

一种显式几何特征匹配的激光雷达 SLAM方法

张红彦¹ 赵昊阳¹ 赵焕峰² 李念轩¹ 孙钦政¹ 黄玲涛^{1*}

1. 吉林大学机械与航空航天工程学院, 长春, 130025

2. 吉林大学人工智能学院, 长春, 130025

摘要: 目前多数LiDAR-SLAM系统采用前端里程计估计初始位姿和后端优化位姿的方法, 缺少批量的后端优化方案。针对此问题, 提出了一个完整的基于显式几何特征的激光雷达同时定位与建图(SLAM)系统。采用凝聚层次聚类方法实现平面特征点云平面分割并通过计算点云的局部曲率值筛选直线特征点; 通过配准点云特征和特征子地图实现激光雷达运动的初始位姿估计; 采用基于直线和平面基元的局部状态优化方法, 基于因子图模型融合了直线因子和平面因子, 通过最小化直线到直线和平面到平面的残差, 实现了位姿、直线和平面参数的联合批量优化。实验结果表明, 所提SLAM系统在其他场景下也能实现较高精度的定位和地图构建, 满足SLAM的实时性要求。

关键词: 同时定位与建图; 激光雷达里程计; 特征提取; 非线性优化

中图分类号: TP242.6

DOI:10.3969/j.issn.1004-132X.2025.08.017

开放科学(资源服务)标识码(OSID):



An Explicit Geometric Feature Matching LiDAR SLAM Method

ZHANG Hongyan¹ ZHAO Haoyang¹ ZHAO Huanfeng² LI Nianxuan¹ SUN Qinzhen¹

HUANG Lingtao^{1*}

1. School of Mechanical and Aerospace Engineering, Jilin University, Changchun, 130025

2. School of Artificial Intelligence, Jilin University, Changchun, 130025

Abstract: Currently, most LiDAR-SLAM systems utilized front-end odometry to estimate the initial pose and back-end optimization to refine the pose, but they lacked batch back-end optimization approaches. To address these issues, a comprehensive LiDAR-SLAM system was proposed based on explicit geometric features. This system employed agglomerative hierarchical clustering for plane feature point cloud segmentation and employed local curvature computation to filter linear feature points. Furthermore, the initial pose estimation of LiDAR motion was achieved through registering point cloud features and submap features. A local state optimization method was utilized based on linear and planar primitives, where linear and planar factors were merged within a factor graph model. By minimizing residuals between linear-to-linear and plane-to-plane associations, joint batch optimization of pose, linear, and planar parameters was achieved. Experimental results demonstrate that the proposed SLAM system achieves high precision localization and map construction in various scenarios, meeting real-time SLAM requirements.

Key words: simultaneous localization and mapping (SLAM); LiDAR odometry; feature extraction; nonlinear optimization

0 引言

通常采用的同时定位与建图(simultaneous localization and mapping, SLAM)技术按照传感器可划分为基于相机的视觉SLAM(visual SLAM, VSLAM)及基于激光雷达的LiDAR-SLAM。虽然基于图像方法进行特征提取与匹配^[1]更为简单,但是图像对初始化、光照和距离的敏感性使得

VSLAM在实际应用中并不可靠,而LiDAR-SLAM比VSLAM具有更好的准确性和鲁棒性。常用的SLAM技术包括基于扩展卡尔曼滤波^[2]的方法、基于粒子滤波器^[3]的方法、基于最大后验估计的方法^[4]以及图优化方法^[5]等。基于图优化的方法计算量更大,算法更加复杂,但是在某些场景具有更优异的性能。ZHANG等^[6]提出了经典激光雷达SLAM框架LOAM(LiDAR odometry and mapping),在两个模块中单独实现激光里程计和建图。SHAN等^[7]基于LOAM提出高实时

收稿日期:2024-07-29

基金项目:吉林省重点研发计划(20200401130GX)

性、低漂移的 LeGO-LOAM (lightweight and ground-optimized LiDAR odometry and mapping) 系统,该系统改进了特征提取方法,通过聚类算法分割点云并保留地面点云和聚类点云,之后从已分割点云中提取特征。WANG 等^[8]按照效率优先的原则设计了 F-LOAM 系统,主要在去除点云畸变方面采用了非迭代两级失真补偿方法来降低计算成本。PAN 等^[9]提出适配多种激光雷达的 MULLS-SLAM (multimodal unsupervised learning for LiDAR SLAM) 系统,这一系统在前端采用双阈值地面滤波和主成分分析提取分类每一帧点云中的特征点,其后端利用 TEASER (truncated least squares estimation and semidefinite relaxation)^[10]算法进行回环检测并执行基于位姿图^[11] (pose graph) 的全局优化构建全局一致的轨迹和地图。WANG 等^[12]将点云特征的来源扩展到强度通道,提出了点云强度辅助 Intensity-SLAM (intensity-assisted SLAM)。

