X. Yuan, e D. Liang, “Multi-perspective terrestrial lidar point cloud registration using planar primitives,” in *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2016, p. 6722–6725.
- [141] M. Zaffar, S. Ehsan, R. Stolkin, e K. M. Maier, “Sensors, slam and long-term autonomy: A review,” in *2018 NASA/ESA Conference on Adaptive Hardware and Systems (AHS)*, 2018, p. 285–290.
- [142] K. Maatta e J. Kostamovaara, “A high-precision time-to-digital converter for pulsed time-of-flight laser radar applications,” *IEEE Transactions on Instrumentation and Measurement*, v. 47, n. 2, p. 521–536, 1998.
- [143] W. Hess, D. Kohler, H. Rapp, e D. Andor, “Real-time loop closure in 2d lidar slam,” in *2016 IEEE International Conference on Robotics and Automation (ICRA)*, 2016, p. 1271–1278.
- [144] R. Yagfarov, M. Ivanou, e I. Afanasyev, “Map comparison of lidar-based 2d slam algorithms using precise ground truth,” in *2018 15th International Conference on Control, Automation, Robotics and Vision (ICARCV)*, 2018, p. 1979–1983.

- [145] D. V. Nam e K. Gon-Woo, “Solid-state lidar based-slam: A concise review and application,” in *2021 IEEE International Conference on Big Data and Smart Computing (Big-Comp)*, 2021, p. 302–305.
- [146] G. Dissanayake, S. Huang, Z. Wang, e R. Ranasinghe, “A review of recent developments in simultaneous localization and mapping,” in *2011 6th International Conference on Industrial and Information Systems*, 2011, p. 477–482.
- [147] T. Chong, X. Tang, C. Leng, M. Yogeswaran, O. Ng, e Y. Chong, “Sensor technologies and simultaneous localization and mapping (slam),” *Procedia Computer Science*, v. 76, p. 174–179, 2015, 2015 IEEE International Symposium on Robotics and Intelligent Sensors (IEEE IRIS2015). [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1877050915038375>
- [148] I. Petrov e T. Janevski, “5g technologies and business aspects: high-level point of view,” *Journal of Electrical Engineering and Information Technologies*, v. 5, n. 1, p. 61–68, 2020.
- [149] S. Zhang, J. Liu, H. Guo, M. Qi, e N. Kato, “Envisioning device-to-device communications in 6g,” *IEEE Network*, v. 34, n. 3, p. 86–91, 2020.
- [150] L. U. Khan, I. Yaqoob, M. Imran, Z. Han, e C. S. Hong, “6g wireless systems: A vision, architectural elements, and future directions,” *IEEE Access*, v. 8, p. 147 029–147 044, 2020.
- [151] S. J. Nawaz, S. K. Sharma, S. Wyne, M. N. Patwary, e M. Asaduzzaman, “Quantum machine learning for 6g communication networks: State-of-the-art and vision for the future,” *IEEE Access*, v. 7, p. 46 317–46 350, 2019.
- [152] M. Shahraki, M. J. Abbasi, M. J. Piran, M. Chen, e S. Chui, “A comprehensive survey of 6g networks: applications core services enabling technologies and future challenges,” 2021, arXiv:2101.xxxxx [cs.NI].
- [153] D. V. Le, N. Meratnia, e P. J. Havinga, “Unsupervised deep feature learning to reduce the collection of fingerprints for indoor localization using deep belief networks,” in *2018 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, 2018, p. 1–7.
- [154] Z. E. Khatab, A. Hajihoseini, e S. A. Ghorashi, “A fingerprint method for indoor localization using autoencoder based deep extreme learning machine,” *IEEE Sensors Letters*, v. 2, n. 1, p. 1–4, 2018.
- [155] X. Wang, X. Wang, e S. Mao, “Deep convolutional neural networks for indoor localization with csi images,” *IEEE Transactions on Network Science and Engineering*, v. 7, n. 1, p. 316–327, 2020.
- [156] C. Zhang, P. Patras, e H. Haddadi, “Deep learning in mobile and wireless networking: a survey,” *arXiv:1803.04311 [cs.NI]*, 2018, available: arXiv:1803.04311. [Online]. Disponível em: <https://arxiv.org/abs/1803.04311>
- [157] Q. Mao, F. Hu, e Q. Hao, “Deep learning for intelligent wireless networks: A comprehensive survey,” *IEEE Communications Surveys Tutorials*, v. 20, n. 4, p. 2595–2621, 2018.

