# Investigação de Técnicas LiDAR SLAM para um Dispositivo Robótico de Inspeção de Ambientes Confinados \*

### Gilmar Pereira da Cruz Júnior \* Lucas Vinicius do Carmo Matos \*\* Héctor Azpúrua \*\*\* Gustavo Pessin \*\*\* Gustavo Medeiros Freitas \*

 \* Programa de Pós-Graduação em Engenharia Elétrica Universidade Federal de Minas Gerais
 \*\* Escola de Engenharia, Universidade Federal de Minas Gerais e-mails: (gilmarpcjunior,lucasvini,gustavomfreitas)@ufmg.br \*\*\* Instituto Tecnológico Vale e-mails: (hector.azpurua,gustavo.pessin)@itv.org

Abstract: The exploration and monitoring of confined environments present in industrial and mining areas pose risks to the operators involved. To improve operational safety, the Instituto Tecnológico Vale in partnership with the Universidade Federal de Minas Gerais have been developing the EspeleoRobô, a robotic platform to inspect natural caves, dams and drain galleries. These environments present great challenges to robotics, especially to estimate the robot's pose and map the surrounding environment, that are essential for autonomous navigation. An appropriate strategy consists of applying Simultaneous Location and Mapping (SLAM) techniques based on LiDAR sensors, which provide accurate distance measurements, regardless of lighting conditions. This article investigates three techniques of LiDAR SLAM – LOAM-Velodyne, LeGO-LOAM, and HDL-Graph-SLAM, seeking to determine the most suitable implementation for the EspeleoRobô. Laboratory and field experiments illustrate the performance of each technique, which are compared with respect to the accuracy, noise level, and processing time required for pose estimation and mapping.

**Resumo**: A exploração e monitoramento de ambientes confinados, presentes em áreas de produção industrial e mineração, representam riscos aos operadores envolvidos. Buscando maior segurança operacional, o Instituto Tecnológico Vale, em parceria com a Universidade Federal de Minas Gerais, vem desenvolvendo o EspeleoRobô, uma plataforma robótica utilizada na inspeção de cavidades naturais e galerias de barragens e dreno. Estes ambientes apresentam grandes desafios à robótica, principalmente em relação à estimação da pose do robô e geração de mapas do ambiente, essenciais para a navegação autônoma. Uma estratégia adequada consiste na aplicação de técnicas de Localização e Mapeamento Simultâneos (SLAM) baseadas em sensores LiDAR, que fornecem medidas de distâncias precisas, independente das condições de iluminação. Este artigo investiga três técnicas de LiDAR SLAM – LOAM-Velodyne, LeGO-LOAM e HDL-Graph-SLAM, buscando determinar a implementação mais adequada para o EspeleoRobô. Experimentos em laboratório e campo são utilizados para comparar o desempenho das técnicas, analisando precisão, nível de ruído e tempo de processamento para o cálculo da odometria e registro do mapa.

*Keywords:* Mobile Robotics; LiDAR SLAM; Service Robots; Confined Environments. *Palavras-chaves:* Robótica Móvel; LiDAR SLAM; Robôs de Serviço; Ambientes Confinados.

# 1. INTRODUÇÃO

Segundo a norma regulamentadora brasileira NR-33 (BRA-SIL, 2006), ambientes confinados são espaços não projetados para ocupação humana com acesso restrito, baixa ventilação e luminosidade que apresentam risco a vida de pessoas que precisam trabalhar nessas áreas. Muitos desses ambientes estão presentes na indústria e mineração, incluindo galerias de dreno, barragens, moinhos, silos, que requerem manutenção constante. Outro ambiente confinado comumente encontrado em regiões de mineração são as cavernas naturais, que apresentam riscos de desabamento, presença de gases tóxicos, fungos, animais peçonhentos, entre outros.

Uma opção para realização de tarefas como inspeção, monitoramento e mapeamento de ambientes confinados

<sup>\*</sup> Este trabalho foi parcialmente financiado pela Vale S.A. e Instituto Tecnológico Vale (ITV), Universidade Federal de Minas Gerais (UFMG), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001.

consiste no uso de robôs móveis evitando a exposição de operadores aos riscos. Neste contexto, o Instituto Tecnológico Vale (ITV) juntamente com a Universidade Federal de Minas Gerais (UFMG) vêm desenvolvendo um dispositivo robótico denominado de EspeleoRobô (Fig. 1). O robô teleoperado foi originalmente desenvolvido para a inspeção de cavernas naturais, e agora está sendo utilizado para monitorar galerias de barragens e drenos, e moinhos de bolas (Azpurua et al., 2019).



Figura 1. EspeleoRobô no laboratório e explorando uma galeria de mineração.

Buscando aumentar o grau de autonomia do dispositivo robótico, estão sendo estudadas técnicas de localização e mapeamento de forma a possibilitar a navegação autônoma do EspeleoRobô em ambientes confinados. Do ponto de vista da robótica, ambientes confinados apresentam grandes desafios para a operação autônoma. Este complexo problema é investigado pela agência de defesa americana através do *Darpa Subterranean Challenge*<sup>1</sup>, que propõe a utilização de robôs para exploração de túneis, metrôs e cavernas.

A falta de sinal de GPS e interferências em magnetômetros podem impossibilitar a utilização destes sensores para a estimação da pose do robô num ambiente confinado. Solos escorregadios acarretam acúmulos expressivos de erros durante o cálculo da odometria através do giro das rodas. Uma possível solução consiste no emprego de técnicas de SLAM (*Simultaneous Localization And Mapping*) para estimar, de forma simultânea, a localização do dispositivo e o mapa do ambiente de operação. No entanto, a baixa luminosidade pode gerar erros na identificação de *features*, prejudicando o desempenho de estratégias de SLAM visuais. Outra opção mais adequada consiste na utilização de técnicas de SLAM baseadas em sensores LiDAR (*Light Detection And Ranging*), que fornecem medidas precisas de distância independente das condições de iluminação.

