doi:10.6041/j.issn.1000-1298.2026.05.010

基于多传感器融合回环检测 MLD - LOAM 的移动机器人定位方法研究

许丽佳[1,2]　胡泽邦[2,3]　周　龙[2,3]　周师杰[2,3]　唐座亮[2,3]　王玉超[2,3]
许宝成[2,3]　冯青春[4]

(1. 成都航空职业技术大学机器人学院, 成都 610000; 2. 四川农业大学机电学院, 雅安 625000;
3. 四川省智慧农业工程技术研究中心, 成都 610000; 4. 北京市农林科学院智能装备技术研究中心, 北京 100097)

摘要: 针对室外非结构化环境地形复杂和环境高相似度导致机器人建图定位精度衰减的问题,提出一种多传感器融合回环检测的 SLAM 算法,即 MLD - LOAM(Multi-sensor loop detection LiDAR - IMU LOAM)。该算法基于 LEGO - LOAM 算法架构,在地面点云过滤阶段,基于激光点距离分布进行快速过滤后引入 IMU 数据,通过实时解算地面法向量对地面点云二次过滤;在回环检测阶段,根据激光点云特征稀疏程度设计激光雷达置信度函数来融合 IMU 与激光雷达数据,构建融合里程计后,基于八叉树改进的 NDT 配准进行回环检测,提高定位精度和效率。本文在 KITTI 数据集和室外非结构化实际场景中进行了试验,结果表明与 LEGO - LOAM 相比,MLD - LOAM 在 KITTI 数据集和实际场景中的定位精度分别提高了 11%、30%;与 LIO - SAM 和 FAST - LIO 相比,MLD - LOAM 在实际场景中的定位精度优于 FAST - LIO,比 LIO - SAM 精度低 2.8%,但内存消耗速度仅为 LIO - SAM 的 50% 和 FAST - LIO 的 32.4%,这为需要较低内存占用的室外机器人长期建图定位任务,提供了一种可行的解决方案。

关键词: 移动机器人; 定位; 改进 LEGO - LOAM; LiDAR - IMU 数据融合; 点云过滤; 回环检测
中图分类号: S24; TP249　　**文献标识码**: A　　**文章编号**: 1000-1298(2026)05-0115-12　　**OSID**:

Research on Mobile Robot Localization Method Based on Multi-sensor Fusion Loop Closure Detection

XU Lijia[1,2]　HU Zebang[2,3]　ZHOU Long[2,3]　ZHOU Shijie[2,3]　TANG Zuoliang[2,3]
WANG Yuchao[2,3]　XU Baocheng[2,3]　FENG Qingchun[4]

(1. *College of Robotics*, *Chengdu Aviation Vocational and Technical University*, *Chengdu* 610000, *China*
2. *College of Mechanical and Electrical Engineering*, *Sichuan Agricultural University*, *Ya'an* 625000, *China*
3. *Sichuan Provincial Intelligent Agriculture Engineering Technology Research Center*, *Chengdu* 610000, *China*
4. *Intelligent Equipment Technology Research Center*, *Beijing Academy of Agriculture and Forestry Sciences*, *Beijing* 100097, *China*)

Abstract: Aiming to address the degradation of robot mapping and localization accuracy caused by complex terrain and high similarity in unstructured environments, a SLAM algorithm based on multi-sensor loop detection, namely multi-sensor loop detection LiDAR - IMU LOAM (MLD - LOAM) was proposed. Based on the LEGO - LOAM algorithm architecture, this algorithm incorporated IMU data in the ground point cloud filtering phase after rapid filtering based on the distance distribution of laser points. This algorithm then performed a more accurate secondary filtering of the ground point cloud by calculating ground normals in real time. In the loop detection phase, the IMU and lidar data were fused by using a LiDAR confidence function designed with the sparsity of laser point cloud features. The fused odometry data triggered loop detection, which was then performed by an octree-modified normal distribution transform (NDT), thereby improving system accuracy and efficiency. Experiments were conducted on the KITTI dataset and in unstructured outdoor real-world scenarios. Results showed that compared with LEGO - LOAM, MLD - LOAM improved localization accuracy by 11% and 30% in both the KITTI dataset and real-world scenarios. Compared with LIO - SAM and FAST - LIO, MLD - LOAM

收稿日期: 2025 - 10 - 25　修回日期: 2025 - 11 - 20
基金项目: 国家自然科学基金项目(32572215)
作者简介: 许丽佳(1973—),女,教授,博士,主要从事丘陵地区中小型智能农机装备和农业机器人研究,E-mail: xulijia@sicau.edu.cn

achieved better localization accuracy in real-world scenarios than FAST - LIO, but it was 2.8% less accurate than LIO - SAM. However, the speed of its memory consumption was only 50% of LIO - SAM and 32.4% of FAST - LIO. The research result can provide a feasible solution for long-term mapping and localization tasks of outdoor robots that required low memory footprint.

Key words: mobile robot; localization; improved LEGO - LOAM; LiDAR - IMU data fusion; point cloud filtering; loop closure detections

0 引言

同时定位与地图构建(Simultaneous localization and mapping,SLAM)能在未知环境中估计地图并能确定机器人位置,因此在野外搜索、太空探测和定位侦察中应用广泛[1-3]。根据使用传感器类型,SLAM 系统可以分为激光 SLAM 和视觉 SLAM 两大类[4-7],其中激光 SLAM 因其不受光照影响、计算需求较低、可靠性高而备受瞩目[8],但在室外非结构化环境中,机器人面临的地形极端复杂、场景特征稀疏或高度相似等严峻挑战,导致依赖于单一传感器的 SLAM 系统,尤其是以激光雷达(Light detection and ranging, LiDAR)为核心的 LOAM(LiDAR odometry and mapping)系列算法,容易出现点云匹配歧义、里程计累积误差增大等问题[9-10],最终引发建图失真与定位失效。因此对 SLAM 系统进一步优化其算法以提升其定位精度,成为众多学者的研究方向。

为解决上述问题,国内外学者进行了广泛研究。由 SHAN 等[11]提出的 LEGO - LOAM(Lightweight and ground-optimized liDAR odometry and mapping)算法是激光 SLAM 领域的主流方法,它通过点云分割、地面优化等方式,实现轻量化并提升了地面车辆场景下的定位性能。然而,LEGO - LOAM 通过假设局部地面为平面来实现高效的地面点云分割与优化,这限制了其在地形变化较大的非结构化环境中的应用;同时,其回环检测模块严重依赖于前端里程计,当前端因环境相似而发生漂移时,回环检测的触发与匹配成功率将大幅降低[12],难以有效校正累积误差。

将惯性测量单元(Inertial measurement unit, IMU)数据融合 LiDAR 数据,是解决激光 SLAM 在非结构化环境中易产生漂移的重要手段[13-17]。此外,LiDAR 与相机融合也是提高激光 SLAM 鲁棒性的有效途径。张文翔等[18]提出了 AprilTag 定位校正方法,通过计算机器人的校正位姿与中心点坐标,解决了移动机器人在纯激光定位时的丢失问题,但该算法实时性有所下降。ZHANG 等[19]将视觉里程计和 LiDAR 里程计结合起来,采用扩展卡尔曼滤波器融合它们的位姿估计结果,在其中一个传感器失效时能提供冗余。另外,LiDAR、IMU 与相机的融合 SLAM 也是当前研究的主流方向之一。SHAN 等[20]提出了 LVI - SAM 算法,该算法在单一传感器失效时有较强应对能力,但此紧耦合框架较复杂且调试和参数整定难度大。LIN 等[21]提出了 R2LIVE 算法,使用 EKF 同时估计机器人状态和环境状态,并通过因子图优化实现了高质量实时地图重建,但该算法内存开销大,且对传感器标定和同步要求极高。ZHENG 等[22]提出了基于紧耦合的激光惯性里程计子系统和视觉惯性里程计子系统的 FAST - LIVO 算法,实现了在高噪声、快速运动等复杂环境中的高精度和高鲁棒性。为了确保 FAST - LIVO 在机器人中的实时应用,ZHENG 等[23]提出了 FAST - LIVO2 算法,使用高效的误差状态迭代卡尔曼滤波器取代了原来的紧耦合优化器,既保持高精度又提升了计算效率。

LiDAR 结合 IMU 的 SLAM 算法利用 IMU 的高频、短时精确的动态特性来弥补激光雷达低频、易受运动畸变影响的不足,是解决激光 SLAM 运动畸变和漂移问题最直接、最有效的手段之一。但是目前 LiDAR - IMU 融合 SLAM 多为高性能紧耦合方案,对 IMU 精度和传感器标定非常敏感,在低成本平台上的适应性略显不足。LiDAR 与相机融合使激光 SLAM 适应视觉特征丰富但几何特征稀疏的场景,但相机本身对非结构化环境中光照变化导致的模糊非常敏感,且标定也比较复杂。LiDAR、IMU 与相机的融合 SLAM 实现了 3 种传感器信息的有效互补,呈现较强鲁棒性,但是参数整定与调试困难、计算负载巨大,故无法适用于低成本平台。