- [158] Z. Qin, H. Ye, G. Y. Li, e B.-H. F. Juang, “Deep learning in physical layer communications,” *IEEE Wireless Communications*, v. 26, n. 2, p. 93–99, 2019.
- [159] M. Kim, N.-I. Kim, W. Lee, e D.-H. Cho, “Deep learning-aided scma,” *IEEE Communications Letters*, v. 22, n. 4, p. 720–723, 2018.
- [160] A. Behravan, V. Yajnanarayana, M. F. Keskin, H. Chen, D. Shrestha, T. E. Abrudan, T. Svensson, K. Schindhelm, A. Wolfgang, S. Lindberg, e H. Wymeersch, “Positioning and sensing in 6g: Gaps, challenges, and opportunities,” *IEEE Vehicular Technology Magazine*, v. 18, n. 1, p. 40–48, 2023.
- [161] Y.-C. Fan e S.-B. Wang, “Three-dimensional lidar decoder design for autonomous vehicles in smart cities,” *Information*, v. 13, n. 1, 2022. [Online]. Disponível em: <https://www.mdpi.com/2078-2489/13/1/18>
- [162] H. Iqbal, D. Campo, P. Marin-Plaza, L. Marcenaro, D. M. Gómez, e C. Regazzoni, “Modeling perception in autonomous vehicles via 3d convolutional representations on lidar,” *IEEE Transactions on Intelligent Transportation Systems*, v. 23, n. 9, p. 14608–14619, 2022.
- [163] A. Poulouse, M. Baek, e D. S. Han, “Point cloud map generation and localization for autonomous vehicles using 3d lidar scans,” in *2022 27th Asia Pacific Conference on Communications (APCC)*, 2022, p. 336–341.
- [164] T.-C. Su, “Special issue on remote sensing applications in archaeology, geography, and the earth sciences,” *Applied Sciences*, v. 13, n. 13, 2023. [Online]. Disponível em: <https://www.mdpi.com/2076-3417/13/13/7631>
- [165] C. G. Andresen e E. S. Schultz-Fellenz, “Change detection applications in the earth sciences using uas-based sensing: A review and future opportunities,” *Drones*, v. 7, n. 4, 2023. [Online]. Disponível em: <https://www.mdpi.com/2504-446X/7/4/258>
- [166] K. Rehman, N. Fareed, e H.-J. Chu, “Nasa icesat-2: Space-borne lidar for geological education and field mapping of aeolian sand dune environments,” *Remote Sensing*, v. 15, n. 11, 2023. [Online]. Disponível em: <https://www.mdpi.com/2072-4292/15/11/2882>
- [167] G. Rivera, R. Porrás, R. Florencia, e J. P. Sánchez-Solís, “Lidar applications in precision agriculture for cultivating crops: A review of recent advances,” *Computers and Electronics in Agriculture*, v. 207, p. 107737, 2023. [Online]. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169923001254>
- [168] S. Debnath, M. Paul, e T. Debnath, “Applications of lidar in agriculture and future research directions,” *Journal of Imaging*, v. 9, n. 3, 2023. [Online]. Disponível em: <https://www.mdpi.com/2313-433X/9/3/57>
- [169] M. J. Micheletto, C. I. Chesñevar, e R. Santos, “Methods and applications of 3d ground crop analysis using lidar technology: A survey,” *Sensors*, v. 23, n. 16, 2023. [Online]. Disponível em: <https://www.mdpi.com/1424-8220/23/16/7212>

- [170] H. J. Renninger, B. R. Frey, M. P. Anderson, e D. L. Evans, “Using LiDAR Data to Estimate Biomass in Afforested Bottomland Oak Sites in the Southern United States,” *Forest Science*, v. 69, n. 5, p. 551–562, 06 2023. [Online]. Disponível em: <https://doi.org/10.1093/forsci/fxad028>
- [171] Y. Yadav, S. K. P. Kushwaha, M. Mokros, J. Chudá, e M. Pondelík, “Integration of iphone lidar with quadcopter and fixed wing uav photogrammetry for the forestry applications,” *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. XLVIII-1/W3-2023, p. 213–218, 2023. [Online]. Disponível em: <https://isprs-archives.copernicus.org/articles/XLVIII-1-W3-2023/213/2023/>
- [172] Q. Robertson, J. Wozencraft, Z. Dong, T. Pierro, e K. Zhang, “Demonstrated coastal engineering applications using lidar data,” *Journal of Coastal Research*, v. 39, n. 2, p. 334–346, 2023.
- [173] J. H. Sekon, Z. Majid, e M. F. M. Ariff, “Lidar for coastal monitoring study – a review,” in *2023 IEEE 14th Control and System Graduate Research Colloquium (ICSGRC)*, 2023, p. 10–15.
- [174] S. S. Hansen, V. B. Ernstsens, M. S. Andersen, Z. Al-Hamdani, R. Baran, M. Niederwieser, F. Steinbacher, e A. Kroon, “Classification of boulders in coastal environments using random forest machine learning on topo-bathymetric lidar data,” *Remote Sensing*, v. 13, n. 20, 2021. [Online]. Disponível em: <https://www.mdpi.com/2072-4292/13/20/4101>
- [175] SLAMTEC, “Slamtec rplidar s2,” <https://www.slamtec.com/en/s2>, 2023, acessado em: 22 de Novembro de 2023.
- [176] M. Heydarian, T. E. Doyle, e R. Samavi, “Mlcm: Multi-label confusion matrix,” *IEEE Access*, v. 10, p. 19 083–19 095, 2022.