

基于三级去畸变和分层降采样机制的 F-LOAM 改进算法

徐鹤^{1,2}, 张阔¹, 李鹏^{1,2}

(1. 南京邮电大学计算机学院、软件学院、网络空间安全学院, 南京 210023)

(2. 江苏省高性能计算与智能处理工程研究中心, 南京 210023)

摘要: 传统的 F-LOAM (Fast LiDAR Odometry and Mapping) 算法虽然对特征点进行了两级去畸变处理, 但仅第一阶段对特征点进行去畸变, 第二阶段去畸变主要用于建图, 这导致了位姿估计的准确性不足。为了解决这一问题, 本文提出了一种改进的三级去畸变机制, 并结合基于体素化网格的分层降采样机制, 以提高算法的实时性。经过改进的 F-LOAM 算法在 KITTI 数据集上的测试结果表现出色。三级去畸变机制和分层降采样策略不仅有效降低了计算负担, 还确保了特征点的有效性和全局地图的精度。

关键词 F-LOAM; 激光雷达; 运动畸变; 匀速模型; 去畸变; 分层降采样

中图分类号: TP249 文献标志码: A

Improved F-LOAM algorithm based on three-stage de-distortion and hierarchical downsampling mechanism

XU He^{1,2}, ZHANG Kuo¹, LI Peng^{1,2}

(1. School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023)

(2. Jiangsu HPC and Intelligent Processing Engineer Research Center, Nanjing 210023)

Abstract: The traditional F-LOAM (Fast LiDAR Odometry and Mapping) algorithm performs a two-stage de-distortion process on the feature points, but only the first stage de-distorts the feature points, and the second-stage de-distortion is mainly used for building the map, which leads to the lack of accuracy in the bit-position estimation. In order to solve this problem, this paper proposes an improved three-stage de-distortion mechanism combined with a voxelized grid-based hierarchical downsampling mechanism to improve the real-time performance of the algorithm. In addition by introducing a voxelized grid based hierarchical downsampling mechanism to improve the real-time performance of the algorithm. The improved F-LOAM algorithm shows excellent test results on the KITTI dataset. The three-stage de-distortion mechanism and the hierarchical downsampling strategy not only effectively reduce the computational burden, but also ensure the validity of feature points and the accuracy of the global map.

Key words F-LOAM; LiDAR; Motion Distortion; Constant Velocity Model; Undistortion; Hierarchical Down-sampling

基金项目: 国家重点研发计划(2019YFB2103003)资助项目

收稿日期: 2024-08-22; **修回日期:** 2024-11-XX

引言

同步定位与地图构建 (SLAM) 是当前机器人研究领域的核心问题之一^[1]。在未知或部分已知的环境中, 机器人通过传感器获取信息, 执行定位任务并构建周围环境的地图。SLAM 算法一般包含两个主要部分: 前端和后端优化^[2]。前端负责估计机器人的位姿并生成地图信息, 而后端则对前端的位姿进行优化, 并用于构建精确的地图。

根据感知设备的不同, SLAM 算法可以分为两种类型: 一种是基于激光雷达的 SLAM, 另一种是基于相机视觉的 SLAM^[3], 视觉 SLAM 会因为场景中动态物品的干扰^[4]导致位姿估计错误, 而基于雷达的 SLAM 算法在姿态估计方面更为准确, 且对光照和天气等环境变化具备更高的鲁棒性^[5], 因此, 激光雷达 SLAM 在许多机器人应用中被广泛采用, 如自动驾驶^[6]、无人机检查^[7]和仓库操作^[8]。

目前, 2D 激光 SLAM 技术已经较为成熟, 并在工业环境和服务机器人中得到广泛应用^[9]。然而, 由于 2D 受限于平面环境, 无法适用于地形复杂的场景。在这种情况下, 3D 激光雷达可以通过发射多个激光束来采集环境中的几何数据, 获取包含距离和角度的点云信息, 从而重建周围三维空间的结构^{[10][11]}。

目前多线激光雷达的普及和生产规模的扩大, 3D 激光雷达技术实现了快速发展。Zhang 等人^[12]提出的 LOAM (LiDAR Odometry and Mapping) 算法将激光 SLAM 算法分成了两部分: 里程计算和地图构建, 然而由于缺乏闭环检测模块, 使得此算法在复杂环境测试中容易出现漂移问题。为此, Shan 等^[13]在 LOAM 算法的基础上增加闭环检测模块, 并优化特征匹配算法, 提出了 LeGO-LOAM (Lightweight and Ground-Optimized LiDAR Odometry and Mapping)。另有研究者采用了 Eigen 库中的线性迭代方法和 Ceres Solver 中的非线性优化技术, 以简化复杂的数学推导和减少冗余计算, 从而提出了 A-LOAM^[14]算法。此外, Deschand 等^[15]提出了 IMLS-SLAM 算法, 使用帧到模型的匹配框架, 实现精确的姿态估计。然而, 由于其计算量较大, 难以实际应用。Behley 等^[16]提出了基于面元的算法 SuMa (Surfel-based Mapping), 该算法即使在点云数据缺失的情况下依旧能够具有较高的鲁棒性。另外, 也有学者提出多传感器融合的算法来进一步推动 SLAM 算法的发展, 李帅鑫等^[17]提出一种激光雷达和惯性传感器(IMU)紧耦合的算法 Inertial-LOAM, 该算法通过 IMU 减少误差累计, 提升定位精度和实时性。Shan^[18]等也提出了一种融合 IMU 与 GPS 的 LIO-SLAM 算法, 也具有相当高的精确性。

