

DOI: 10.19650/j.cnki.cjsi.J2514244

LIO-SAM 改进: 自适应降采样与特征筛选优化 *

曾宪阳, 于 浩, 梁远生, 杨红莉

(南京工程学院工程训练中心应用技术学院 南京 211167)

摘要:针对激光雷达 SLAM 算法中的 LIO-SAM 算法在复杂环境中高度定位精度不足的问题,围绕特征点提取与后端点云匹配两个关键环节提出改进策略。在后端匹配方面,鉴于其存在的帧间误差波动大、鲁棒性差的情况,创新性地提出一种基于前置匹配的自适应降采样方法。该方法借助预匹配操作,有效提升初始匹配精度,并依据点云局部密度,动态调整体素滤波分辨率,从而在保证匹配精度的同时显著提升计算效率。在前端特征点提取环节,针对 LIO-SAM 中曲率计算冗余、排序开销大以及近处点云特征提取率低问题,提出一种结合早期截断(Early Cutoff)与多尺度体素空间协方差分析的双阶段特征筛选机制。该机制主要针对近处点云,首先通过局部几何变化阈值快速剔除冗余点,随后在多尺度体素网格中进行协方差特征分析,从中筛选出空间分布均衡、几何结构稳定的代表性特征点,远处点云采用原算法提取。在公开数据集 KITTI 中选取表现稳定的序列 07 进行对比实验证明,优化后的算法在 X、Y 轴精度少有提升情况下,Z 轴的平均绝对误差下降了 26.44%,RMSE 下降了 24.43%,标准差下降了 30.24%,且已在实车平台上完成部署验证,具备良好的鲁棒性与工程适用性。

关键词: 特征点; 自适应降采样; 多尺度体素空间; 前置匹配

中图分类号: TH701 文献标识码: A 国家标准学科分类代码: 406.40

Improved LIO-SAM: Adaptive downsampling and feature selection optimization

Zeng Xianyang, Yu Hao, Liang Yuansheng, Yang Hongli

(Engineering Training Center & School of Applied Technology, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: Aiming at the problem that the LIO-SAM algorithm in the SLAM algorithm of LiDAR lacks sufficient localization accuracy in complex environments, this paper proposes an improvement strategy focusing on two key aspects, feature point extraction and back-end point cloud matching. In the back-end matching, in view of its large inter-frame error fluctuation and poor robustness, this paper innovatively proposes an adaptive downsampling method based on pre-matching. The method effectively improves the initial matching accuracy through pre-matching operation, and dynamically adjusts the voxel filtering resolution based on the local density of the point cloud. Thus, the computational efficiency is significantly improved while ensuring the matching accuracy. In the front-end feature extraction, a two-stage feature filtering mechanism combining Early Cutoff and multi-scale voxel spatial covariance analysis is proposed to address the problems of redundant curvature computation, large sorting overhead, and low feature extraction rate of the near point cloud in LIO-SAM. The mechanism mainly focuses on the near point cloud: the redundant points are quickly eliminated by the local geometric change threshold, after which the covariance feature analysis is performed in the multiscale voxel grid. From this, the representative feature points with a balanced spatial distribution and a stable geometric structure are screened out, and the far point cloud is extracted by the original algorithm. Comparison experiments are carried out on the public dataset KITTI by selecting the stable sequence 07. Results show that, while the optimized algorithm provides only slight improvements in X- and Y-axis accuracy, it reduces the average absolute error of Z-axis by 26.44%, the RMSE by 24.43%, and the standard deviation by 30.24%. Furthermore, the algorithm has been deployed on a real-vehicle platform, where its robustness and engineering applicability have been verified.

Keywords: feature points; adaptive downsampling; multi-scale voxel space; pre matching

0 引言

当前,移动机器人在众多领域中得到了广泛应用,其运行主要依托各类传感器来采集与处理周边环境数据,进而实现在不同环境下的地图创建与路径规划^[1]。早期,同步定位与建图(simultaneous localization and mapping, SLAM)技术受传感器类型的限制,主要采用轮式编码器、超声波及二维激光雷达进行数据采集,并运用扩展卡尔曼滤波(extracted Kalman filter, EKF)进行数据处理^[2]。经典算法包括EKF-SLAM和GraphSLAM^[3-4]等,但这些算法计算复杂度较高,难以有效拓展至大规模场景。2000年至2010年期间,随着传感器技术的发展以及相关技术的突破,稀疏化与图优化^[5]SLAM应运而生,其后端构建因子图,前端负责数据关联与特征跟踪,例如通用图优化(general graph optimization, G2O)^[6]、增量平滑与地图构建(indexed sequential access method, iSAM/incremental smoothing and mapping of Bayesian trees, iSAM2)算法^[7]等。然而,这些算法在视觉应用方面存在不足,直至2007年Klein等^[8]提出了并行跟踪与地图构建(Parallel tracking and mapping, PTAM)。在视觉SLAM技术的发展历程中,PTAM算法的提出具有里程碑意义,此算法创新性地把视觉SLAM划分为并行的跟踪和建图两部分,这一举措极大地提升了建图定位的实时性与精确度。2015年Mur-Artal等^[9]提出了基于特征点(oriented FAST and rotated BRIEF, ORB)的匹配和优化算法ORB-SLAM,融入了包括回环检测、全局优化和重新定位功能,成为视觉SLAM领域的重要基准。2014年Zhang等^[10]提出实时激光雷达SLAM(LiDAR odometry and mapping, LOAM)算法,从激光雷达中提取点云特征点(角点、平面点),利用点云匹配技术提高精度和位姿估计,并将里程计和建图过程进行解耦,使得整个系统能够同时保持实时性和精确度。2018年Shan等^[11]提出了轻量级且地面优化的激光雷达测距与建图系统(lightweight and ground-optimized LiDAR odometry and mapping, LEGO-LOAM)算法,特别针对地面车辆应用进行了轻量化和实时性优化。2019年Qin等^[12]提出VINS-Fusion算法,其支持多种传感器组合,例如单目/双目+惯性测量单元(inertial measurement unit, IMU)+全球定位系统(global positioning system, GPS),并继承VINS-Mono框架。同年Shan等^[13]提出基于平滑与映射的紧密耦合激光雷达惯性测距系统(tightly-coupled LiDAR inertial odometry via smoothing and mapping LIO-SAM)算法,采用因子图(factor graph)优化方法,将LiDAR里程计与IMU预积分残差高度融合,提升了系统对快速运动、非结构化环境的鲁棒性与估计精度。作为一个开源框架,LIO-