针对传统 LiDAR-SLAM 方法存在无法提取显式几何特征的问题,本文改进了点云的几何特征提取方法,提出了基于聚类的显式直线与平面特征提取方法。采用凝聚层次聚类方法分割点云来实现平面特征提取,利用图数据结构储存有序点云,通过凝聚层次聚类合并图中属性相似的节点;采用基于广度优先搜索的直线特征检测方法,首先筛选高曲率点作为候选直线特征点,然后遍历候选直线特征点,通过合并共线的邻近特征点实现直线特征的聚类提取。此外,本文提出了基于直线和平面基元的局部状态优化方法,该方法使用因子图模型融合了直线因子和平面因子,通过最小化直线到直线和平面到平面的残差,实现了位姿、直线和平面参数的联合批量优化。

1 基于聚类的显式几何特征提取方法

主成分分析^[13] (principal component analysis, PCA) 可以利用点云分布特性拟合点云的直线方向或平面方程。通常情况下激光雷达输出点云是无序的三维点云,可使用球面投影将其映射到二维图像空间变为有序点云^[14]:

$$\begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} \frac{1}{2} (1 - \theta/\pi) w \\ [1 - (\phi + f_{up})/f] h \end{bmatrix} \quad (1)$$

式中: u 、 v 分别为投影后的图像横纵坐标; θ 、 ϕ 分别为激光点的水平方位角和俯仰角; $f = f_{up} + f_{down}$ 为激光雷达的垂直视场角,由正仰角 f_{up} 和负仰角 f_{down} 确定; w 、 h 分别为球面图像的宽度和高度。

无序激光雷达点云经过球面投影,按点云的强度通道和深度通道可得到强度图像和深度图像。本文基于凝聚层次聚类 (agglomerative hierarchical clustering, AHC) 方法^[15] 提出一种由粗到细的激光雷达点云平面分割算法。将二维直线拟合推广为三维有序点云的平面分割,邻域信息存储在二维索引中。利用有序点云的组织结构将点云分割为固定大小的网格并同时确定每个网格节点的邻居节点。以邻居节点代替全体节点,从而加速合并节点过程,减小聚类的计算复杂度。

如图 1 和图 2 所示,将有序点云划分为若干分辨率为 $w \times h$ 的网格作为初始节点,之后使用图 (graph) 数据结构保存网格。在图数据结构中,网格以节点 (node) 的形式保存,每个节点的上下左右邻居节点以边 (edge) 的形式保存。对于任意两个节点 n_i 和 n_j , 应满足 $n_i \cap n_j = \emptyset, \forall i \neq j$ 。根据每个划分的节点状态将其分为具有高均方误差 (mean square error, MSE) 值的节点、缺失数据的节点、深度不连续的节点、两个平面之间边界处的节点、正常节点。



图 1 有序点云的深度图像

Fig.1 Depth image of an ordered point cloud




图 2 合并邻居节点示意图

Fig.2 Schematic diagram of merging neighbor nodes

使用黑色“○”表示缺失数据的节点、“×”表示深度不连续的节点、红色“●”表示具有高 MSE 值的节点、黑色“●”表示正常的节点,使用直线将正常节点连接作为图的边。如果某个正常节点没有边与其连接,则该节点表示两个平面之间边界处的节点。

获得最小 MSE 值节点 m 之后,会从图 2 中查找节点 m 的邻居节点。之后,从邻居节点中选择给出最小合并 MSE 值的节点 n_{best} , 将其与节点 m 合并组成新节点 n_{merge} 。若新节点的 MSE 值大于预定义阈值 T_{mse} , 则从图 2 中找到并提取节点 n_{merge} 作为候选平面保存到 β ; 如果该 MSE 值小于预定义阈值 T_{mse} , 则节点 n_{merge} 继承节点 m 与节点 n_{best} 的边, 并将节点 n_{merge} 和其对应的边保存到图 2 中, 同时从图 2 中删除节点 m 与 n_{best} 及其对应的边。对平面粗分割的效果如图 3 所示。




图3 AHC平面粗略分割效果示意图

Fig.3 Schematic diagram of the rough segmentation effect of the AHC plane

平面之间的边界不平滑且呈现锯齿状,会降低平面方程估计的准确性从而产生不准确的平面边界。通过边界增长算法逐像素侵蚀每个平面的边界区域消除边界锯齿,以粗分割平面 β_k 作为节点,以 β_k 的邻域像素点作为边,保存到一个新的规模较小的图中。在这个小规模图上再次执行AHC聚类实现平面分割优化,其效果如图4所示。



图4 优化后的平面分割效果

Fig.4 Optimized plane segmentation effect

合并两个节点时使用PCA方法在常数时间内即可计算平面的方程和MSE值。判断节点深度是否连续时,参考了传感器的噪声特性,对于激光雷达传感器,本文使用文献[16]和PCL(point cloud library)中建议的函数:

$$f(p_a, p_b) = \begin{cases} 1 & |r_a - r_b| > 2\alpha(|r_a| + 0.5) \\ 0 & |r_a - r_b| \leq 2\alpha(|r_a| + 0.5) \end{cases} \quad (2)$$

式中: p_a, p_b 为三维点; r_a, r_b 为点到激光雷达坐标系原点的距离,mm; $\alpha \in [0.01, 0.02]$ 为传感器噪声相关参数,是经验值。

