

Sistema de Posicionamento Baseado em LiDAR e Redes Neurais para Aplicações B5G

Matheus Ferreira Silva, Egidio Raimundo Neto, Gabriel Filhagosa Guimarães, Luiz Otávio Sales Alves Amante, Luiz Augusto Melo Pereira e Arismar Cerqueira Sodré Junior

Resumo—A necessidade de sistemas de posicionamento interno precisos é crescente em diversas aplicações, mas enfrenta desafios, pois tecnologias convencionais, como o Sistema de Posicionamento Global (GPS), apresentam limitações em ambientes internos. Neste contexto, sensores de Light Detection and Ranging (LiDAR) surgem como uma solução promissora. Este artigo apresenta o desenvolvimento e a avaliação de um sistema de posicionamento interno utilizando LiDAR 2D, complementado por estudos preliminares com LiDAR 3D. O sistema proposto emprega redes neurais artificiais (RNAs) para aprimorar a precisão do posicionamento de pessoas em ambientes internos, visando aplicações Beyond 5G (B5G). A arquitetura do projeto inclui a aquisição e processamento de dados e a visualização dos resultados, com a metodologia envolvendo a detecção de objetos usando exclusivamente dados de LiDAR e a aplicação de uma rede neural para identificação de pessoas. Os resultados demonstram que a tecnologia LiDAR 2D proporciona uma detecção eficaz de pessoas dentro de uma área designada, sendo uma solução promissora para o posicionamento interno com potencial para futuras integrações com LiDAR 3D.

Palavras-Chave—Posicionamento interno, LiDAR 2D, LiDAR 3D, redes neurais artificiais, B5G.

Abstract—The need for accurate indoor positioning systems is growing in various applications but faces challenges, as conventional technologies like the Global Positioning System (GPS) have limitations in indoor environments. In this context, Light Detection and Ranging (LiDAR) sensors emerge as a promising solution. This paper presents the development and evaluation of an indoor positioning system using 2D LiDAR, supplemented by preliminary studies with 3D LiDAR. The proposed system employs artificial neural networks (ANNs) to enhance the positioning accuracy of people in indoor environments, targeting Beyond 5G (B5G) applications. The project architecture includes data acquisition, processing, and result visualization, with the methodology involving object detection using only LiDAR data and applying a

neural network for person identification. The results demonstrate that 2D LiDAR technology provides effective person detection within a designated area, making it a promising solution for indoor positioning with potential for future integration with 3D LiDAR.

Keywords—Indoor positioning, 2D LiDAR, 3D LiDAR, artificial neural networks, B5G.

I. INTRODUÇÃO

A precisão no posicionamento e mapeamento desempenha um papel crucial em diversas aplicações de telecomunicações, como navegação em ambientes internos e automação de processos industriais. Essas aplicações dependem de dados de localização precisos para otimizar operações e proporcionar uma melhor experiência ao usuário. No entanto, as tecnologias tradicionais de posicionamento, como o Sistema de Posicionamento Global (GPS), enfrentam várias limitações em ambientes internos. O GPS depende de sinais de satélites que podem ser degradados por obstáculos, resultando em uma precisão reduzida. Além disso, a interferência de outros dispositivos eletrônicos pode agravar esse problema, tornando o GPS inadequado para muitas aplicações internas [1], [2].

Neste contexto, a tecnologia de Light Detection and Ranging (LiDAR) surge como uma solução promissora. O LiDAR utiliza pulsos de laser para medir distâncias, criando representações com nuvem de pontos detalhadas de um ambiente. Esta tecnologia é capaz de operar eficientemente em ambientes internos, oferecendo uma precisão de posicionamento significativamente melhor. O LiDAR pode ser utilizado em diversas aplicações, como a detecção de pedestres em cidades inteligentes [3], seleção de feixes [4], e navegação de robôs [5]. Além disso, o LiDAR 3D não só melhora a precisão do posicionamento, mas também permite a criação de mapas detalhados e a detecção de objetos com alta resolução. A versão 3D é amplamente utilizada em aplicações como o mapeamento de florestas [6] e no reconhecimento de interseções em sistemas de condução autônoma [7], onde é necessário um alto nível de detalhe e precisão.