针对非结构化环境中机器人的定位问题,考虑到 LiDAR - IMU 融合 SLAM 的特点,本文以 LEGO - LOAM 算法框架为基础并优化融合 IMU 数据的方法,在地面点云过滤阶段基于激光点距离分布进行快速过滤后,使用 IMU 预积分实时解算地面法向量进行二次过滤,以减少原算法中地面点云错误过滤带来的误匹配;在回环检测阶段使用基于激光点云特征数量的激光雷达置信度函数融合 IMU 与 LiDAR 数据,并使用八叉树改进的 NDT 配准加速回环检测,提高回环检测时的匹配精度和速度。

1　LEGO－LOAM 算法原理

LEGO－LOAM 包括数据预处理、特征提取、构建激光雷达里程计、地图更新和回环检测，其整体技术框架如图 1 所示。

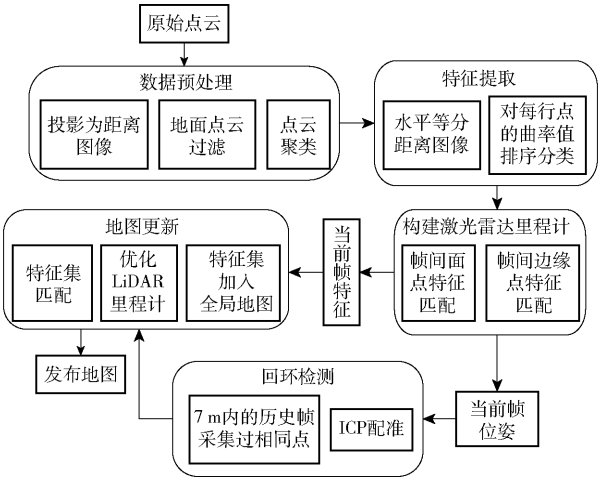

图 1　LEGO－LOAM 整体技术框架

Fig. 1　LEGO－LOAM overall technical framework

从图 1 可知，LEGO－LOAM 算法流程为：

（1）数据预处理。采集激光点云数据并投影为距离图像，距离图像的同行表示同一激光线束在 360°范围采集到的点云，同列表示激光雷达线束，像素点的像素值代表激光点与激光雷达的欧氏距离。在距离图像中，由相邻线束同列激光点垂直高度差 h 和水平距离差 d，求得垂直高度差和水平高度差的角度 atan2(h,d)，角度接近 0°则识别为地面点，否则识别为非地面点进行过滤，LEGO－LOAM 地面点云过滤原理如图 2 所示。过滤非地面点之后，再对剩下的距离图像进行聚类，过滤掉点云数量小于 30 的点云簇，对保留下来的点云簇分配不同的标签。

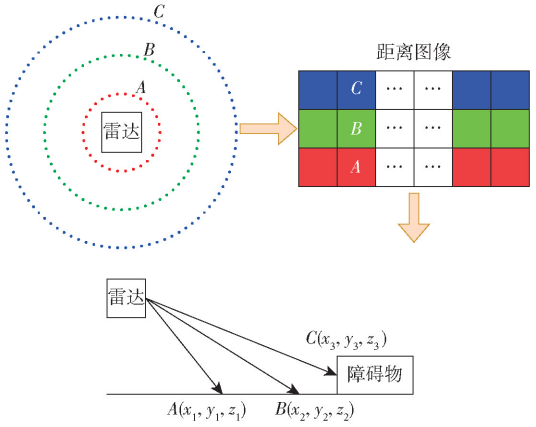

图 2　LEGO－LOAM 地面点云过滤原理图

Fig. 2　LEGO－LOAM ground point cloud filtering principle diagram

（2）特征提取。将预处理后的点云数据对应的距离图像水平分割成几个相等的子图像，将 360°均匀分成 6 等份。计算分割后的子图像每一行点的曲率值，对曲率值进行排序分类，分为边缘点特征和面点特征。

（3）构建激光雷达里程计。得到边缘点特征和面点特征后，首先通过连续两帧面点特征匹配得到 z 轴平移、翻滚角、俯仰角，再通过边缘点特征匹配得到 x 轴平移，y 轴平移和偏转角，实现高频粗略的位姿估计，从而构建激光雷达里程计。

（4）地图更新。将一段时间得到的特征集与此前地图进行面点特征和边缘点特征匹配后，进一步优化激光雷达里程计的位姿变换，得到低频高精度的位姿估计，最后将特征集拼接到之前的点云地图，实现地图更新。

（5）回环检测。LEGO－LOAM 使用简单的轨迹位姿触发回环检测，触发回环条件是当前帧与距离小于 7 m 的历史帧之间采集过相同的点，并且时间相差 30 s 以上，触发后将当前帧点云与历史帧进行 ICP 配准，从而纠正激光雷达里程计的漂移，LEGO－LOAM 回环检测原理如图 3 所示。

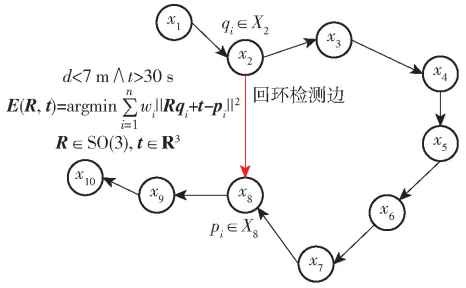

图 3　LEGO－LOAM 回环检测原理图

Fig. 3　LEGO－LOAM loop closure detection principle diagram

2　MLD－LOAM 算法设计

LEGO－LOAM 的地面点云过滤和回环检测在非结构化环境中存在局限性：

（1）该算法在地面点云过滤时存在对地形特征的强假设，即该算法工作场景是连续平坦地面，此时通过相邻点的角度关系来工作能有效过滤非地面点，但在陡坡、斜坡或充满碎石、草地、坑洼的非结构化环境中，此时会将较多真实地面点过滤掉，导致应该用于匹配的地面点云变得稀疏，或错将地面点云聚类为障碍物点云，增加后续匹配的噪声和错误。

（2）该算法的回环检测仅依赖激光点云数据，在一个大范围且有很多相似结构的激光退化场景下，则可能会发生激光雷达里程计漂移，导致错误的回环和地图畸变。

针对 LEGO－LOAM 地面点云过滤和回环检测局限性导致非结构化环境中定位精度无法满足要求

的问题,本文设计的 MLD - LOAM 算法融入了 IMU 数据,将 IMU 数据与 LiDAR 数据时间同步后,使用 IMU 数据辅助改进了地面点云过滤和回环检测策略。MLD - LOAM 整体技术框架如图 4 所示。

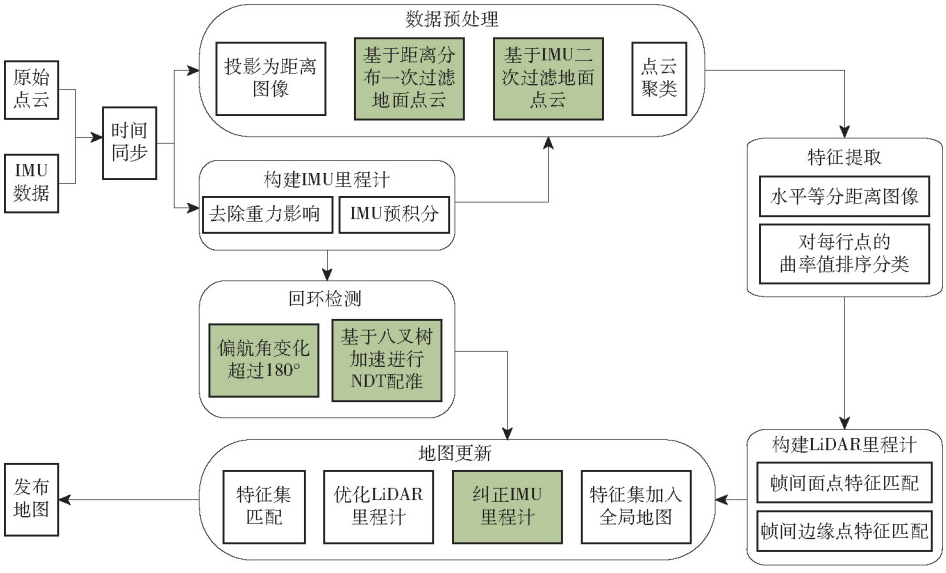

图 4 MLD - LOAM 整体技术框架

Fig. 4 MLD - LOAM overall technical framework

2.1 地面点云过滤

相比 LEGO - LOAM 使用相邻线束同列激光点垂直高度差和水平距离差过滤地面点云,MLD - LOAM 首先利用激光点距离分布进行快速地面点选取,对非地面点进行初步过滤;随后,结合 IMU 数据估计地面法向量,进一步过滤误识别的地面点,提高点云的质量和可靠性。

2.1.1 基于距离分布的地面点云一次过滤

在实际环境中,若使用 16 线激光雷达采集点云数据,地面点一般集中在激光雷达下 8 线的位置,其中最大的点云集合便是地面点云。对于 16 线激光雷达的单条扫描线,其点云距离集合记为

$$X=\{x_1,x_2,\cdots,x_i,\cdots,x_n\} \tag{1}$$

式中 x_i——第 i 个激光点的测量距离

使用的激光雷达最小检测距离 $d_{\min}$ 和最大检测距离 $d_{\max}$ 分别为 0.4 m 和 150 m,将距离范围均匀划分为 K 个区间,区间宽度 $w=\dfrac{d_{\max}-d_{\min}}{K}$,通过统计落在区间内激光点距离的频数区分地面点和非地面点。