然而, 基于多传感器融合的定位方法在提高定位精度的同时, 也增加了各传感器的同步和全面校准的需求。基于此, Wang^[19]等在 Ceres Solver^[19]基础上提出了纯雷达 SLAM 系统——Fast LiDAR Odometry and Mapping (F-LOAM), 优化了 LOAM 的帧匹配精度, 同时降低了计算成本; 但 F-LOAM 在复杂室外环境中仍存在定位偏差的问题。为解决以上问题, 提高 SLAM 算法的实时性和准确性, 本文在 F-LOAM 的基础上进行了以下工作:

本文通过增加匀速模型对原始点云进行基本的点云去运动畸变, 以改进 F-LOAM 的二级去畸变缺少对畸变点的处理, 增加算法的稳定性和准确性。本文使用基于体素化网格的分层降采样机制, 分别对局部特征点和整体特征点分别进行一次降采样, 以保留特征点的局部特征和整体特征, 在减少计算量的同时, 保留算法的准确性。

1. 提出的模型架构

(1) F-LOAM 算法

F-LOAM (Fast LiDAR Odometry and Mapping) 是针对激光雷达提出的一种高效精准实时定位算法。其采取的该方法主要关注计算效率和定位精度, 其在现有 LiDAR SLAM 工作中常见的扫描到扫描匹配和扫描到地图优化两个模块的基础上进行了改进。通过采用非迭代

的两阶段失真补偿方法，大幅降低了计算成本。具体而言，F-LOAM 将每个扫描输入也就是帧的点云分为边缘和平面特征，并分别与局部边缘地图和局部平面地图匹配，在得到精确的位姿数据之后进行地图构建。




图 1 F-LOAM 算法流程图

Fig. 1 Flowchart of F-LOAM algorithm

如图一所示，F-LOAM 算法在接收到 LIDAR 采集到的原始点云数据后，直接采取基于局部点平滑度提取特征点。平滑度大于指定阈值的点被视为边缘点，小于指定阈值的则被视为平面点。然后，对提取出来的边缘点云 ε_k^L 和平面点云 S_k^L 使用匀速模型去运动畸变；接着将去畸变后的特征点传递到位姿估计模块，此模块将边缘点云 ε_k^L 和平面点云 S_k^L 变换到全局坐标系中，得到 ε_k^W 和 S_k^W ，然后基于此计算此时的机器人位姿；位姿估计完成后，用得到的准确位姿重新对特征点进行去畸变，本次去畸变后的点将用于地图构建。

(2) CH-F-LOAM 算法

G-LOAM 算法中，针对雷达传感器获取的点云数据并没有进行去畸变处理。相反，该算法直接对点云数据进行特征点提取，然后通过两级去畸变来保证位姿的准确性。然而，F-LOAM 的两级去畸变机制用于位姿估计的只有第一级对特征点去运动畸变，第二级去畸变后的点用于制图，因此无法保证定位的准确性，并且直接对点云数据进行特征提取也会导致特征点的准确性不高。因此，在本文中，将两级去畸变改为三级去畸变，在原有算法的基础上引入匀速模型对原始数据进行去运动畸变，以改进 F-LOAM 算法的在位姿估计上的不准确。但为了实时性的保证，此匀速模型只以匀速运动为前提进行一次畸变点的去除；此外为进一步提高算法的实时性，引入基于体素化网格的特征点分层降采样机制，减少特征点数量的同时，保留足够的局部特征和整体特征。

1.1 三级去畸变机制

本文所涉及的三级去畸变机制主要包括：基于匀速模型的原始点云去畸变、基于匀速模型的特征点去畸变和畸变补偿建立三维地图。

1.1.1 基于匀速模型的原始点云去畸变

① 运动畸变的含义

激光雷达通过发射激光束测量周围物体的距离和方向，从而确定机器人与障碍物之间的相对位置。当激光束数量增加时，产生的激光点会组合成一个点云，展现出周围环境的三维空间信息，这就是常说的点云数据。