O uso de LiDAR em sistemas de telecomunicações Beyond 5G (B5G) apresenta uma solução potencial em diversas áreas, como a alocação de recursos em fábricas [8], previsão de feixe [9], seleção de feixe [10], previsão de bloqueios de enlace [11] e Superfícies Inteligentes Reconfiguráveis (RIS) [12]. Essas aplicações prometem oferecer uma conectividade ultra-rápida e confiável, essencial para suportar as exigências de processamento de dados em tempo real e as aplicações avançadas de posicionamento interno. Neste cenário, o presente estudo visa

Matheus Ferreira Silva, Departamento de Engenharia de Telecomunicações, INATEL (Instituto Nacional de Telecomunicações), Santa Rita do Sapucaí, Brasil, e-mail: matheus.ferreira@get.inatel.br; Egidio Raimundo Neto, Departamento de Engenharia de Telecomunicações, INATEL, Santa Rita do Sapucaí, Brasil, e-mail: egidio.neto@inatel.br; Gabriel Filhagosa Guimarães, Departamento de Engenharia de Software, INATEL, Santa Rita do Sapucaí, Brasil, e-mail: gabriel.filhagosa@ges.inatel.br; Luiz Otávio Sales Alves Amante, Departamento de Engenharia de Software, INATEL, Santa Rita do Sapucaí, Brasil, e-mail: luiz.alves@ges.inatel.br; Luiz Augusto Melo Pereira, Departamento de Engenharia de Telecomunicações, INATEL, Santa Rita do Sapucaí, Brasil, e-mail: luiz.melo@inatel.br; Arismar Cerqueira Sodré Júnior, Departamento de Engenharia de Telecomunicações, INATEL, Santa Rita do Sapucaí, Brasil, e-mail: arismar@inatel.br. Este trabalho foi totalmente/parcialmente financiado pelo projeto NOME DO PROJETO suportado pelo xGMobile – Centro de Competência EMBRAPPI em Tecnologia e Infraestrutura em Conectividade 5G e 6G, com recursos financeiros oriundos do PPI IoT/Manufatura 4.0 do MCTI, através do Termo de Cooperação 052/2023, firmado com a EMBRAPPI. Adicionalmente, os autores também agradecem o apoio financeiro do CNPq, da CAPES, da FINEP, da FAPEMIG (Contracts PPE-00124-23, RED-00194-23 and APQ-02746-21) e da FAPESP (Contratos 2021/06569-1 e 2022/09319-9).

avaliar a eficácia do LiDAR e analisar seus benefícios para o posicionamento interno. O objetivo principal deste estudo é avaliar a precisão de um sistema de posicionamento baseado em LiDAR e a eficácia da detecção de pessoas utilizando RNAs, visando aprimorar a identificação e localização de indivíduos em ambientes internos.[13], [14].

II. REVISÃO DA LITERATURA

Esta seção apresenta uma revisão da literatura, destacando as principais diferenças e similaridades com o presente trabalho, e posicionando-o em comparação com o estado da arte em sistemas de sensoriamento e posicionamento.

Os estudos apresentados em [15], [16] e [17] são referentes à trabalhos desenvolvidos com foco em ambientes internos. Esses trabalhos utilizam informações disponíveis no padrão de comunicação para determinar a localização/posição dos usuários em um ambiente interno com o objetivo de substituir sistemas de GPS. No entanto, o uso de padrões de comunicação que transmitem dados por meio de sinais de rádiofrequência em ambientes internos sofre interferência devido à coexistência com várias outras redes. Por outro lado, o uso de sensores LiDAR no ambiente e a independência do padrão de comunicação, como no trabalho atual, não sofrem essa interferência.

Já os trabalhos [18], [19], [22] e [25] utilizam dados de sensores LiDAR 3D, que fornecem alta precisão ao custo de aumentar o investimento à ser feito, bem como a complexidade e a carga computacional necessária. Além disso, se essa solução for aplicada em larga escala, o volume de dados transmitidos por meio de uma rede de dados ou processados localmente é muito alto, o que poderia tornar esses sistemas impraticáveis para aplicações internas.