Técnicas de odometria e mapeamento 3D usando sensores LiDAR são o foco de algumas pesquisas sobre SLAM. Cole and Newman (2006) realizaram uma extensão das técnicas de SLAM 2D para 3D usando um sensor LiDAR montado em um veículo terrestre. Desenvolvido para mapeamentos de ambientes *outdoor*, esta estratégia emprega segmentação para separar os dados da nuvem de pontos e um Filtro de Kalman Extendido (EKF) de Estado Atrasado para estimar a pose (posição e orientação) do dispositivo. Uma das metodologias de 3D LiDAR SLAM mais empregadas atualmente é denominada de LOAM (*Lidar Odometry And Mapping*), uma técnica em tempo real baseada no algorítmo ICP – *Itecractive Closest Points* (Zhang and Singh, 2017). Adotando uma estratégia similar, Shan and Englot (2018) propõem uma adaptação na metodologia LOAM, denominada LeGO-LOAM, otimizada para veículos terrestres. Outra solução apresentada em (Koide et al., 2019), denominada HDL-Graph-SLAM, implementa uma nova técnica de LiDAR SLAM aplicada num sistema para medição e análise de comportamento de pessoas em ambientes *indoor* e *outdoor*. Implementações baseadas em inteligência artificial também são investigadas, como Cho et al. (2019) que propõem uma abordagem de odometria LiDAR baseada em uma Rede Neural Convolucional (RNC).

Visando determinar a técnica de LiDAR SLAM mais adequada para o EspeleoRobô, este artigo realiza uma comparação entre 3 técnicas de SLAM 3D baseadas em sensor LiDAR: LOAM-Velodyne, LeGO-LOAM e HDL-Graph-SLAM. Resultados obtidos durante experimentos de laboratório e campo são utilizados em análises qualitativas e quantitativas de estimação de poses e geração de mapas. Neste sentido, 6 métricas são propostas para avaliar o desempenho de cada técnica com respeito à precisão, nível de ruído e tempo de processamento entre estimativas de pose.

Este artigo está dividido em 5 seções. A primeira Seção relata os problemas a serem enfrentados pelo EspeleoRobô na realização das suas atividades, e comenta sobre algumas implementações de técnicas de LiDAR SLAM. A segunda Seção descreve a estrutura do robô e os sensores embarcados. A terceira Seção relata as principais etapas do SLAM 3D utilizando sensor LiDAR. A quarta Seção descreve os experimentos realizados e discursa sobre os resultados obtidos. A quinta Seção apresenta a conclusão e trabalhos futuros.

# 2. PLATAFORMA ROBÓTICA

O EspeleoRobô foi projetado para atuar em campo inspecionando ambientes insalubres e dispõe de um encapsulamento atendendo a certificação IP67. A estrutura do seu chassi possui dimensões de 0,  $55 \times 0$ ,  $25 \times 0$ , 14 m e peso de 28, 0 kg com capacidade de carga extra de 10 kg. Capaz de se adaptar a diferentes terrenos, o robô pode se mover com diferentes tipos de mecanismos de locomoção, projetados para fácil troca através de pinos de engate rápido.

O robô está equipado com 6 conjuntos de caixas de redução, motores, encoders e Power Drivers MCP EPOS da Maxon Motors; duas baterias militares Bren-Tronics; um par de câmeras Axis P12 HD com LEDs e sistemas de iluminação IR; e um mini PC Intel NUC Core I5 com 16Gb de memória RAM rodando o meta-sistema operacional Robot Operating System – ROS (Quigley et al., 2009), no Ubuntu 16.04. Para comunicação o robô dispõe de um sistema de rádio Ubiquinti Rocket M900. O dispositivo possui também um sensor Ouster OS1-16 multi-flash Li-DAR<sup>2</sup> e uma Xsense MTi-G-710 GNSS/INS<sup>3</sup>, utilizados nos experimentos deste artigo, além de uma câmera Intel RealSense Tracking T265 $^4\,$ e um módulo UWB Decawave DWM1001<sup>5</sup>. A Figura 2 mostra uma visão geral do EspeleoRobô com uma descrição dos seus equipamentos e sensores.

<sup>3</sup> https://www.xsens.com/products/mti-100-series

 $<sup>^2</sup>$  https://ouster.com/products/os1-LiDAR-sensor/

<sup>&</sup>lt;sup>4</sup> https://www.intelrealsense.com/tracking-camera-t265/

<sup>&</sup>lt;sup>5</sup> https://www.decawave.com/product/dwm1001-module/

 $<sup>^1</sup>$  https://www.subtchallenge.com/



Figura 2. Visão geral do EspeleoRobô com seus equipamentos e sensores.

#### 3. SLAM UTILIZANDO SENSOR LIDAR

De forma geral as abordagens de SLAM buscam resolver os problemas de localização e mapeamento de forma simultânea. Os dois problemas são dependentes, pois para se determinar a posição de um robô é necessário um mapa do ambiente ao redor, e para construir um mapa é necessário conhecer a localização do robô.