尽管大多数激光雷达的激光发射与接收速度极快，但每个点云点的生成时间并非完全同

步。通常，激光雷达会将 100 毫秒（即 10Hz 频率）内采集的点云数据作为一帧输出。如果在此过程中激光雷达或其安装平台发生了位移，那么这一帧点云中的各个点将处于不同的坐标系中。

② 运动畸变产生的原因

激光雷达点云的自运动畸变与其扫描方式密切相关。传统的 360 度机械式激光雷达每一帧数据是通过雷达围绕中心进行一圈扫描（通常约 100ms）。当雷达和车辆保持静止时，扫描的起始点与终止点可以较好地对接，坐标原点保持一致。然而，当雷达或车辆发生运动时，点云数据会出现畸变，导致扫描一圈的数据产生扭曲，从而使得环绕扫描无法闭合（不同扫描点的坐标原点发生变化）。




图 2 360 度机械式雷达运动畸变示意图

Fig.2 Schematic diagram of 360-degree mechanical radar motion distortion

激光雷达点云的运动畸变本质上源于同一帧内不同点所处坐标系的差异。如图所示，在图 3（a）中， p_1 ， p_2 ， p_3 表示激光雷达在一次扫描中检测到的三个位置点，这三点在现实世界中是共线的。然而，由于激光雷达在扫描过程中存在运动，如图 3（b）所示，它在不同的实际姿态下对这些点进行了扫描。因此，最终生成的点云如图 3（c）中，三个点的坐标属于不同的坐标系，导致它们不再共线。




图 3 点云坐标系变化示意图

Fig. 3 Schematic diagram of the change of point cloud coordinate system

③ 匀速模型去运动畸变

F-LOAM 对特征点进行两级去畸变以消除雷达运动畸变的影响，但只有第一阶段的去畸变是对雷达的位姿预测有效的，第二阶段的去畸变是为了建造三维地图，因此对于位姿预测阶段，特征点实际并不是完全稳定的，依旧存在噪声点的存在，这会使位姿的预测不准确导致雷达自身定位的不准确，因此，本节在其基础上在引入匀速模型对原始点云进行去运动畸变，保证提取的特征点更加稳定，以确保位姿预测阶段使用的特征点更加有效。

匀速模型假设机器人以与前一个时间步长相同的平移速度和旋转速度运动，不需要额外的传感器，并避免了传感器之间的时间同步需求。此外，因为机器人 LiDAR 目前大多以 10Hz~20Hz 的频率记录和传输点云，所以在大多数情况下，机器人加速或减速，在这么短的时间间隔内偏离恒定速度模型的偏差是相当小的。

匀速模型通过利用 t 时刻之前的两个位姿估计 $T_{t-1} = (R_{t-1}, t_{t-1})$ 和 $T_{t-2} = (R_{t-2}, t_{t-2})$ 来估计 t 时刻的平移速度 v_t 和角速度 ω_t ，其中 $R_t \in SO(3)$ 为 t 时刻的旋转矩阵， $t_t \in \mathbb{R}^3$ 为 t 时刻的平移向量。所以 t 时刻的相对位姿 $T_{pred,t}$ 可以用以下公式表示

$$T_{pred,t} = \begin{bmatrix} R_{t-2}^T R_{t-1} & R_{t-2}^T (t_{t-1} - t_{t-2}) \\ 0 & 1 \end{bmatrix} \quad (1)$$

所以相应的平移速度和角速度可由以下公式推导

$$v_t = \frac{R_{t-2}^T (t_{t-1} - t_{t-2})}{\Delta t} \quad (2)$$

$$\omega_t = \frac{\text{Log}(R_{t-2}^T R_{t-1})}{\Delta t} \quad (3)$$

其中 Δt 为一次激光雷达扫描采集的时间，一般为 0.05s 或者 0.1s， $\text{Log}: SO(3) \rightarrow \mathbb{R}^3$ 提取了旋转的轴-角度表示。

在一次激光雷达扫描的采集时间 Δt 内，扫描仪测量多个三维点，对于每个点 $p_i \in P$ ，

都有一个相对时间戳 $s_i \in [0, \Delta t]$ ，描述了该点相对于扫描的第一个测量的记录时间，通过这个相对时间戳便可计算运动补偿，从而得到经过矫正后的点集 P^* ，其中的每个点 p_i^* 的矫正通过以下公式实现

$$p_i^* = \text{Exp}(s_i \omega_t) + s_i v_t \quad (4)$$

其中 $SO(3) \rightarrow \mathbb{R}^3$ 表示将一个三维实数域中的向量映射到特殊正交群 $SO(3)$ 中的旋转矩阵的函数。这个旋转矩阵是从轴—角度表示中计算得到的， $\text{Exp}(s_i \omega_t)$ 表示在轴—角度域执行 SLERP 操作，SLERP 是一种在旋转表示中进行插值的方法，用于平滑地插值两个旋转之间的路径。