Os trabalhos [20], [24] e [25] destacam a fusão de dados de um sensor LiDAR com sinais de ondas milimétricas e dados de câmeras. Nesses casos, a fusão de dados pode auxiliar na tomada de decisão, melhorando o desempenho do sistema. Os estudos [23] e [24] foram concebidos para ambientes internos. Nesse cenário, o uso de câmeras pode ser considerado uma desvantagem, pois levanta preocupações sobre a privacidade dos indivíduos nesses ambientes. Já os estudos realizados em [24] também utilizam múltiplos sensores LiDAR 2D combinados para otimizar o sistema. Em relação à aplicação em sistemas B5G, apenas a referência [25] compartilha esse objetivo, embora explore isso em ambientes externos.

Em termos de complexidade e custo permite concluir que sistemas que não utilizam sensores adicionais podem ser ampliados mais facilmente, como em [15], [16] e [17]. Sistemas que utilizam sensores LiDAR 2D incorreram em um custo adicional para implementação, conforme proposto em [20],[23], [24] e neste trabalho, mas são menos caros do que sensores LiDAR 3D aplicados nos trabalhos [18], [19], [21], [22] e [25]. Além disso, a complexidade de lidar com a enorme quantidade de dados de sensores LiDAR 3D não impede a implementação escalável, mas torna a solução mais difícil e cara. A maioria dos estudos utilizou RNAs para implementar suas soluções.

Os trabalhos apresentados em [15] e [25] aplicaram Redes Neurais Recorrentes, enquanto as referências [16], [18], [19],

[20] e [21] aplicaram Redes Neurais Convolucionais. Os trabalhos apresentados em [17], [22], [23] e [24] aplicaram outras técnicas de tomada de decisão. Portanto, é evidente que este trabalho explora as principais vantagens dos estudos relacionados apresentados na revisão da literatura.

III. SISTEMA PROPOSTO BASEADO EM RNA E LiDAR 2D

O objetivo principal deste projeto é melhorar a precisão do posicionamento interno utilizando um sistema baseado em RNA e sensores LiDAR 2D. Especificamente, o projeto visa testar a viabilidade do uso do LiDAR 2D para detecção e localização de pessoas em ambientes internos.

O sensor utilizado é o RPLiDAR S2, fabricado pela SLAMTEC, que possui um alcance de medição de 0.05 a 50 metros e uma frequência de amostragem de 32000 amostras por segundo [26]. O sensor é estrategicamente posicionado em ambientes internos para facilitar a detecção de pessoas. Os dados coletados pelos sensores LiDAR são transmitidos para uma unidade central de processamento onde são inicialmente processados antes de serem encaminhados para a rede central. Na rede central, um algoritmo RNA é empregado para determinar com precisão as localizações das pessoas.



Fig. 1. Sensor LiDAR 2D RPLiDAR S2 fabricado pela SLAMTEC.

Para validar o sistema proposto, foi configurado um ambiente de testes em laboratório. Sensores LiDAR foram posicionados nos vértices de um quadrado de 4 x 4 metros quadrados. Os testes variaram o número de sensores e suas posições. A coleta de dados passou por uma fase de pré-processamento, incluindo o uso de um filtro mediano digital para remover ruídos, garantindo a utilização de amostras dentro da área definida e otimizando a eficiência do sistema [27]. O cenário de avaliação não continha obstáculos internos, sendo composto apenas pelas pessoas que se moviam dentro da área de teste. Os sensores LiDAR foram posicionados a uma altura de 1,3 metros acima do chão, uma escolha estratégica para maximizar a eficiência da detecção. Esta altura foi selecionada para equilibrar a detecção de pessoas de diferentes estaturas e evitar pontos cegos, já que a altura dos indivíduos pode variar

significativamente. A Figura 2 ilustra a configuração dos testes realizados.