As técnicas de LiDAR SLAM geralmente seguem as seguintes etapas para resolver o problema do SLAM, podendo variar de acordo com a abordagem utilizada (Siciliano and Khatib, 2016):

- Aquisição de dados: registra os pontos, eliminando ruídos e distorções utilizando ou não dados da IMU, e realiza transformações necessárias para construção da nuvem de pontos;
- *Extração de features*: utiliza os pontos pertencentes às quinas e planos;
- Estimação da pose: calcula a pose a partir de duas varreduras do sensor, utilizando técnicas de otimização para matching;
- Mapeamento: registra os pontos por meio da fusão de múltiplas varreduras em estruturas de dados;
- Integração das transformações: combina as poses dadas pelos algoritmos de Estimação da pose e Mapeamento.

O restante dessa seção descreve as técnicas de SLAM 3D baseada em sensor LiDAR e suas características, assim como as metodologias utilizadas nos experimentos.

### 3.1 Aquisição de Dados por Sensor LiDAR

Sensores a laser capturam as caraterísticas do ambiente por meio da detecção de feixes de luz refletidos. Baseado no princípio de ToF (*Time of Flight*), estes dispositivos medem o tempo que a luz emitida retorna após ser refletida por uma superfície. Esse tipo de sensor permite, teoricamente, uma medida de profundidade com precisão na ordem de centímetros (Siciliano and Khatib, 2016).

Para aplicações em robótica, que necessitam de muita informação do ambiente, sensores LiDAR do tipo *Scanning* 3D são mais utilizados devido a suas representações densas. Os dados gerados pelos sensores 3D são comumente expressos na forma de uma lista  $[x_i \ y_i \ z_i]^T$ , denominada de nuvem de pontos. Uma visão geral dos diferentes sensores LiDAR pode ser encontrada em (Wong et al., 2011), que apresenta uma descrição e comparação de diferentes sensores.

### 3.2 Extração de Features do Ambiente

As principais estruturas 3D para representação de *features* para sensores LiDAR são planos e segmentos de retas.

Superfícies planares podem ser representadas por uma equação matemática. A sua extração em uma nuvem de pontos é um problema de modelagem, no qual se determina um conjunto de planos que descrevem os pontos. Uma solução possível é uma adaptação do algoritmo RANSAC (*Random Sample Consensum*) (Fischler and Bolles, 1981).

Segmentos de reta são comumente encontrados em ambientes como quinas de portas, encontro de paredes com pisos e bordas de objetos, porém são mais difíceis de se determinar. Esse tipo de *feature* geralmente é extraída de forma indireta, como exemplo, após a extração de planos.

Uma solução para a classificação de pontos em bordas ou plano foi implementada por Zhang and Singh (2017), que utilizam uma equação de suavidade normalizada dada por:

$$c = \frac{1}{|\mathcal{S}|} \| \mathbf{p}_{Ln,i} \| \sum_{k \in \mathcal{S}, k \neq n} (\mathbf{p}_{Ln,i} - \mathbf{p}_{Lk,i}) \|, \quad (1)$$

no qual  $\mathbf{p}_{Ln,i}$  é o vetor da coordenada 3D de um ponto *n* na varredura *i* do sensor LiDAR,  $\mathbf{p}_{Lk,i}$  é o vetor de um ponto *k* da varredura *i* e S é o conjunto de pontos nas proximidades do ponto *n*. Desta forma, os pontos são classificados como bordas quando o valor *c* é maior que um limiar máximo, ou pertencentes a um plano quando o valor de *c* é menor que um limiar mínimo.

#### 3.3 Estimação da Pose do Dispositivo

A estimação da pose corresponde ao cálculo da posição e orientação de um corpo com respeito a um sistema de coordenadas inercial. Em SLAM usando sensores LiDAR, a pose é calculada pelo alinhamento entre duas nuvens de pontos consecutivas. Três soluções possíveis são: estimação da pose por um conjunto de pontos, por linhas retas e por planos. Os três são resolvidos por problemas de otimização usando uma função de custo, como na equação 2:

$$e(R, \mathbf{p}) = \sum_{j} \|\mathbf{p}_{L, i-1, j} - (R \ \mathbf{p}_{L, i, j} - \mathbf{p})\|_{H}^{2}, \quad (2)$$

no qual  $e(R, \mathbf{p})$  equivale a um erro a ser minimizado,  $R \in SO(3)$  é uma matriz de rotação,  $\mathbf{p} \in \mathbb{R}^3$  é o vetor de translação entre duas varreduras do sensor,  $\mathbf{p}_{L,i,j}$  é a coordenada o ponto j para a varredura i, e H é uma matriz positiva definida de ganhos.

Uma solução envolvendo conjunto de pontos é o algoritmo *Iteractive Closest Points* (ICP), um método iterativo que utiliza uma distância máxima para analisar os pontos mais próximos, determinando um conjuntos de pontos parcialmente sobrepostos. Outras formas encontradas para resolver o problema de otimização, dada pela equação 2, são os métodos de mínimo quadrados como Levenberg-Marquadt, métodos de Gradientes Conjugados, e Gauss-Newton (Shirangi and Emerick, 2016).

### 3.4 Mapeamento de Ambientes

O mapeamento de ambientes escaneados por um sensor LiDAR nada mais é que o registro de múltiplas varreduras. Para realizar o alinhamento das nuvens de pontos com o mapa, técnicas de otimização geralmente são aplicadas, como as descritas na subseção 3.3.

Para salvar os pontos detectados, duas estruturas de performance similares em forma de árvore são comumente utilizadas: Octrees e KD-trees. Octrees são estruturas de dados hierárquicas de subdivisão de espaços, onde cada nó representa o espaço contendo um voxel (Meagher, 1982). O volume da estrutura é subdividido de forma recursiva em oito partes com uma certa profundidade. KD-trees são estruturas semelhantes, porém subdividem os espaços sempre em duas regiões até uma profundidade definida (Ooi, 1987).

