

基于自适应特征及闭环优化的激光即时定位与建图算法

韦和钧¹, 许恩永², 韩冰¹, 蒙艳玫^{1*}, 韦锦¹, 李正强¹

¹广西大学机械工程学院, 广西 南宁 530004;

²东风柳州汽车有限公司, 广西 柳州 545005

摘要 即时定位与建图(SLAM)应用的场景多样但受限于计算成本。基于此,提出了一种基于自适应特征及闭环优化的激光SLAM算法(Fast-SAM)。采用自适应特征提取方法 Better Feature 在不同的距离下保证特征提取的准确性,再通过基于随机一致性采样优化的地面特征滤除方法去除不可靠的特征并使特征数量保持稳定,在帧间匹配和闭环检测模块分别采用正态分布变换粗配准与最近点迭代精配准结合的匹配算法及所提两段式闭环检测算法,最终输出激光惯性里程计并建立全局点云地图。在LIO-SAM、KITTI 开源数据集及广西大学实测数据集上的实验结果表明,与主流的SLAM算法相比,所提算法在提升精度的同时,将各环节的计算效率提升 25.6% 以上。

关键词 图像处理; 即时定位与建图; 激光雷达; 特征提取; 闭环检测; 帧间匹配

中图分类号 TP242.6

文献标志码 A

DOI: 10.3788/LOP213074

Laser Simultaneous Localization and Mapping Algorithm Based on Adaptive Features and Closed-Loop Optimization

Wei Hejun¹, Xu Enyong², Han Bing¹, Meng Yanmei^{1*}, Wei Jin¹, Li Zhengqiang¹

¹College of Mechanical Engineering, Guangxi University, Nanning 530004, Guangxi, China;

²Dongfeng Liuzhou Motor Co., Ltd., Liuzhou 545005, Guangxi, China

Abstract Simultaneous localization and mapping (SLAM) has various application scenarios but is limited due to computational cost. Therefore, a SLAM algorithm (Fast-SAM) based on adaptive features and closed-loop optimization is proposed. The proposed algorithm uses the adaptive feature extraction method Better Feature to ensure the accuracy of the feature extraction at different distances. Then, it uses the ground feature filtering method based on random sample consensus to remove unreliable features and keep the number of features stable. In the scan matching and loop-closure detection modules, we use a matching algorithm combining the normal distribution transformation, nearest point iteration algorithm, and the proposed two-stage loop-closure detection algorithm to output the laser inertial odometry and establish a global point cloud map. The experimental results on the LIO-SAM, KITTI open source datasets, and the measured datasets of Guangxi University show that compared with the mainstream SLAM algorithms, the proposed algorithm improves the accuracy and the computational efficiency of each link by more than 25.6%.

Key words image processing; simultaneous localization and mapping; Lidar; feature extraction; loop closure; scan matching

1 引言

随着即时定位与建图(SLAM)技术的成熟和发展,其已经广泛应用于室内外2D/3D建图、机器人导航、自动驾驶等领域。目前主流的SLAM方法主要分

为两大类,基于视觉传感器的方法和基于激光雷达的方法。基于视觉传感器的SLAM方法能够高效提取特征点,但其易受光照影响,鲁棒性不高;基于激光雷达的SLAM方法不受光照影响能够在室内外环境中很好地运行,且能够捕捉到环境中细节的结构信息。

收稿日期: 2021-11-26; 修回日期: 2021-12-29; 录用日期: 2022-01-05; 网络首发日期: 2022-01-17

基金项目: 国家自然科学基金(61763001)、广西创新驱动发展专项基金(桂科AA19254019)、广西研究生教育创新计划研究生创新项目(YCBZ2021019)

通信作者: *gxu_mengyun@163.com

近年来,许多优秀的激光 SLAM 算法被提出: Zhang 等^[1]提出的 LOAM 通过两轴激光雷达和惯性测量单元(IMU)的松耦合来提升里程计精度,但其未考虑闭环矫正;Shan 等^[2]在 LOAM 的基础上提出了 LEGO-LOAM,LEGO-LOAM 通过点云分割的方法大大降低计算量,并且加入了闭环检测;Shan 等^[3]同样基于 LOAM 提出了 LIO-SAM,LIO-SAM 加入了 IMU 预积分及 GPS 因子约束,能够对偏斜点云进行高频矫正,获得更小的地图匹配误差。点云配准算法是 SLAM 系统前端的关键,用于估计相邻点云的帧间运动情况,主要分为基于概率匹配和基于特征点距离匹配。正态分布变换(NDT)^[4]是基于概率匹配的代表性算法,其先将参考点云转换为多维变量的正态分布,以概率密度作为衡量匹配好坏的指标。基于特征点距离匹配的代表算法是最近点迭代(ICP)^[5]及其变种算法,较为典型的有 PP-ICP^[6]、NICP^[7]、IMLS-ICP^[8]、GICP^[9]等,这类算法直接通过扫描点匹配来实现运动估计。目前已经有学者将两者的优点相互结合,如 VGICP^[10],该方法通过体素化,避免了高代价的最近邻搜索,同时保持了算法的精度。传统的特征提取方法可分为两大类:基于曲率判断的角面特征以 LOAM 系列的算法作为代表;基于点云法向量的直方图特征以快速点特征直方图(FPFH)^[11]、向量场直方图(VFH)^[12]等为代表。闭环检测作为 SLAM 消除累计误差的一个重要后端模块,通过历史点云数据进行匹配识别是否回到相同场景,进而消除全局的累计误差,代表性的算法有基于欧氏距离的 ICP 匹配方法^[5]、将点云投影到深度图中,利用深度信息进行编码以形成一个全局描述符进行匹配的 Scan context^[13]、基于几何与密度信息编码的 ISC^[14]闭环检测等。