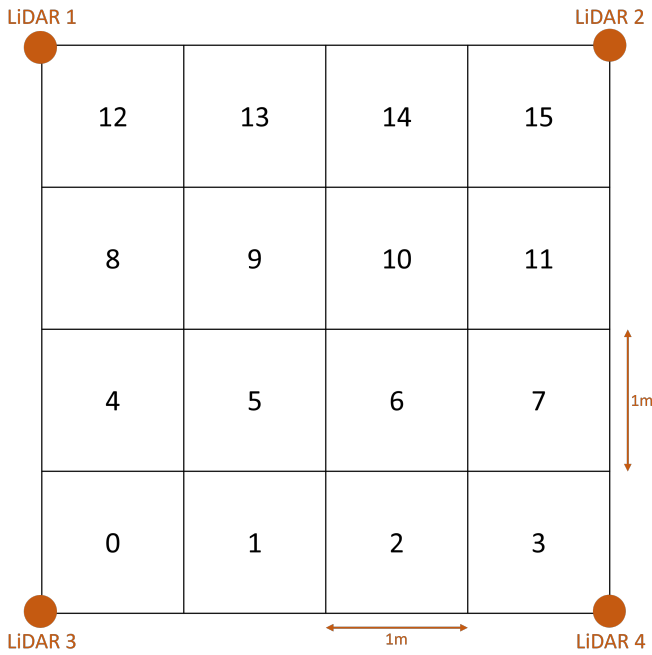


Fig. 2. Configuração dos testes realizados.

IV. METODOLOGIA

Os dados de treinamento da RNA foram rotulados manualmente com vetores binários de 16 posições, indicando a presença (1) ou ausência (0) de pessoas em cada quadrante específico. Esses rótulos foram essenciais para o treinamento supervisionado, permitindo que a rede aprendesse a relação entre os dados de entrada e a classificação desejada. Durante o treinamento, a rede foi ajustada para minimizar a diferença entre suas previsões e os rótulos fornecidos, utilizando a função de perda binária cross-entropy e o otimizador Adam. O treinamento ocorreu ao longo de 16.000 épocas, com 80% dos dados destinados ao treinamento e 20% à validação. Camadas de dropout com uma taxa de 20% foram aplicadas para evitar sobreajuste.

Testaram-se diferentes configurações de redes neurais para encontrar a arquitetura mais eficaz. As configurações variaram o número de camadas ocultas (1, 2 ou 3 camadas), as funções de ativação (sigmoid ou ReLU) e o número de neurônios (32, 64, 128). A configuração escolhida, que apresentou o melhor desempenho, incluiu duas camadas ocultas com 128 e 64 neurônios, respectivamente, e a função de ativação ReLU.

A RNA foi desenvolvida com uma arquitetura composta por três camadas principais. A camada de entrada possui 16 neurônios, correspondendo aos quadrantes definidos por uma grade de 4x4 metros.

A primeira camada oculta contém 128 neurônios, escolhidos para equilibrar a capacidade de computação e a complexidade necessária para capturar uma vasta gama de padrões nos dados.

A função de ativação ReLU é utilizada para introduzir não-linearidade ao modelo, permitindo que a rede aprenda padrões complexos nos dados de entrada.

A segunda camada oculta possui 64 neurônios, onde a redução gradual no número de neurônios ajuda a consolidar os padrões aprendidos e a simplificar o modelo, promovendo melhor generalização para novos dados. A função ReLU é mantida nesta camada para preservar a não-linearidade.

A camada de saída tem 16 neurônios, correspondente ao número de quadrantes na grade. Esta camada utiliza a função de ativação sigmoide, ideal para classificações binárias, transformando as saídas da rede em um vetor binário de 16 posições, indicando a presença (1) ou ausência (0) de pessoas em cada quadrante. A Figura 3 ilustra a estrutura da RNA.

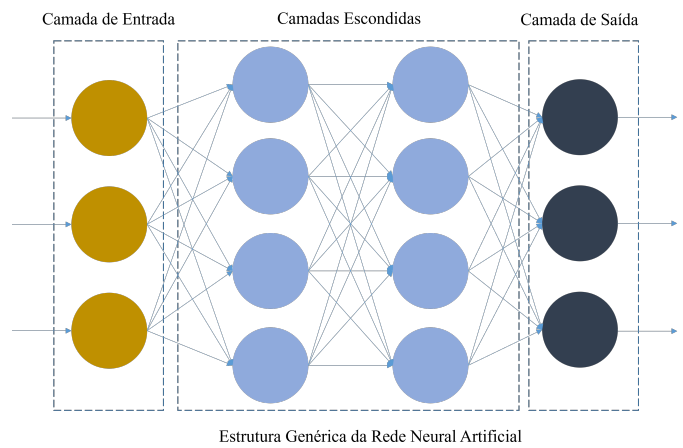


Fig. 3. Estrutura Genérica da Rede Neural Artificial.