# 3.5 Técnicas de LiDAR SLAM Investigadas

As técnicas de LiDAR SLAM utilizadas nos experimentos deste artigo possuem abordagens diferentes, porém seguem um padrão para solução do SLAM subdividindo o problema em dois subproblemas.

### LOAM-Velodyne:

A técnica LOAM-Velodyne é uma proposta em tempo real desenvolvida em (Zhang and Singh, 2017), que possui baixo erro de desvio da odometria e dispensa o uso de técnicas de *loop closure*. A metodologia é subdivida em 4 etapas: Registro da Nuvem de Pontos, Odometria LiDAR, Mapeamento LiDAR e Integração das Transformações, como mostrados na Figura 3.



Figura 3. Visão geral da técnica LOAM-Velodyne.

No módulo Registro da Nuvem de Pontos o algoritmo permite o ajuste da distorção da nuvem por meio dos dados fornecidos pela IMU. As *features são extraídas* destacando as bordas e os planos conforme a equação 1. No módulo de Odometria LiDAR, o método Levenberg-Marquardt é utilizado para determinar a pose do dispositivo. Para o mapeamento LiDAR é utilizado uma estrutura do tipo KD-tree, onde o alinhamento do mapa é feito utilizando um método similar ao ICP. A mesma técnica de otimização, Levenberg-Marquardt, é aplicada para determinação da pose em relação ao mapa. No módulo de Integração das transformações as poses retornadas pelos módulos de Odometria LiDAR e Mapeamento LiDAR são fundidas gerando uma pose integrada, baseado no método de otimização descrito em (Kaess et al., 2012).

### LeGO-LOAM:

A técnica LeGO-LOAM é uma versão mais leve do LOAM-Velodyne otimizada para veículos terrestres, que obtém estimativas de pose em tempo real em um sistema embarcado de baixo consumo energético, por exemplo uma Jetson Nano (Shan and Englot, 2018). As principais diferenças entre as técnicas são: a opção de uso de *loop closure*, permitindo a correção tanto da estimação da pose quanto do mapa. Para determinar as componentes da pose, dada pela translação  $[x \ y \ z]^T$  e orientação  $[\phi \ \theta \ \psi]^T$ , é utilizado o método de Levenberg-Marquardt em duas etapas. Por meio dos pontos detectados no piso, calcula-se as translações em  $x \ e \ y$  e a rotação  $\psi$ , e com os pontos de bordas calcula-se as rotações  $\phi \ e \ \theta$  e a translação em z. A visão geral do sistema pode ser vista na Figura 4.



Figura 4. Visão geral da técnica LeGO-LOAM.

### HDL-Graph-SLAM:

O HDL-Graph-SLAM é um sistema de medição de comportamento de pessoas utilizando um sensor LiDAR, desenvolvido em (Koide et al., 2019). A metodologia realiza a estimação da pose do dispositivo, mapeamento do ambiente e rastreamento de pessoas próximas. Para auxilio da estimação da pose, a metodologia utiliza um sistema de detecção de *features* no plano do piso juntamente com uma IMU, para o uso em ambientes *indoor*, e GPS para ambientes *outdoor*. A Figura 5 mostra uma visão geral do sistema.



Figura 5. Visão geral da técnica HDL-Graph-SLAM.

Para a extração de *features* da nuvem de pontos, a técnica HDL-Graph-SLAM utiliza o algoritmo RANSAC. Estas informações são utilizadas como restrições na determinação da pose do dispositivo, que é estimada utilizando o método NDT (*Normal Distribution Transform*) Scan Matching. O mapeamento é gerado pelo algoritmo Graph SLAM, que aplica método de otimização para alinhamento dos pontos e estimação da pose em relação ao mapa. Para determinar a localização do sensor, etapa equivalente à Integração de Transformações, o sistema utiliza um filtro UKF (Unscented Kalman Filter). Assim como o LeGO-LOAM, a abordagem possui a opção de habilitar a técnica de *loop closure*.

# 4. EXPERIMENTOS E RESULTADOS

Esta seção descreve os experimentos realizados para avaliar as técnicas de LiDAR SLAM descritas na Subseção 3.5. Para fins de comparação, foi analisado também a odometria das rodas, já implementada no EspeleoRobô, fundida com os dados da IMU utilizando um filtro EKF (*Extended Kalman Filter*). Nesses experimentos o robô foi teleoperado e os testes foram realizados em laboratório e em campo, na Mina Du Veloso na cidade de Ouro Preto-MG, Brasil. Os experimentos de laboratório foram realizados em corredores do prédio da Escola de Engenharia da UFMG. Este ambiente possui superfícies planas com um alto coeficiente de atrito e muitas *features* como quinas de portas, janelas e pilastras. O experimento de campo na Mina Du Veloso é utilizado para verificar o desempenho das técnicas em condições reais de operação. A Figura 6 ilustra os ambientes utilizados.



Figura 6. Localização dos experimentos: (a) Corredor reto,
(b) Caminho fechado dentro dos corredores e (c) Mina Du Veloso.

As técnicas de LiDAR SLAM, implementadas como pacotes do ROS LOAM-Velodyne <sup>6</sup>, LeGO-LOAM <sup>7</sup> e HDL-Graph-SLAM <sup>8</sup>, foram adaptadas para utilização do sensor LiDAR Ouster OS1-16 e embarcadas no EspeleoRobô. Os 3 pacotes foram executados *offline* num computador Intel(R) Core(TM) i5-3210M de 2.5GHz com 4Gb de RAM, processando dados de um arquivo de extensão *.bag* do ROS publicados na mesma frequência em que foram gravados durante os experimentos. Para fundir a odometria das rodas com a IMU foi utilizado o pacote do ROS robot\_pose\_ekf<sup>9</sup>.