本文基于因子图优化的方法框架,在提高算法精度的同时提高计算效率,引入 IMU 预积分对点云畸变

进行矫正,并优化点云特征提取方法,采用结合 NDT 与 ICP 的帧间匹配算法^[15]匹配出机器人当前时刻的六自由度位姿,再由基于两段式闭环检测算法进一步矫正位姿,最终输出精确的机器人六自由度位姿,并建立全局点云地图。

2 FAST-SAM 算法原理

所提基于自适应特征提取及闭环优化的即时定位与建图算法 FAST-SAM,基于 ISAM2^[16]因子图优化的框架处理来自 3D 雷达、IMU 等传感器的数据,使用这些传感器数据估计出机器人的状态和轨迹。这个状态估计问题可以构造为一个最大化后验问题(MAP),因此可以使用一个因子图去刻画这个问题,当机器人的位姿改变超过人为设定的阈值时(本研究阈值设置为 1 m 和 10°),则添加新的机器人状态节点到因子图中。一旦插入新的节点,因子图就会使用 ISAM2 进行优化。所提算法主要引入 3 个因子:1)IMU 预积分因子,在一次激光雷达扫描过程中使用 IMU 测量数据进行预积分,除了用于点云的偏斜矫正外,还可作为激光雷达里程计优化过程中的初始位姿估计;2)激光雷达里程计因子,系统的核心部分,用于机器人本体的运动姿态估计,此外激光雷达里程计结果可以用于估计因子图中 IMU 的偏差;3)闭环检测因子,通过对历史相似帧的检测,矫正激光雷达里程计的累积误差。FAST-SAM 算法整体框图如图 1 所示,系统的输入为 3D 激光雷达所扫描的点云及 IMU 测量得到的加速度信息:首先对 IMU 的测量值进行预积分,并利用预积分值进行点云的偏斜矫正;其次,对点云进行特征提取和帧间匹配初步得到激光里程计,同时进行闭环检测;随后将 IMU 预积分因子、激光雷达里程计因子和闭环检测因子输入 ISAM2 因子图进行优化;最终输出准确的激光惯性里程计(LIO)及全局点云地图。

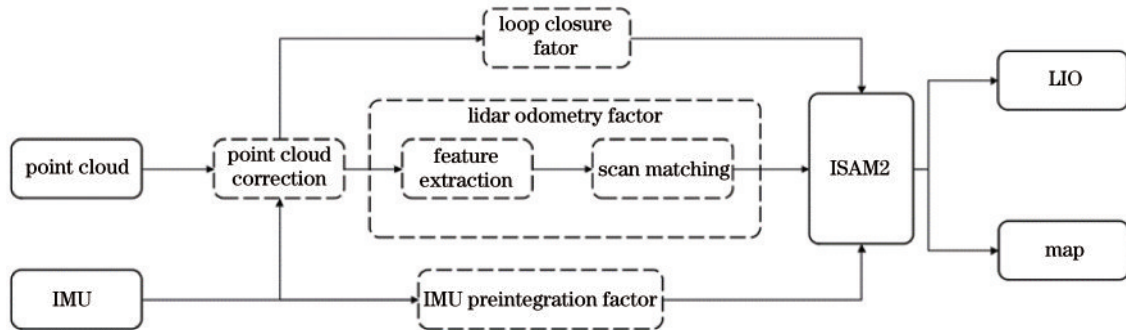


图 1 FAST-SAM 算法整体框图

Fig. 1 FAST-SAM algorithm overall framework

2.1 IMU 预积分因子

激光 SLAM 在建图定位过程中由于运动不均、抖动等因素无法避免会造成点云偏斜,进而导致点云配准误差的累积。IMU 可以得到运动本体自身的角速度、加速度等测量数据,通过对 IMU 测量值的积分操

作,能够获得机器人的位姿信息进而为里程计提供运动约束。但 IMU 自身存在噪声漂移,在计算时需要考虑噪声漂移的影响,所测量的角速度和加速度为

$$\hat{\boldsymbol{w}}_t = \boldsymbol{w}_t + \boldsymbol{b}_t^{\boldsymbol{w}} + \boldsymbol{n}_t^{\boldsymbol{w}}, \quad (1)$$

$$\hat{\boldsymbol{a}}_t = \boldsymbol{R}_t^{\text{WB}}(\boldsymbol{a}_t - \boldsymbol{g}) + \boldsymbol{b}_t^{\boldsymbol{a}} + \boldsymbol{n}_t^{\boldsymbol{a}}, \quad (2)$$

式中: W 为世界坐标系; B 为 IMU 坐标系; w_t, a_t 分别表示 IMU 在时刻 t 的角速度和加速度测量值; b_t^w, b_t^a 表示 IMU 自身的角速度偏置及加速度偏置; n_t^w, n_t^a 表示 IMU 自身的角速度噪声及加速度噪声; \hat{w}_t, \hat{a}_t 表示 IMU 在时刻 t 的测量真实值; R_t^{BW} 表示世界坐标系到 IMU 坐标系的旋转矩阵; g 是在世界坐标系下的重力加速度。