V. RESULTADOS

Os testes do sistema foram realizados utilizando várias combinações de sensores LiDAR para avaliar o desempenho da RNA. Foram testadas as seguintes configurações: um único LiDAR, dois LiDARs posicionados nas diagonais, três LiDARs, e quatro LiDARs nos vértices da grade de 4 x 4 metros quadrados. Além disso, foi adotada uma abordagem de processamento de dados combinada, onde todos os dados coletados pelos LiDARs foram unificados, formando um único conjunto de dados de entrada para a rede neural.

Nos casos em que foram utilizados três ou mais LiDARs, foi possível aplicar a técnica de trilateração para identificar a posição exata de uma pessoa no ambiente. A trilateração é realizada utilizando a minimização da soma dos quadrados das distâncias entre as coordenadas medidas e a posição estimada. A função de minimização emprega um palpite inicial baseado na média das leituras filtradas e utiliza o método Nelder-Mead [29] para convergir para a posição mais provável. Este método aumentou ainda mais a precisão do sistema, proporcionando uma detecção mais confiável. A figura 4 mostra o plot dos dados combinados de todos os LiDARs junto com a aplicação da trilateração.

Os resultados do treinamento da RNA mostraram um desempenho sólido na detecção de pessoas. A Tabela I apresenta

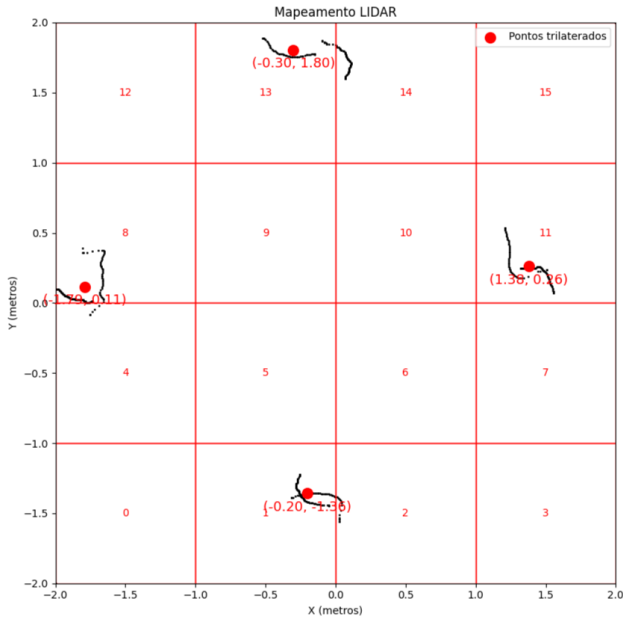


Fig. 4. Plot dos dados combinados de todos os LiDARs com a aplicação da trilateração.

a avaliação de desempenho da RNA em termos de acurácia, precisão, recall e F1-score para os diferentes cenários de configurações dos sensores com dados combinados, formando um único conjunto de dados de entrada. Os testes foram realizados utilizando 2.000 amostras coletadas, com quatro pessoas movendo-se aleatoriamente a cada 20 amostras, resultando em uma avaliação robusta das capacidades do modelo.

TABELA I
DESEMPENHO DA RNA

Número de sensores	Acurácia	Precisão	Recall	F1-score
1 LiDAR	99.47%	99.12%	98.89%	99.00%
2 LiDARs	99.37%	98.70%	98.53%	98.61%
3 LiDARs	99.63%	99.24%	99.35%	99.30%
4 LiDARs	99.30%	98.65%	98.71%	98.68%

Embora os valores calculados para acurácia, precisão, recall e F1-score sejam relativamente próximos, há distinções importantes a serem observadas. Com um único LiDAR, o sistema apresentou alta precisão, mas com limitações em situações de oclusão, onde uma pessoa pode bloquear a visão do sensor, dificultando a detecção de outras pessoas. Este problema é parcialmente mitigado ao se utilizar dois LiDARs, posicionados nas diagonais do ambiente, resultando em uma leve diminuição na acurácia, mas melhorando a cobertura do ambiente e reduzindo os pontos cegos.

Quando três LiDARs são empregados, a acurácia aumenta. A configuração triangular permite uma melhor trilateração e minimiza os pontos cegos ainda mais eficazmente. A combinação dos dados de três sensores também proporciona uma visão mais abrangente do ambiente, aumentando a precisão da detecção.