1.1.2 基于匀速模型的特征点去畸变

基于匀速模型的特征点去畸变过程如下：在第一阶段完成后，对去除运动畸变的点云数据进行特征点的提取，接着对提取出来的特征点进行第二阶段的去畸变，在这一阶段中，可用矩阵 T_k 表示第 k 次扫描时的机器人姿态，连续两帧 $k-1$ 和 k 之间的 6-Dof 变换可估计为：

$$\xi_{k-1}^k = \log(T_{k-1}^{-1} T_k) \quad (5)$$

连续扫描之间的小周期 δt 变换可通过线性插值估计其公式如下：

$$T_k(\delta t) = T_{k-1} \exp\left(\frac{N-n}{N} \xi_{k-1}^k\right) \quad (6)$$

其中函数 $\exp(\xi)$ 将一个李代数转换为相应的李群，那么第 k 次 LiDAR 扫描 P_k 的失真可通过以下公式纠正：

$$\tilde{P}_k = \{T_k(\delta t) P_k^{(m,n)} \mid P_k^{(m,n)} \in P_k\} \quad (7)$$

在上述阶段完成后，将纠正好的特征点来进行机器人的位姿估计，并在位姿估计完成后进行第三阶段。

1.1.3 畸变补偿建立三维地图

① 位姿估计

在完成第二阶段后，算法进入位姿估计模块，在这一模块中算法利用当前无畸变的边缘特征 $\tilde{\mathcal{E}}_k$ 和平面特征 $\tilde{\mathcal{S}}_k$ 与全局特征地图对齐。全局特征地图由边缘特征地图和平面特征地图组成，并且它们分别进行更新和维护。通过在这些特征图上收集相邻点，可以估算全局的线特征和面特征。对于每个边缘特征点 $P_\varepsilon \in \tilde{\mathcal{E}}_k$ ，F-LOAM 会计算得到一个带有位置 P_ε^g 和方向 n_ε^g 的全局边缘。类似地，对于每个平面特征点 $P_s \in \tilde{\mathcal{S}}_k$ ，F-LOAM 会计算得到一个带有位

置 P_s^g 和表面法线 n_s^g 的全局平面，全局平面的法线被视为与最小特征值相关联的特征向量。

一旦推导出相应的最佳边缘和最佳平面，F-LOAM 会从 $\tilde{P}_k$ 中为每个特征点找到关联的全局边缘或平面，接着通过求解特征点与全局边缘或平面之间的最小距离，估计当前帧相对于全局地图的最佳位姿。边缘特征和全局边缘之间的距离为：

$$f_\varepsilon(P_\varepsilon) = P_n \lrcorner ((T_k P_\varepsilon - P_\varepsilon^g) \times n_\varepsilon^g) \quad (8)$$

其中符号 $\lrcorner$ 是点积， P_n 是单位向量，由以下公式给出

$$P_n = \frac{(T_k P_\varepsilon - P_\varepsilon^g) \times n_\varepsilon^g}{\|(T_k P_\varepsilon - P_\varepsilon^g) \times n_\varepsilon^g\|} \quad (9)$$

平面特征和全局平面之间的距离为：

$$f_s(P_s) = (T_k P_s - P_s^g) \lrcorner n_s^g \quad (10)$$

此外，F-LOAM 为进一步平衡匹配过程重新利用曲率作为权重函数，对于每个具有局部平滑度 σ_ε 的边缘点 P_ε 和每个具有局部平滑度 σ_s 的平面点 P_s ，其权值定义为：

$$W(P_\varepsilon) = \frac{\exp(-\sigma_\varepsilon)}{\sum_{P^{(i,j)} \in \tilde{\mathcal{E}}_k} \exp(-\sigma_k^{(i,j)})} \quad (11)$$

$$W(P_s) = \frac{\exp(\sigma_s)}{\sum_{P^{(i,j)} \in \tilde{\mathcal{S}}_k} \exp(\sigma_k^{(i,j)})} \quad (12)$$

其中 $\mathcal{E}_k$ 和 $\mathcal{S}_k$ 是激光雷达第 k 次扫描时的边缘特征和平面特征。然后，为了估计新的姿态，通过最小化点到边缘和点到平面距离的加权和：

$$\min_{T_k} \sum W(P_\varepsilon) f_\varepsilon(P_\varepsilon) + \sum W(P_s) f_s(P_s) \quad (13)$$

接着通过高斯—牛顿法解非线性方程，便可以推导出最优姿态估计。雅可比矩阵可以通过使用左摄动模型来估计：

$$\begin{aligned} J_p &= \frac{\partial T_p}{\partial \delta \xi} = \lim_{\delta \xi \rightarrow 0} \frac{(\exp(\delta \xi) T_p - T_p)}{\delta \xi} \\ &= \begin{bmatrix} I_{3 \times 3} & -[T_p] \times \\ \mathbf{0}_{1 \times 3} & \mathbf{0}_{1 \times 3} \end{bmatrix} \end{aligned} \quad (14)$$