SAM支持多类型雷达(Velodyne、Ouster)、IMU型号与机器人操作系统(robot operating system, ROS)接口集成,已成为学术界和工业界LiDAR SLAM的基准实现之一^[14]。然而,LIO-SAM算法中点云提取策略对点云密度、扫描角度和噪声较为敏感,且基于环状匹配的方法在室内或非结构化环境中存在误匹配或检测失败的潜在风险^[15]。鉴于此,针对LIO-SAM算法框架展开优化,主要贡献为:

1)在局部点云匹配过程中,提出了一种基于前置匹配的自适应降采样方法,采用先匹配后降采样的方式。相较于原算法,匹配精确度提高了11.9%,信噪比(signal-to-noise ratio, SNR)提升了2.38 dB,稳定性提升了21.27%。

2)为平衡特征提取的准确性与计算效率,本研究提出一种基于距离自适应切换机制的混合特征点提取策略。针对近距离点云区域分布密集且特征细节丰富的特性,采用基于Early Cutoff和多尺度体素空间协方差分析的双阶段高效筛选机制^[16],以快速识别具有显著结构性的边缘点。对于远距离稀疏点云区域,则沿用原始LIO-SAM中的曲率排序与筛选方法,确保特征点在远处的几何稳定性和匹配鲁棒性。实验结果显示,Z轴的平均绝对误差降低26.44%,均方根误差(root mean square error, RMSE)降低24.43%,标准差下降30.24%该策略显著提升了特征点在三维空间中的分布均衡性和几何稳定性。

1 前置匹配与自适应降采样

由于算法官网数据集运行稳定,且与算法适配,无需做额外修改,因此本研究基于官网公开数据集(<https://github.com/TixiaoShan/LIO-SAM>)开展了系统性仿真实验分析。实验结果表明,现有算法在三维特征点云匹配过程中存在显著匹配误差及稳定性不足问题,其量化表现如图1所示。

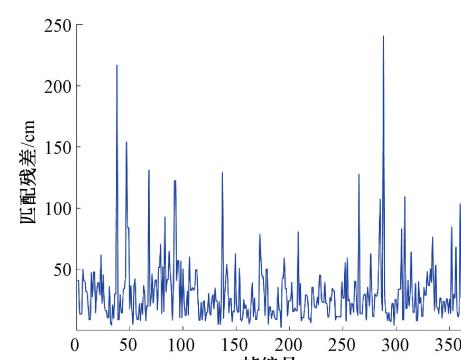


图1 匹配误差
Fig. 1 Matching error

在点云匹配过程中,误差波动的主要区间集中在 0~100 cm 范围。然而,在多个特定时间点上,系统会观测到显著的异常现象,此时匹配误差显著上升至 100~250 cm 的范围。

1.1 前置匹配

在 LIO-SAM 系统中,局部点云匹配作为前端里程计的重要步骤之一,主要通过“Scan-to-Map”优化完成^[17],如图 2 所示。

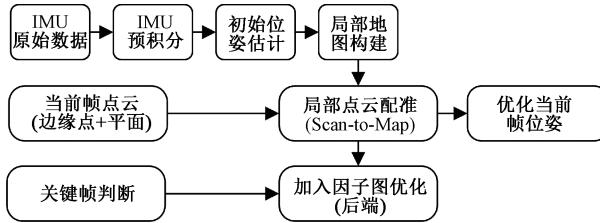


图 2 局部点云匹配流程

Fig. 2 Local point cloud matching flowchart

鉴于原算法采取先降采样后匹配的操作方式,易致使匹配精准度降低,且匹配误差增大。为有效化解此问题,特提出前置点云匹配的方法,其具体流程如图 3 所示。

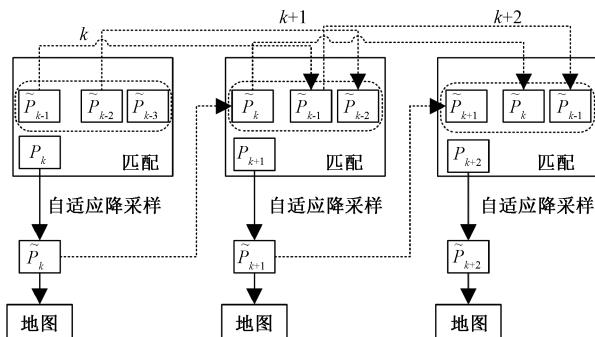


图 3 前置采样流程

Fig. 3 Pre-sampling flowchart

在当前特征点云与局部特征点的匹配流程中,将降采样操作滞后,提前执行匹配过程,这一举措显著提升了匹配的精准度。

首先,系统提取当前帧点云中的特征点云,具体涵盖边缘点 $Q_E = \{q_i^{\text{edge}}\}_{i=1}^{N_E}$ (边缘点、角点) 和平面点 $Q_S = \{q_i^{\text{surf}}\}_{i=1}^{N_S}$,并利用 IMU 预积分结果提供当前帧的初始位姿估计 $T_k^{\text{init}} \in SE(3)$,其中 $SE(3)$ 表示 3D 空间内的点云变换。为了匹配点云,需再从历史关键帧构建的局部地图中提取一定范围内的边缘点 $M_E = \bigcup_{i=1}^N p_i^{\text{edge}}$ 、平面点 $M_S = \bigcup_{i=1}^N p_i^{\text{surf}}$ 作为匹配参考。随后,系统将当前帧的特征点与局部地图中对应的几何特征进行匹配,通过构建

