

doi: 10.7690/bgzdh.2023.01.018

基于因子图优化的激光 SLAM

刘康宁，丁春嵘，吕崇伟

(国能铁路装备有限责任公司沧州机车车辆维修分公司，河北 沧州 061113)

摘要：为提高基于激光雷达的同步定位和建图(simultaneous localization and mapping, SLAM)精度,提出一种基于因子图的高效率、高精度的激光雷达SLAM框架。采用一种基于滑动窗口的因子图方法,将当前帧进行帧间匹配得到相对位姿,按照一定规则选出关键帧,将关键帧与全局地图进行匹配得到绝对位姿;构建一个因子图,将得到的连续帧之间的相对位姿与关键帧的绝对位姿作为优化因子,机器人的位姿作为状态节点放入因子图中进行位姿优化,得到高频率的机器人位姿以及全局一致的环境地图。结果表明:该算法能够减小误差的累积,具有更高的定位精度。

关键词: 因子图; SLAM; 机器人; 激光雷达

中图分类号: TP24 **文献标志码:** A

Laser SLAM Based on Factor Graph Optimization

Liu Kangning, Ding Chunrong, LYU Chongwei

(Cangzhou Vehicle Maintenance Branch, China Energy Railway Equipment Co., Ltd., Cangzhou 061113, China)

Abstract: In order to improve the accuracy of simultaneous localization and mapping (SLAM) based on laser radar, an efficient and high-precision SLAM framework based on factor graph is proposed in this paper. A factor graph method based on sliding window is used to match the current frame to get the relative pose, and then the key frame is selected according to certain rules, and the absolute pose is obtained by matching the key frame with the global map. A factor graph is constructed, and the relative pose between consecutive frames and the absolute pose of key frames are taken as optimization factors, and the pose of the robot is taken as a state node to be put into the factor graph for pose optimization, so that the pose of the robot with high frequency and a globally consistent environment map are obtained. The results show that the algorithm can reduce the accumulation of errors and has higher positioning accuracy.

Keywords: factor graph; SLAM; robot; LiDAR

0 引言

同步定位和建图(SLAM)是机器人技术中最基本的研究课题之一。SLAM的任务是根据板载传感器对机器人进行定位并在未知或部分未知的环境中构建周围地图。根据感知设备,SLAM算法可大致分为LiDAR SLAM和Visual SLAM。与Visual SLAM相比,LiDAR SLAM在姿态估计方面通常更准确,并且对照明和天气变化等环境变化具有鲁棒性^[1]。因此,LiDAR SLAM被许多机器人应用广泛采用,如自动驾驶^[2]、无人机检查^[3]。

虽然现有的LiDAR SLAM算法在公共数据集上取得了良好性能,但在实际应用中仍存在一些局限性。其中一个限制是在不同环境的鲁棒性,例如,从室内到室外环境以及从静态环境到动态环境,在室内场景中表现出良好的表现^[4],但在户外环境中,定位精度下降了很多。另一个挑战是计算效率,在无人机等许多机器人平台中,计算资源是

有限的,其中板载处理单元需要同时执行高频定位和路径规划^[5]。

估计2次扫描之间变换的最经典方法是迭代最近点(iterative closest point, ICP)^[6],其中2个需要匹配的点云通过最小化点云距离来迭代对齐。但是,该方法针对的是稠密点云,而单帧激光雷达点云稀疏无法使用,而且该方法对初始值要求较高,以及对噪声比较敏感,这些缺点限制了该方法在SLAM算法中的使用。另一种方法是基于特征点的匹配,该方法计算效率高、精度高。一个典型例子是激光雷达定位和建图(lidarodometry and mapping, LOAM)^[7],提取边缘特征和平面特征,并通过最小化点到平面和点到边距离来计算载体的姿态。然而,失真补偿和激光里程计都需要迭代计算,仍在耗费很大的计算资源,而且在大场景环境中会产生误差累积。

因子图是一种概率图模型,可用函数的因式分

收稿日期: 2022-09-28; 修回日期: 2022-10-24

作者简介: 刘康宁(1996—),男,河北人,从事电力机车检修研究。E-mail: 1784288990@qq.com。

解表示^[8]。在 SLAM 系统中，随着机器人的运动，系统优化的规模逐渐增大，需要同时处理具有大量不同变量的复杂全局函数；因此，将全局函数进行因式分解，并改写成多个简单局部函数的乘积。因子图在机器人 SLAM 领域具有广泛的应用^[9]。