Para análise das técnicas de LiDAR SLAM foram propostas 6 métricas. Em relação às odometrias, considera-se  $\mathbf{p}[k] \in \mathbb{R}^3$  como a posição estimada do robô por cada uma das técnicas no instante k com um total de N iterações.

A primeira métrica, usada para avaliar os experimentos realizados em laboratório, compara o caminho percorrido pelo robô com uma distância de referência  $l_{max}$ . A métrica  $\mathcal{M}_1$  é dada por:

$$\mathcal{M}_{1} = \left| \sum_{k=1}^{N-1} \| \mathbf{p}[k+1] - \mathbf{p}[k] \| - l_{max} \right| l_{max}^{-1}, \quad (3)$$

A segunda métrica foi proposta para os experimentos onde o robô retorna à posição inicial. A métrica  $\mathcal{M}_2$  é a medida do erro acumulado pela odometria dado por:

$$\mathcal{M}_2 = \|\mathbf{p}[N] - \mathbf{p}[1]\|,\tag{4}$$

A terceira métrica,  $\mathcal{M}_3$ , quantifica o quão ruidoso é o sinal da odometria, dado pela mínima distância da posição  $\mathbf{p}[k]$ no instante de tempo k em relação a um segmento de reta formado pelas posições  $\mathbf{p}[k-n] \in \mathbf{p}[k+n]$ . A métrica  $\mathcal{M}_3$ corresponde ao ruído médio, calculado por:

$$\mathcal{M}_3 = \frac{1}{N-2n} \sum_{k=n+1}^{N-n} \frac{\|\mathbf{q}_{k-n,k+n} \times \mathbf{q}_{k,k-n}\|}{\|\mathbf{q}_{k-n,k+n}\|}$$
(5)

onde  $\mathbf{q}_{k-n,k+n}$  é o vetor formado pelas posições  $\mathbf{p}[k-n]$ e  $\mathbf{p}[k+n]$ , e  $\mathbf{q}_{k,k-n}$  é o vetor formado pelas posições  $\mathbf{p}[k]$ e  $\mathbf{p}[k-n]$ . Para os experimentos foi determinado o valor de *n* de forma que o segmento de reta  $\mathbf{q}_{k-n,k+n}$  não fosse grande o suficiente para comprometer os resultados.

A quarta e quinta métricas fornecem uma estimativa da variação entre os resultados obtidos pelas diferentes técnicas de localização, calculando o erro médio e a variância com respeito às posições  $\mathbf{p}_g[k]$  fornecidas pela técnica de SLAM com melhor precisão. A escolha desta técnica utilizada como referência pode ser feita com base nos resultados obtidos por  $\mathcal{M}_1$ ,  $\mathcal{M}_2$  e  $\mathcal{M}_3$ . As métricas  $\mathcal{M}_4$  e  $\mathcal{M}_5$  são obtidas por:

$$\mathcal{M}_4 = \frac{1}{N} \sum_{k=1}^{N} (\mathbf{p}[k] - \mathbf{p}_g[k]), \tag{6}$$

$$\mathcal{M}_5 = \frac{1}{N-1} \sum_{k=1}^{N} (\mathbf{p}[k] - \mathcal{M}_4)^2, \tag{7}$$

A sexta métrica descreve o tempo de processamento médio entre a estimação de duas poses consecutivas p[k] e p[k-1]. A métrica  $\mathcal{M}_6$  é calculada com:

$$\mathcal{M}_6 = \frac{1}{N-1} \sum_{k=2}^{N} (t[k] - t[k-1]), \tag{8}$$

onde t[k] é o tempo da estimação da posição p[k] do robô no instante k em relação ao inicio do experimento.

#### 4.1 Percorrendo um Corredor Reto

Este experimento avalia a estimação de poses computadas enquanto o robôs se move dentro de um corredor reto. Controlado remotamente por um operador, o robô realiza um percurso em linha reta de 22, 3 m, vira 180° e retorna para o ponto de partida executando um percurso com perfil senoidal. As métricas  $\mathcal{M}_1$  com  $l_{max} = 22, 3$  m e  $\mathcal{M}_2$  são utilizadas para avaliar a precisão das posições computadas. O nível de ruído associado é quantificado pela métrica  $\mathcal{M}_3$ . As métricas  $\mathcal{M}_4$  e  $\mathcal{M}_5$  fornecem uma estimativa da variação entre os resultados obtidos pelas diferentes estratégias, utilizando como referência a técnica com melhor precisão. O tempo de processamento entre estimações é indicado pela métrica  $\mathcal{M}_6$ .

A Figura 7 e Tabela 1 apresentam os resultados relativos às localizações do robô computadas por cada técnica. Nesta figura, a posição inicial do robô está marcada com um círculo cheio, e a posição final com um círculo vazio.

Tabela 1. Resultado das métricas para o experimento percorrendo um corredor reto.