在获得 IMU 测量真值后, 通过机器人运动方程求出机器人在 $t + \Delta t$ 时刻的速度、位置、旋转姿态估计向量 $V_{t+\Delta t}, P_{t+\Delta t}, R_{t+\Delta t}$, 假设 B 坐标系下的角速度和加速度在积分过程中不变。随后应用文献[17]所提出的预积分方法去获得物体在相邻时间戳内的相对运动。在 i 时刻到 j 时刻的预积分值 $\Delta v_{ij}, \Delta p_{ij}, \Delta R_{ij}$ 的表达式分别为

$$\Delta v_{ij} = R_i^T (v_j - v_i - g \Delta t_{ij}), \quad (3)$$

$$\Delta p_{ij} = R_i^T (p_j - p_i - v_i \Delta t_{ij} - \frac{1}{2} g \Delta t_{ij}^2), \quad (4)$$

$$\Delta R_{ij} = R_i^T R_j, \quad (5)$$

式中: $R_i^T = R_i^{WB^T}$ 。

IMU 预积分后形成 IMU 预积分因子加入因子图中形成约束, IMU 的偏置可以在因子图中与雷达里程计因子共同优化。

2.2 激光雷达里程计因子

每收到一帧新的点云时: 系统首先对点云进行特征提取并将特征分类为角点特征和面点特征; 随后再基于关键帧采用 NDT-ICP 算法进行帧间匹配, 以获得初步姿态估计并采用列文伯格-马夸尔特算法^[18]进行优化求解, 最终输出较精确的激光雷达里程计因子并添加到因子图中进一步优化矫正。

2.2.1 基于深度变化的自适应特征提取

由于激光雷达都是线扫描的, 以 16 线激光雷达为例, 水平扫描分辨率为 0.2° , 垂直扫描分辨率仅为 2° , 所以整个环境的点云是稀疏的。常用的特征提取^[1]采用关键点前后 5 个点深度差值和的平方作为判断指标, 然而易出现错误和漏提取的特征点。受文献[19]分组策略的启发, 本研究提出了一种基于深度变化的自适应特征提取算法 Better Feature。在计算关键点与邻近点的深度差值时: 首先根据关键点深度值进行一个预对比, 若误差过大可视为噪点直接剔除, 并建立一个基于深度变化的自适应曲率计算公式[式(6)]; 关键点 i 的深度越小, 所需的邻近点越多, 其深度越大所需的邻近点越少, 邻近点数 S 在 (4, 10) 自适应波动, 对应水平包角 θ 为 $0.8^\circ \sim 2^\circ$ 。图 2 为基于深度变化的自适应曲率计算示意图, 图中包含两个扫描深度不同的激光扫描圈: 在深度 R_1 比较小时, 相应的角度 θ_1 包含的距离 l_1 过短, 因此要扩大角度为 θ_2 以获取更多的邻近点来计算曲率 (即增大临近点数 S), 以增强曲率信息的可靠性; 当深度 R_2 较大时, 相应的角度 θ_1 包含的距离 l_2 过长, 则应缩小角度为 θ_3 以减少邻近点来计算




图 2 基于深度变化的自适应曲率计算示意图

Fig. 2 Schematic of adaptive curvature calculation based on depth change

曲率 (即减小邻近点数 S), S 的数值计算规则如式(7)所示。当关键点 i 曲率小于阈值判断其为平面点, 大于阈值判断为角点。

关键点 i 的水平曲率 C 的计算公式为

$$C = \frac{1}{S \cdot \|r_i\|} \left\| \sum_{j \in S, j \neq i} (r_j - r_i) \right\|, \quad (6)$$

式中: r_i 为点 i 的三维坐标, 单位为 m; S 为同一行激光扫描线上连续点集。点集 S 在点 i 两侧平均分布, S 的值与点 i 的深度值 R_i 存在如下自适应关系:

$$S \in [(10, R_i \leq 10), (8, 10 < R_i \leq 20), (6, 20 < R_i \leq 30), (4, R_i > 30)]. \quad (7)$$

平面特征阈值设置为 0.1, 角点特征阈值设置为 0.5。当 $C < 0.1$ 时, 点 i 为平面特征点, 当 $C > 0.5$ 时, 则为角点特征点。

图 3 展示了在不同距离下传统特征提取算法与所提基于深度变化的自适应特征提取算法的效果对比, 紫色代表平面特征点, 绿色代表角点特征。从图 3 可以看到, 所提算法对角点特征的提取更加准确, 能够在深度变化的情况下, 保证对角点的敏感度, 使特征分布更加合理。

2.2.2 地面点云特征滤除

特征提取时可获得大量的点云特征点, 但过多的特征点对里程计精度的提升不大, 反而会使系统消耗更多的计算资源, 因此对冗余的特征点进行滤除和降采样能够降低计算成本。在结构丰富的环境中平面特征数量能超过 2000 个点, 平面特征常常聚集于地面点云上, 同时地面的特征点分布是相似的, 相似的特征容易造成闭环检测的误匹配, 故去除地面点云中的特征点能降低闭环检测的误匹配率并节省大量的计算资源。因此, 本研究提出了一种基于随机一致性采样 (RANSAC)^[20] 的地面点云特征滤除算法, 该算法通过