笔者介绍一种基于因子图的 LiDAR SLAM，旨在为公众提供实用的实时 LiDAR SLAM 解决方案。提出一种新框架，能够实时输出高频位姿，并减小误差累积。与传统方法相比，笔者在帧间匹配和关键帧全局匹配之后，利用基于滑动窗口的方法进行位姿矫正，提高了定位精度。为证明其精度，对所提方法进行室外实验，与现有方法相比，该方法取得了较好的精度与更高的鲁棒性。

1 因子图优化

随着机器人的运动，一系列激光雷达的测量不断被收集，用来估计机器人的运动状态以及对周围环境建模。此过程可用图来表示，其中待估计的状态参数作为节点，不断收集到的测量作为边被引入来连接它们涉及的因子。通常，这些测量的误差独立且服从高斯分布。可将上述因子图表示的机器人状态估计问题看作最大后验估计问题；因此，以下面非线性形式构造一个最大后验估计问题：

$$\hat{x} = \arg \min_x \sum_i \|r_i(x)\|_{\Sigma_i}^2. \quad (1)$$

式中： r_i 测量 i 对应均值为 0 的残差； Σ_i 是相应的方差。

上述非线性优化问题可通过对当前估计状态进行线性化来迭代解决。定义状态的增量为 Δx ，将上述优化问题以状态增量的形式描述：

$$\begin{aligned} \Delta \hat{x} &= \arg \min_{\Delta x} \sum_i \|r_i(x \oplus \Delta x)\|_{\Sigma_i}^2 = \\ &= \arg \min_{\Delta x} \sum_i \|r_i(x) + H_i \Delta x\|_{\Sigma_i}^2. \end{aligned} \quad (2)$$

式中 $H_i = \partial r_i / \partial x$ 是第 i 个残差相对于机器人状态的雅各比矩阵。

定义了广义更新操作 \oplus ，可将迭代中状态的变化映射到完整状态的变化。经过线性优化之后得到最优的状态增量，然后对当前状态以 $\hat{x}^+ = \hat{x}^- \oplus \Delta x$ 形式进行更新。不断进行上述的迭代过程直至系统收敛得到需要的最优解。

2 方法概述

笔者采用的方法如图 1 所示，整个系统可分为 3 部分。当新的激光雷达帧到来时，首先进入点云

预处理模块。该模块包括点云去畸变以及特征点的提取。点云去畸变是将由于载体的运动所造成的一致的激光点云转化到同一个坐标系下，然后在无畸变的点云中提取特征点作为匹配点。相对于传统的 ICP 匹配方法，基于特征点的点云匹配方法更有效率，而且对噪声不敏感。经过点云预处理之后，得到无畸变的特征点云，这些特征点就会进入构建约束因子的模块。首先与前 n 帧激光雷达扫描组成的局部地图进行帧间匹配，局部地图的点云都已转化到与当前帧相邻的激光雷达坐标系中；因此，通过帧间匹配得到了连续 2 帧激光雷达之间的相对位姿变换，并以此构建激光雷达里程计因子。然后与全局点云匹配构建激光雷达全局位姿因子，但是为保证系统的实时性能，引入关键帧的方法，只有被选为关键帧的激光雷达扫描才会进行全局匹配，为系统提供全局约束因子。而且在与全局地图匹配时，只是根据全局位姿先验在全局地图中截取一部分作为关键帧的匹配点云。当关键帧得到全局位姿后会将当前帧的特征点云转化到全局地图中来更新全局地图。当得到关键帧的全局位姿后，系统会开启因子图优化模块，将具有相对位姿的激光雷达里程计因子与绝对位姿的激光雷达全局位姿因子一起放入基于滑动窗口的因子图中进行优化，最终得到一个更高频率、更加准确的机器人位姿。