Com quatro LiDARs, colocados nos vértices do quadrado de teste, a acurácia é ligeiramente inferior à configuração de

três LiDARs. No entanto, essa disposição oferece a melhor cobertura geral, eliminando quase todos os pontos cegos. A ligeira diminuição na acurácia pode ser atribuída ao aumento da complexidade dos dados e à necessidade de processamento mais intensivo.

Esses resultados mostram que o uso de múltiplos LiDARs não só melhora a cobertura e a precisão da detecção, mas também demonstra a importância de posicionar estrategicamente os sensores para otimizar o desempenho do sistema. A abordagem com três ou mais LiDARs, em particular, oferece uma solução eficaz para superar os desafios de detecção em ambientes internos complexos.

VI. ESTUDOS PRELIMINARES COM O LiDAR 3D

Para os estudos preliminares com o LiDAR 3D, foi utilizado o sensor OS1 da fabricante Ouster. O OS1 oferece uma série de especificações avançadas que o tornam ideal para aplicações em mapeamento e navegação autônoma. Este sensor possui um campo de visão de 360° horizontal e até 45° vertical, sendo capaz de fornecer uma taxa de atualização de até 20 Hz, com um alcance máximo de 200 metros. Além dos pontos tridimensionais, o OS1 retorna informações sobre a intensidade do retorno do laser e a reflectividade do sinal, permitindo uma melhor caracterização dos objetos detectados. O sensor pode capturar até 5,2 milhões de pontos por segundo, o que facilita a criação de representações detalhadas do ambiente [28].

Nos testes preliminares, a Software Development Kit (SDK) fornecida pela Ouster foi utilizada para coletar e processar os dados do LiDAR 3D. Um dos experimentos incluiu a detecção e mapeamento de um laboratório no Instituto Nacional de Telecomunicações (Inatel). O plot gerado, mostrado na Figura 5, demonstra a capacidade do sensor em criar representações detalhadas do ambiente interno.




Fig. 5. Mapeamento do laboratório no Inatel utilizando LiDAR 3D.

Comparado ao LiDAR 2D utilizado anteriormente, o LiDAR 3D oferece uma dimensão adicional de dados que pode melhorar significativamente a detecção e identificação de pessoas. Com a capacidade de capturar pontos em três dimensões, é possível diferenciar indivíduos com base em sua altura e posição espacial, algo que não é viável com sensores 2D que só fornecem dados no plano horizontal. Isso pode ser particularmente útil em ambientes onde a altura dos objetos ou pessoas é um fator crítico para a identificação precisa, melhorando a precisão e a confiabilidade do sistema proposto.

VII. CONCLUSÃO E TRABALHOS FUTUROS

O presente artigo apresenta a avaliação de um sistema de posicionamento interno baseado em sensores LiDAR 2D e RNA, com estudos preliminares utilizando LiDAR 3D. Os resultados obtidos demonstraram a eficácia do LiDAR 2D na detecção de pessoas em ambientes internos, proporcionando uma precisão significativa na identificação e localização. A integração da RNA mostrou-se crucial para aprimorar a precisão do sistema, confirmando seu potencial em aplicações B5G.

Os testes realizados indicaram que a utilização de múltiplos sensores LiDAR e a técnica de trileração contribuem para a eliminação de pontos cegos e aumentam a confiabilidade do sistema. As métricas de desempenho obtidas, incluindo acurácia, precisão, recall e F1-score, destacam a robustez da abordagem proposta.

Para trabalhos futuros, pretende-se explorar de forma mais abrangente a utilização do LiDAR 3D no sistema proposto, aproveitando suas capacidades avançadas para capturar informações tridimensionais detalhadas do ambiente. Isso permitirá uma detecção e identificação de pessoas ainda mais precisa e confiável.

Além disso, futuros trabalhos incluirão a integração de sensores LiDAR com Superfícies Inteligentes Reconfiguráveis e não reflexivas (RIS). Essa junção promete melhorar a detecção e ampliar o alcance dos sensores, permitindo aplicações em ambientes mais complexos e dinâmicos. A combinação de LiDAR 3D e RIS pode potencializar as capacidades do sistema em diversas áreas, desde a automação industrial até a navegação autônoma e mapeamento em ambientes internos.