点到线和点到面的误差项,进而形成如式(1)所示的非线性最小二乘优化问题,目的是求解一个最优位姿 $T_k \in SE(3)$,边缘点和平面点的点到面误差项如式(2)、(3)所示。

$$\min_{T_k} \sum_{i=1}^{N_E} \rho(s_{\text{edge},i}^2) + \sum_{i=1}^{N_S} \rho(s_{\text{surf},i}^2) \quad (1)$$

$$\begin{aligned} s_{\text{edge},i} &= \|(\mathbf{T}_k \times \mathbf{q}_i - \mathbf{p}_1) \times (\mathbf{T}_k \times \mathbf{q}_i - \mathbf{p}_2)\| / \\ &\|\mathbf{p}_2 - \mathbf{p}_1\| \end{aligned} \quad (2)$$

$$s_{\text{surf},i} = |n^T(\mathbf{T}_k \times \mathbf{q}_i) + d| \quad (3)$$

对于每一个边缘点 $\mathbf{q}_i^{\text{edge}}$ 在局部地图中找到最近邻构成的直线 $L(\mathbf{p}_1, \mathbf{p}_2)$,构造点到线的残差。而对于每一个平面点 $\mathbf{q}_i^{\text{surf}}$,在局部地图中找到拟合平面 $\pi: n^T x + d = 0$,构造点到面残差。通常借助 Ceres Solver 进行迭代求解,以获得当前帧的最优位姿估计。当位姿变换满足关键帧条件时,再进行自适应降采样,以控制特征点云的数量、避免冗余点并加速匹配过程,提高下一帧的匹配速度。并将当前帧被纳入关键帧集合,用于更新局部地图并参与后端因子图优化。

1.2 自适应降采样

在点云处理中,体素滤波降采样方法由于未充分考虑匹配任务的需求,可能会错误地删除重要的特征点,进而对匹配的精确度和稳定性产生负面影响。为解决这一问题,在图像压缩领域引入了一种基于匹配残差反馈的自适应降采样策略^[18],并对其进行改进,以应用于点云匹配问题。该策略首先在初始位姿条件下,迅速将当前帧的特征点与局部地图特征进行匹配,并计算这些点对之间的欧式距离残差,以此作为评估各点重要性的依据。接着,在规则的体素网格框架内,根据每个点的残差权重,精选出对匹配贡献最大的若干点,构建起一种以匹配效果为导向的特征选择机制。与传统静态体素滤波技术相比,此策略能更有效地保护那些在匹配过程中难以处理的关键特征点,减少信息损失,同时优化点云的空间分布均匀性和几何表达力,极大提升了后续匹配步骤的准确性和鲁棒性。

首先在点云匹配的同时,计算当前点 Q 中每个 \mathbf{p}_i 对应的匹配点 $\mathbf{m}_i \in M$ 的残差 r_i ,如式(4)所示。

$$r_i = T_k^{\text{init}} \times \mathbf{p}_i - \mathbf{m}_i \in \mathbb{R}^3 \quad (4)$$

之后计算每个点云的相对权重 w_i ,其中 ε 为固定值 10^{-6} 。随着残差的不断变化,越大越不容易匹配,处于结构边缘及误差高的区域,对优化敏感,应先进行保留。如式(5)、(6)所示。

$$w_i = \frac{r_i}{\sum_{k=1}^N r_k + \varepsilon} \quad (5)$$

$$\sum_{i=1}^N w_i = 1 \quad (6)$$

将所有的点 \mathbf{p}_i 映射到三维网格中, 每个体素内含有多个点, 计为 $V_k = \{\mathbf{p}_{k,1}, \mathbf{p}_{k,2}, \dots, \mathbf{p}_{k,nk}\}$, 在体素 V_k 中, 选择保留点策略如式(7)所示。

$$\mathbf{p}_k^* = \arg \max_{\mathbf{p}_{k,j} \in V_k} \mathbf{w}_{k,j} \rho_i \quad (7)$$

并且为了进一步保持点云空间的均匀性, 引入每个点的空间密度惩罚项 ρ_i , 则最终权重如式(8)、(9)所示。

$$\mathbf{w}_i^{final} = \frac{\mathbf{r}_i}{\mathbf{p}_i + \varepsilon} \quad (8)$$

$$\rho_i = |\{\mathbf{p}_j \in \mathbf{p} \mid \|\mathbf{p}_j - \mathbf{p}_i\| < \delta\}| \quad (9)$$

其中, δ 是作为邻域点云的距离阈值。式(10)中经过最终每个体素的优选, 输出自适应降采样后的特征子集。

$$\mathbf{p}' = \bigcup_k \mathbf{p}_k^* \quad (10)$$

为评估优化策略的实际效能, 本研究基于系统架构实施了仿真验证。采用官方渠道公开的校园场景数据集作为实验样本, 通过对比分析优化前后算法在空间匹配精度方面的差异性表现。实验数据如图4所示, 优化后的算法在误差控制维度展现显著优势: 其平均误差值稳定控制在 50 cm 基准线以下, 未出现异常离群误差点, 且误差波动区间从原始算法的 [3.38 cm, 57.25 cm] 压缩至 [3.73 cm, 43.77 cm]。匹配误差提升了 11.9%, 并通过式(11)、(12)中计算 SNR、变异系数 (coefficient of variation, CV) 来比较匹配的稳定性。