AHC聚类使用动态阈值分割平面,动态阈值 T_{mse} 计算公式如下:

$$T_{mse}(r) = (\sigma r^2 + \epsilon)^2 \quad (3)$$

其中, r 是点的深度值, σ 是激光雷达的测量噪声, $\epsilon \in [3, 8]$ 为经验值。同理,动态阈值 T_{ang} 的计算方式如下:

$$T_{ang}(r) = \cos\left(\frac{\alpha_{max} - \alpha_{min}}{r_{max} - r_{min}} \cdot (r - r_{min}) + \alpha_{min}\right) \quad (4)$$

式中: $\alpha_{max}, \alpha_{min}$ 为向量夹角范围; r_{max}, r_{min} 为激光雷达的有效测量距离。

将分割后的点云进行三维可视化,如图5所示。

本文选择基于局部曲率的边角点提取方法,将点云按列均分为6个子点云。每个子点云的每一行点按曲率大小升序排列,使用预设阈值 T_c 筛选出最大曲率的6个点作为候选特征点。算法的输入为候选特征点 P ,算法输出为提取的直线 \mathcal{L} 。首先使用树形数据结构kd-tree(k-dimensional tree)保存候选特征点 P ,并计算每个候选特征点的局部方向向量;然后遍历候选特征点 P ,选取 P




图5 平面分割结果的三维点云

Fig.5 A 3D point cloud of the result of plane segmentation

中某个未聚类的点 P_i 作为待聚类直线 L 的起点。选取 L 中最后一个点 P_j ,使用最近邻查找获得其最近的10个点 N ;然后选取 N 中的某个未聚类的点 P_k ,计算 P_k 与 P_j 的方向向量夹角以及 P_k 到 P_j 所在直线的距离。若方向向量夹角小于预设阈值 α 且 P_k 到 P_j 所在直线的距离小于预设阈值 β ,将 P_k 添加到 \mathcal{L} 中保存。重复执行该步骤,直到 L 遍历结束;最后检查 L 中的点数是否满足最小点数要求,若满足要求,将 L 保存到 \mathcal{L} ,并返回特征点,直到候选特征点 P 遍历结束。

在实际环境中对上述直线方法进行测试,图6所示为直线特征投影到强度图像的结果,图7所示为直线特征点云的三维可视化结果,图中不同的颜色表示不同的直线。



图6 直线提取结果的二维投影

Fig.6 The 2D projection of the results extracted from a straight line




图7 直线提取结果的三维点云

Fig.7 The 3D point cloud extracted from the linear results

2 基于聚类的显式几何特征提取方法

姿态估计和后端优化可以建模为无约束的最小二乘优化问题,对于目标函数

$$\min_x F(x) = \frac{1}{2} \|f(x)\|^2 \quad (5)$$

其中, $\boldsymbol{x} \in \mathbf{R}^n$ 是自变量, $f(\boldsymbol{x}): \mathbf{R}^n \rightarrow \mathbf{R}$ 是标量非线性函数, $\|\cdot\|_2$ 表示向量的二范数。采用GN方法迭代求解, 将标量非线性函数 $f(\boldsymbol{x})$ 进行泰勒展开, 可以得到线性最小二乘问题公式:

$$\delta \boldsymbol{x}^* = \arg \min_{\delta \boldsymbol{x}} \frac{1}{2} \|f(\boldsymbol{x}) + J(\boldsymbol{x})\delta \boldsymbol{x}\|_2^2 \quad (6)$$

式中: $J(\boldsymbol{x})\delta \boldsymbol{x}$ 为雅可比矩阵与状态变量增量的乘积, 代表状态空间中对非线性函数 $f(H)$ 的局部线性化近似。

在机器人学中, 通常使用旋转矩阵 \boldsymbol{R} 表示刚体的姿态。因为旋转矩阵是正交矩阵, 所以其逆矩阵 \boldsymbol{R}^{-1} (即转置矩阵 \boldsymbol{R}^T) 表示一个相反的旋转运动。三维空间的刚体运动除了旋转还有平移, 通常使用三维向量 $\boldsymbol{t} = (t_x, t_y, t_z)^T \in \mathbf{R}^3$ 表示刚体在空间中的平移。假设激光雷达坐标系 (也称局部坐标系) 为 c , 世界坐标系 (也称全局坐标系) 为 ω 。假设局部坐标系 c 到全局坐标系 ω 的旋转矩阵为 \boldsymbol{R}_c^ω , 平移向量为 \boldsymbol{t}_c^ω 。假设 \boldsymbol{p}_c 为激光雷达坐标系中的三维点, 可通过旋转矩阵 \boldsymbol{R}_c^ω 和平移向量 \boldsymbol{t}_c^ω 变换为世界坐标系 ω 下的三维点 \boldsymbol{p}_ω , 即

$$\begin{bmatrix} \boldsymbol{p}_\omega \\ 1 \end{bmatrix} = \begin{bmatrix} \boldsymbol{R}_c^\omega & \boldsymbol{t}_c^\omega \\ \mathbf{0}^T & 1 \end{bmatrix} \begin{bmatrix} \boldsymbol{p}_c \\ 1 \end{bmatrix} = \boldsymbol{T}_c^\omega \begin{bmatrix} \boldsymbol{p}_c \\ 1 \end{bmatrix} \quad (7)$$