区间宽度选择不当会导致过拟合或欠拟合,因为所用激光雷达最大俯角为 15°,分辨率为 2°,地面上的最低障碍物与地面之间的高度差通常在 0.1 ~ 0.2 m 之间,所以假设在激光线束俯角为 θ 的近距离处存在着高度 $\Delta h=0.15$ m 的障碍物以确定合适的区间宽度。障碍物会使得激光束的终点沿激光束的方向上移动一小段距离 Δs,即

$$\Delta s=\frac{\Delta h}{\sin\theta}\approx\frac{\Delta h}{\tan\theta} \tag{2}$$

实际中 θ 总是一个较小的角,因此 $\sin\theta$ 总是接近 $\tan\theta$。俯角为 15°时,Δs 约为 0.56 m;俯角为 11°时,Δs 约为 0.77 m。为了在大多数场景下获得稳定的过滤性能,选择 0.66 m 为区间宽度 w。第 k 个区间 B_k 为

$$B_k=[d_{\min}+(k-1)w,d_{\min}+kw] \tag{3}$$

定义区间指示函数 $\varepsilon_k(x)$,确定激光点是否落在区间 B_k 中,可得

$$\varepsilon_k(x)=\begin{cases}1 & (x\in B_k)\\ 0 & (x\notin B_k)\end{cases} \tag{4}$$

对同一激光线束上的激光点构建距离分布直方图,组数为 K,组距为 w,激光点数为 n,第 k 组频数 $H(k)$ 为

$$H(k)=\sum_{i=1}^{n}\varepsilon_k(x_i) \tag{5}$$

要确定地面点所在的距离区间,需对距离分布直方图进行峰值检测。峰值区间集合 p 定义为满足以下条件的区间索引 $k\in[2,K-1]$ 的集合

$$\begin{cases}H(k)>H(k-1)\cap H(k)>H(k+1)\\ H(k)-\max(H(k-1),H(k+1))\geqslant\tau\end{cases} \tag{6}$$

式中 τ——突出度阈值

τ 用于衡量一个峰值与相邻谷值的相对高度,确保峰值是显著的。实际环境中,非地面点集合相对地面点集合十分稀疏,导致距离分布直方图中非零集合的中位数 $\mathrm{median}(H_{non-zero})$ 远低于峰值,所以令 $\tau=2\mathrm{median}(H_{non-zero})$。

找到峰值区间集合后,确定一条激光线束上地面点距离集合 q

$$q=\left\{d_k\ \middle|\ d_k=d_{\min}+\left(k-\frac{1}{2}\right)w,k\in p\right\}\tag{7}$$

此时可求得单条激光线束上地面点距离的平均数$\bar{d}$,结合非结构化环境允许的最大坡度$\theta_{\max}$,确定最佳距离阈值 Δd 为

$$\Delta d=\bar{d}\tan\theta_{\max}\tag{8}$$

激光点距离与平均数差的绝对值若大于距离阈值则进行过滤,剩余点保留为地面点,对每条线束的激光点重复上述操作,完成地面点云的一次过滤,快速剔除明显的非地面点,降低二次过滤的计算开销。

2.1.2　基于 IMU 数据的地面点云二次过滤

在非结构化环境中,可能存在许多凸起或不确定的地面特征,LEGO-LOAM 通过相邻点的角度关系过滤地面点云易导致漏选,故基于 IMU 数据实时估计地面法向量,再通过激光点向量和地面法向量夹角过滤非地面点[24],使得区分地面点和非地面点更加准确,其原理如图 5 所示。图中 A、B 为激光点,$\boldsymbol{I}_1$,$\boldsymbol{I}_2$ 为激光点在全局坐标系下对应的向量,$\boldsymbol{n}$ 为地面法向量,ϕ_1、ϕ_2 为激光向量与地面法向量夹角。

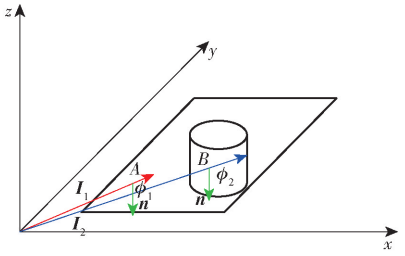

图 5　IMU 数据过滤地面点云原理图

Fig. 5　IMU data filtering principle diagram of ground point cloud

IMU 读数为加速度和角速度,状态变量为旋转、速度和位移,观测为状态变量的变化,噪声为零偏和随机噪声。高频 IMU 原始数据直接处理的计算负担较大,因此构建预积分观测模型,认为在$[i,j]$时间段内噪声只有零偏,且恒定为 i 时刻的零偏,累积该时间段内的加速度和角速度读数,将高频 IMU 观测转化为关键帧 i 与 j 时刻间的观测,即

$$\begin{cases}\Delta\widetilde{\boldsymbol{R}}_{ij}=\prod\limits_{k=i}^{j-1}\exp\left(\left(\widetilde{\boldsymbol{\omega}}_k-\boldsymbol{b}_{g,i}\right)\Delta t\right)\\ \Delta\widetilde{\boldsymbol{v}}_{ij}=\sum\limits_{k=i}^{j-1}\Delta\widetilde{\boldsymbol{R}}_{ik}\left(\widetilde{\boldsymbol{a}}_k-\boldsymbol{b}_{a,i}\right)\Delta t\\ \Delta\widetilde{\boldsymbol{p}}_{ij}=\sum\limits_{k=i}^{j-1}\left[\Delta\widetilde{\boldsymbol{v}}_{ik}\Delta t+\frac{1}{2}\Delta\widetilde{\boldsymbol{R}}_{ik}\left(\widetilde{\boldsymbol{a}}_k-\boldsymbol{b}_{a,i}\right)(\Delta t)^2\right]\end{cases}\tag{9}$$

式中　$\Delta\widetilde{\boldsymbol{R}}_{ij}$——$i$ 与 j 时刻相对旋转矩阵的观测值

$\Delta\widetilde{\boldsymbol{v}}_{ij}$——$i$ 与 j 时刻速度变化的观测值

$\Delta\widetilde{\boldsymbol{p}}_{ij}$——$i$ 与 j 时刻位移变化的观测值

$\widetilde{\boldsymbol{a}}_k$——$k$ 时刻加速度读数,$k\in[i,j]$

$\widetilde{\boldsymbol{\omega}}_k$——$k$ 时刻角速度读数,$k\in[i,j]$

$\boldsymbol{b}_{g,i}$、$\boldsymbol{b}_{a,i}$——i 时刻的零偏

Δt——$[i,j]$区间中,i 到 $i+1$ 时刻的最小时间间隔

考虑随机噪声的影响,得到观测与旋转矩阵、速度、位移预测的关系为

$$\begin{cases}\Delta\widetilde{\boldsymbol{R}}_{ij}=\boldsymbol{R}_i^{\mathrm{T}}\boldsymbol{R}_j\exp(\delta\boldsymbol{\varphi}_{ij})\\ \Delta\widetilde{\boldsymbol{v}}_{ij}=\boldsymbol{R}_i^{\mathrm{T}}\Delta\boldsymbol{v}+\delta\boldsymbol{v}_{ij}\\ \Delta\widetilde{\boldsymbol{p}}_{ij}=\boldsymbol{R}_i^{T}\Delta\boldsymbol{p}+\delta\boldsymbol{p}_{ij}\end{cases}\tag{10}$$

其中

$$\Delta\boldsymbol{v}=\boldsymbol{v}_j-\boldsymbol{v}_i-\boldsymbol{g}\Delta t_{ij}$$

$$\Delta\boldsymbol{p}=\boldsymbol{p}_j-\boldsymbol{p}_i-\boldsymbol{v}_i\Delta t_{ij}-\frac{1}{2}g(\Delta t_{ij})^2$$

式中　$\boldsymbol{R}_i$、$\boldsymbol{R}_j$——i 与 j 时刻旋转矩阵的预测值

$\boldsymbol{v}_i$、$\boldsymbol{v}_j$——i 与 j 时刻速度的预测值

$\boldsymbol{p}_i$、$\boldsymbol{p}_j$——i 与 j 时刻位移的预测值

$\boldsymbol{g}$——重力加速度

Δt_{ij}——i 与 j 时刻间的时间差

$\delta\boldsymbol{\varphi}_{ij}$——$i$ 与 j 时刻间预积分过程中,旋转部分的随机噪声

$\delta\boldsymbol{v}_{ij}$——$i$ 与 j 时刻间预积分过程中,速度部分的随机噪声

$\delta\boldsymbol{p}_{ij}$——$i$ 与 j 时刻间预积分过程中,位移部分的随机噪声

式(10)变换定义残差为

$$\begin{cases}\boldsymbol{r}_{\Delta\boldsymbol{R}_{ij}}=\lg(\Delta\widetilde{\boldsymbol{R}}_{ij}^{\mathrm{T}}\boldsymbol{R}_i^{\mathrm{T}}\boldsymbol{R}_j)\\ \boldsymbol{r}_{\Delta\boldsymbol{v}_{ij}}=\boldsymbol{R}_i^{\mathrm{T}}\Delta\boldsymbol{v}-\Delta\widetilde{\boldsymbol{v}}_{ij}\\ \boldsymbol{r}_{\Delta\boldsymbol{p}_{ij}}=\boldsymbol{R}_i^{\mathrm{T}}\Delta\boldsymbol{p}-\Delta\widetilde{\boldsymbol{p}}_{ij}\end{cases}\tag{11}$$