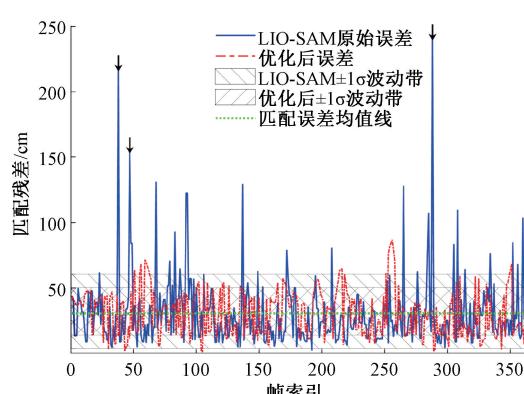


图4 匹配误差对比

Fig. 4 Matching error comparison chart

$$SNR = 10 \lg \left(\frac{\text{成功匹配均方}}{\text{失败匹配均方}} \right) \quad (11)$$

$$CV = \frac{\text{标准差}}{\text{均差}} \times 100\% \quad (12)$$

通过计算, 原算法的 SNR 为 1.03 dB, CV 为 88.86%, 优化算法 SNR 为 3.40 dB, CV 为 67.59%, SNR 提升 2.38 dB, 稳定性提 21.27%。分析结果表明, 该优

化方案有效提升了空间匹配过程的精确度指标, 同时增强了系统在复杂场景下的鲁棒性特征。

2 边缘点提取策略

于 LIO-SAM 算法的提取策略而言, 其依据点云曲率大小予以排序, 其中曲率排名靠前的被认定为边缘点, 而排名居后的则归为平面点^[19]。对于近距离点云的提取, 此方案易受点云密度、激光雷达扫描角度以及噪声等因素的干扰, 进而出现对边缘点的误判或漏判情形^[20]。鉴于此, 针对近距离特征点云的提取, 提出在原算法基础上引入“将 Early Cutoff 与多尺度体素空间协方差分析相结合”的边缘点提取策略优化算法, 以实现近距离特征点提取的优化。

2.1 Early Cutoff 结合多尺度体素空间协方差分析

本优化方法流程如图 5 所示, 首先在点云提取时, 引入 Early Cutoff 机制, 依据式(13)中快速剔除低区分度点。设置阈值 Γ , 来对边缘点进行判断。

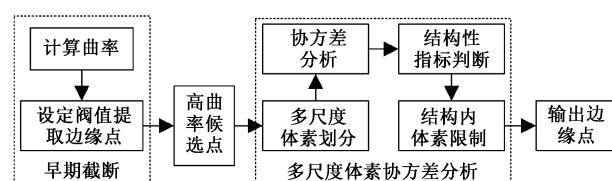


图 5 边缘点提取流程

Fig. 5 Flowchart of edge point extraction

$$P_{high} = \{p_i \in P \mid C(i) > \Gamma\} \quad (13)$$

$$\underbrace{O(n)}_{\text{计算曲率}} + \underbrace{O(n \log n)}_{\text{排序}} = O(n \log n) \quad (14)$$

$$\underbrace{O(n)}_{\text{遍历+判断}} \quad (15)$$

相较于原算法的复杂度, 式(14)、(15)中本方法只进行曲率计算+判断, 采用 Early Cutoff 与多尺度体素空间协方差分析相结合的策略, 有效缩减了匹配时长并降低了误判风险, 进而生成高曲率候选点 P_{high} 并执行体素划分操作。将体素划分为 S , 取值在 0.5 ~ 1。对每个体素内计算该体素内的结构方差 Σv 如式(16)所示。

$$\sum v = \frac{1}{n} \sum_{i=1}^n (\mathbf{p}_i - \tilde{\mathbf{p}})(\mathbf{p}_i - \tilde{\mathbf{p}})^T \quad (16)$$

其中, $\tilde{\mathbf{p}}$ 为该体素内所有点的质心。并对 Σv 进行特征值分解, 得到特征值 $\lambda_1 \leq \lambda_2 \leq \lambda_3$ 。并如式(17)所示计算出体素 v 的线性特征。

$$L_v = \frac{\lambda_3 - \lambda_2}{\lambda_3} \quad (17)$$

若 $L_v > \delta_{line}$, 则判断其为该体素内曲率最大点, 判定为边缘点并输出。

2.2 特征点提取策略结合

通过使用录制的点云数据进行仿真,由此证明近距离特征点提取对于引入优化算法的必要性。本次仿真单独对比了原算法和“Early Cutoff 与多尺度体素空间协方差分析相结合”算法,结果如图 6 所示。