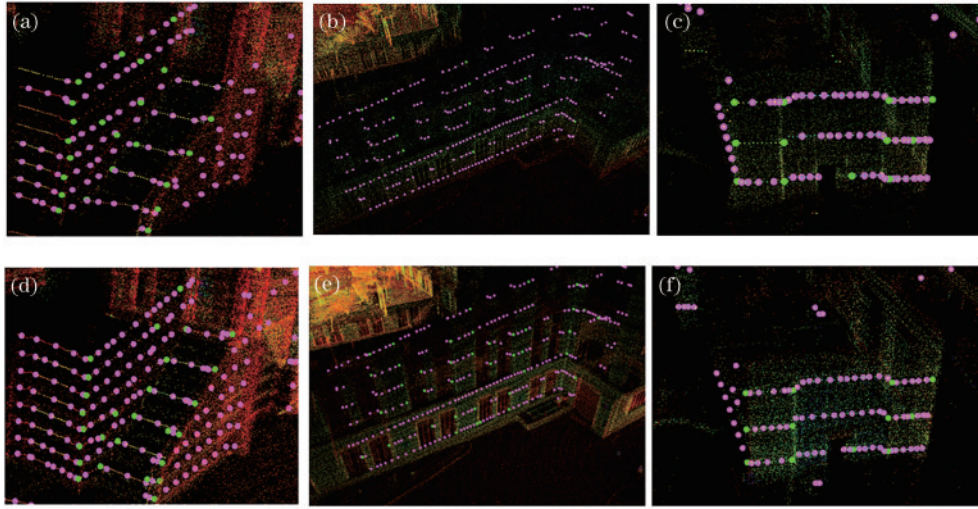


图 3 不同距离下的特征提取对比图。(a)(b)(c)原特征提取算法分别在 5、15、30 m 距离下的效果；(d)(e)(f)所提特征提取算法分别在 5、15、30 m 距离下的效果

Fig. 3 Comparison of feature extraction at different distances. (a) (b) (c) Original feature extraction effects at distances of 5, 15, 30 m respectively; (d) (e) (f) effects of proposed feature extraction at distances of 5, 15, 30 m respectively

滤除地面点云中的特征点达到降采样及去除地面相似特征的目的。

RANSAC 地面点云特征滤除算法的基本假设如下：索引为 $-15^\circ \sim 0^\circ$ 之间的线束所扫描产生的点云包含着地面平面模型的内点，符合平面模型的称为内点，不符合的称为外点。在每帧点云中随机抽取 3 个点作为内点计算，假设它们满足某平面模型 $ax + by + cz = D$ ，将剩余点云代入模型求解，只要距离误

差在阈值内（本研究距离阈值设置为 0.1 m）便满足平面模型并添加到内点集合 $I = \{p_1, \dots, p_i, \dots, p_n\}$ 中，比较每次产生的数学模型所包含的内点数，迭代 k 次后保存内点数最多的模型，便得到地面数学模型最合理的解，所保存的内点即为地面点。最后将所有的内点都标记为地面点云，识别出地面点云后，不对地面点云进行特征提取、帧间匹配等后续操作，滤除地面特征的效果图如图 4 所示。




图 4 滤除地面点云特征点效果图。(a)滤除地面特征点前；(b)为滤除地面特征点后

Fig. 4 Effect maps of filtering feature points of ground point cloud. (a) Before filtering out ground feature points; (b) after filtering out ground feature points

考虑到 SLAM 应用场景变化较大，所提取的特征点数量也在波动，若特征点过少会影响点云配准精度，以连续 5 帧的平面特征点数均值大于 1000 为阈值来判断是否需要采用 RANSAC 地面点云特征滤除算法，并且还需要根据特征点数量级来调整迭代次数 k ，调整规则为

$$k = [(20, 1000 < N_p \leq 1500), (30, 1500 < N_p \leq 2000), (40, N_p > 2000)]. \quad (8)$$

2.2.3 点云帧间匹配

帧间匹配利用点云相邻帧的特征进行匹配进而求出两帧点云之间的转换关系，即旋转矩阵 R 与平移矩

阵 t ，并以此来估计机器人的运动位姿。在点云帧间匹配环节中，采用鲁棒性更好、速度更快的 NDT 与 ICP 结合的 NDT-ICP 匹配算法。NDT-ICP 匹配算法能够结合两者的优点，先利用 NDT 进行粗配准，为 ICP 提供一个比较精确的初始值，再利用 ICP 进行精确矫正，可实现匹配精度和计算效率的平衡，具体算法流程如下：

1) 对前一帧点云 P 进行体素划分，再求出每个体素的均值 M 和协方差矩阵 Z ：

$$M = \frac{1}{n} \sum_i X_i, \quad (9)$$

$$\mathbf{Z} = \sum_i (\mathbf{X}_i - \mathbf{M})(\mathbf{X}_i - \mathbf{M})^T, \quad (10)$$

式中: \mathbf{X}_i 是点云集合; n 为点云个数。

2) 初始化旋转矩阵 \mathbf{R} 与平移矩阵 \mathbf{t} , 当前帧点云 \mathbf{Q} 根据坐标转换关系映射到前一帧的坐标系中, 获得新的点云集合 \mathbf{X}'_i , 并求出每个点映射后的正态分布 $p(\mathbf{X}'_i)$ 。

$$p(\mathbf{X}'_i) \sim \exp \left[-\frac{(\mathbf{X}'_i - \mathbf{M}_i)^T \sum_i^{-1} (\mathbf{X}'_i - \mathbf{M}_i)}{2} \right]. \quad (11)$$

3) 将每点的概率密度相加得到 $s(p)$ 参数, 用来评估坐标变换情况, 再利用 Hessian 矩阵进行优化。

$$s(p) = \sum_i \exp \left[-\frac{(\mathbf{X}'_i - \mathbf{M}_i)^T \sum_i^{-1} (\mathbf{X}'_i - \mathbf{M}_i)}{2} \right]. \quad (12)$$

4) 跳转到步骤 2) 不断迭代直至满足收敛条件, 输出两帧点云间的位姿粗估计。

5) 利用 ICP 算法基于位姿粗估计之上进行精确匹配, 首先计算前一帧点云 \mathbf{P} 中每一点在当前帧点云 \mathbf{Q} 中的最近点, 求得使对应点对平均距离最小的变换, 利用奇异值分解 (SVD) 求得旋转参数 \mathbf{R} 和平移参数 \mathbf{t} , 使得 $E(\mathbf{R}, \mathbf{t})$ 最小。

$$\min E(\mathbf{R}, \mathbf{t}) = \sum_{i=1}^n \|\mathbf{Q}_i - (\mathbf{P}_i \cdot \mathbf{R} + \mathbf{t})\|^2. \quad (13)$$