由于旋转矩阵是过参数化的表示方法, 故在非线形优化过程中引入李代数实现非线性优化旋转矩阵。特殊正交群 $SO(3)$ 的李代数 $so(3)$ 定义如下:

$$so(3) = \{ \boldsymbol{\phi} \in \mathbf{R}^3, \boldsymbol{\varphi} = \boldsymbol{\phi}^- = \begin{bmatrix} 0 & -\phi_3 & \phi_2 \\ \phi_3 & 0 & -\phi_1 \\ -\phi_2 & \phi_1 & 0 \end{bmatrix} \in \mathbf{R}^{3 \times 3} \} \quad (8)$$

其中, $\boldsymbol{\phi}$ 为旋转的角度和方向, $\boldsymbol{\phi}^-$ 表示 $\boldsymbol{\phi}$ 的反对称矩阵。通过指数映射可将 $so(3)$ 转换为 $SO(3)$:

$$\boldsymbol{R} = \exp(\boldsymbol{\phi}) = \boldsymbol{I}_3 + \frac{\sin(\|\boldsymbol{\phi}\|_2)}{\|\boldsymbol{\phi}\|_2} \boldsymbol{\phi}^- + \frac{1 - \cos(\|\boldsymbol{\phi}\|_2)}{\|\boldsymbol{\phi}\|_2^2} \boldsymbol{\phi} \boldsymbol{\phi}^- \quad (9)$$

令 $\boldsymbol{\phi} = \theta \boldsymbol{a}$, 其中, \boldsymbol{a} 是旋转矩阵的转轴方向的单位向量, θ 是旋转矩阵的转角。将李代数与平移向量组合, 可使用六维向量 $\boldsymbol{x} \in \mathbf{R}^6$ 参数化变换矩阵, 假设三维空间中有一个点 \boldsymbol{p}_s 和 \boldsymbol{p}_e , 则直线的普吕克坐标定义 $\boldsymbol{l} \in \mathbf{R}^6$ 如下:

$$\boldsymbol{l} = \begin{bmatrix} \boldsymbol{u} \\ \boldsymbol{v} \end{bmatrix} = \begin{bmatrix} \frac{\|\boldsymbol{p}_e - \boldsymbol{p}_s\|}{\|\boldsymbol{p}_e \times \boldsymbol{p}_s\|_2} (\boldsymbol{p}_e \times \boldsymbol{p}_s) \\ 1 \\ \frac{\|\boldsymbol{p}_e - \boldsymbol{p}_s\|}{\|\boldsymbol{p}_e - \boldsymbol{p}_s\|_2} (\boldsymbol{p}_e - \boldsymbol{p}_s) \end{bmatrix} \in \mathbf{R}^6 \quad (10)$$

式中: $\boldsymbol{u} \in \mathbf{R}^3$ 为原点、 \boldsymbol{p}_s 、 \boldsymbol{p}_e 三点所在平面的法向量; $\boldsymbol{v} \in \mathbf{R}^3$ 为 \boldsymbol{p}_s 、 \boldsymbol{p}_e 所在直线的单位方向向量, \boldsymbol{u} 和 \boldsymbol{v} 正交。

由于普吕克坐标是过参数化的表示方法, 故本文引入基于李代数的三维直线最小参数化方法^[17], 对于激光雷达坐标系 c 中的直线 l_c 可通过变

换矩阵 \boldsymbol{T}_c 的伴随映射 H_c 转换为世界坐标系 ω 中的直线 l_ω 。

对于Hesse形式平面方程, 用平面的单位法向量 \boldsymbol{n} 和原点到平面的距离 d 表示。文献[18]提出一种最近点(close point, CP)的平面参数化方法:

$$\boldsymbol{\eta} = d \cdot \boldsymbol{n} \in \mathbf{R}^3 \quad (11)$$

其中, $\boldsymbol{\eta}$ 表示平面上到原点最近的三维点。最近点表示法在 $d=0$ 时存在奇异性, 但是可以通过将平面变换到局部坐标系来避免这种奇异性。将全局坐标系中的平面 η_ω 转换为局部坐标系中的平面 η_c 。

3 基于显式几何特征的SLAM系统

假设在时间间隔 $(t_k, t_{k+1}]$ 激光雷达采集点云 S_k , 激光雷达在 t_k 和 t_{k+1} 时刻的位姿分别为 T_k 和 T_{k+1} , 那么从 T_k 到 T_{k+1} 的相对位姿为 T_{k+1}^k , 其最小化参数表达形式为

$$\boldsymbol{x}_{k+1}^k = [\phi_{k+1}^k \quad t_{k+1}^k]^T \quad (12)$$

当帧间运动较为平稳时, 通过线性插值公式计算 t 时刻的相对位姿 T_t^k 的最小参数化形式 \boldsymbol{x}_t^k , 结合式(6)可得 t 时刻的相对位姿 T_t^k , 则 S_k 经去畸变后的点云为