AGRADECIMENTOS

Este trabalho foi totalmente/parcialmente financiado pelo projeto NOME DO PROJETO suportado pelo xGMobile – Centro de Competência EMBRAPII em Tecnologia e Infraestrutura em Conectividade 5G e 6G, com recursos financeiros oriundos do PPI IoT/Manufatura 4.0 do MCTI, através do Termo de Cooperação 052/2023, firmado com a EMBRAPII. Adicionalmente, os autores também agradecem o apoio financeiro do CNPq, da CAPES, da FINEP, da FAPEMIG (Contracts PPE-00124-23, RED-00194-23 and APQ-02746-21) e da FAPESP (Contratos 2021/06569-1 e 2022/09319-9).

REFERÊNCIAS

- [1] B. Sadoun and O. Al-Bayari, "Location-based services using geographical information systems," *Comput. Commun.*, vol. 30, pp. 3154-3160, 2007.
- [2] D. Dao, C. Rizos, and J. Wang, "Location-based services: technical and business issues," *GPS Solutions*, vol. 6, pp. 169–178, 2002.
- [3] P. Torres, H. Marques, and P. Marques, "Pedestrian Detection with LiDAR Technology in Smart-City Deployments—Challenges and Recommendations," *Computers*, vol. 12, no. 65, 2023.
- [4] M. Dias, A. Klautau, N. González-Prelcic, and R. W. Heath, "Position and LiDAR-aided mmWave beam selection using deep learning," in *Proc. 2019 IEEE 20th Int. Workshop on Signal Processing Advances in Wireless Communications*, Cannes, France, 2019, pp. 1-5.
- [5] S.-H. Chan, P.-T. Wu, and L.-C. Fu, "Robust 2D Indoor Localization Through Laser SLAM and Visual SLAM Fusion," in *Proc. 2018 IEEE Int. Conf. on Systems, Man, and Cybernetics*, Miyazaki, Japan, 2018, pp. 1263-1268.
- [6] M. Pierzchała, P. Giguère, and R. Astrup, "Mapping Forests Using an Unmanned Ground Vehicle with 3D LiDAR and Graph-SLAM," *Comput. Electron. Agric.*, vol. 145, pp. 217-225, 2018.
- [7] Q. Zhu, L. Chen, Q. Li, M. Li, A. Nüchter, and J. Wang, "3D LiDAR Point Cloud Based Intersection Recognition for Autonomous Driving," in *Proc. 2012 IEEE Intell. Vehicles Symp.*, Madrid, 2012, pp. 456-461.
- [8] N. Jayaweera, D. Marasinghe, N. Rajatheva, and M. Latva-Aho, "Factory Automation: Resource Allocation of an Elevated LiDAR System with URLLC Requirements," in *Proc. 2020 2nd 6G Wireless Summit (6G SUMMIT)*, Levi, Finland, 2020, pp. 1-5.
- [9] S. Jiang, G. Charan, and A. Alkhateeb, "LiDAR Aided Future Beam Prediction in Real-World Millimeter Wave V2I Communications," *IEEE Wirel. Commun. Lett.*, vol. 12, no. 2, pp. 212–216, Feb. 2023.
- [10] M. Zecchin, M. B. Mashhadi, M. Jankowski, D. Gündüz, M. Kountouris, and D. Gesbert, "LiDAR and Position-Aided mmWave Beam Selection With Non-Local CNNs and Curriculum Training," *IEEE Trans. Veh. Technol.*, vol. 71, no. 3, pp. 2979-2990, Mar. 2022.
- [11] S. Wu, C. Chakrabarti, and A. Alkhateeb, "Proactively Predicting Dynamic 6G Link Blockages Using LiDAR and In-Band Signatures," *IEEE Open J. Commun. Soc.*, vol. 4, pp. 392-412, 2023.
- [12] R. Chen, M. Liu, Y. Hui, N. Cheng, and J. Li, "Reconfigurable Intelligent Surfaces for 6G IoT Wireless Positioning: A Contemporary Survey," *IEEE Internet Things J.*, vol. 9, no. 23, pp. 23570-23582, Dec. 2022.
- [13] E. R. Neto, M. F. Silva, T. P. V. Andrade, and A. C. S. Junior, "ANN-Based LiDAR Positioning System for B5G," *Micromachines*, vol. 15, no. 620, pp. 1-16, May 2024. DOI: <https://doi.org/10.3390/mi15050620>.