6) 对前一帧点云 \mathbf{P} 使用步骤 5) 中求出的 \mathbf{R} 、 \mathbf{t} 转换成新的点云集 \mathbf{P}_1 , 若 \mathbf{P}_1 与当前帧点云 \mathbf{Q} 的平均距离小于给定的阈值, 则退出迭代, 否则继续以 \mathbf{P}_1 作为前一帧点云进行迭代。

2.3 SC-ICP 闭环检测因子

激光 SLAM 在闭环检测时由于历史帧随着 SLAM 进程不断累积, 历史帧数量庞大难以快速计算, 因此闭环检测往往需要消耗大量的计算机资源, 在闭环时刻也常常出现卡顿。受文献 [21-23] 的启发, 引入 Scan Context^[13] 与基于欧氏距离的 ICP 相结合的两段式闭环检测算法。

Scan Context 在点云的径向和环向进行划分, 区

域数量分别为 N_r 和 N_s (本研究分别设置为 20、60), 如图 5 所示, 如此每一帧点云可以采用 $N_r \times N_s$ 维的矩阵表示, 每一个元素值代表的是区域内点云高度最大值, 将三维点云压缩成二维表示。对矩阵的每一行 \mathbf{c}_i (对应每一环) 进行计算得到向量 \mathbf{k} , \mathbf{k} 中的每一元素表示该圆环区域中的占据率 (非空区域与 N_s 的比值), 即 Ring Key 描述子。

$$\mathbf{k} = [\gamma(\mathbf{c}_1), \dots, \gamma(\mathbf{c}_{N_r})], \quad (14)$$

$$\gamma(\mathbf{c}_i) = \frac{\|\mathbf{c}_i\|_0}{N_s}. \quad (15)$$

式中: $\|\cdot\|_0$ 代表 L_0 范数。




图 5 Scan Context 描述子示意图

Fig. 5 Scan Context descriptor diagram

在得到 Ring Key 描述子的向量 \mathbf{k} 之后, 用 \mathbf{k} 构建 K 维树 (KD Tree), 在 KD Tree 中搜索 N 个最相似的点云帧可大大加快候选帧搜索的速度。本研究将 Scan Context 与基于欧氏距离的 ICP 算法融合成两段式闭环检测算法 SC-ICP, 如图 6 所示。先用 Scan Context 环状编码每一帧点云高度分布, 通过中间描述子 Ring Key 预先比较历史关键帧快速选出相似度较高的候选闭环关键帧, 候选相似帧 N 的取值为 15, 再用基于欧氏距离的 ICP 闭环检测算法来精确定闭环对应的历史关键帧。




图 6 SC-ICP 算法流程

Fig. 6 Flow chart of SC-ICP algorithm

3 实验结果及分析

为了验证所提算法的有效性, 本小节在以下 3 种数据集上进行实验验证: 1) LIO-SAM 的开源数据集 Park, 采集环境为郊区园林, 拥有超过 24000 帧的点云

数据量, 数据量丰富且场景变化多; 2) KITTI 数据集^[24] 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, 原始数据录制于 2011 年, 录制环境为城市街道, 提取 2011_09_30_0027 序列作为所提算法的验证数据集, 简称为 KITTI 27; 3) 校园数据集, 采用实

实验室的 VLP-16 线激光雷达、华测 CGI-410 组合惯导的内置 IMU 及拥有 i7-10700 CPU 和 Titan 24 GB GPU 的计算机搭建的数据采集平台在广西大学校园里的综合楼附近采集的数据,实验平台如图 7 所示。对 LIO-SAM、LEGO-LOAM、A-LOAM^[25]及所提算法等进行了多维度的评测,包括全局里程计偏差、绝对位姿误差、相对位姿误差及算法计算效率等。所有算法实验均在拥有 AMD Ryzen 7 4800H CPU、16 GB RAM 的计算机上运行,且拥有相同的参数设置,例如:关键帧阈值为位移 1 m 和旋转 10°;进行闭环检测的阈值设置为 10 m;所有数据集播放速率均为 1 倍速;角点特征及平面特征曲率阈值分别为 0.5 和 0.1。

差、相对位姿误差及算法计算效率等。所有算法实验均在拥有 AMD Ryzen 7 4800H CPU、16 GB RAM 的计算机上运行,且拥有相同的参数设置,例如:关键帧阈值为位移 1 m 和旋转 10°;进行闭环检测的阈值设置为 10 m;所有数据集播放速率均为 1 倍速;角点特征及平面特征曲率阈值分别为 0.5 和 0.1。



图 7 校园数据集采集平台
Fig. 7 Campus data collection platform

3.1 全局里程计偏差实验

全局里程计偏差能够直观体现出 SLAM 算法的里程计与真实里程计整体偏差,在 Park 和 Kitti27 数据集上针对各算法进行了全局里程计偏差对比,结果如图 8、9 所示。从图 8 可以看出,LIO-SAM 与所提算法较真实里程计的偏差均较低,偏差最大的为 A-LOAM 算法。从图 9 可以看出,在 KITTI 27 数据集上,所提算法的里程计与真实里程计的偏差最小,其余算法均出现一定的偏差,并且 A-LOAM 与 LEGO-LOAM 均出现闭环失败的情况,未能矫正累积的位姿误差,而所提算法及 LIO-SAM 闭环成功。

基于常用的 SLAM 轨迹精度评测软件 EVO^[26]统计出在世界坐标系下的 XYZ、翻滚角(Roll)、俯仰角(Pitch)、偏航角(Yaw)等 6 个维度上的偏差,详细实验