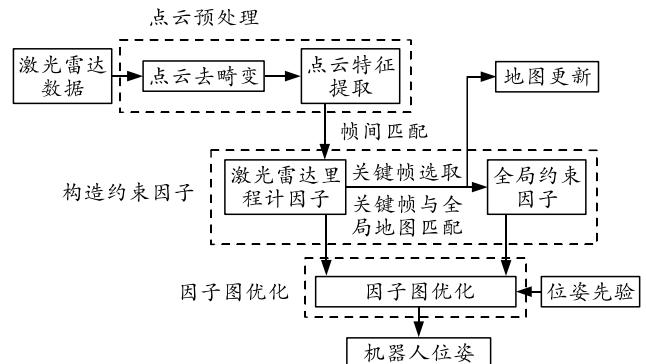


图 1 系统框架

3 基于因子图优化的激光 SLAM 算法

3.1 激光点云预处理

点云去畸变：由于雷达计算激光点坐标时，都是以接收到激光束时刻的雷达自身坐标系为基础的，所以载体运动过程中，每 1 列激光点的基准坐标系都不一样，但在同 1 帧点云里，希望能统一在同 1 个坐标系下，所以需要知道每次采集时的坐标系相对于初始时刻坐标系的转换关系。由于现有的激光雷达输出的测量数据一般不会超过 10 Hz，因

此相邻 2 帧之间的时间间隔特别短。假设相邻 2 帧之间载体的角速度和线速度都是恒定的，即匀速模型。假设当前帧 i 对应的机器人位姿为 T_i ，则连续 2 帧 i 和 $i-1$ 之间的变换为：

$$\xi_{i-1}^i = \log(T_{i-2}^{-1} T_{i-1})。 \quad (3)$$

式中 $\xi \in se(3)$ ，则连续扫描之间任意时间段 δt 时刻的变换为：

$$T_i(\delta t) = T_{i-1} \text{Exp}\left(\frac{\delta t}{\Delta t} \xi_{i-1}^i\right)。 \quad (4)$$

式中 Δt 为 2 帧之间的时间间隔。当前帧 L_i 的畸变可以通过以下方式进行校正：

$$\bar{L}_i = \{T_i(\delta t)p_k | p_k \in L_i\}。 \quad (5)$$

特征提取：接下来，从去畸变的点云中提取特征点云。同 LOAM 一样，笔者提取边缘点和表面点作为匹配的特征点。对于任何点 P ，从与 P 同 1 行扫描中找到 10 个连续点，用 S 表示，均匀的位于 P 的两侧。则 P 的粗糙度可以通过以下公式计算：

$$c = \frac{1}{|S| \cdot \|r_k\|} \left\| \sum_{j \in S, j \neq k} (r_j - r_k) \right\|。 \quad (6)$$

式中 $|S|$ 为所选取的点集中点的个数。

选择粗糙度值较小的点作为平面点，相反粗糙度值较大的点作为边缘点。则从经过点云预处理后，当前帧的点云可以表示为 $L_i = \{p_i^\pi, p_i^\varepsilon\}$ ， p_i^π 表示平面特征点， p_i^ε 表示边缘特征点。

3.2 激光雷达里程计因子

激光雷达里程计因子：当新的雷达帧 L_i 到来时，经过预处理后，得到边点 L_i^ε 和平面点 L_i^π 。此时，当前帧与前 1 帧之间的相对变换作为因子，当前帧机器人运动状态作为节点被加入到因子图中；因此，需要得到当前帧激光点云与前 1 帧激光点云之间的变换。笔者将与当前帧相邻的前 n 帧激光雷达特征点云组合成一个局部地图作为匹配点云，用 M_{i-1} 表示。此时，该子地图包含的激光雷达帧如下：

$$M_{i-1} = \{L_{i-1}, L_{i-2}, L_{i-3} \dots L_{i-n}\}。 \quad (7)$$

这些激光雷达帧通过变换 $[T_{i-1}^w \ T_{i-2}^w \ T_{i-3}^w \ \dots \ T_{i-n}^w]$ 转换到第 $i-1$ 帧激光雷达坐标系中。对于扫描匹配算法，使用与 LOAM 相同的方法，因为它在各种具有挑战性的环境中具有很好的计算效率和鲁棒性。首先，将此帧激光雷达的特征点转换到前一帧的局部地图中得到 $M_{i-1} L_i$ ，初始

变换是通过匀速模型获得，对于 $M_{i-1} L_i$ 中的每个特征点，在子地图中找到相应的边缘和平面；然后，最小化特征点到其相应边和平面的距离，以获得最优的变换：

$$r_i = \sum_{M_{i-1} \tilde{P}_k^\varepsilon \in M_{i-1} L_i^\varepsilon} d_{L_i^\varepsilon}^\varepsilon + \sum_{M_{i-1} \tilde{P}_k^\pi \in M_{i-1} L_i^\pi} d_k^\pi。 \quad (8)$$