其中, $[T_k p_k]_x$ 将 4D 点表达式 $\{x, y, z, 1\}$ 转换为 3D 点表达式 $\{x, y, z\}$ 并计算其斜对称矩阵。边缘残差的雅可比矩阵可以通过以下方式计算:

$$J_\varepsilon = W(p_\varepsilon) \frac{\partial f_\varepsilon}{\partial T p} \frac{\partial T p}{\partial \delta \xi} = W(p_\varepsilon) p_n \lceil (n_\varepsilon^g \times J_p) \rceil \quad (15)$$

类似的, 平面残差的雅可比矩阵可以由以下方式计算:

$$J_s = W(p_s) \frac{\partial f_s}{\partial T p} \frac{\partial T p}{\partial \delta \xi} = W(p_s) (n_s^g \lceil J_p \rceil) \quad (16)$$

通过求解非线性优化问题, 可以基于上述的匹配关系推导出里程的估计值。然后, 利用这个估计值来更新对应关系, 并计算出新的里程估计。当前的姿态估计 T_k^* 可以通过迭代优化过程来求解, 直到达到收敛状态。

② 地图建立与失真补偿更新

在完成位姿估计后, 系统进入第三阶段, 开始进行三维地图的构建和失真补偿。三维全局地图由全局边缘地图和全局平面地图组成, 并根据关键帧进行更新。选择关键帧的标准是: 当平移变化超过预设的平移阈值, 或旋转变化的超过预定的旋转阈值时。与逐帧更新相比, 基于关键帧的地图更新能够显著减少计算开销。虽然该算法的失真补偿采用的是匀速模型, 而非基于迭代的运动估计, 这降低了计算负担, 但相比 LOAM 中的迭代失真补偿方法, 其精度有所下降。因此, 在第三阶段, 运动畸变会根据上一步位姿估计的结果 T_k^* 重新计算:

$$\Delta \xi^* = \log(T_{k-1}^{-1} \cdot T_k^*) \quad (17)$$

$$\tilde{P}_k^* = \{\exp(\frac{N-n}{N} \cdot \Delta \xi^*) P_k^{(m,n)} \mid P_k^{(m,n)} \in P_k\} \quad (18)$$

经过重新计算的边缘特征和平面特征, 将被分别更新到全局边缘图和全局平面图中, 这样可以保持特征的精确度和全局的一致性。每次更新后, 使用 3D 体素化网格方法对地图进行降采样, 以防止内存溢出。

1.2 基于体素化网格的分层降采样机制

SLAM 系统在户外的高速环境下, 实时性会受到硬件计算性能的影响, 因此本文在 F-LOAM 基础上引入基于体素化网格的特征点分层降采样机制, 对特征点采取两层的降采样, 在减少计算量的同时, 使得降采样之后的特征点能同时保存局部特征和整体特征, 以此缓解特征点变少导致的定位准确性下降, 极大提高了系统的实时性。

(1) 特征提取

F-LOAM 为了提高匹配精度和匹配效率, 舍弃了使用传统的 ICP(Iterative Closest Point) 点云匹配算法, 而是使用特征点匹配算法来进行位姿匹配。由于三维激光雷达返回的点云数据在水平方向上较为密集, 因此水平方向的特征更加突出, 且错误的特征检测较少。基于这一特点, F-LOAM 在特征提取时将重点放在水平面上, 并选择曲率作为判断标准, 其计算

公式如下：

$$c = \frac{1}{|S_k^{(m,n)}|} \parallel \sum_{P_k^{(m,n)} \in S_k^{(m,n)}} (P_k^{(m,j)} - P_k^{(m,n)}) \parallel \quad (19)$$

其中， m, n 分别表示点云的行号和列号， $S_k^{(m,n)}$ 是 $P_k^{(m,n)}$ 在同行的相邻点， $|S_k^{(m,n)}|$ 是相邻点的个数，具体而言，选取 $P_k^{(m,n)}$ 水平方向上左右各 5 个点，计算其曲率，曲率较大的作为边缘特征点，较小的作为平面特征点。

(2) 基于体素化网格的降采样

体素降采样 (Voxel Grid Downsampling) 常被应用于点云处理，旨在保留其主要特征的同时，减少点云密度和数据量。这种方法通过在三维空间中构建体素网格，并将每个体素内的点数据替换为一个代表点来实现降采样。体素的尺寸可以根据实际需求进行调整，较大的体素会导致更大程度的下采样，而较小的体素则能够保留更多的细节信息。

体素化网格降采样方法主要有两种类型：一种是基于体素质心的降采样，它通过对每个非空体素计算质心，并将其作为该体素内所有点的代表，来进行降采样；另一种则是基于体素中心的降采样，它通过计算每个非空体素的几何中心并用其替代该体素内所有点来完成降采样。