式中　$\boldsymbol{r}_{\Delta\boldsymbol{R}_{ij}}$——$i$ 与 j 时刻旋转矩阵的预测与预积分观测的残差

$\boldsymbol{r}_{\Delta\boldsymbol{v}_{ij}}$——$i$ 与 j 时刻速度的预测与预积分观测的残差

$\boldsymbol{r}_{\Delta\boldsymbol{p}_{ij}}$——$i$ 与 j 时刻位移的预测与预积分观测的残差

式(11)中的残差代表图优化的边,关键帧 i 与 j 时刻的旋转矩阵、速度、位移预测将作为图优化顶点,从而对状态变量进行优化。将预积分模型归结至图优化得到旋转矩阵、速度和位移信息,即发布 IMU 里程计数据后,分解速度得到车体坐标系下 x 轴速度 $\boldsymbol{v}_x$和 y 轴速度 $\boldsymbol{v}_y$,根据获得的 $\boldsymbol{v}_y$ 和 $\boldsymbol{v}_x$,估计此刻在车体坐标系下地面法向量 $\boldsymbol{n}_b$为

$$\boldsymbol{n}_b=\boldsymbol{v}_y\times\boldsymbol{v}_x\tag{12}$$

后续计算激光点向量和地面法向量夹角时,激光点向量在世界坐标系下,故将地面法向量由车体坐标系变换到世界坐标系下,即

$$\boldsymbol{n}_w = \boldsymbol{T}_{bw}\boldsymbol{n}_b = (u_x, u_y, u_z)^{\mathrm{T}} \tag{13}$$

式中 $\boldsymbol{T}_{bw}$——车体坐标系到世界坐标系的转换矩阵

$\boldsymbol{n}_w$——变换到世界坐标系的地面法向量

激光点向量 $\boldsymbol{I}_n$ 为

$$\boldsymbol{I}_n = (x_n, y_n, z_n)^{\mathrm{T}} \tag{14}$$

激光点向量和地面法向量的夹角 ϕ 计算式为

$$\cos\phi = \frac{x_n u_x + y_n u_y + z_n u_z}{\sqrt{x_n^2 + y_n^2 + z_n^2}\sqrt{u_x^2 + u_y^2 + u_z^2}} \tag{15}$$

对每个激光点进行计算,通过 $\cos\phi$ 反三角变换得到夹角 ϕ。在理想情况下,激光点向量与地面点夹角应为 90°,实际中考虑传感器噪声、安装误差和环境扰动等因素易导致夹角波动,故设定波动阈值(5°)来判定激光点是否为地面点,即

$$\Delta\phi = |\phi - 90°| \tag{16}$$

若 $\Delta\phi \geqslant 5°$,则该点被判定为非地面点被过滤,反之则认为是地面点并保留。

2.2 回环检测

2.2.1 基于 IMU - LiDAR 数据触发回环检测

由 IMU 和 LiDAR 分别获取机器人位姿 P_I 和 P_L 后,根据当前帧特征提取结果来设计 LiDAR 数据置信度:

(1)维护一个滑动窗口,记录最近 50 帧的特征数量,计算其均值 μ 和方差 σ。

(2)统计当前帧提取出的边缘点特征数量 n_{edge} 和面点特征数量 n_{plane},相加得到总特征数量 n_{total}。根据最近 50 帧的特征数量,计算当前帧总特征数量相对历史水平的 Z-score(Z 分数)

$$Z_{\mathrm{score}} = \frac{n_{\mathrm{total}} - \mu}{\sigma} \tag{17}$$

Z_{score} 表示当前帧特征数量偏离历史平均水平的程度,其值高表示环境特征丰富,反之表示环境特征稀疏。

(3)根据当前帧的 Z 分数,设计 LiDAR 数据置信度函数 α 为

$$\alpha = \frac{1}{1 + \mathrm{e}^{-\lambda Z_{\mathrm{score}}}} \tag{18}$$

式中 λ——激光退化敏感度

λ 控制置信度变化曲线的陡峭程度,λ 值较小(如 $\lambda = 0.5$)时,表明采取平滑过渡策略,在特征数量变化时,LiDAR 和 IMU 的权重不会产生突变,更容易获得光滑的轨迹,但是在激光退化严重的环境中,LiDAR 的权重减幅过小,会导致显著的漂移;λ 值较大(如 $\lambda = 10$)时,表明采取激进过渡策略,在特征数量变化时,会突然切换权重,但是在轻度激光退化环境中,LiDAR 数据依然具有可靠性,而这种策略下置信度函数容易将 LiDAR 数据全部否决。因此,实际采用均衡的过渡策略,保证在严重退化时快速过渡,在轻度退化时平滑过渡,经多次试验取 λ 为 2。LiDAR 和 IMU 数据的置信度随 Z 分数的变化曲线如图 6 所示。

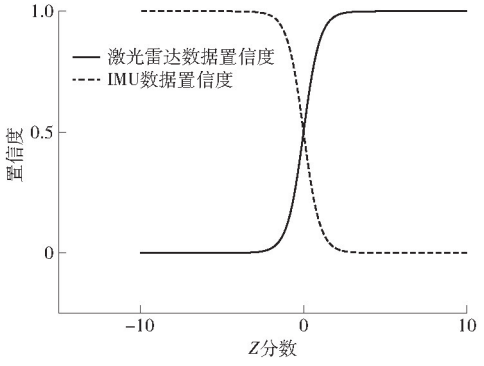

图 6 传感器数据置信度变化曲线

Fig. 6 Change curves of sensor data confidence

使用 Z 分数数据结合置信度函数纠正后的机器人位姿 $P_{\mathrm{IMU\text{-}corrected}}$ 为

$$P_{\mathrm{IMU\text{-}corrected}} = (1 - \alpha)P_I + \alpha P_L \tag{19}$$

当机器人的偏航角变化量 $\Delta\psi \geqslant 180°$ 时,触发回环检测。

2.2.2 基于改进 NDT 配准回环检测

在非结构化环境中,激光点云数据的局部缺失和环境噪声容易在回环检测时导致 LEGO - LOAM 的 ICP 配准陷入局部最优[25],故使用对局部缺失和噪声不敏感的 NDT 配准进行回环检测。

但原始 NDT 配准易造成计算资源的浪费(在空旷区域创建了大量无用体素)和尺度选择的困境(固定体素大小难以适应不均匀的点云密度),本文为实现高效 NDT 配准,对历史帧点云构建八叉树,分割函数设置为

$$\mathrm{Split}(O_i) = \begin{cases} 1 & (N(O_i) > n_{\max} \vee l < l_{\min}) \\ 0 & (N(O_i) \leqslant n_{\max} \wedge l \geqslant l_{\min}) \end{cases} \tag{20}$$

式中 O_i——八叉树子节点

$N(O_i)$——O_i 中点云数量

l——子节点层级

$n_{\max}$——叶子节点中点云数量阈值

$l_{\min}$——叶子节点最小层级

$\mathrm{Split}(O_i) = 1$ 表示将 O_i 分为 8 个小立方体(体素),$\mathrm{Split}(O_i) = 0$ 表示不分割。

历史帧点云构建八叉树后,每个叶子节点将存储内部点云的均值 $\boldsymbol{\mu}_i$ 和协方差矩阵 $\boldsymbol{\Sigma}_i$,即

$$\begin{cases}\boldsymbol{\mu}_i=\dfrac{1}{N(O_i)}\displaystyle\sum_{\boldsymbol{p}_j\in O_i}\boldsymbol{p}_j\\ \boldsymbol{\Sigma}_i=\dfrac{1}{N(O_i)}\displaystyle\sum_{\boldsymbol{p}_j\in O_i}(\boldsymbol{p}_j-\boldsymbol{\mu}_i)(\boldsymbol{p}_j-\boldsymbol{\mu}_i)^{\mathrm{T}}\end{cases}\tag{21}$$

式中　$\boldsymbol{p}_j$——激光点坐标

回环检测时，通过最近邻查找在八叉树中确定当前帧激光点 $\boldsymbol{q}_i$ 所属叶子节点，记录激光点残差 $\boldsymbol{e}_i$ 为

$$\boldsymbol{e}_i=\boldsymbol{R}\boldsymbol{q}_i+\boldsymbol{t}-\boldsymbol{\mu}_i\tag{22}$$