式中：

$$d_k^\varepsilon = \frac{\left| \left(M_{i-1} \tilde{P}_k^\varepsilon - M_{i-1} P_l^\varepsilon \right) \times \left(M_{i-1} \tilde{P}_k^\varepsilon - M_{i-1} P_m^\varepsilon \right) \right|}{\left| M_{i-1} P_l^\varepsilon - M_{i-1} P_m^\varepsilon \right|}； \quad (9)$$

$$d_k^\pi = \frac{\left| \left(M_{i-1} \tilde{P}_k^\pi - M_{i-1} P_l^\pi \right) \times \left(M_{i-1} P_l^\pi - M_{i-1} P_n^\pi \right) \right|}{\left| \left(M_{i-1} P_l^\pi - M_{i-1} P_m^\pi \right) \times \left(M_{i-1} P_m^\pi - M_{i-1} P_n^\pi \right) \right|}； \quad (10)$$

$$M_{i-1} \tilde{P}_k^\varepsilon = \left(T_{M_{i-1}}^{L_i} \right)^{-1} L_i P_k^\varepsilon； \quad (11)$$

$$M_{i-1} \tilde{P}_k^\pi = \left(T_{M_{i-1}}^{L_i} \right)^{-1} L_i P_k^\pi。 \quad (12)$$

式中： P_k^ε, P_k^π 分别是当前关键帧的边缘特征点和平面特征点； $M_{i-1} \tilde{P}_k^\varepsilon, M_{i-1} \tilde{P}_k^\pi$ 是 P_k^ε, P_k^π 转换到局部坐标系后得到的点； $M_{i-1} P_l^\varepsilon, M_{i-1} P_m^\varepsilon$ 是局部地图中与 P_k^ε 对应的匹配边缘点； $M_{i-1} P_l^\pi, M_{i-1} P_m^\pi, M_{i-1} P_n^\pi$ 是局部地图中与 P_k^π 对应的匹配平面点。通过匹配得到相邻关键帧之间的相对位姿变换，此时新的关键帧位姿会作为节点，相对位姿作为因子加入了因子图中。

3.3 激光雷达全局位姿因子与地图更新

经过 3.2 节的点云匹配之后，得到相邻 2 帧激光雷达扫描之间的相对变换。以得到的相对变换为初值，将当前帧与全局地图做匹配，得到当前帧在世界坐标系下的位姿，并将当前帧的点云融入全局地图中，得到全局一致的地图。将当前帧点云与全局点云做匹配，匹配方法同样选择特征点方法。不同的是，与全局地图匹配时，为保证系统的实时性，引入了关键帧的概念，当前帧的位姿与前一帧激光雷达扫描的位姿相比超过定义的阈值，当前帧就会被选择为关键帧。全局匹配只在关键帧中进行，并且以得到的相对变换为先验，在全局地图中提取以当前帧中心，一个长宽各 10 m，高 5 m 的长方体内的所有点云作为匹配点。假设第 j 时刻当前帧被选为关键帧，用 F_j 表示；与之对应，在全局地图中提取的局部地图，用 S_j 表示。同样，先验位姿 \hat{T}_j^w (由上节得到的相对变换转化得到) 将当前帧的特征点

云转换到世界坐标系，得到 wF_j 。对于 wF_j 中的每个特征点，在子地图 S_j 中找到相应的边缘线和平面。然后，最小化特征点到其相应边和平面的距离，以获得最优的变换 T_j^w 。并根据此变换将激光雷达关键帧的点云转化到世界坐标系下，得到全局一致的地图。

3.4 因子图优化

在3.2节中，得到激光雷达扫描之间的相对变换，3.3节中获得了关键帧相对于世界坐标系下的位姿变换，但相对世界坐标系的绝对变换只在关键帧中计算，所以两者的计算频率并不相同。为得到每帧激光雷达扫描的绝对位姿，构建一个基于滑动

窗口的因子图，如图2所示。将得到的相对变换和绝对变化作为约束因子节点，每一帧激光雷达扫描对应的机器人位姿作为状态节点，加入到因子图中进行优化。为保证系统的实时性，引入滑动窗口的方法，在滑动窗口中固定需要优化的激光雷达普通帧和激光雷达关键帧的数量。这样就保证了计算量的稳定，当新的关键帧到来时，启动因子图优化，将最新的关键帧加入到因子图中，同时边缘化掉最早进入滑动窗口中关键帧以及与它相邻关键帧之间的普通帧。因为位姿仅与前后两帧相关，所以不用考虑去掉的激光雷达帧对当前系统的影响。经过因子图优化得到了更加准确且频率更高的机器人位姿。