本文采用基于体素质心的降采样，因为体素质心降采样方法虽然耗时长，但可以保留更多的点云的具体位置信息，体素质心的计算如下：

已知一个非空体素 V ，其中包含 m 个点，则该体素质心 $P_{\text{centroid}}(x_{\text{centroid}}, y_{\text{centroid}}, z_{\text{centroid}})$ 为：

$$\begin{cases} x_{\text{centroid}} = \frac{\sum_{i=1}^m x_i}{m} \\ y_{\text{centroid}} = \frac{\sum_{i=1}^m y_i}{m} \\ z_{\text{centroid}} = \frac{\sum_{i=1}^m z_i}{m} \end{cases} \quad (20)$$

(3) 分层降采样

1) 局部特征点降采样

在激光雷达点云处理过程中，特征保持对优化算法的表现至关重要。针对 64 线激光雷达数据，本研究首先计算每条扫描线中所有点的曲率值，以便识别并保留重要的局部特征。曲率的计算依赖于每个点与其邻域点之间的空间关系，从而确定每个点的几何特征。

为了最大化局部特征的利用，我们将每条扫描线的点分为六个扇区，并在每个扇区内独立执行特征提取。根据点的曲率值大小，点通吃被分为：平面点或边缘点，具体说明如下。

平面点：通常位于几何形态较为平坦的区域，这些点与周围点的曲率相差不大，表明它们处于一个相对平滑的平面上。

边缘点：通常位于尖锐或显著的边缘上，与周围点的曲率差异较大，表现出较高的几何变化。

在每个扇区内，首先根据点的曲率值进行排序，然后选取曲率值最高的前 20 个点作为边缘点，其余的点则被归类为平面点。在提取了各扇区的特征点后，对这些特征点按功能不同进行不同规模的降采样处理：平面点的降采样规模是边缘点的两倍。这样的降采样策略旨在保留足够的特征以支持精确的环境理解，同时减少数据处理的负担。

2) 整体特征点降采样

完成局部特征点的降采样后，我们将各扫描线的边缘点与平面点合并。这些合并后的点云进一步进行降采样，其中平面点的降采样规模再次设置为边缘点的两倍。此步骤的目的是进一步优化数据结构，减少后续位姿估计算法的计算量，同时保持足够的特征点来支持准确的定位与建图。

2. 实验与分析

2.1 实验设置

实验中电脑 CPU 是 12 代 Intel i5-12500H，显卡型号是 NVIDIA GeForce RTX 3060 Laptop GPU，操作环境是 Ubuntu18.04，所对应的 ROS 版本是 ROS Melodic，具体的激光雷达实验参数设置如表所示。

表 1 激光雷达实验参数设置

Table 1 LiDAR experimental parameter settings

参数	KITTI 数据集
N_SCAN	64
Horizon_SCAN	1024
ang_res_x	360.0/float(Horizon_SCAN)
ang_res_y	33.2/float(N_SCAN-1)

参数设置如表 1 所示。其中，N_SCAN 是激光雷达线数、Horizon_SCAN 是激光雷达旋转一周采样次数；ang_res_x、ang_res_y 分别表示激光雷达的水平分辨率、垂直分辨率；

2.2 评估指标

在本实验中，采用 EVO 评估工具对算法的运行结果进行测试。EVO 是一个广泛使用的工具，用于评估和比较不同的 SLAM 算法的性能。SLAM 算法的评估通常依赖于一系列的评估标准，包括位置精度、轨迹误差等，而 EVO 提供了一个标准化、易于使用的框架，用于量化和可视化这些误差。它支持多种输入格式，兼容多种数据集，可以有效地评估 SLAM 系统的性能。

2.3 实验设计与结果分析

① KITTI 数据集

本次实验使用了 KITTI07 数据集进行验证。KITTI 数据集是自动驾驶和计算机视觉领域中最具影响力和广泛使用的公开数据集之一，专门用于评估自动驾驶系统和传感器融合技术的性能，特别是在视觉和激光雷达（LiDAR）数据方面。该数据集由卡尔斯鲁厄理工大学（KIT）和丰田技术研究院（TRI）合作创建，主要用于测试和评估各种视觉、激光雷达、传感器融合技术和自动驾驶算法。

② 实验结果分析

将改进前后的算法在 KITTI07 数据集上测试，通过对比 F-LOAM 算法和 CH-F-LOAM 算法的绝对轨迹误差来评判算法的性能。





图 4 改进前后的 F-LOAM 算法轨迹对比

Fig.4 Comparison of the trajectory of the F-LOAM algorithm before and after the improvement