式中　$\boldsymbol{R}$——回环检测估计旋转机器人旋转矩阵

$\boldsymbol{t}$——回环检测估计机器人平移向量

最后的 $\boldsymbol{R}$、$\boldsymbol{t}$ 由一个加权的最小二乘问题决定，即

$$(\boldsymbol{R},\boldsymbol{t})^*=\underset{\boldsymbol{R}\in SO(3),\boldsymbol{t}\in\mathbf{R}^3}{\operatorname{argmin}}\sum_i(\boldsymbol{e}_i^{\mathrm{T}}\boldsymbol{\Sigma}_i^{-1}\boldsymbol{e}_i)\tag{23}$$

求解最小二乘问题，得到 $\boldsymbol{R}$、$\boldsymbol{t}$ 后，对机器人位姿进一步优化。

3　试验

为验证 MLD－LOAM 的有效性，在公开数据集与实际场景中均进行了试验，载体为 Buffalo－x 履带式移动底盘（图 7），用于搭载机器人至室外的移动作业过程。此外，试验器材还包括一台创物者 Mini2 主机，该主机搭载 Intel Core i7－13620H 处理器，主频 5.6 GHz、内存 32 GB，并运行 Ubuntu 20.04 操作系统，使用速腾 16 线 LiDAR，IMU 为 LPMS－BE1 六轴惯导模块。差分定位仪为华测 CGI－230，姿态精度 0.2°，定位精度 1 cm。采用 EVO（Estimation，validation，and optimization）为轨迹评估工具，采用高精度差分定位仪进行数据测量。

3.1　KITTI 数据集试验

KITTI 数据集[26]包含了丰富的真实世界场景，如车辆、行人、自行车、建筑物、树木等，能很好地模拟现实中环境多样性，同时提供了来自高精度 GPS/IMU 定位系统的参考轨迹。试验中既进行轨迹定性对比，也采用绝对位姿误差（Absolute pose error，APE）定量对比[27]。APE 表示真实位姿与估计位姿之间的偏差，越小则表明精度越高。后续对比中，使用综合评价指标均方根误差来统计 APE。

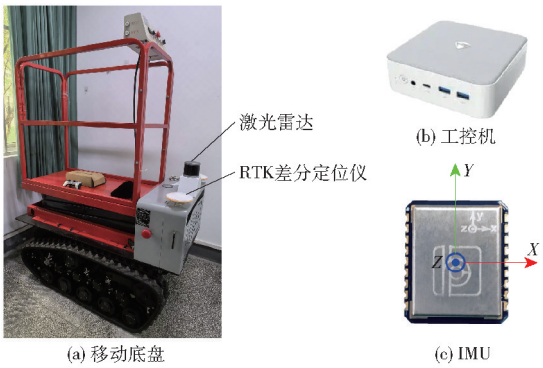

图 7　Buffalo－x 履带式移动底盘

Fig. 7　Buffalo－x tracked mobile chassis

KITTI_00 采集于普通城市环境，拥有丰富环境特征和轻微高度变化区域，该数据集适于测试算法在常规环境中的定位精度，算法运行结果如图 8 所示。图 8a 为 LEGO－LOAM 和 MLD－LOAM 分别在 KITTI_00 上得到的轨迹。在图 8b 中 0～200 s 区域地面高度 y 连续变化，LEGO－LOAM 将较多的真实地面点过滤掉，出现了特征误匹配现象，使后续估计的轨迹发生明显漂移，而 MLD－LOAM 在该区域的轨迹漂移明显小于前者，源于在这种情况下 IMU 辅助的地面点云过滤策略能较好地改善特征匹配时出现的误匹配情况，从而减少了估计轨迹与真实轨迹之间的偏差。从图 8c 可知 MLD－LOAM 的绝对位姿误差优于 LEGO－LOAM。

KITTI_05 采集于更复杂的城市环境，其地面高度变化相对 KITTI_00 的采集环境更加剧烈，故用此数据集检验算法的地面点云过滤性能，算法运行结果如图 9 所示。图 9b 中 0～250 s 内，MLD－LOAM

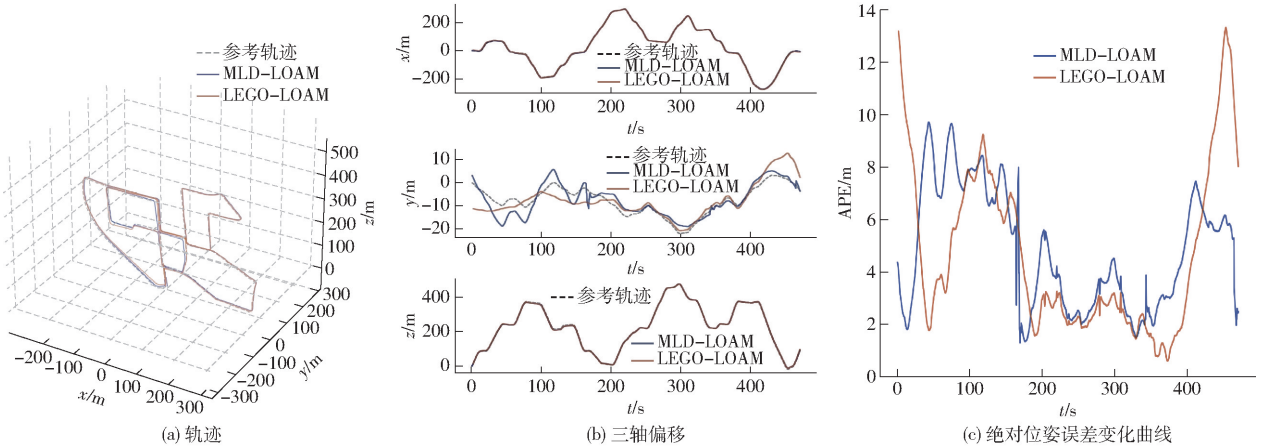

图 8　KITTI_00 数据集轨迹与绝对位姿误差曲线

Fig. 8　Trajectory and absolute pose error curves in KITTI_00

相对 LEGO－LOAM 具有更小的轨迹漂移，但在 250～290 s 内，MLD－LOAM 的轨迹漂移出现了较大波动，因为这段时间通过的是特征最稀疏的区域，融合里程计中 IMU 达到了较大的权重，IMU 本身的噪声和稀疏特征共同导致了轨迹漂移的波动。但图 9c 依然说明 MLD－LOAM 相对 LEGO－LOAM 明显减小了地面高度变化导致的绝对位姿误差。

KITTI_09 采集于乡村道路，有很多树木和植被，其环境相似度相对 KITTI_00 的采集环境更高，故用此数据集检验算法的回环检测性能，算法运行结果如图 10 所示。由图 10a、10b 可知两种算法的轨迹漂移无明显区别，图 10b 中约 75 s 处轨迹的 z 坐标由上升变为下降，即车辆调头，说明此刻开始发生回环检测，从图 10c 可知此时 MLD－LOAM 的绝对位姿误差明显低于 LEGO－LOAM，在后续轨迹中前者的绝对位姿误差总体也低于后者。这充分证明面对相似度高的环境时，MLD－LOAM 算法的回环检测策略能有效降低误匹配从而提高定位精度。