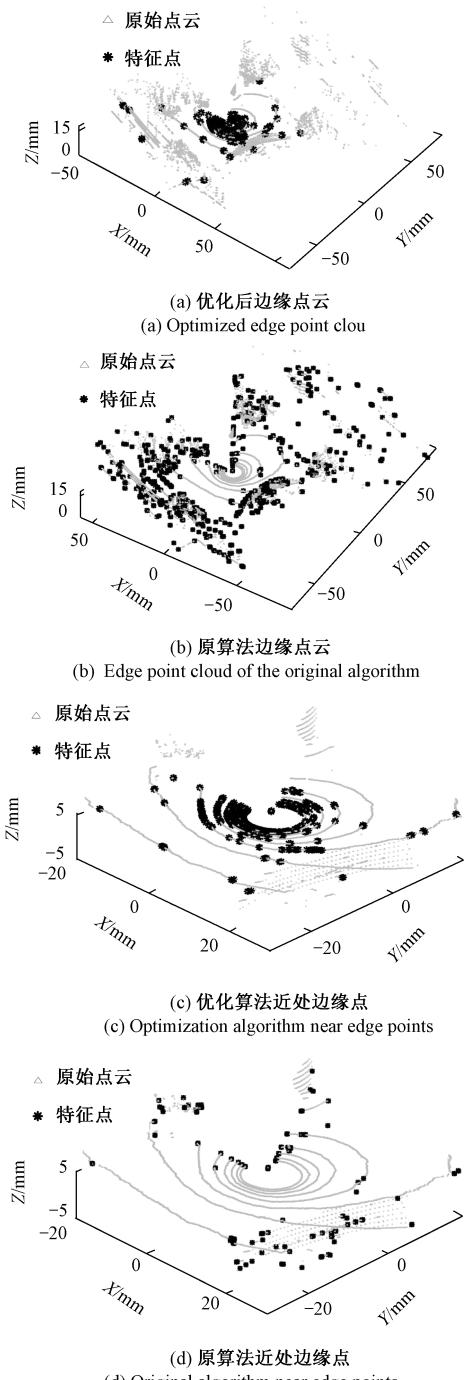


图 6 优化前后边缘点云对比

Fig. 6 Comparison of edge point clouds before and after optimization

图 6(b) 和(d) 中,前者在远距离处提取效率较高,但在近距离区域的提取效率较低。相比之下,图 6(a) 和(c) 中,后者在远距离区域的点云提取呈现稀疏特征,而在近距离区域则表现出较高的提取效率;为深入分析这一现象,特别展示了前后算法近距离区域内点云数量变化的对比图。

如图 7 所示,分析表明点云密度在 2~8 m 达到峰值。因此,本研究重点比较了 2 种算法在该特定范围内的点云数量差异,具体结果如图 8 所示。

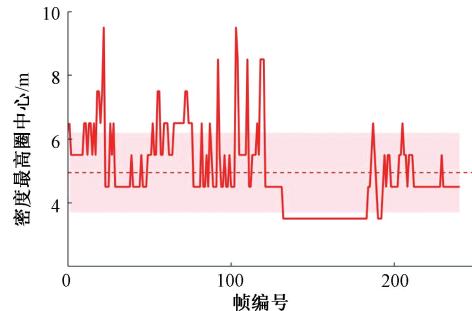


图 7 优化后点云密度集中范围

Fig. 7 The concentrated range of the optimized point cloud density

图 8 中 0~8 m 的范围,经优化后的算法所提取的数量显著高于原算法。由此可以得出结论,近距离应采用优化算法,远距离应使用原算法。因此,LIOSAM 算法近距离特征点的提取对于引入优化算法很有必要。

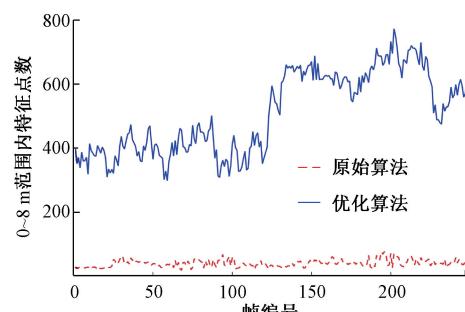


图 8 近距离边缘点提取数量对比

Fig. 8 Comparison chart of the number of extracted edge points at close range

将“Early Cutoff 与多尺度体素空间协方差分析相结合”与原算法进行融合。前者适用于近距离特征点的提取,后者用于远距离特征点的提取,并且通过检测两种算法的点云密度范围,动态地调整这两种方法的具体适用范围。随后再次开展仿真分析,结果如图 9 所示。点云提取数如表 1 所示。

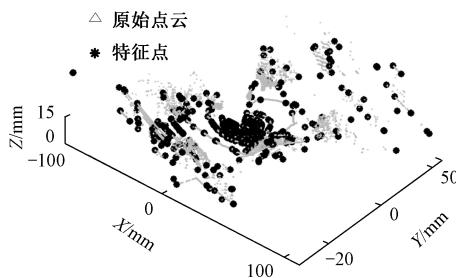


图 9 结合优化边缘点云

Fig. 9 Combine and optimize the edge point cloud

表 1 优化前后点云数对比

Table 1 Comparison of point cloud numbers before and after optimization

点云类型	近处点云数	远处点云数	总数
LIO-SAM	62	731	793
优化后算法	186	652	838

仿真分析显示,所采用的融合策略成功整合了 2 种方法在不同距离范围内的优势,显著优化了特征点空间分布的均匀性及提取效率,从而在定位准确性和稳定性上实现了显著提升,展现出较高的工程应用潜力。

3 实验验证

3.1 仿真分析

由于算法官方的录制数据集没有用于对比的真实轨迹数据,因此为了评估所提算法的优化效能,本研究采用具有数据集对应真实轨迹数据的德国卡尔斯鲁厄理工学院与美国芝加哥丰田技术研究所合作创建的自动驾驶和计算机视觉领域的知名公开数据集(Karlsruhe Institute of Technology and Toyota Technological Institute at Chicago, KITTI)标准数据集(<https://www.cvlibs.net/datasets/kitti/index.php>)开展仿真实验分析。KITTI 数据集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,包含多个场景采集的真实图像数据^[21]。在所有序列中,仅有 07 序列运行稳定,因此选取具有典型特征的 07 号序列地图数据作为基准测试场景,通过与主流 LIO-SAM 系统进行多维度性能对比,重点从全局路径一致性及高度方向误差两个关键指标展开量化评估^[22]。实验硬件平台配置为搭载 128 核处理器、4 GB 显存的 64 位嵌入式系统(NVIDIA Jetson Nano 开发板)。该测试序列包含约 1 101 个机器人位姿节点,其封闭多边形轨迹结构为算法性能验证提供了完整的运动闭环条件。如图 10 所示,展示了改进前后两种定位系统的全局轨迹对比结果。