SLAM/Métricas	$\mathcal{M}_1[\%]$	$\mathcal{M}_2[\mathrm{m}]$	$\mathcal{M}_3[\mathrm{m}]$	$\mathcal{M}_4[\mathrm{m}]$	$\mathcal{M}_5[\mathrm{m}]$	$\mathcal{M}_{6}[s]$
LOAM-Velodyne	0,071	0,731	0,016	0,632	0,093	0,128
LeGO-LOAM	0,082	0,120	0,010	-	-	0,100
HDL-Graph-SLAM	0,033	0,215	0,005	0,267	0,015	0,100
Rodas+IMU	0,008	1,763	0,001	1,036	$0,\!279$	0,039

A odometria das rodas com filtro EKF obteve a melhor precisão na estimação da distância percorrida de acordo com a métrica  $\mathcal{M}_1$ , com um erro de 18 cm, equivalente a

 $<sup>^{6}~{\</sup>rm https://github.com/laboshinl/loam_velodyne}$ 

<sup>&</sup>lt;sup>7</sup> https://github.com/RobustFieldAutonomyLab/LeGO-LOAM

<sup>&</sup>lt;sup>8</sup> https://github.com/koide3/hdl\_graph\_slam

<sup>&</sup>lt;sup>9</sup> https://github.com/ros-planning/robot pose ekf



Figura 7. Visão em perspectiva e superior dos resultados do experimento percorrendo um corredor reto.

0,8% do percurso de ida em linha reta. Porém, a estimativa diverge ao realizar curvas, como ocorre no percurso de volta, finalizando o experimento com um erro acumulado  $(\mathcal{M}_2)$  de 1,76 m. Devido ao processo de integração, o nível de ruído  $(\mathcal{M}_3)$  e tempo de processamentos entre poses  $(\mathcal{M}_6)$  são baixos.

Neste experimento a técnica LOAM-Velodyne obteve melhor precisão que o LeGO-LOAM, com erro de 1,58 m equivalente a 7,1% do comprimento total do percurso  $(\mathcal{M}_1)$ . Porém os resultados do LOAM-Velodyne foram inferiores aos obtidos pelas outras técnicas de LiDAR SLAM, incluindo erro acumulado  $(\mathcal{M}_2)$  de 73, 1 cm, com maiores níveis de ruído médio  $(\mathcal{M}_3)$  e tempo de processamento entre estimativas ( $\mathcal{M}_6$ ). As técnicas LeGO-LOAM e HDL-Graph-SLAM obtiveram tempo de processamento similar (0,1 s) e baixo nível de ruído, na casa dos centímetros. Porém, a técnica HDL-Graph-SLAM, mesmo possuindo uma boa precisão expressa pela métrica  $\mathcal{M}_1$ , com um erro de 3,3% contra 8,2% da técnica LeGO-LOAM, obteve um desvio consideravelmente maior em relação à métrica  $\mathcal{M}_2$ , com uma diferença de 21,5 cm entre posições final e inicial, contra 12 cm obtido pela técnica LeGO-LOAM.

Devido a consistência do conjunto dos resultados obtidos em todos os experimentos, a técnica LeGO-LOAM foi utilizada como referência para o cálculo das métricas  $\mathcal{M}_4$ e  $\mathcal{M}_5$ , que quantificam o erro médio e variância das poses estimadas pelas demais técnicas. Tanto a odometria das rodas com filtro EKF quanto a técnica LOAM-Velodyne apresentaram erros médios elevados em relação ao LeGO-LOAM, com valores de 1,03 m e 63,2 cm respectivamente. A técnica HDL-Graph-SLAM obteve resultado muito próximo do LeGO-LOAM durante todo o percurso, com um erro médio de 26,7 cm e variância de 1,5 cm. Os resultados podem ser vistos em detalhes na Figura 8, que ilustra as variações na estimação de posições computadas pelas técnicas avaliadas com respeito ao LeGO-LOAM.



rendo um corredor reto com respeito à técnica LeGO-LOAM.

4.2 Percorrendo Corredores em um Circuito Fechado

Neste experimento o robô, comandado por um operador remoto, executa duas voltas em um caminho fechado dentro dos corredores do prédio das Engenharias na UFMG, percorrendo uma distância total de 270 m, parando na mesma posição de início. Os resultados obtidos podem ser vistos na Figura 9 e Tabela 2, que ilustram as odometrias estimadas e as respectivas métricas calculadas, e na Figura 10 que apresenta os mapas gerados por cada umas das técnicas de LiDAR SLAM.



Figura 9. Visão em perspectiva e superior dos resultado do experimento percorrendo corredores em um circuito fechado.

Tabela 2. Métricas para o experimento percorrendo um circuito fechado.

SLAM/Métricas	$\mathcal{M}_1[\%]$	$\mathcal{M}_2[m]$	$\mathcal{M}_3[m]$	$\mathcal{M}_4[\mathrm{m}]$	$\mathcal{M}_5[\mathrm{m}]$	$\mathcal{M}_6[s]$
LOAM-Velodyne	1,200	2,872	0,052	2,510	1,944	0,474
LeGO-LOAM	0,200	0,241	0,033	-	-	0,468
HDL-Graph-SLAM	1,100	3,813	0,020	2,042	0,617	0,468
Rodas+IMU	3,000	$3,\!420$	0,002	$5,\!380$	$5,\!292$	0,039

Com respeito ao cálculo da distância percorrida pelo robô expressa pela métrica  $\mathcal{M}_1$ , com  $l_{max} = 270$  m, a odometria das rodas obteve neste experimento a pior precisão, estimando uma distância 3% superior ao caminho executado. A técnica LOAM-Velodyne obteve novamente resultados inferiores às demais técnicas de LiDAR SLAM, com erro de 3,24 m referente à distância percorrida – equivalente a 1,2% do percurso total percorrido ( $\mathcal{M}_1$ ), diferença de 2,87 m entre a posição final e inicial ( $\mathcal{M}_2$ ) e o maior nível de ruído médio ( $\mathcal{M}_3$ ). A técnica HDL-Graph-SLAM, apesar de possuir erro de 1,1% com respeito à distância total percorrida ( $\mathcal{M}_1$ ) e o menor nível de ruído ( $\mathcal{M}_3$ ) entre as técnicas de LiDAR SLAM, finalizou o experimento com uma diferença de 3,81 m da posição inicial, culminando no pior resultado com respeito à  $\mathcal{M}_2$ .