$$P_k = \{ T_t^k \boldsymbol{p}_i | \boldsymbol{p}_i \in S_k \} \quad (13)$$

采用scan-to-map的点云配准方法将无畸变的点云特征 $\boldsymbol{\phi}$ 与特征子地图 M 配准, 使用点云特征代替整个点云与特征子地图进行匹配并设计了基于滑动窗口的特征子地图构建方法。特征子地图由历史关键帧组成, 使用队列数据结构保存历史关键帧。假设从 S_k 中提取的特征 $F_k = \{ F_k^l, F_k^\pi \}$, F_k^l 是 k 时刻的直线特征, F_k^π 是 k 时刻的平面特征。之后, 从关键帧队列中提取距离 F_k 最近的 n 个关键帧组成关键帧子集 $\{ F_{k-n-1}, F_{k-n}, \dots, F_{k-1} \}$, 与其对应的全局变换矩阵子集为 $\{ T_{k-n-1}, T_{k-n}, \dots, T_{k-1} \}$ 。利用全局变换矩阵将关键帧集合变换到世界坐标系下, 得到全局关键帧子集 $\{ \bar{F}_{k-n-1}, \bar{F}_{k-n}, \dots, \bar{F}_{k-1} \}$ 。

全局关键帧子集构成的全局子地图 M_k 包括两个特征子地图, 分别由全局关键帧子集的直线特征和平面特征组成。当前帧 F_k 与特征子地图 M_k 进行点云匹配后可得到当前的位姿 T_k , 使用估计后的位姿判断当前帧是否关键帧并将 F_k 保存到关键帧队列中。当接收第 $k+1$ 帧特征 F_{k+1} 时, 窗口会向前滑动将 F_k 添加到关键帧子集, 并将 F_{k-n-1} 从关键帧子集中移除。通过点云特征与特征子地图的匹配关系构建位姿估计的目标函

数,该目标函数由点到直线的距离 d_i^l 以及点到平面的距离 d_j^p 两部分组成:

$$T^* = \arg \min_T \frac{1}{2} \left\{ \sum_{p_i \in F^l} \rho(\|d_i^l\|_2^2) + \sum_{p_j \in F^p} \rho(\|d_j^p\|_2^2) \right\} \quad (14)$$

式中: $\rho(\cdot)$ 为鲁棒核函数。

本文使用高斯牛顿法迭代求解增量方程来最小化目标函数,增量方程中的 H 矩阵可通过待优化位姿 x 关于目标函数的雅可比矩阵 J 来计算。记第 i 个点点到直线的残差项 d_i^l 关于位姿 x 的雅可比矩阵 $J_i^l = \partial d_i^l / \partial x$,第 j 个点点到平面的残差项 d_j^p 关于位姿 x 的雅可比矩阵 $J_j^p = \partial d_j^p / \partial x$,由链式求导法则计算得到整个目标函数关于位姿 x 的雅可比矩阵 J ,在增量方程中 $H = J^T J$,则有

$$H = \sum_{i=1}^{|F^l|} (J_i^l)^T J_i^l + \sum_{j=1}^{|F^p|} (J_j^p)^T J_j^p \quad (15)$$

在后端优化模块中,本文提出了基于直线/平面基元的批量优化方法,实现位姿、直线和平面的局部状态优化。基于因子图(factor graph)模型,将后端优化问题建模为图优化问题并转化为最大后验估计。在后端的滑动窗口中,本文使用一种基于局部邻域搜索的特征匹配方法,利用激光里程计提供的变换矩阵将激光雷达坐标系中的特征投影到世界坐标系中获得其预测位置,之后在其预测位置的局部邻域选择最相似的特征作为匹配对象,特征匹配后可通过最小化滑动窗口中所有变量的残差优化直线、平面和位姿。假设滑动窗口中有 N 个位姿,具有 M 条直线和 L 个平面,那么该局部优化问题的目标函数如下:

$$\chi^* = \arg \min_{\chi} \left\{ \|r_p\|_2^2 + \sum_{i=1}^N \sum_{j=1}^M \|r_{x_i, l_j}\|_2^2 + \sum_{i=1}^N \sum_{k=1}^L \|r_{x_i, p_k}\|_2^2 \right\} \quad (16)$$

式中: r_p 为窗口滑动时窗口外变量关于窗口内变量的先验约束,可通过舒尔补方法计算; r_{x_i, l_j} 为滑动窗口中第 j 条直线与其在第 i 个位姿下的测量值形成的残差项; r_{x_i, p_k} 为滑动窗口中第 k 个平面与其在第 i 个位姿下的测量值形成的残差项。

4 实验与评估

精度评估实验分别在牛津大学的公开数据集

Newer College Dataset^[19]以及自制的校园数据集上进行。其中,Newer College Dataset提供了激光雷达的轨迹真值(ground truth, GT),因此,采用绝对轨迹误差(absolute trajectory error, ATE)作为误差指标对SLAM系统的估计轨迹和轨迹真值的差异进行定量评估^[20]。

由于所提的激光雷达SLAM系统更适合在直线和平面特征丰富的结构化场景中运行,故从Newer College Dataset的12个序列中挑选7个序列作为测试数据集。序列信息见表1。

表1 Newer College Dataset 序列信息

Tab.1 Newer college dataset sequence information

序列名称	场景	帧数	难度	时长/s	长度/m
序列1	方形庭院	1991	简单	198	246.7
序列2	方形庭院	1910	中等	190	260.4
序列3	环形走廊	2788	简单	190	428.8
序列4	数学研究所	2160	简单	216	263.6
序列5	数学研究所	1770	中等	176	176.9
序列6	地下矿洞	1412	简单	141	162.5
序列7	地下矿洞	1487	中等	148	174.1