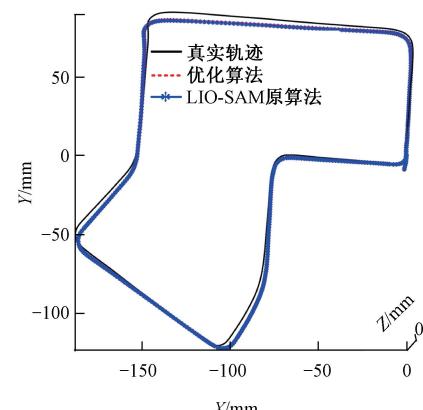
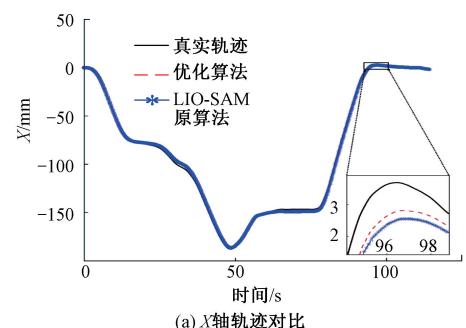


图 10 整体轨迹对比

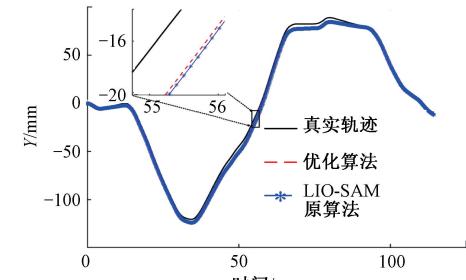
Fig. 10 Overall trajectory comparison chart

通过对图 10 分析可知,原始算法与优化后的算法在 X 、 Y 平面内相较于真实轨迹均存在一定程度的偏差,且在完成一次转弯回环操作后,两者均出现了一次偏移现象(图 10 中 Z 轴变化较小可忽略)。如图 11 所示, X 、 Y 轴优化前后轨迹之间的差异相对较小,具体的误差数值如表 2 所示。



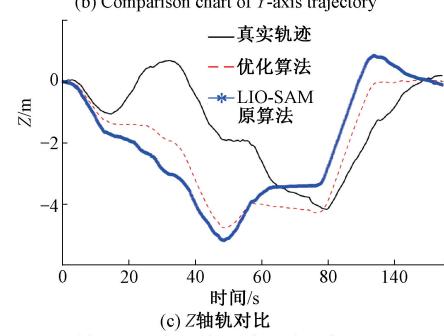
(a) X轴轨迹对比

(a) Comparison chart of X-axis trajectory



(b) Y轴轨迹对比

(b) Comparison chart of Y-axis trajectory



(c) Z轴轨迹对比

(c) Comparison chart of Z-axis trajectory

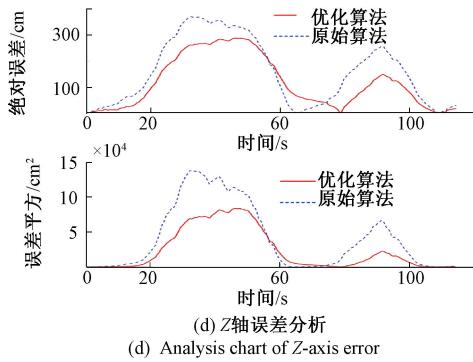


图 11 优化前后轨迹对比

Fig. 11 Comparison of trajectories before and after optimization

表 2 三轴误差对比

Table 2 Comparison of three-axis errors (cm)

坐标轴	对比算法	平均绝对误差	均方根误差	标准差
X 轴	原算法	152.24	188.88	188.64
	优化算法	138.72	172.48	171.24
Y 轴	原算法	295.97	362.15	208.85
	优化算法	281.08	341.42	194.09
Z 轴	原算法	159.81	202.97	190.56
	优化算法	117.55	153.39	132.94

优化后的算法在 X、Y、Z 这 3 轴上的误差均小于原始算法, 其中 X 和 Y 轴的精度略有提升, 而 Z 轴的精度优化效果尤为显著。

如图 11(c)、(d) 所示, 在 Z 轴方向上, 改进前后的优化效果极为显著。将第 i 个位姿误差 e_i 和位姿总数 n 代入式(18)~(20) 中进行对比分析, μ 为误差均值。

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (18)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (19)$$

$$STD = \sqrt{\frac{1}{n} \sum_{i=1}^n (e_i - \mu)^2} \quad (20)$$

经对比分析可知, 本文提出的优化算法使得平均绝对误差降低了 26.44%, 均方根误差减少了 24.43%, 标准差下降了 30.24%。结合图 11, 实验数据充分表明, 在维持 X 与 Y 轴定位精度不变或略有提升的情况下, 所提优化算法在 Z 轴定位精度方面呈现出显著的性能优势, 有力地验证了本文的提出优化策略的有效性。

3.2 实车验证

为验证优化算法在实际道路场景中的运行效能, 基于实体实验平台展开测试。该平台采用模块化架构设计, 车身规格为 $30\text{ cm} \times 22\text{ cm} \times 25\text{ cm}$, 系统框架如

图 12(a) 所示, 共分为前端以及外部传感器 3 个部分。前端运动控制系统搭载 WHEELTEC 公司开发的专用驱动主板, 主要实现车辆本体的运动控制与 IMU 数据采集