A técnica LeGO-LOAM alcançou os melhores resultados, com uma diferença de 0,2% na distância total percorrida  $(\mathcal{M}_1)$ , erro de 24,1 cm para a posição inicial  $(\mathcal{M}_2)$ , e com um ruído médio de 3,3 cm  $(\mathcal{M}_3)$ . Assim como no experimento anterior, esta técnica foi utilizada como referência para o cálculo das métricas  $\mathcal{M}_4 \in \mathcal{M}_5$ , mensurando a variação das estimativas computadas pelos diferentes métodos. Das técnicas investigadas, o HDL-Graph-SLAM foi o que obteve o menor erro médio com respeito ao LeGO-LOAM, com um valor de 2,04 m, contra 2,51 m obtido pelo LOAM-Velodyne e 5,38 m computado pela odometria das rodas com filtro EKF. A Figura 11 ilustra a variação das estimativas de posição computadas com respeito ao LeGO-LOAM.

O mapa gerado pelo LOAM-Velodyne (Fig. 10(a)) consegue representar o ambiente percorrido pelo robô, porém, por não aplicar a técnica de *loop closure*, este mapa possui algumas deformações e aspecto visivelmente mais poluído. Em contrapartida, o mapa obtido com o LeGO-LOAM (Fig. 10(b)) possui menos distorções e contornos mais regulares devido à ação do *loop closure*, que corrige tanto



Figura 10. Mapas do experimento da Figura 9 para as técnicas: (a) LOAM-Velodyne, (b) LeGO-LOAM e (c) HDL-Graph-SLAM.



Figura 11. Erro das posições para o experimento percorrendo um circuito fechado com respeito à técnica LeGO-LOAM.

a odometria quanto o mapa gerado no início da segunda volta. Já a Fig. 10(c) apresenta o mapa gerado pelo HDL-Graph-SLAM que, assim como LeGO-LOAM, apresenta poucas distorções e contornos bem representados. Porém, erros de estimação da altura durante o cálculo de odometria (ilustrados na Fig. 9) provocam uma elevação de parte do mapa, conforme destacado na imagem em roxo.

Em geral, a técnica LeGO-LOAM obteve um conjunto de resultados mais consistentes dentre os dois experimentos realizados em laboratório, fornecendo estimativas precisas de localização e mapa mais detalhado e representativo.

# 4.3 Experimento de Campo - Mina Du Veloso

Para testar as técnicas de LiDAR SLAM implementadas em campo, foi realizado um experimento na Mina Du Veloso, representando um ambiente real de operação do EspeleoRobô. Pertencente ao complexo de mineração do Veloso na cidade de Ouro Preto, esta foi uma mina de extração de ouro durante os séculos XVIII e XIX. Este ambiente confinado apresenta estruturas irregulares, pisos escorregadios e ausência de sinal de GPS.

Neste experimento o robô executa um caminho curto composto por segmentos retos com pequenas defasagens de orientação, de forma a mapear uma das galerias da mina. Para avaliar a performance das técnicas de LiDAR SLAM foram consideradas as métricas  $\mathcal{M}_3$  para avaliar o ruído nas odometrias,  $\mathcal{M}_4$  e  $\mathcal{M}_5$  para quantificar a variação da localização do robô estimada pelas técnicas com respeito ao LeGO-LOAM, e  $\mathcal{M}_6$  para computar os tempos de processamentos entre poses. A Figura 12 ilustra o caminho estimado por cada técnica, e a Tabela 3 apresenta as respectivas métricas calculadas.

Tabela 3. Métricas para o experimento na Mina

Du Veloso.							
SLAM/Métricas	$\mathcal{M}_3[\mathrm{m}]$	$\mathcal{M}_4[\mathrm{m}]$	$\mathcal{M}_5[\mathrm{m}]$	$\mathcal{M}_6[s]$			
LOAM-Velodyne	0,005	1,252	0,731	0,133			
LeGO-LOAM	0,010	-	-	0,109			
HDL-Graph-SLAM	0,004	0,290	0,039	0,109			
Rodas+IMU	5e-4	0,464	$0,\!145$	0,039			

A odometria das rodas com filtro EKF resultou em pequeno erro médio e variância com respeito ao LeGO-



Figura 12. Visão em perspectiva e superior dos resultado do experimento na Mina Du Veloso.

LOAM, diferentemente dos resultados obtidos em laboratório. Isto ocorreu devido ao percurso realizado pelo robô não possuir curvas acentuadas que aumentam o escorregamento das rodas e acarretam em maiores erros de orientação. A técnica LOAM-Velodyne obteve um nível de ruído médio ( $\mathcal{M}_3$ ) menor neste experimento. Porém, o erro médio ( $\mathcal{M}_4$ ) foi de 1,25 m, terminando o percurso com uma diferença de quase 2 m em relação ao LeGO-LOAM, conforme ilustrado nas Figuras 12 e 13. As técnicas HDL-Graph SLAM e LeGO-LOAM obtiveram novamente resultados muito próximos, com níveis de ruído ( $\mathcal{M}_3$ ) na casa dos centímetros, erro médio ( $\mathcal{M}_4$ ) de 29 cm e variância ( $\mathcal{M}_5$ ) de 3,9 cm.