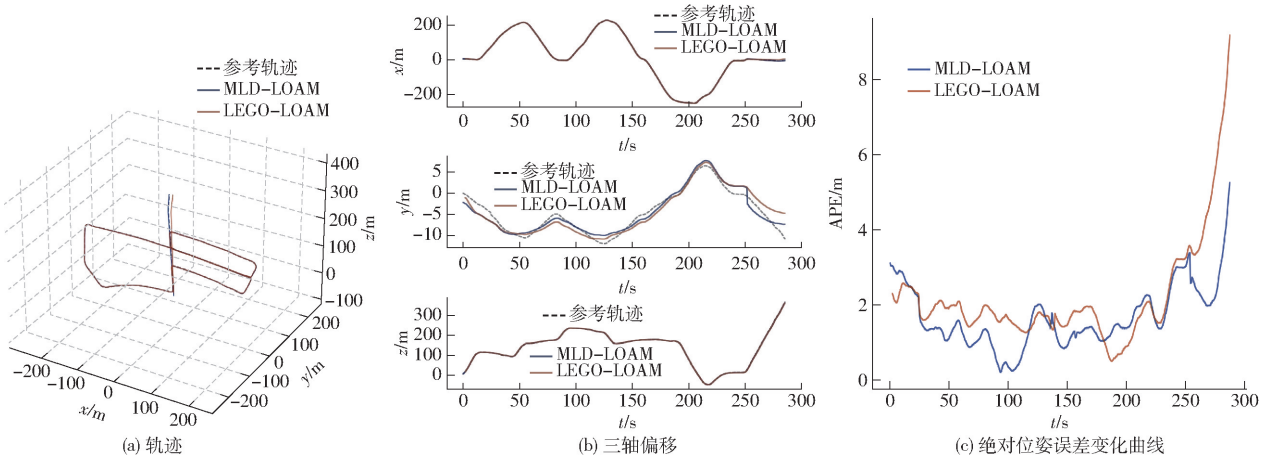

(a) 轨迹　(b) 三轴偏移　(c) 绝对位姿误差变化曲线

图 9　KITTI_05 数据集轨迹与绝对位姿误差曲线

Fig. 9　Trajectory and absolute pose error curves in KITTI_05

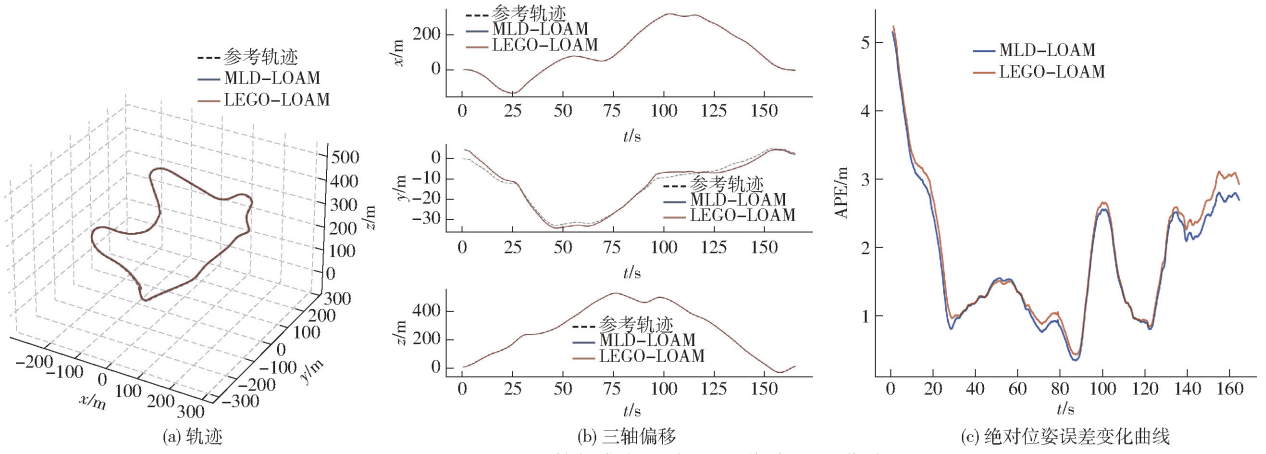

(a) 轨迹　(b) 三轴偏移　(c) 绝对位姿误差变化曲线

图 10　KITTI_09 数据集轨迹与绝对位姿误差曲线

Fig. 10　Trajectory and absolute pose error curves in KITTI_09

同时选取 3 组数据集下绝对位姿误差的均方根误差、误差平方和、标准差作为评判标准，表 1 为两种算法的绝对位姿误差结果对比。由表 1 可知，在 KITTI_00 中，MLD－LOAM 相比 LEGO－LOAM 的绝对位姿误差降低了 5.7%，表明在常规环境中前者的定位精度也有所提升。在 KITTI_05 中，MLD－LOAM 相比 LEGO－LOAM 的绝对位姿误差降低了 28%，证明前者的地面点云过滤策略有效提升了地形变化场景中的定位精度。在 KITTI_09 中，MLD－LOAM 相比 LEGO－LOAM 的绝对位姿误差降低了 5%，说明前者的回环检测降低了高相似度环境中误匹配导致的定位误差。从 3 组数据集来看，MLD－LOAM 相比 LEGO－LOAM 的定位精度提高了 11%，进而验证了本文所提出的基于 IMU 辅助的地面点云过滤和基于 IMU－LiDAR 融合的回环检测可有效提升 SLAM 的定位精度。

3.2　实际场景试验

选用校园两片树林区域作为实际场景，用图 7 所示试验平台进行数据采集和处理。考虑到 MLD－LOAM 是针对 LEGO－LOAM 在相似度高和非平坦地形环境中的优化方法，图 11 所示的两个环境中树木行距和株距不均匀，大量树木高度和冠幅接近，提

表 1　绝对位姿误差结果对比

Tab. 1　Comparison of absolute pose error results

数据集	均方根误差/m		误差平方和/m^2		标准差/m	
	LEGO－LOAM	MLD－LOAM	LEGO－LOAM	MLD－LOAM	LEGO－LOAM	MLD－LOAM
KITTI_00	5. 690 284	5. 367 597	36 621. 026 679	32 700. 591 326	3. 164 026	2. 309 578
KITTI_05	2. 564 743	1. 842 29	4 512. 444 046	2 341. 881 541	1. 369 386	0. 820 894
KITTI_09	2. 126 165	2. 025 26	1 781. 107 763	1 620. 163 183	0. 990 314	0. 955 694

取特征时会出现很多相似特征，且地面拥有 5° ~ 10°的明显坡度，为典型非结构化激光退化场景，因此所选场景适于测试算法在实景运行中的定位精度。试验中底盘平均移动速度为 0. 5 m/s，高精度差分定位仪采集真实轨迹。



(a) 环境1　　(b) 环境2

图 11　试验环境

Fig. 11　Experimental environment

3. 2. 1　消融试验

基于 IMU 数据的地面点云二次过滤对非平坦地面的适应性强于 LEGO－LOAM 的相邻点角度过滤，这在理论上易得到证明，但基于激光点距离分布的地面点云一次过滤对系统准确性和稳定性的提升，需要通过使用完整过滤与仅使用单次过滤进行试验对比来论证。在环境 1 和环境 2 中，分别使用改进算法、距离分布法和 IMU 辅助法进行实时位姿估计消融试验，得到 2 个环境中的绝对位姿误差及对应指标，结果如表 2 所示。

表 2　消融试验的绝对位姿误差指标对比

Tab. 2　Comparison of various indicators of absolute pose error in ablation experiments

真实环境	均方根误差/m			误差平方和/m^2			标准差/m		
	距离分布法	IMU 辅助法	改进算法	距离分布法	IMU 辅助法	改进算法	距离分布法	IMU 辅助法	改进算法
环境 1	1. 012 59	0. 887 52	0. 784 21	552. 657	424. 567	331. 484	0. 290 49	0. 205 12	0. 177 60
环境 2	0. 964 15	0. 727 61	0. 719 85	330. 004	187. 946	183. 957	0. 397 86	0. 200 31	0. 179 35

由表 2 可知，IMU 辅助法的绝对位姿误差明显低于距离分布法，但与改进算法对比时，即使在环境 2 下 IMU 辅助法的精度十分接近改进算法，在环境 1 中 IMU 辅助法也呈现了较大的绝对位姿误差。分析原因为环境 1 相对环境 2 包含着更密集的垂直障碍物(即树干)，面对庞大的原始点云，对每个点计算与地面法向量夹角将显著提升系统的计算负担；而且 IMU 辅助法的单点计算对噪声较为敏感，大量的噪声会影响系统的定位精度。由表 2 还可得，距离分布法的定位精度随环境的改变没有较大变化，因为距离分布法是基于激光点距离的聚类方法，擅长处理垂直维度的明显变化，能够对树木等明显非地面点的障碍进行快速过滤；同时，由于该方法采用了基于距离区间的地面点云过滤策略，对噪声不敏感，拥有较强的稳定性。

消融试验的结果说明，基于激光点距离分布的地面点云一次过滤为基于 IMU 数据的地面点云二次过滤快速排除了大量明显的非地面点，减轻了系统的计算开销，并且提升了系统对于噪声的鲁棒性，使得 MLD－LOAM 在不同环境中保持较高且稳定的定位性能。

3. 2. 2　与原算法对比试验

为了验证 MLD－LOAM 和原算法在 Buffalo－x 底盘闭环运动下的定位精度，通过观察它们的轨迹偏移量，并比较其绝对位姿误差指标来统计定位误差。图 12 为两种算法的运动轨迹对比。

从图 12a、12d 可知，在大幅度转弯的情况下，MLD－LOAM 相比原算法明显更接近真实轨迹，即 MLD－LOAM 在真实的高相似度环境中能更好地回环检测以抑制轨迹的漂移。图 12b 展示了两种算法轨迹在环境 1 中的三轴偏移，在 425 ~ 440 s 区域内地面高度 z 出现了显著波动，此时 LEGO－LOAM 发生了明显纵向漂移，而 MLD－LOAM 则有效减小了纵向漂移；图 12e 为环境 2 中的三轴偏移，可知 MLD－LOAM 的纵向漂移波动比 LEGO－LOAM 更平缓，由图 12b、12e 可得 MLD－LOAM 的基于 IMU 辅助的地面点云过滤策略良好适应了地面高度波动场景，对地面点云进行了准确过滤，减少了 LEGO－LOAM 算法出现误匹配的情况，提高了定位精度。图 12c 表明在环境 1 中，MLD－LOAM 的俯仰角误