数据如表 1 所示。由表 1 中基于 Park 数据集的里程计偏差数据可知,所提算法在 Y、Z 及 Roll 这 3 个维度上均为最小偏差,其余维度上 LIO-SAM 偏差最小,但 LIO-SAM 在 Z 方向上的偏差较大,达到 1.86 m,而所提算法仅为 0.92 m。由表 1 中基于 KITTI 27 数据集的偏差数据可知,所提算法在 Z、Roll、Yaw 这 3 个维度上的偏差最小,LIO-SAM 在其余 3 个维度上偏差最小。综合所述,所提算法精度良好,能在提升计算效率的同时与 LIO-SAM 的精度基本持平,在个别维度上表现更佳。图 10 展示了各算法在两个数据集上的建图效果:A-LOAM 算法建图后产生较多噪点;LEGO-LOAM 出现两处明显偏差;LIO-SAM 与所提算法建图整体基本无偏差,边界清晰,但所提算法滤除了部分点云,故 LIO-SAM 地图更加稠密。




图 8 Park 数据集上的全局轨迹偏差示意图
Fig. 8 Global trajectory error on Park dataset




图9 KITTI 27数据集上的全局轨迹偏差示意图
Fig. 9 Global trajectory error on KITTI 27 dataset

表1 里程计的6自由度位姿偏差
Table 1 6-DOF pose deviation of odometry

Dataset	Algorithm	X /m	Y /m	Z /m	Roll /(^{\circ})	Pitch /(^{\circ})	Yaw /(^{\circ})
Park	Proposed algorithm	1. 81	0. 23	0. 92	1. 65	0. 91	0. 32
	LIO-SAM	1. 12	0. 31	1. 86	1. 77	0. 86	0. 28
	LEGO-LOAM	2. 35	0. 48	1. 64	1. 35	0. 93	0. 47
	A-LOAM	2. 79	0. 35	2. 97	2. 89	2. 36	0. 89
KITTI 27	Proposed algorithm	0. 38	0. 57	0. 98	0. 12	0. 38	0. 23
	LIO-SAM	0. 26	0. 53	1. 34	0. 25	0. 31	0. 27
	LEGO-LOAM	0. 49	0. 78	2. 06	0. 86	0. 68	0. 38
	A-LOAM	0. 62	0. 77	2. 68	0. 97	0. 54	0. 52




图10 在KITTI 27上的全局效果图比较。(a)所提算法;(b) LIO-SAM;(c) LEGO-LOAM;(d)A-LOAM

Fig. 10 Global point cloud map comparison on KITTI 27. (a) Proposed algorithm; (b) LIO-SAM; (c) LEGO-LOAM; (d) A-LOAM

3.2 绝对位姿误差与相对位姿误差实验

本小节针对各算法在数据集上与真实里程计进行绝对及相对位姿误差实验。绝对位姿误差(APE)可以比较估计轨迹和参考轨迹并计算整个轨迹的统计数据,适用于测试轨迹的全局一致性;相对位姿误差(RPE)比较姿态增量的变化,可以给出局部精度,例如SLAM系统每米的平移或者旋转漂移量。具体结果如表2所示。

由表2可知,所提算法与LIO-SAM的绝对/相对位姿误差均较小。在Park数据集上,所提算法的绝对/相对位姿偏差均为最低,仅为0.25 m和0.12 m,较LIO-SAM的绝对/相对位姿偏差均值分别降低24%

和33%。KITTI 27数据集上,LIO-SAM在绝对位姿偏差上较所提算法低5.5%,但所提算法相对位姿偏差较LIO-SAM降低14%。此外,所提算法在不使用自适应特征提取时,在Park数据集的绝对、相对位姿误差均值分别上升56%和75%,在KITTI 27数据集的绝对、相对位姿误差均值分别上升36%和61.5%,说明所提自适应特征提取与SC-ICP闭环检测能有效降低位姿误差。图11给出了各算法在Park数据集上的绝对/相对误差全局分布示意图。

由图11可知,A-LOAM的绝对位姿误差分布在局部出现(1.86,3.62)的大误差,LEGO-LOAM的分布变化最小,但其分布区间都在(0.05,0.87)区间,所提算法

表 2 绝对位姿误差与相对位姿误差
Table 2 Absolute pose error and relative pose error

unit: m

Dataset	Algorithm	Absolute pose error			Relative pose error	
		Max	Mean	Min	Max	Mean
Park	LIO-SAM	0.76	0.33	0.04	0.38	0.18
	A-LOAM	3.62	1.33	0.10	0.47	0.25
	LEGO-LOAM	1.69	0.67	0.05	0.42	0.23
	Proposed algorithm	0.63	0.25	0.01	0.33	0.12
	Proposed algorithm (without Better Feature)	0.92	0.39	0.06	0.39	0.21
	Proposed algorithm (without SC-ICP)	3.35	1.08	0.08	0.56	0.27
KITTI 27	LIO-SAM	1.54	0.52	0.15	1.82	0.63
	A-LOAM	4.00	1.38	0.10	4.59	1.86
	LEGO-LOAM	3.98	1.16	0.01	3.80	1.59
	Proposed algorithm	1.66	0.55	0.03	1.68	0.52
	Proposed algorithm (without Better Feature)	1.94	0.75	0.11	2.07	0.84
	Proposed algorithm (without SC-ICP)	3.54	1.02	0.16	4.21	1.77




图 11 绝对/相对位姿误差全局分布。(a)所提算法;(b)LIO-SAM;(c)LEGO-LOAM;(d)A-LOAM

Fig. 11 Absolute/relative pose error global distribution. (a) Proposed algorithm; (b) LIO-SAM; (c) LEGO-LOAM; (d) A-LOAM