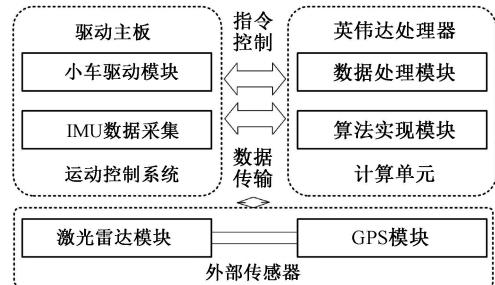
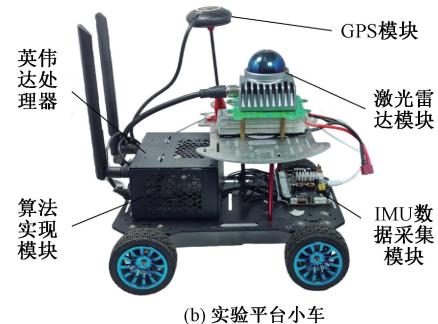
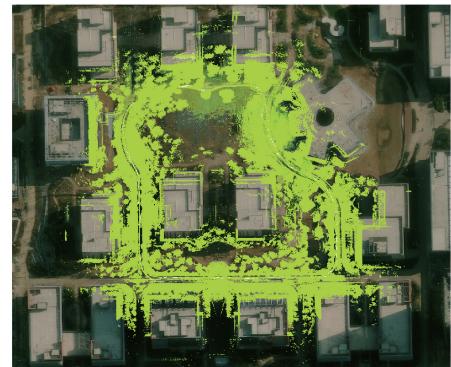
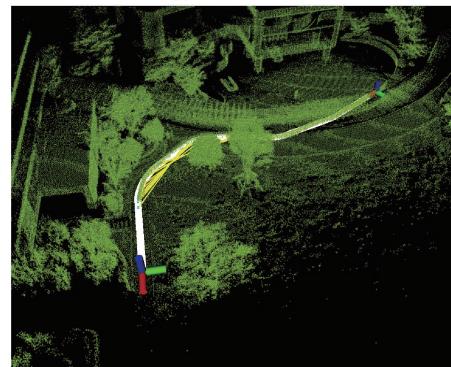
(a) 系统框架
(a) System framework diagram(b) 实验平台小车
(b) Experimental platform trolley(c) 实际地形
(c) Actual terrain(d) 局部细节
(d) Local detail drawing

图 12 实车验证实验

Fig. 12 Real vehicle verification experiment diagram

传输功能。后端计算单元配置 NVIDIA Jetson Nano 英伟达处理器开发套件,该处理器具备 128 核心架构、4 GB 图形显存及 64 位运算能力,操作系统采用 Ubuntu 18.04 LTS 长期支持版,主要用于数据的处理以及具体算法的实现。外部传感器配备 MID-360 激光雷达及 GPS 模块,通过千兆以太网接口与计算单元建立数据通道,形成完整的车-雷达-GPS 协同感知系统。本实验平台的硬件架构实物图如图 12(b)所示。

为充分展示本算法在复杂环境下的定位建图效能,特开展室外实验予以验证。如图 12(c)所示,此场景环境复杂且环境开阔,存在各种距离的点云。环境中既有外表平整的教学楼,又有大规模的树木,使得各处边缘点的密度分布杂乱。这不仅满足本文针对不同距离点云的提取策略,而且对特征点的提取具有很大的考验。在小车所构建的点云地图中,全局地图如图 12(c)所示,局部细节图如图 12(d)所示。为便于观察分析,保留了历史关键帧。从图 12 中可清晰洞察,本算法在回环检测及定位方面,与实际地图呈现出高度匹配性,且未出现运动畸变现象,展现出极高的稳定性。无论是周边的树木,还是各类建筑物,本算法扫描所呈现的轮廓均极为清晰,在确保稳定性的同时,兼具高精度特性。

4 结 论

本研究聚焦于 LIO-SAM 在复杂环境下高度定位精度欠佳的问题,着重围绕特征点提取以及后端点云匹配这两个关键模块展开改进方法的探究。经在 KITTI 数据集上的仿真实验以及真实平台部署测试后,算法的有效性得以验证,并得出的结论为:

1) 在点云匹配阶段,针对原始 LIO-SAM 存在帧间误差波动较大以及匹配鲁棒性欠佳的问题,提出基于前置匹配的自适应降采样方法,有效的提升了系统的运行效率和稳健性,其中匹配精确度提高了 11.9%,SNR 提升了 2.38 dB,稳定性提升了 21.27%。

2) 针对曲率计算冗余、排序开销大及近距离点云特征提取率低等问题,提出融合“Early Cutoff 与多尺度体素协方差分析”的双阶段特征筛选机制。此机制着重优化近距离点云,远距离点云沿用原始算法提取,以提升整体特征提取效能与质量。在公共数据集序列 07 的对比实验中,优化算法于 Z 轴方向成效显著,平均绝对误差降低了 26.44%、RMSE 降低了 24.43%、误差标准差降低了 30.24%。且该方法已在实车平台部署,系统运行平稳,环境结构还原清晰,工程适用性佳。