A Figura 14 ilustra diferentes vistas do mapa gerado pelo LeGO-LOAM na Mina Du Veloso; a linha em vermelho no centro do mapa representa a estimação da odometria. É possível verificar pelas imagens que o mapa corresponde a um modelo geométrico preciso do interior da mina. O nível de detalhamento deste modelo pode ser modificado alterando a profundidade da árvore da estrutura de dados; mapas densos são adequados para a visualização do ambiente, enquanto mapas esparsos podem ser utilizados por sistemas de navegação autônoma, reduzindo o processamento computacional necessário.



Figura 13. Erro das posições para o experimento na Mina Du Veloso com respeito à técnica LeGO-LOAM

## 5. CONCLUSÕES

Buscando determinar a estratégia de localização e mapeamento mais adequada para o EspeleoRobô, este artigo investigou 3 técnicas de LiDAR SLAM: LOAM-Velodyne,



Figura 14. Mapa da Mina Du Veloso gerado pelo LeGO-LOAM: (a) vista em perspectiva, (b) vista superior, (c) vista interna da posição inicial, (d) vista interna a 4m e (e) vista interna a 8m.

LeGO-LOAM e HDL-Graph-SLAM. Além de testes executados nos corredores da UFMG, também foi realizado um experimento de campo na Mina Du Veloso, emulando uma operação de inspeção do Espeleorobô a fim de validar as técnicas num ambiente representativo. Os resultados obtidos são analisados através de 6 diferentes métricas, avaliando a precisão, o nível de ruído e tempo de processamento entre estimativas de pose.

Apesar de muito utilizada, a técnica LOAM-Velodyne apresentou menor precisão e maior nível de ruído com respeito às demais estratégias. A técnica HDL-Graph-SLAM obteve resultados muito próximos aos do LeGO-LOAM, porém com acúmulo de erros na odometria acarretando em menor precisão. A técnica LeGO-LOAM obteve boa performance em todos os experimentos, sendo utilizada como referência para o cálculo do erro associado às outras técnicas de LiDAR SLAM. Devido aos bons resultados, a técnica LeGO-LOAM foi adotada como principal sistema de localização e mapeamento do EspeleoRobô.

Como trabalhos futuros está prevista a implementação de um filtro EKF, fundindo odometria calculada com o Li-DAR e velocidade linear do robô obtida através do giro das rodas; esta estratégia será especialmente útil em ambientes com poucas features, por exemplo longas galerias com paredes uniformes. O sistema de LiDAR SLAM será também utilizado em experimentos de navegação autônoma, fornecendo o mapa do ambiente para o planejamento de caminhos, e estimando a pose do robô para realimentar o controle de navegação.

# REFERÊNCIAS

- Azpurua, H., Rocha, F., Garcia, G., Santos, A.S., Cota, E., Barros, L.G., Thiago, A.S., Pessin, G., and Freitas, G.M. (2019). EspeleoRobô - a robotic device to inspect confined environments. In 2019 19th Int. Conf. on Advanced Robotics (ICAR). IEEE.
- BRASIL (2006). Nr 33 segurança e saúde nos trabalhos em espaços confinados.
- Cho, H.M., Jo, H., Lee, S., and Kim, E. (2019). Odometry estimation via cnn using sparse lidar data. In 2019 16th Int. Conf. on Ubiquitous Robots (UR), 124–127. IEEE.
- Cole, D.M. and Newman, P.M. (2006). Using laser range data for 3d slam in outdoor environments. In Proceedings 2006 IEEE Int. Conf. on Robotics and Automation, 2006. ICRA 2006., 1556–1563. IEEE.

- Fischler, M.A. and Bolles, R.C. (1981). Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, 24(6), 381–395.
- Kaess, M., Johannsson, H., Roberts, R., Ila, V., Leonard, J.J., and Dellaert, F. (2012). isam2: Incremental smoothing and mapping using the bayes tree. *The Int. Journal of Robotics Research*, 31(2), 216–235.
- Koide, K., Miura, J., and Menegatti, E. (2019). A portable three-dimensional lidar-based system for long-term and wide-area people behavior measurement. *Int. Journal of Advanced Robotic Systems*, 16(2), 1729881419841532.
- Meagher, D. (1982). Geometric modeling using octree encoding. Computer graphics and image processing, 19(2), 129–147.
- Ooi, B.C. (1987). Spatial kd-tree: A data structure for geographic database. In *Datenbanksysteme in Büro*, *Technik und Wissenschaft*, 247–258. Springer.
- Quigley, M., Conley, K., Gerkey, B., Faust, J., Foote, T., Leibs, J., Wheeler, R., and Ng, A.Y. (2009). Ros: an open-source robot operating system. In *ICRA workshop* on open source software, volume 3, 5. Kobe, Japan.
- Shan, T. and Englot, B. (2018). Lego-loam: Lightweight and ground-optimized lidar odometry and mapping on variable terrain. In 2018 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS), 4758–4765. IEEE.
- Shirangi, M.G. and Emerick, A.A. (2016). An improved tsvd-based levenberg-marquardt algorithm for history matching and comparison with gauss-newton. *Journal* of Petroleum Science and Engineering, 143, 258–271.
- Siciliano, B. and Khatib, O. (2016). Springer handbook of robotics. Springer.
- Wong, U., Morris, A., Lea, C., Lee, J., Whittaker, C., Garney, B., and Whittaker, R. (2011). Comparative evaluation of range sensing technologies for underground void modeling. In 2011 IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, 3816–3823. IEEE.
- Zhang, J. and Singh, S. (2017). Low-drift and realtime lidar odometry and mapping. Autonomous Robots, 41(2), 401–416.