- [14] E. R. Neto, M. F. Silva, and A. C. S. Junior, "ANN-Based LiDAR Positioning System for B5G," *2023 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC)*, Santa Rita do Sapucaí, Brazil, 2023, pp. 1-8.
- [15] M. T. Hoang, B. Yuen, X. Dong, T. Lu, R. Westendorp, and K. Reddy, "Recurrent neural networks for accurate RSSI indoor localization," *IEEE Internet of Things Journal*, vol. 6, no. 6, pp. 10639-10651, Dec. 2019.
- [16] C. Jiang, J. Shen, S. Chen, Y. Chen, D. Liu, and Y. Bo, "UWB NLOS/LOS classification using deep learning method," *IEEE Communications Letters*, vol. 24, no. 10, pp. 2226-2230, Oct. 2020.
- [17] M. Zhou, Y. Tang, Z. Tian, L. Xie, and W. Nie, "Robust neighborhood graphing for semi-supervised indoor localization with light-loaded location fingerprinting," *IEEE Internet of Things Journal*, vol. 5, no. 5, pp. 3378-3387, Oct. 2018.
- [18] A. Klautau, N. González-Prelcic, and R. W. Heath, "LiDAR data for deep learning-based mmWave beam-selection," *IEEE Wireless Communications Letters*, vol. 8, no. 3, pp. 909-912, June 2019.
- [19] M. Zecchin, M. B. Mashhadi, M. Jankowski, D. Gündüz, M. Kountouris, and D. Gesbert, "LiDAR and position-aided mmWave beam selection with non-local CNNs and curriculum training," *IEEE Transactions on Vehicular Technology*, vol. 71, no. 3, pp. 2979-2990, March 2022.
- [20] S. Jiang, G. Charan, and A. Alkhateeb, "LiDAR aided future beam prediction in real-world millimeter wave V2I communications," *IEEE Wireless Communications Letters*, vol. 12, no. 2, pp. 212-216, Feb. 2023.
- [21] H. Gao, B. Cheng, J. Wang, K. Li, J. Zhao, and D. Li, "Object classification using CNN-based fusion of vision and LiDAR in autonomous vehicle environment," *IEEE Transactions on Industrial Informatics*, vol. 14, no. 9, pp. 4224-4231, Sept. 2018.
- [22] H. Wang, B. Wang, B. Liu, X. Meng, and G. Yang, "Pedestrian recognition and tracking using 3D LiDAR for autonomous vehicle," *Robotics and Autonomous Systems*, vol. 88, pp. 71-78, 2017.
- [23] S. Yoon, H.-W. Jung, H. Jung, K. Kim, S.-K. Hong, H. Roh, and B.-M. Oh, "Development and validation of 2D-LiDAR-based gait analysis instrument and algorithm," *Sensors*, vol. 21, no. 2, article 414, 2021.
- [24] H. T. Duong and Y. S. Suh, "Human gait estimation using multiple 2D LiDARs," *IEEE Access*, vol. 9, pp. 56881-56892, 2021.
- [25] O. Rinchi, A. Alsharoha, and I. Shatnawi, "Deep-learning-based accurate beamforming prediction using LiDAR-assisted network," in *Proc. 2023 IEEE 34th Annu. Int. Symp. Personal, Indoor, and Mobile Radio Communications (PIMRC)*, Toronto, ON, Canada, 2023, pp. 1-5.
- [26] "RPLiDAR S2," Available: <https://www.slamtec.ai/product/slamtec-rplidar-s2/>. Accessed on: Feb 14, 2023.
- [27] A. Vijaya and M. Sundaresan, "Significant image enhancement technique for removal of noise in LiDAR images," *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)*, New Delhi, India, 2016, pp. 3904-3908.
- [28] "Ouster OS1 LiDAR Sensor," Available: <https://ouster.com/products/hardware/os1-lidar-sensor>. Accessed on: May 22, 2024.
- [29] H. Kitaoka, K. Amano, N. Nishi, and T. Sakka, "Improvement of the Nelder-Mead Method Using Direct Inversion in Iterative Subspace," *Optimization and Engineering*, vol. 23, pp. 1033-1055, 2021.