绝大部分都在(0.01,0.32)区间,LIO-SAM的绝对位姿平均误差分布大部分都在(0.04,0.40)区间。故所提算法估计的里程计全局一致性更好。在相对位姿分布中,各算法的分布均为低误差分布,所提算法的相对位姿平均误差分布基本都在(0,0.16)区间内,分布区间最小。

3.3 算法速度性能实验

在 Park 数据集上以相同的 1 倍速率进行实验,统计每一帧点云的特征提取数量及耗时、帧间匹配耗时、闭环检测耗时、里程计耗时及建图耗时等实验数据,实验结果如表 3 所示,其中所有数据都为数据集所有帧

表 3 各算法在各环节每帧处理速度对比
Table 3 Comparison of the processing speed of each algorithm

unit: ms

Algorithm	Feature	Extraction	Scan matching	Loop closure	Odometry	Mapping
Proposed algorithm	Planar:807 Corner:321	1.94	35.38	8.22	11.53	91.85
Proposed algorithm (without Better Feature)	Planar:1547 Corner:535	8.36	49.34	10.35	21.4	114.38
Proposed algorithm (without SC-ICP)	Planar:884 Corner:381	2.34	40.75	15.36	15.73	109.24
LIO-SAM	Planar:1479 Corner:411	4.21	63.26	12.19	18.77	123.50
LEGO-LOAM	Planar:573 Corner:186	1.37	38.47	11.36	16.82	86.57
A-LOAM	Planar:1135 Corner:386	35.54	98.64		41.63	215.80

处理速度的平均值。

结合表 3 中数据可知,所提算法在保持精度的前提下,相比 LIO-SAM 将每帧特征数降低了 40.3%,提取速度提升 217.0%;在帧间匹配环节上,耗时缩减近 45%,闭环检测耗时缩短 39%。综合所述,所提算法的闭环检测在速度提升的同时保证了闭环精度,里程计及建图耗时较 LIO-SAM 分别降低 38.6%、25.6%。所提算法在不使用自适应特征提取和 SC-ICP 闭环检测时,各环节耗时增加 2.13~22.53 ms。

3.4 广西大学校园数据集实验

为了更好地验证所提算法的效果,在广西大学综合楼周围采集了一份点云数据集,卫星地图如图 12 所示,并采用各算法进行对比实验,各算法建图效果如图 13 所示。从图 13 可以看到:在地图左下角闭环处,所提算法与 LIO-SAM 闭环成功,并矫正了点云偏移,但 LIO-SAM 的地图右上角部分出现漂移偏差,A-LOAM 同样出现了这个问题;LEGO-LOAM 与 A-




图 12 校园数据集卫星地图
Fig. 12 Satellite map of campus dataset

LOAM 在闭环处因为累积的位姿漂移未能完全矫正,所以出现了地图重影,进而影响了全局精度。




图 13 各算法在校园数据集上的建图效果对比图。(a)所提算法;(b)LIO-SAM;(c)LEGO-LOAM;(d)A-LOAM
Fig. 13 Comparison of mapping of each algorithm on campus dataset. (a) Proposed algorithm; (b) LIO-SAM; (c) LEGO-LOAM; (d) A-LOAM

针对校园数据集实验,统计了各算法的里程误差,并进行压力实验,观察各算法在数据集倍速播放下的表现,在越高倍速下运行的算法鲁棒性越强,结果如表 4 所示。数据集的实际里程为 893.5 m,由表 4 可知,所提算法的里程误差最小仅为 0.7 m。在压力实

验中,所提算法与 LIO-SAM 算法均能在数据集 15 倍率之下完成精确建图,LEGO-LOAM 在数据集超过 5 倍率速度播放后初始化失败,A-LOAM 在数据集超过 3 倍率速度播放后便初始化失败。综上所述,所提算法不仅在精度上获得提升,鲁棒性也得到了保证。

表 4 里程计误差及压力测试结果
Table 4 Odometry error and pressure test

Algorithm	Odometry /m	Odometry error /m	Max rate
Proposed algorithm	892.8	0.7	15
LIO-SAM	894.6	1.1	15
LEGO-LOAM	891.4	2.1	5
A-LOAM	896.4	2.9	3

4 结 论

提出了一种基于自适应特征提取及闭环优化的即时定位建图算法 FAST-SAM。在特征提取、帧间匹配及闭环检测等环节进行优化,在多个数据集上的实验结果验证了 FAST-SAM 在精度最优的前提下,还能实现速度上的提升,且拥有较好的鲁棒性,可满足实时建图的工程应用需求。在进一步的研究中,将考虑加入语义信息来输出精确的语义地图,并着重研究语义地图构建轻量化实现。