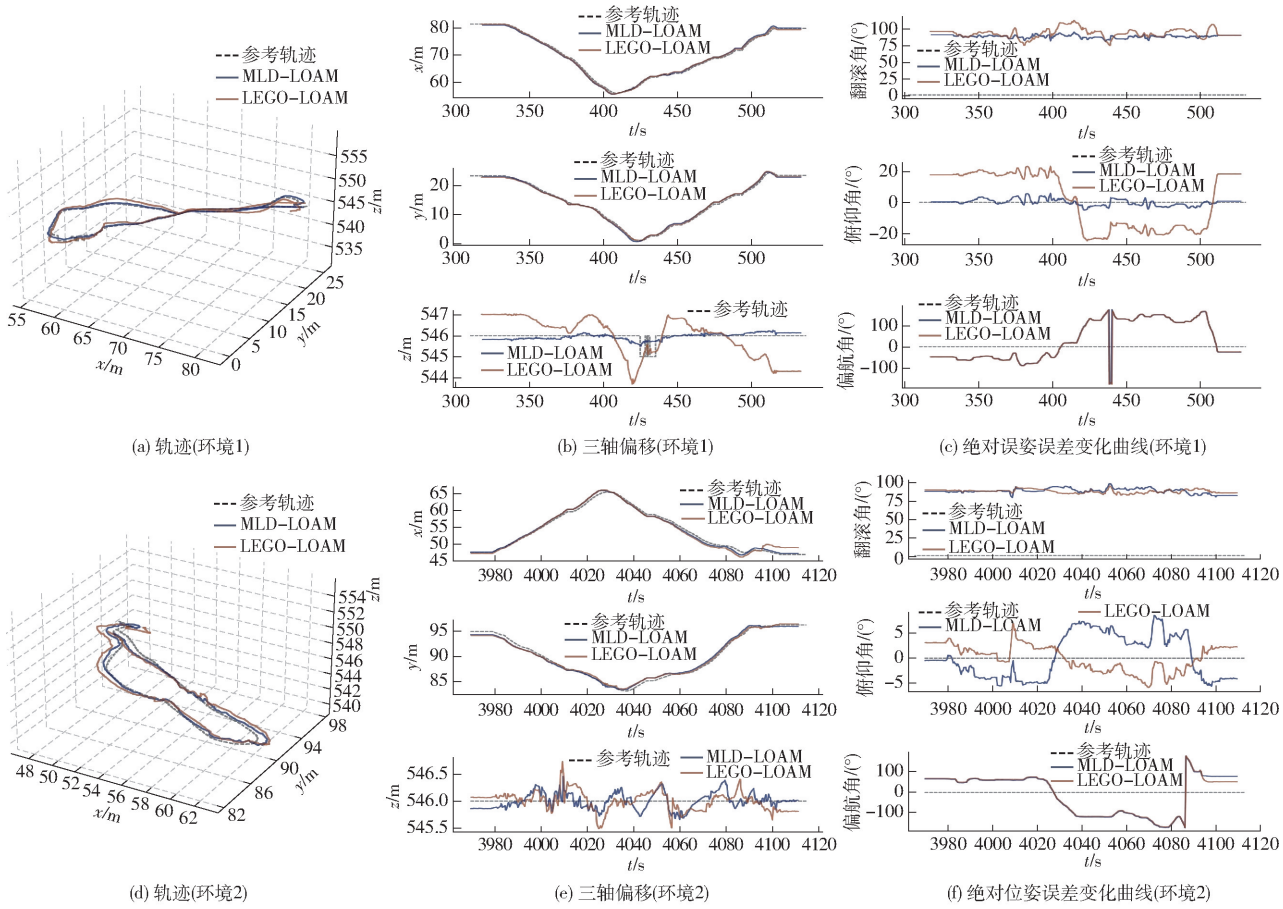

图 12 非结构化环境中的运动轨迹对比

Fig. 12 Motion trajectory comparison in unstructured environment

差明显低于 LEGO－LOAM，但在图 12f 中，MLD－LOAM 也出现了较大的俯仰角误差，分析原因为环境 2 的环境标志物较少，特征更稀疏，导致融合里程计中 IMU 数据权重较大，IMU 本身的噪声导致了更大的俯仰角误差。由图 12a～12f 可知在地面点云过滤以及回环检测的过程中 MLD－LOAM 具备更高定位精度，明显优于 LEGO－LOAM。

表 3 为非结构环境中绝对位姿误差评价指标对比。从表 3 可知，相比上述 3 组 KITTI 数据集的试验结果，MLD－LOAM 的绝对位姿误差更加明显地低于 LEGO－LOAM，源于在非结构化环境中的地面变化相对 KITTI 数据集中的城市环境和乡村道路更加陡峭，以及环境相似度更高，导致 LEGO－LOAM 错误过滤更多地面点云，以及在回环检测时进行更多的误匹配，而 MLD－LOAM 针对性优化了此两种情况导致的定位误差，故相较于 KITTI 数据集中的试验，非结构环境中的实时定位精度提升更为明显。MLD－LOAM 的定位精度相较于 LEGO－LOAM 算法提升了 30%。

3.2.3 与其他先进 SLAM 方法对比

为了进一步体现 MLD－LOAM 用于低成本平台在非结构化环境中定位的优势，将 MLD－LOAM 与因子图框架的代表 LIO－SAM 和滤波方法的代表 FAST－LIO 进行对比，将从测试时的定位精度、内存消耗速度，以及所建地图点云数量来综合评价每个算法的性能。所建地图对比如图 13 所示，绝对位姿误差的均方根误差、内存消耗速度、地图点云数量等指标如表 4 所示。

由表 4 可得，LIO－SAM 的定位精度优于 MLD－LOAM 算法，而 FAST－LIO 相比另外两种算法出现了较大的定位误差，分析原因为 FAST－LIO 基于迭代式卡尔曼滤波，当接收到新的 LiDAR 数据和 IMU

表 3 非结构环境中绝对位姿误差评价指标对比

Tab. 3 Comparison of absolute pose error evaluation metrics in unstructured environments

真实环境	均方根误差/m		误差平方和/m^2		标准差/m	
	LEGO－LOAM	MLD－LOAM	LEGO－LOAM	MLD－LOAM	LEGO－LOAM	MLD－LOAM
环境 1	1. 133 459	0. 784 219	695. 038 702	331. 484 548	0. 390 676	0. 177 609
环境 2	1. 067 018	0. 719 855	404. 177 212	183. 957 658	0. 489 612	0. 179 350

数据时，将会用新的观测来更新当前状态，在高相似度环境中出现漂移时，滤波器会基于带有误差的状态进行下一步的预测和更新，定位误差容易出现累积，而 FAST－LIO 缺乏回环检测模块，无法修正历史轨迹；LIO－SAM 使用图优化框架对 IMU 数据和 LiDAR 数据进行联合优化，IMU 预积分提供 LiDAR 里程计的初始化，LiDAR 里程计用于估计 IMU 预积分的偏差，因此比 MLD－LOAM 在结果层面融合

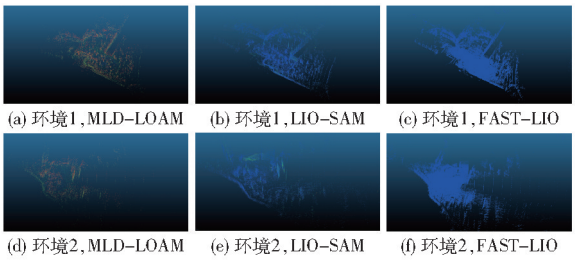

图 13　3 种算法的地图对比

Fig. 13　Map comparison of three algorithms

表 4　3 种算法性能指标对比

Tab. 4　Comparison of performance metrics of three algorithms

真实环境	绝对位姿误差的均方根误差/m			内存消耗速度/(MB·s^{-1})			地图点云数量/个		
	MLD－LOAM	LIO－SAM	FAST－LIO	MLD－LOAM	LIO－SAM	FAST－LIO	MLD－LOAM	LIO－SAM	FAST－LIO
环境 1	0. 784 22	0. 754 06	1. 016 40	1. 46	2. 96	4. 77	49 566	335 105	6 651 344
环境 2	0. 719 86	0. 709 43	0. 989 32	1. 69	3. 32	4. 94	39 428	232 379	4 490 989

LiDAR 里程计和 IMU 里程计拥有更高的定位精度。但是，由图 13 和表 4 可得，虽然 MLD－LOAM 在非结构化环境中的定位精度比 LIO－SAM 要低 2. 8%，但是得益于简洁的系统设计以及使用更少的激光点云，MLD－LOAM 的内存消耗速度仅为 LIO－SAM 的 50% 和 FAST－LIO 的 32. 4%，在低成本平台上拥有更好的适应性。

4　讨论

LEGO－LOAM 对平坦地面的假设是非结构化环境中的主要误差源之一，本文通过引入 IMU 数据，有效地放宽了这一强假设约束。基于 IMU 数据的地面点云二次过滤方法对地面法向量进行实时估计后，再通过激光点向量和地面法向量夹角过滤地面点云，相比 LEGO－LOAM 的地面点云过滤方法，本文所设计的 MLD－LOAM 对区分地面点和非地面点有更高准确度。在 KITTI_05 中 MLD－LOAM 的定位精度比 LEGO－LOAM 提升了 28%，这表明前者在结构化的城市环境中对地形起伏和斜坡具有更好鲁棒性，减少了错误的地面点云过滤对后续特征匹配的干扰。

在非结构化环境中，另一误差源为高相似度的环境特征导致回环检测时进行的错误匹配。基于点云特征稀疏程度设计的置信度函数，能够判断纯激光雷达里程计在高相似度环境中的可靠程度，从而有效融合 IMU 里程计数据进行回环检测，以减少纯激光雷达里程计回环检测时的误匹配，而基于八叉树的 NDT 配准则进一步保证了匹配的效率和成功率。在 KITTI_09 中 MLD－LOAM 的定位精度相比 LEGO－LOAM 提升了 5%，这表明，MLD－LOAM 在非结构化乡村道路上运行时能有效改善高相似度环境带来的回环误匹配问题。