采用常见的绝对轨迹误差量化SLAM系统估计的轨迹和真实轨迹之间的误差,使用均方根误差(root mean squared error, RMSE)统计ATE来评估系统的精度。本文方法利用直线和平面特征的激光雷达SLAM,所以在下文中称该系统为LPL-SLAM。实验测试了A-LOAM、LeGO-LOAM以及本文的LPL-SLAM,还对LPL-SLAM系统的变体算法进行消融实验以验证后端中直线因子、平面因子以及回环因子的优化效果。在消融实验中,称仅使用直线因子的系统为LL-LO,称仅使用平面因子的系统为LP-LO,称使用直线因子和平面因子不进行回环优化的系统为LPL-LO。A-LOAM、LeGO-LOAM、LPL-SLAM及其变体算法的测试结果见表2和表3。

表2所示为绝对轨迹平移误差,可看出在绝对轨迹平移误差方面,LPL-SLAM在6个序列上精度最高,其平均误差也最小。表3所示为绝对轨迹角度误差,可看出在绝对轨迹角度误差方面,

表2 绝对轨迹平移误差

Tab.2 Absolute trajectory translation error

方法	序列1	序列2	序列3	序列4	序列5	序列6	序列7	误差均值
A-LOAM	0.0856	0.4034	0.2639	0.0863	0.8257	0.1451	0.1935	0.2862
LeGO-LOAM	0.0929	0.5453	0.1865	0.1303	0.4315	0.1081	0.1311	0.2322
LL-LO	0.1139	0.3569	0.2942	0.1522	0.3162	0.1255	0.1629	0.2174
LP-LO	0.1068	0.3847	0.1742	0.1182	0.2835	0.1138	0.1497	0.1901
LPL-LO	0.0888	0.2912	0.1224	0.0804	0.2617	0.0919	0.1244	0.1515
LPL-SLAM	0.0865	0.2891	0.1027	0.0685	0.2388	0.0683	0.0935	0.1353

表3 绝对轨迹角度误差

Tab.3 Absolute trajectory angular error

(°)

方法	序列1	序列2	序列3	序列4	序列5	序列6	序列7	平均误差
A-LOAM	1.3262	2.1683	1.8402	0.6375	3.9587	2.1558	2.6240	2.1015
LeGO-LOAM	1.3705	2.3082	1.9917	0.8802	3.3395	2.3710	2.3344	2.0851
LL-LO	2.1462	2.3851	2.3518	0.9573	3.6842	2.3568	2.5713	2.3504
LP-LO	1.7438	2.4692	2.1566	0.8359	3.1183	2.1366	2.1724	2.0904
LPL-LO	1.3405	2.2011	1.6433	0.5451	2.9053	1.9088	2.1230	1.8096
LPL-SLAM	1.2309	2.1816	1.5943	0.5553	2.8719	1.9140	2.0116	1.7656

LPL-SLAM在5个序列上精度最高,其平均误差也最小。同时,观察LL-LO、LP-LO及LPL-LO这三个变体算法的绝对轨迹误差,可知加入直线因子、平面因子及回环因子后可提高系统估计轨迹的精度。

自制数据集包含三个序列,见表4。序列1采集场景中包含墙体、门窗等物体和结构;序列2采集场景为长走廊,其中包含门窗、立柱等;序列3采集场景中包含大量的斜梁、几面主墙和许多窗户。

表4 自制数据集序列信息


Tab.4 Scene diagram of a custom dataset

序列名称	场景	帧数	时长/s	长度/m
序列1	机械馆	3422	343	386.4
序列2	机械馆	2904	291	321.7
序列3	体育馆	4284	429	606.4


由于受到数据采集平台的限制,故自制的校园数据集无法获得对应的轨迹真值。采集校园数据集时,将轨迹的起点和终点设置为同一点,通过端到端的相对位姿误差(relative pose error, RPE)计算两个相同时间戳上相机位姿的真实值与SLAM系统的估计值之间每隔一段时间位姿变化量之间的差值,将其作为误差指标量化评估系统估计轨迹的精度。

在自制的校园数据集上进行了A-LOAM、LeGO-LOAM、LPL-LO及LPL SLAM测试。结果见图8~图10。图8a、图9a、图10a为上述四种方法估计的轨迹和地图,其中,红色点为起点和终点,灰色点为LPL-SLAM生成的点云地图,该点云地图经过降采样投影到XY平面。图8b、图9b、图10b为LPL-SLAM系统运行示意图。

对比表5中A-LOAM、LeGO-LOAM、LPL-LO以及LPL-SLAM在自制数据集上测试的相对位姿误差可以看出,本文LPL-SLAM系统具有最小的相对平移误差和相对位姿误差,在其他场景下也能实现较高精度的定位和地图构建。