根据图 4 的观察结果,可以得出结论:改进后的算法在轨迹上不仅整体更接近真值轨迹,而且在局部轨迹对比上也远远优于 F-LOAM。这种改善的原因主要归功于基于体素化网格的分层降采样机制。该机制使得保存下来的特征点不仅保留了点云的整体特征,而且具有更准确的局部特征。因此,在算法进入位姿预测模块时,算法能够使用更准确的特征点,从而使得轨迹估计更接近真值轨迹。



(a)F-LOAM 算法轨迹的 ape 值

(b)CH-F-LOAM 算法轨迹的 ape 值

图 5 F-LOAM 改进前后绝对误差对比图

Fig.5 Comparison of absolute error before and after F-LOAM improvements

通过图 5 的对比可以清楚地观察到,改进后的算法在整个轨迹上的绝对误差值相对于原算法更为稳定,并且平均绝对误差值也更小。这种改善主要归功于改进算法中使用了基于匀速模型的去运动畸变机制。通过使用匀速模型去除运动畸变,算法能够在运行过程中获得稳定而准确的特征点。这些特征点能够在位姿估计模块中提供稳定的参考,从而使得雷达的位姿估计更加准确。因此,改进后的算法能够保持较小的误差范围,并且在整个轨迹上表现出更加稳定和精确的轨迹估计结果。

表 2 算法的绝对位姿误差对比

Table 2 Comparison of the absolute pose error of the algorithm

A	误差指标	F-L	改进后的系统框架 CH-F-LOAM
PE		OAM	
M	最大误差	1.82	1.281
ax		2	
M	平均误差	1.82	0.678
ean		2	
M	误差中值	0.67	0.694
edian		2	
M	最小误差	0.17	0.150
in		5	
R	均方根误差	0.83	0.722
MSE		7	
S	标准差	0.36	0.246
TD		6	
Ti	一帧处理时间	103	78ms
me		ms	
Ef	一帧边缘特征点	340	2228
p	数量	7	
Sf	一帧平面特征点	328	3089
p	数量	9	

通过表 2 可以观察到 CH-F-LOAM 算法在多个指标上表现均优于 F-LOAM。首先，在关键的 RMSE 指标上，CH-F-LOAM 相对于 F-LOAM 减少了约 14%，这意味着改进后的系统对零误差定位更为准确，能够更有效地排除环境噪声等因素的影响。此外，CH-F-LOAM 的 STD 相对于 F-LOAM 减少了约 32.7%，表明改进后的系统定位误差更加稳定，能够在不同环境下展现出更为可靠的定位表现。

进一步地，在时间对比方面，CH-F-LOAM 表现出更低的一帧处理时间，相对于 F-LOAM 减少了约 24.2%，这更主要是通过基于体素化网格的分层降采样机制来实现的，如表 2 中所示，CH-F-LOAM 一帧所使用的特征点数量相较于 F-LOAM 减少了 20%。

此外，将 CH-F-LOAM 与其他主流 SLAM 算法进行对比，如表 3 所示

表 3 与其他定位算法在 KITTI07 运行结果对比

Table 3 Comparison results with other localization algorithms

APE	A-LOAM	LEGO-LOAM(去回 环检测)	CH-F-LOAM
STD	0.891	1.56	0.722
Time	154ms	75ms	78ms

如表 3 所示，改进后的算法在时间和精度上均优于 A-LOAMS 算法，而与 LEGO-LOAM 的对比中，虽然在时间对比上稍有不足，但在定位精度上明显优于 LEGO-LOAM；

通过以上对比，可以说明 CH-F-LOAM 系统更适合于需要高精度和高效率的 SLAM 应用场景。

3. 总结与展望

本文提出了一种改进的面向激光雷达的实时定位与三维地图重建算法,通过引入三级去畸变机制和基于体素化网格的分层降采样机制,显著提升了 F-LOAM 算法的精度和实时性。本文首先通过匀速模型对原始点云数据进行初步去畸变,接着对提取的特征点进行二次去畸变,最后在位姿估计完成后进行三维地图的建立和失真补偿。这一改进不仅确保了特征点在位姿估计过程中更加准确和可靠,同时也通过分层降采样机制有效减少了计算量,提升了算法的实时性能。实验结果表明,CH-F-LOAM 算法在 KITTI 数据集上的表现优于 F-LOAM 算法。通过对比轨迹、绝对轨迹误差等指标,改进后的 CH-F-LOAM 算法在多个关键指标上均表现出色。未来的研究主要包括如下:首先,目前的匀速模型假设在短时间内机器人运动是匀速的,这在高速动态环境中可能会有所限制。因此,未来可以考虑引入更复杂的运动模型,例如加速度模型或基于机器学习的方法,以进一步提高运动畸变的矫正精度。其次,尽管分层降采样机制显著减少了计算量,但在更大规模的点云数据处理场景中,仍需要进一步优化数据结构和算法,以应对更高的实时性要求。总的来说,本文提出的改进算法在提高激光雷达 SLAM 系统的精度和实时性方面取得了显著进展,为自主导航和环境感知提供了更加可靠的技术支持。未来的研究应继续在算法优化、多传感器融合、高动态场景应用、雷达干扰欺骗^[20]等方面展开深入探索。