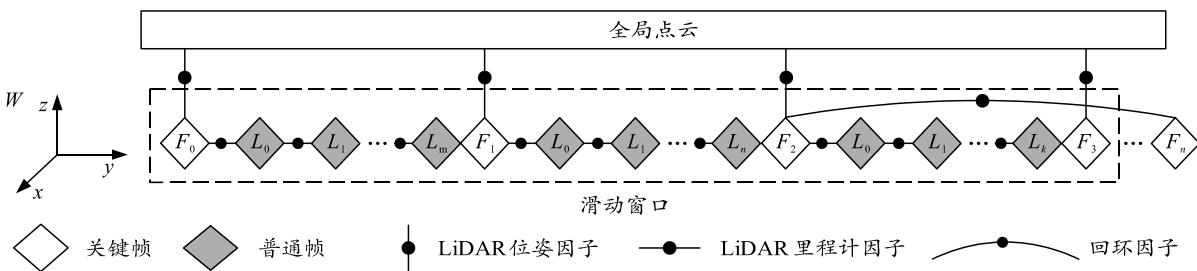


图2 系统构建的因子图

4 实验

为证明本文中算法，在SLAM领域常用的大场景公开数据集KITTI上进行实验。KITTI数据集由德国卡尔斯鲁厄理工学院和丰田(美国)技术研究院联合创办，是目前国际上最大的自动驾驶场景下的计算机视觉算法评测数据集。该数据集是从配备Velodyne HDL-64 LiDAR、摄像头和GPS的驾驶汽车中收集的。大多数最先进的SLAM方法都在这个数据集上进行了评估，例如LOAM等。由于篇幅限制，只采用KITTI数据集的序列09进行验证。路程全长1 705.05 m。同时采用绝对位姿估计均方根误差作为验证算法的指标，并同现有的算法LOAM进行比较，各个算法得到的轨迹以及轨迹真值对比如图3所示，其具体误差如表1所示。通过上述结

果可知，在室外大场景中，本文中算法具有更高的精度，充分体现了其低漂移的特点。

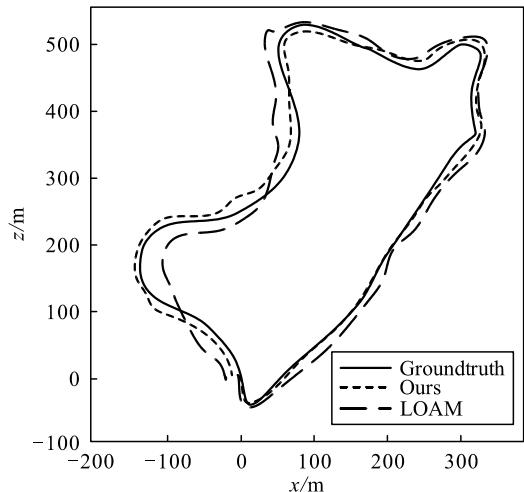


图3 本文中算法与LOAM算法的估计位姿与真值的对比

表1 KITTI数据集09序列下本文中算法与LOAM算法的误差对比

m

场景	距离	算法	绝对位姿估计均方根误差
KITTI数据集09序列	1 705.051	LOAM Ours	11.574 8.231

5 结束语

笔者基于因子图提出一种激光雷达SLAM框架。因子图作为一种能够表示函数因子分解的图模型，由于其数学特性在特定的模型建立、状态估计

算法中有独特的优越性，可实时求解大规模最优估计问题，简化了最优估计问题中的计算量，提高系统的实时性。算法首先进行帧间匹配得到相邻两激光雷达帧之间相对变换；然后根据所设阈值选择关

键帧,关键帧用来与全局地图匹配得到其绝对位姿;最后构建一个基于滑动窗口的因子图,将绝对位姿和相对位姿放在一起进行优化,最终得到更加精确的机器人位姿以及全局一致的地图。在公开数据集 KITTI 上的实验结果证明:该算法能够减小误差的累积,具有更高定位精度。

参考文献:

- [1] DEBEUNNE C, VIVET D. A review of visual-lidar fusion based simultaneous localization and mapping[Sensors[J]. Sensors, 2020, 20(7): 2068.
 - [2] MILZ S, ARBEITER G, WITT C, et al. Visual slam for automated driving: Exploring the applications of deep learning[C]//in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. IEEE, 2018: 247–257.
 - [3] CUNHA F, YTOUMI K. Ultra-wideband radar for robust inspection drone in underground coal mines[C]//in 2018 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2018: 86–92.
 - [4] HESS W, KOHLER D, RAPP H, et al. Real-time loop closure in 2d lidar slam[C]//in 2016 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2016: 1271–1278.
 - [5] LI R, LIU J, ZHANG L, et al. Lidar/mems imu integrated navigation (SLAM) method for a small uav in indoor environments[C]//in 2014 DGON Inertial Sensors and Systems (ISS). IEEE, 2014: 1–15.
 - [6] BESL P J, MCKAY N D. Method for registration of 3-d shapes, in Sensor fusion IV: control paradigms and data structures[J]. International Society for Optics and Photonics, 1992, 1611: 586–606.
 - [7] ZHANG J, SINGH S. Low-drift and real-time lidar odometry and mapping[J]. Autonomous Robots, 2017, 41(2): 401–416.
 - [8] LOELIGER H. An introduction to factor graphs[J]. IEEE Signal Processing Magazine, 2004, 21(1): 28–41.
 - [9] KSCHISCHANG F R, FREY B J, LOELIGER H A. Factor graphs and the sum-product algorithm[J]. IEEE Transactions on Information Theory, 2001, 47(2): 498–519.
-

(上接第 91 页)

参考文献:

- [1] 商靠定, 洪航, 李博, 等. 层次分析法在消防部队灭火救援战斗力评估中的应用[J]. 安全与环境工程, 2009, 16(3): 70–74.
- [2] 秦霜霜, 吕伟, 余惠琴, 等. 基于案例推理的火灾事故相似度及应对措施研究[J]. 安全与环境工程, 2018, 25(5): 150–155.
- [3] 肖方兵. 两款国产消防机器人简介[J]. 消防技术与产品信息, 2009(5): 91–92.
- [4] NEGRELLO F, GARABINI M, CATALANO M G, et al. WALK-MAN humanoid lower body design optimization for enhanced physical performance[C]//2016 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2016: 1817–1824.
- [5] 刘志勇. 智能巡检灭火机器人的设计[D]. 大连: 大连工业大学, 2017.
- [6] TURNER P, DICKINSON M. HyKim-Development of a robot bear: Bringing the strength and robustness of a bear's biomimetic features to a robot[C]//2008 IEEE International Conference on Robotics and Biomimetics. IEEE, 2009: 13–18.
- [7] 周伯男. 基于 ROS 的自平衡消防机器人定位导航系统的开发与实现[D]. 杭州: 浙江工业大学信息工程学院, 2020.
- [8] 申士宝. 化工园区的整体性安全风险评价研究[D]. 青岛: 山东科技大学, 2018.
- [9] 金华彪, 夏雨人, 张振伟. 数字图像处理在火灾探测技术领域的应用[J]. 微型电脑应用, 2003(5): 25–27.
- [10] 刘松涛, 殷福亮. 基于图割的图像分割方法及其新进展[J]. 自动化学报, 2012, 38(6): 911–922.
- [11] 张航. 基于红外热成像的消防灭火机器人自动控制系统的研究[D]. 南京: 南京航空航天大学, 2019.
- [12] 胡春旭. ROS 机器人开发实践[M]. 北京: 机械工业出版社, 2018: 49–58.
- [13] RIVERA S, IANNILLO A K, LAGRAA S, et al. ROS-FM: Fast Monitoring for the Robotic Operating System(ROS)[C]//2020 25th International Conference on Engineering of Complex Computer Systems (ICECCS). IEEE, 2020: 187–196.
- [14] 梁晓辉, 慕永辉, 吴北华, 等. 关于路径规划的相关算法综述[J]. 价值工程, 2020, 39(3): 295–299.
- [15] 彭晓燕, 谢浩, 黄晶. 无人驾驶汽车局部路径规划算法研究[J]. 汽车工程, 2020, 42(1): 1–10.
- [16] 刘光伟, 王巍, 邱贤雨, 等. 室内移动机器人主动 SLAM 技术研究[J]. 机械设计与制造, 2020(3): 246–249.
- [17] 王晓华, 傅卫平. 一种新的自主移动机器人主动式 SLAM 算法[J]. 系统工程与电子技术, 2012, 34(11): 2334–2338.