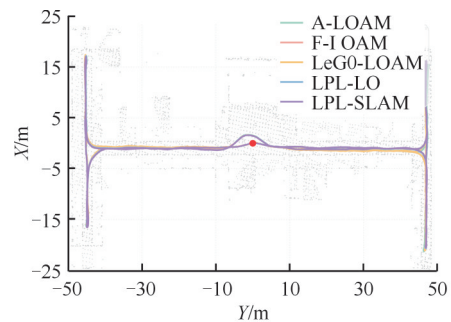
(a)轨迹与地图




(b)系统运行示意图

图8 自制数据集序列1实验结果

Fig.8 Experimental results of self-made data set sequence 1



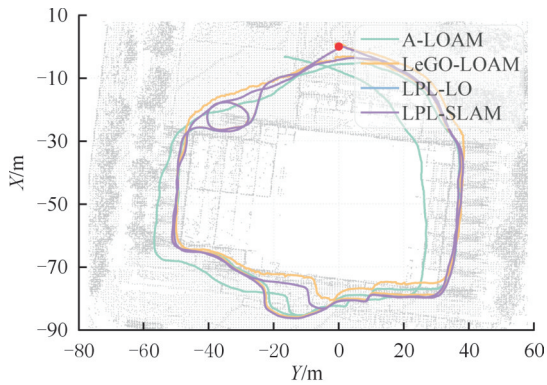
(a)轨迹与地图




(b)系统运行示意图

图9 自制数据集序列2实验结果

Fig.9 Experimental results of self-made data set sequence 2



(a) 轨迹与地图



(b) 系统运行示意图

图10 自制数据集序列3实验结果

Fig.10 Experimental results of self-made data set sequence 3

SLAM系统要求算法具有较高的实时性,需要对LPL-SLAM的各模块运行耗时进行测试。以Newer College Dataset的序列1和校园数据集的序列1为例,分别测试LPL-SLAM系统处理128线激光雷达点云和64线激光雷达点云时各主要模块的运行时间。测试模块包括:特征提取、位姿估计、局部优化、全局优化,各模块的运行时间见表6。此外,分别以Newer College Dataset和校园数据集的序列1为例测试LPL-SLAM和A-LOAM系统局部优化时间,结果见表7。

LPL-SLAM的特征提取、位姿估计、局部优化在以上两个序列的总耗时分别为64.18 ms和58.5 ms,A-LOAM的耗时为49.12 ms。由于A-LOAM中并未通过光束平差法(bundle adjustment,BA)进行优化,处理速度更快但精度较低。激光雷达采集点云的频率为100 ms(10 Hz),LPL-SLAM的总耗时低于点云采集频率,所以LPL-SLAM达到了实时要求。另外,回环检测和全局优化在独立线程执行^[21],故有足够的时间执行优化。

表5 相对平移/角度误差

Tab.5 Relative translation/rotation error

序列名称	A-LOAM	LeGO-LOAM	LPL-LO	LPL-SLAM
序列1	0.131 m/2.146°	0.245 m/2.436°	0.104 m/1.708°	0.075 m/1.485°
序列2	0.096 m/2.348°	0.075 m/2.341°	0.091 m/1.522°	0.062 m/1.379°
序列3	17.43 m/5.269°	0.535 m/2.571°	0.205 m/2.675°	0.121 m/1.841°

表6 各模块运行时间

Tab.6 Runtime of each module

ms

序列名称	特征提取	位姿优化	局部优化	全局优化
LPL-SLAM/Newer College Dataset 序列1	24.07	20.67	19.44	88.53
LPL-SLAM/校园数据集 序列1	17.51	14.97	26.02	109.6

表7 局部优化运行时间

Tab.7 Local optimization runtime

ms

序列名称	局部优化
LPL-SLAM/Newer CollegeDataset 序列1	19.44
LPL-SLAM/校园数据集 序列1	26.02
A-LOAM/Newer College Dataset 序列1	10.27
A-LOAM/校园数据集 序列1	11.98

5 结语

本文改进了点云的几何特征提取方法,提出了基于聚类的显式直线与平面特征提取方法。对于平面特征和直线特征,分别使用凝聚层次聚类方法实现点云的快速平面分割并提出基于广度优先搜索的直线特征检测方法。基于显式的直线和平面特征实现了基于scan-to-map的前端激光里

程计。通过配准点云特征和局部点云地图,实现了激光雷达运动的初步估计。在后端模块中,提出了基于直线和平面基元的批量状态优化方法,实现了位姿、直线和平面参数的联合批量优化。此外,分别在公开数据集和自制数据集上进行了精度评估。在公开数据集实验中,采用绝对轨迹误差度量系统估计轨迹和真实轨迹的差异,与其他方法比较的同时还进行了消融实验,实验结果表明本文方法能提高精度。在自制数据集实验中采用端到端的相对位姿误差度量轨迹误差,所提的SLAM系统在其他场景下也能实现较高精度的定位和地图构建。同时对LPL-SLAM系统进行了运行效率评估实验,分别测量各主要模块的运行时间并与A-LOAM系统进行对比实验,实

验结果表明,所设计的LPL-SLAM系统满足系统的实时性要求。

参考文献:

- [1] GALVEZ-LÓPEZ D, TARDOS J D. Bags of Binary Words for Fast Place Recognition in Image Sequences[J]. IEEE Transactions on Robotics, 2012, 28(5):1188-1197.
- [2] RIBEIRO M I. Kalman and Extended Kalman Filters: Concept, Derivation and Properties[J]. Institute for Systems and Robotics, 2004, 43(46):3736-3741.
- [3] MURPHY K, RUSSELL S. Rao-blackwellised Particle Filtering for Dynamic Bayesian Networks[M]//Sequential Monte Carlo Methods in Practice. New York: Springer New York, 2001:499-515.
- [4] THRUN S. Probabilistic Robotics[J]. Communications of the ACM, 2002, 45(3):52-57.
- [5] OLSON E B. Real-time Correlative Scan Matching[C]//2009 IEEE International Conference on Robotics and Automation. Kobe, 2009:4387-4393.
- [6] ZHANG Ji, SINGH S. LOAM: Lidar Odometry and Mapping in Real-time[C]//Robotics; Science and Systems. Berkeley, 2014:1-9.
- [7] SHAN Tixiao, ENGLLOT B. LeGO-LOAM: Light-weight and Ground-Optimized Lidar Odometry and Mapping on Variable Terrain[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Madrid, 2018:4758-4765.
- [8] WANG Han, WANG Chen, CHEN Chunlin, et al. F-LOAM: Fast LiDAR Odometry and Mapping[C]//2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Prague, 2021:4390-4396.
- [9] PAN Yue, XIAO Pengchuan, HE Yujie, et al. MULLS: Versatile LiDAR SLAM via Multi-metric Linear Least Square[C]//2021 IEEE International Conference on Robotics and Automation (ICRA). Xi'an, 2021:11633-11640.
- [10] YANG Heng, SHI Jingnan, CARLONE L. TEASER: Fast and Certifiable Point Cloud Registration[J]. IEEE Transactions on Robotics, 2021, 37(2):314-333.
- [11] SÜNDERHAUF N, PROTZEL P. Towards a Robust Back-end for Pose Graph SLAM[C]//2012 IEEE International Conference on Robotics and Automation. St Paul, 2012:1254-1261.
- [12] WANG Han, WANG Chen, XIE Lihua. Intensity-SLAM: Intensity Assisted Localization and Mapping for Large Scale Environment[J]. IEEE Robotics and Automation Letters, 2021, 6(2):1715-1721.
- [13] WOLD S, ESBENSEN K, GELADI P. Principal Component Analysis[J]. Chemometrics and Intelligent Laboratory Systems, 1987, 2(1/2/3):37-52.
- [14] BEHLEY J, STACHNISS C. Efficient Surfel-based SLAM Using 3D Laser Range Data in Urban Environments[C]//Robotics; Science and Systems. Pittsburgh, 2018:46954808.
- [15] FENG Chen, TAGUCHI Y, KAMAT V R. Fast Plane Extraction in Organized Point Clouds Using Agglomerative Hierarchical Clustering[C]//2014 IEEE International Conference on Robotics and Automation (ICRA). Hong Kong, 2014:6218-6225.
- [16] GAO Haiming, ZHANG Xuebo, FANG Yongchun, et al. A Line Segment Extraction Algorithm Using Laser Data Based on Seeded Region Growing[J]. International Journal of Advanced Robotic Systems, 2018, 15:1729881418755245.
- [17] ZUO Xingxing, XIE Xiaojia, LIU Yong, et al. Robust Visual SLAM with Point and Line Features[C]//2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Vancouver, 2017:1775-1782.
- [18] GENEVA P, ECKENHOFF K, YANG Yulin, et al. Lips: LiDAR-inertial 3D Plane Slam[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Madrid, 2018:123-130.
- [19] ZHANG L, CAMURRI M, WISTH D, et al. Multi-camera LiDAR Inertial Extension to the Newer College Dataset[M]//arXiv Preprint, 2022.
- [20] LIU Zheng, LI Haotian, YUAN Chongjian, et al. Voxel-SLAM: a Complete, Accurate, and Versatile LiDAR-Inertial SLAM System [EB/OL]. arXiv: 2410.08935, 2024-10-11 [2024-10-20]. <https://doi.org/10.48550/arXiv.2410.08935>.
- [21] XU Ziheng, LI Qingfeng, CHEN Chen, et al. GLC-SLAM: Gaussian Splatting SLAM with Efficient Loop Closure [EB/OL]. arXiv: 2409.10982, 2024-09-17 [2024-10-20]. <https://doi.org/10.48550/arXiv.2409.10982>.

(编辑 陈勇)

作者简介:张红彦,女,1973年生,副教授、博士。研究方向为智能移动机器人。E-mail:zhanghy@jlu.edu.cn。黄玲涛*(通信作者),男,1979年生,副教授、博士。研究方向为机器人定位导航与控制。E-mail:hlt@jlu.edu.cn。

本文引用格式:

张红彦,赵昊阳,赵焕峰,等.一种显式几何特征匹配的激光雷达SLAM方法[J].中国机械工程,2025,36(8):1824-1831.
ZHANG Hongyan, ZHAO Haoyang, ZHAO Huanfeng, et al. An Explicit Geometric Feature Matching LiDAR SLAM Method[J]. China Mechanical Engineering, 2025, 36(8):1824-1831.