参考文献

- [1] 曾宪阳, 张加旺. 改进 A 算法融合 DWA 机器人路径规划研究[J]. 电子测量技术, 2025, 48(6): 20-27.
- [2] 陈耀华, 何丽, 王宏伟, 等. 基于可视点法剔除动态目标的激光-惯导 SLAM[J]. 仪器仪表学报, 2023, 44(9): 248-256.
- [3] CHEN Y H, HE L, WANG H W, et al. LiDAR-inertial SLAM based on visible point method to remove dynamic objects [J]. Chinese Journal of Scientific Instrument, 2023, 44(9): 248-256.
- [4] MAILKA H, ABOUZAHIR M, RAMZI M. An efficient end-to-end EKF-SLAM architecture based on LiDAR, GNSS, and IMU data sensor fusion for autonomous ground vehicles[J]. Multimedia Tools and Applications, 2024, 83(18): 56183-56206.
- [5] PIAO W CH, ZHAO X H, LI Z. MMGraphSLAM: Autonomous indoor positioning based on millimeter Wave GraphSLAM[J]. Measurement, 2023, 220:113300.
- [6] ECKENHOFF K, PAULL L, HUANG G Q. Decoupled, consistent node removal and edge sparsification for graph-based SLAM[C]. 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2016: 3275-3282.
- [7] SUN H X, ZHANG Y Y, ZHENG Y J, et al. G20-Pose: Real-time monocular 3D human pose estimation based on general graph optimization[J]. Sensors, 2022, 22(21): 8335.
- [8] CALIFANO P, PICCOLO F, PANICUCCI P, et al. Enhanced full visual Slam for close proximity exploration of asteroids combining incremental smoothing with filtering techniques[C]. 35th AAS/AIAA Space Flight Mechanics Meeting, 2025: 1-22.
- [9] KLEIN G, MURRAY D. Parallel tracking and mapping for small AR workspaces[C]. 2007 6th IEEE and ACM International Symposium on Mixed and Augmented Reality, 2007: 225-234.
- [10] MUR-ARTAL R, MONTIEL J M M, TARDOS J D. ORB-SLAM: A versatile and accurate monocular SLAM system [J]. IEEE Transactions on Robotics, 2015, 31(5): 1147-1163.
- [11] ZHANG J, SINGH S. LOAM: LiDAR odometry and mapping in real-time [C]. Robotics: Science and Systems, 2014, 2(9): 1-9.
- [12] SHAN T X, ENGLOT B. LeGO-LOAM: Lightweight and ground-optimized lidar odometry and mapping on variable terrain[C]. 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2018: 4758-4765.
- [13] QIN T, CAO SH Z, PAN J, et al. A general

- optimization-based framework for global pose estimation with multiple sensors [J]. ArXiv preprint arXiv: 1901.03642, 2019.
- [13] SHAN T X, ENGLOT B, MEYERS D, et al. LIO-SAM: Tightly-coupled LiDAR inertial odometry via smoothing and mapping[C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020: 5135-5142.
- [14] YUE L, LU D B, CAI B G, et al. LIO-SAM for vehicle localization using FGO architecture[C]. 2024 International Conference on Electromagnetics in Advanced Applications, 2024: 765-770.
- [15] MENG X Y, CHEN X, CHEN SH F, et al. An improved LIO-SAM algorithm by integrating image information for dynamic and unstructured environments [J]. Measurement Science and Technology, 2024, 35(9): 096313.
- [16] 谭浩晨,胡佳成,郭鑫,等. X射线三维尺寸测量机体素模型不确定度评定方法研究[J].电子测量与仪器学报,2025,39(1): 101-111.
- TAN H CH, HU J CH, GUO X, et al. Research on the uncertainty evaluation method of voxel model of X-ray three-dimensional dimension measurement[J]. Journal of Electronic Measurement and Instruments, 2025, 39(1): 101-111.
- [17] 刘名星,徐晓苏. 基于语义辅助的强度扫描上下文回环检测方法[J]. 仪器仪表学报, 2025, 46(2): 292-304.
- LIU M X, XU X S. A semantic-assisted intensity scan context loop closure detection method [J]. Chinese Journal of Scientific Instrument, 2025, 46 (2): 292-304.
- [18] HESSE R, SCHAUB-MEYER S, Roth S. Content-adaptive downsampling in convolutional neural networks[C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 4544-4553.
- [19] TSAI T C, PENG CH CH. Ground segmentation based point cloud feature extraction for 3D LiDAR SLAM enhancement[J]. Measurement, 2024, 236: 114890.
- [20] 武星,汤凯,李兴达,等. 多视角雷达点云融合的移动机器人集群跟踪[J]. 仪器仪表学报, 2023, 44(12): 175-186.
- WU X, TANG K, LI X D, et al. Mobile robot cluster tracking based on multi-perspective LiDAR point cloud fusion [J]. Chinese Journal of Scientific Instrument, 2023, 44 (12):175-186.
- [21] 邓鹏,罗静. 复杂环境下机器人多传感器融合定位方法[J]. 电子测量与仪器学报, 2023, 37(12): 48-57.
- DENG P, LUO J. Multi-sensor fusion positioning method of robots in complex environments [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(12): 48-57.
- [22] JAMALUDIN A, RADZI S S M, YATIM N M, et al. SLAM performance evaluation on uneven terrain under varying illuminance conditions and trajectory lengths[J]. IEEE Access, 2025, 13: 46426-46447.

作者简介



曾宪阳,2003年毕业于襄樊学院获学士学位,2009年毕业于浙江师范大学获硕士学位,2018年毕业于南京大学获博士学位。现为南京工程学院正高级实验师,主要研究方向为智能机器人控制、电工电子技术等。
E-mail:zxymcu@163.com

Zeng Xianyang received his B. Sc. degree from Xiangfan University in 2003, received his M. Sc. degree from Zhejiang Normal University in 2009, and received his Ph. D. degree from Nanjing University in 2018. He is currently a senior experimentalist (full professor level) at Nanjing Institute of Technology, with his main research areas including intelligent robot control, electrical and electronic technology, etc.



于浩(通信作者),2023年于江苏海洋大学获得机械工程学士学位,目前正攻读机械工程硕士学位。研究课题主要包括:SLAM、路径规划等。
E-mail:y145028@163.com

Yu Hao (Corresponding author) received his B. Sc. degree in Mechanical Engineering from Jiangsu Ocean University in 2023. He is currently pursuing a M. Sc. degree in Mechanical Engineering. His research focuses on topics including SLAM and path planning, etc.



杨红莉,2003年毕业于山西大学获学士学位,2009年毕业于南京大学获博士学位,现为南京工程学院副教授,主要研究方向为数值分析。
E-mail:yanghongli1016@163.com

Yang Hongli received her B. Sc. degree from Shanxi University in 2003, and received her Ph. D. degree from Nanjing University in 2009. She is currently an associate professor at Nanjing Institute of Technology and her main research direction is numerical analysis.