参考文献

- [1] SMITH RC, CHEESEMANN P. On the Representation and Estimation of Spatial Uncertainty[J]. The International Journal of Robotics Research, 1986,5(4): 56-68.
- [2] KHAIRUDDIN A R, TALIB M S, HARON H. Review on Simultaneous Localization and Mapping (SLAM)[C]// 2015 IEEE International Conference on Control System, Computing and Engineering (ICCSCE). Penang:IEEE, 2015: 85-90.
- [3] 李嘉辉, 范馨月, 张干, 等. 基于背景修复的动态 SLAM[J]. 数据采集与处理, 2024, 39(5): 1204-1213.
- [4] 沈晔湖, 陈嘉皓, 李星, 等. 基于几何-语义联合约束的动态环境视觉 SLAM 算法[J]. 数据采集与处理, 2022,37(3): 597-608.
- [5] DEBEUNNE C, VIVET D. A review of visual-lidar fusion based simultaneous localization and mapping[J]. Multidisciplinary Digital Publishing Institute, 2020, 20(7): 2068.
- [6] MILZ S, ARBEITER G, Witt C, et al. Visual slam for automated driving: Exploring the applications of deep learning[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Salt Lake City:IEEE, 2018: 10.1109/CVPRW.2018.00062.
- [7] CUNHA F, YOUCEF-TOUMI K. Ultra-wideband radar for robust inspection drone in underground coal mines[C]// 2018 IEEE International Conference on Robotics and Automation (ICRA). Brisbane:IEEE, 2018: 86-92.
- [8] ITO S, HIRATSUKA S, OHTA M, et al. Small imaging depth lidar and dcnn-based localization for automated guided vehicle[J]. Sensors, Multidisciplinary Digital Publishing Institute, 2018,18(1): 177.
- [9] TAKETOMI T, UCHIYAMA H, IKEDA S. Visual SLAM algorithms: a survey from 2010 to 2016[J/OL]. IPSJ T Comput Vision and Applications, 2017, 9(1): <https://doi.org/10.1186/s41074-017-0027-2>.
- [10] 周戈.基于激光雷达导航的移动机器人 SLAM 算法研究[D].浙江大学,2021.
- [11] 兰徐山.基于激光信息的移动机器人定位与导航方法研究[D].哈尔滨工业大学,2020.
- [12] ZHANG J, SINGH S. Loam: Lidar odometry and mapping in realtime[C]// Robotics: Science and Systems Conference. Berkeley:CMU, 2014: 1-9.
- [13] SHAN T, ENGLLOT 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). Madrid:IEEE, 2018: 4758-4765.
- [14] GitHub. GitHub-cgbcgb/A-LOAM-NOTED: Chinese annotated version of A-LOAM[EB/OL]. (2020-05-20)[2022 -03 -27]. [https:// github.com/ cgbcgb/ A-LOAM-NOTED](https://github.com/cgbcgb/A-LOAM-NOTED).
- [15] DESCHAUD J -E. IMLS-SLAM: Scan-to-Model Matching Based on 3D Data[C]// 2018 IEEE International Conference on Robotics and Automation (ICRA). Brisbane:IEEE, 2018: 2480-2485.
- [16] BEHLEY J, STACHNISS C. Efficient surfel-based SLAM using 3D laser range data in urban environments[C]// Robotics:Science and System Conference. Berkeley:CMU, 2018: 1-10.
- [17] 李帅鑫, 李广云, 王力, 等.(2021).LiDAR/IMU 紧耦合的实时定位方法[J]. 自动化学报, 2021, 47(6): 1377 - 1389.
- [18] SHAN T, ENGLLOT 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 (IROS). Las Vegas:IEEE, 2020: 10.1109/IROS45743.2020.9341176.
- [19] WANG H, WANG C, XIE L, et al. F-LOAM : Fast LiDAR Odometry and Mapping[C]//2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Prague:IEEE, 2021: 10.1109/IROS51168.2021.9636655.
- [20] 赵珊珊, 易民举, 刘子威, 等. 多干扰源下多站雷达抗欺骗式干扰方法[J]. 南京邮电大学学报:自然科学版, 2022, 42(5): 15-20.

作者简介:



徐鹤（1985-），男，博士，教授，CCF 高级会员。研究方向：人工智能与大数据、物联网技术。Email:

xuhe@njupt.edu.cn



张阔（2000-），男，硕士研究生。研究方向：人工智能与大数据。Email:1222045607@njupt.edu.cn



李鹏（1979-），男，博士，教授，博士生导师，CCF 会员。研究方向：高性能计算、大数据、人工智能

和网络安全。Email: lipeng@njupt.edu.cn