参 考 文 献

- [1] Zhang J, Singh S. Low-drift and real-time lidar odometry and mapping[J]. *Autonomous Robots*, 2017, 41(2): 401-416.
- [2] 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 (IROS), October 1-5, 2018, Madrid, Spain. New York: IEEE Press, 2018: 4758-4765.
- [3] Shan T, Englot B, Meyers D, et al. LIO-SAM: tightly-coupled lidar inertial odometry via smoothing and mapping[EB/OL]. (2020-07-01) [2021-05-08]. <https://arxiv.org/abs/2007.00258v1>.
- [4] Biber P, Strasser W. The normal distributions transform: a new approach to laser scan matching[C]//Proceedings 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003(Cat. No.03CH37453), October 27-31, 2003, Las Vegas, NV, USA. New York: IEEE Press, 2003: 2743-2748.
- [5] Rusinkiewicz S, Levoy M. Efficient variants of the ICP algorithm[C]//Proceedings Third International Conference on 3-D Digital Imaging and Modeling, May 28-June 1, 2001, Quebec City, QC, Canada. New York: IEEE Press, 2001: 145-152.
- [6] Low K L. Linear least-squares optimization for point-to-plane ICP surface registration: TR04-004[R]. North Carolina: University of North Carolina at Chapel Hill, 2004.
- [7] Serafin J, Grisetti G. NICP: dense normal based point cloud registration[C]//2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), September 28-October 2, Hamburg, Germany. New York: IEEE Press, 2015: 742-749.
- [8] Deschaud J E. IMLS-SLAM: scan-to-model matching based on 3D data[C]//2018 IEEE International Conference on Robotics and Automation, May 21-25, 2018, Brisbane, QLD, Australia. New York: IEEE Press, 2018: 2480-2485.
- [9] Segal A, Haehnel D, Thrun S. Generalized-ICP[C]//Robotics: Science and Systems V, Robotics: Science and Systems Foundation, June 28-July 1, 2009, University of Washington, Seattle, USA. Cambridge: The MIT Press, 2009.
- [10] Koide K, Yokozuka M, Oishi S, et al. Voxelized GICP for fast and accurate 3D point cloud registration: technical report[R]. Manchester: EasyChair, 2020.
- [11] Rusu R B, Blodow N, Beetz M. Fast point feature histograms (FPFH) for 3D registration[C]//2009 IEEE International Conference on Robotics and Automation, May 12-17, 2009, Kobe, Japan. New York: IEEE Press, 2009: 3212-3217.
- [12] Rusu R B, Bradski G, Thibaux R, et al. Fast 3D recognition and pose using the Viewpoint Feature Histogram[C]//2010 IEEE/RSJ International Conference on Intelligent Robots and Systems, October 18-22, 2010, Taipei, China. New York: IEEE Press, 2010: 2155-2162.
- [13] Kim G, Kim A. Scan context: egocentric spatial descriptor for place recognition within 3D point cloud map [C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 1-5, 2018, Madrid, Spain. New York: IEEE Press, 2018: 4802-4809.
- [14] Wang H, Wang C, Xie L H. Intensity scan context: coding intensity and geometry relations for loop closure detection[C]//2020 IEEE International Conference on Robotics and Automation, May 31-August 31, 2020, Paris, France. New York: IEEE Press, 2020: 2095-2101.
- [15] 王庆闪, 张军, 刘元盛, 等. 基于 NDT 与 ICP 结合的点云配准算法[J]. *计算机工程与应用*, 2020, 56(7): 88-95. Wang Q S, Zhang J, Liu Y S, et al. Point cloud registration algorithm based on combination of NDT and ICP[J]. *Computer Engineering and Applications*, 2020, 56(7): 88-95.
- [16] Kaess M, Ranganathan A, Dellaert F. iSAM: incremental smoothing and mapping[J]. *IEEE Transactions on Robotics*, 2008, 24(6): 1365-1378.
- [17] Forster C, Carlone L, Dellaert F, et al. On-manifold preintegration for real-time visual: inertial odometry[J]. *IEEE Transactions on Robotics*, 2017, 33(1): 1-21.
- [18] Marquardt D W. An algorithm for least-squares estimation of nonlinear parameters[J]. *Journal of the Society for Industrial and Applied Mathematics*, 1963, 11(2): 431-441.
- [19] 方琪, 王晓华, 苏杰. 基于分组策略的点线特征融合同步定位与地图构建算法[J]. *激光与光电子学进展*, 2021, 58(14): 1415003. Fang Q, Wang X H, Su J. Simultaneous localization and mapping algorithm with point and line features based on

- grouping strategy[J]. *Laser & Optoelectronics Progress*, 2021, 58(14): 1415003.
- [20] Fischler M A, Bolles R C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography[J]. *Communications of the ACM*, 1981, 24(6): 381-395.
- [21] 张翠军, 张玉河. 基于 HHO 算法的 SLAM 闭环检测方法研究 [J]. *激光与光电子学进展*, 2021, 58(12): 1215006.
Zhang C J, Zhang Y H. Research on SLAM loop closure detection method based on HHO algorithm[J]. *Laser & Optoelectronics Progress*, 2021, 58(12): 1215006.
- [22] 李炯, 邵金菊, 王任栋, 等. 基于 SR-Context 的激光雷达点云闭环检测算法 [J]. *光学学报*, 2021, 41(22): 2228002.
Li J, Shao J J, Wang R D, et al. A SR-context loop-closure detection algorithm of lidar point clouds[J]. *Acta Optica Sinica*, 2021, 41(22): 2228002.
- [23] 史佳豪, 孟庆浩, 戴旭阳. 基于改进 LBD 和数据依赖度量的视觉 SLAM 回环检测 [J]. *激光与光电子学进展*, 2021, 58(6): 0615001.
Shi J H, Meng Q H, Dai X Y. Loop closure detection of visual SLAM based on improved LBD and data-dependent measure[J]. *Laser & Optoelectronics Progress*, 2021, 58(6): 0615001.
- [24] Geiger A, Lenz P, Urtasun R. Are we ready for autonomous driving? The KITTI vision benchmark suite [C]//2012 IEEE Conference on Computer Vision and Pattern Recognition, June 16-21, 2012, Providence, RI, USA. New York: IEEE Press, 2012: 3354-3361.
- [25] Qin T, Cao S Z. A-LOAM: advanced implementation of LOAM[EB/OL]. [2021-06-08]. <https://github.com/HKUST-Aerial-Robotics/A-LOAM>.
- [26] Michael G. evo: Python package for the evaluation of odometry and SLAM[EB/OL]. [2021-06-08]. <https://github.com/MichaelGrupp/evo>.