在高相似度和非平坦地形的非结构化激光退化环境中，MLD－LOAM 的定位精度相比 LEGO－LOAM 提升了 30%，说明在非结构化环境中，地面的明显波动和更高相似度的环境特征会进一步加剧 LEGO－LOAM 的误匹配，从而导致更显著的定位误差，而 MLD－LOAM 可有效适应非结构化环境，表现出较好的鲁棒性和较高的定位精度。此外，与 LIO－SAM 和 FAST－LIO 相比，MLD－LOAM 定位精度优于 FAST－LIO 且接近 LIO－SAM，但内存消耗速度显著低于 LIO－SAM 与 FAST－LIO。

尽管 MLD－LOAM 得到了良好结果，但本研究仍存在一些局限性。比如在 KITTI_05 数据集的试验中，当激光点云特征十分稀疏时，激光雷达里程计置信度将变得很小，导致 IMU 里程计达到一个很大的权重，此时机器人里程计接近于纯 IMU 里程计，但其本身的随机游走误差和零偏误差会导致运动轨迹发生较大的漂移，因此激光雷达里程计置信度函数的设计还需进一步优化。

5　结束语

提出了一种基于 LEGO－LOAM 架构的优化算法 MLD－LOAM，在地面点云过滤阶段，加入 IMU 数据改进地面点云过滤策略，在回环检测阶段，基于 IMU－LiDAR 数据融合的里程计进行回环检测。通过加入 IMU 数据，实时估计地面法向量，对初次快速过滤结果进行准确剔除，同时将原有的 IMU 里程计换为 IMU－LiDAR 融合的里程计进行回环检测，进一步减少误匹配情况，提高了匹配准确度，从而有效提升了系统定位精度。试验结果表明，MLD－LOAM 比 LEGO－LOAM 在 KITTI 数据集和非结构

化环境中的定位精度分别提升了 11% 和 30%,且在内存消耗速度远低于 LIO - SAM 与 FAST - LIO 的条件下达到了接近 LIO - SAM 的定位精度,体现了本文算法的可行性和有效性。

参 考 文 献

[1] 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). IEEE, 2015: 85 - 90.

[2] GUPTA A, FERNANDO X. Simultaneous localization and mapping (SLAM) and data fusion in unmanned aerial vehicles: recent advances and challenges[J]. Drones, 2022, 6(4):85.

[3] CADENA C, CARLONE L, CARRILLO H, et al. Past, present, and future of simultaneous localization and mapping: toward the robust-perception age[J]. IEEE Transactions on Robotics, 2016, 32(6): 1309 - 1332.

[4] ZAFFAR M, EHSAN S, STOLKIN R, et al. Sensors, slam and long-term autonomy: a review[C]// 2018 NASA/ESA Conference on Adaptive Hardware and Systems (AHS). IEEE, 2018: 285 - 290.

[5] 陈明方,黄良恩,王森,等. 移动机器人视觉里程计技术研究综述[J]. 农业机械学报,2024,55(3):1 - 20.
CHEN Mingfang, HUANG Liang'en, WANG Sen, et al. Survey of research on visual odometry technology for mobile robots[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(3):1 - 20. (in Chinese)

[6] 沈跃,肖鑫桦,刘慧,等. 果园机器人 LiDAR/IMU 紧耦合实时定位与建图方法[J]. 农业机械学报,2023,54(11):20 - 28,48.
SHEN Yue, XIAO Xinhua, LIU Hui, et al. Real-time localization and mapping method for agricultural robot in orchards based on LiDAR/IMU tight-coupling[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(11):20 - 28,48. (in Chinese)

[7] TOURANI A, BAVLE H, SANCHEZ-LOPEZ J L, et al. Visual slam: what are the current trends and what to expect? [J]. Sensors, 2022, 22(23): 9297.

[8] TAKETOMI T, UCHIYAMA H, IKEDA S. Visual SLAM algorithms: a survey from 2010 to 2016[J]. IPSJ Transactions on Computer Vision and Applications, 2017, 9: 1 - 11.

[9] ZHANG J, SINGH S. LOAM: LiDAR odometry and mapping in real-time[C]// Robotics: Science and Systems, 2014: 1 - 9.

[10] DUBÉ R, DUGAS D, STUMM E, et al. Segmatch: segment based place recognition in 3D point clouds[C]// 2017 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2017: 5266 - 5272.

[11] SHAN T, 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). IEEE, 2018: 4758 - 4765.

[12] 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). IEEE, 2018: 4802 - 4809.

[13] SHAN T, 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 (IROS). IEEE, 2020: 5135 - 5142.

[14] XU W, ZHANG F. Fast-lio: a fast, robust lidar-inertial odometry package by tightly-coupled iterated Kalman filter[J]. IEEE Robotics and Automation Letters, 2021, 6(2): 3317 - 3324.

[15] XU W, CAI Y, HE D, et al. Fast - lio2: fast direct lidar-inertial odometry[J]. IEEE Transactions on Robotics, 2022, 38(4): 2053 - 2073.

[16] 伟利国,李广瑞,董鑫,等. 基于激光 SLAM 的小麦点云采集系统与冠层高度提取方法[J]. 农业机械学报,2024,55(增刊2):263 - 276.
WEI Liguo, LI Guangrui, DONG Xin, et al. Point cloud acquisition and canopy geometric features in wheat based on laser SLAM[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(Supp.2):263 - 276. (in Chinese)

[17] 路春晓,钟焕,刘威,等. 复杂地形环境中的多传感器融合 SLAM 技术[J]. 机器人,2024,46(4):425 - 435.
LU Chunxiao, ZHONG Huan, LIU Wei, et al. Multi-sensor fusion SLAM in complex terrain environments[J]. Robot, 2024, 46(4): 425 - 435. (in Chinese)

[18] 张文翔,卢鑫羽,张兵园,等. 基于激光 SLAM 和 AprilTag 融合的温室移动机器人自主导航方法[J]. 农业机械学报,2025,56(1):123 - 132.
ZHANG Wenxiang, LU Xinyu, ZHANG Bingyuan, et al. Autonomous navigation method of greenhouse mobile robot based on laser SLAM and AprilTag[J]. Transactions of the Chinese Society for Agricultural Machinery,2025,56(1):123 - 132. (in Chinese)

[19] ZHANG J, SINGH S. Visual-lidar odometry and mapping: low-drift, robust, and fast[C]// 2015 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2015: 2174 - 2181.

[20] SHAN T, ENGLOT B, RATTI C, et al. LVI-SAM: tightly-coupled lidar-visual-inertial odometry via smoothing and mapping[C]// 2021 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2021: 5692 - 5698.

[21] LIN J, ZHENG C, XU W, et al. R2LIVE: a robust, real-time, LiDAR-inertial-visual tightly-coupled state estimator and mapping[J]. IEEE Robotics and Automation Letters, 2021, 6(4): 7469 - 7476.

(下转第 158 页)

[7] 毕泽洋,杨立伟,吕树盛,等. 基于 EDH - YOLO 的轻量型温室番茄检测方法[J]. 农业机械学报,2024,55(增刊2):246 - 254.
BI Zeyang, YANG Liwei, LÜ Shusheng, et al. Lightweight greenhouse tomato detection method based on EDH - YOLO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(Supp. 2): 246 - 254. (in Chinese)
[8] GAO G, SHUAI C, WANG S, et al. Using improved YOLO V5s to recognize tomatoes in a continuous working environment [J]. Signal, Image and Video Processing, 2024, 18(5): 4019 - 4028.
[9] ZHENG X, XINYI A I, QIN H, et al. Tomato - nerf: advancing tomato model reconstruction with improved neural radiance fields[J]. IEEE Access, 2024, 12: 184206 - 184215.
[10] MAGALHÃES S A C, DOS SANTOS F N, MOREIRA A P, et al. MonoVisual3DFilter: 3D tomatoes' localisation with monocular cameras using histogram filters[J]. Robotica, 2024, 42(8): 2528 - 2547.
[11] SMITT C, HALSTEAD M, ZIMMER P, et al. PAg - NeRF: towards fast and efficient end-to-end panoptic 3D representations for agricultural robotics[J]. IEEE Robotics and Automation Letters, 2023, 9(1): 907 - 914.
[12] MILDENHALL B, SRINIVASAN P P, TANCIK M, et al. Nerf: representing scenes as neural radiance fields for view synthesis[J]. Communications of the ACM, 2021, 65(1): 99 - 106.
[13] CHEN J, MA A, HUANG L, et al. Efficient and lightweight grape and picking point synchronous detection model based on key point detection[J]. Computers and Electronics in Agriculture, 2024, 217: 108612.
[14] ZHANG F, GAO J, SONG C, et al. TPMv2: an end-to-end tomato pose method based on 3D key points detection[J]. Computers and Electronics in Agriculture, 2023, 210: 107878.
[15] CI J, WANG X, RAPADO-RINCÓN D, et al. 3D pose estimation of tomato peduncle nodes using deep keypoint detection and point cloud[J]. Biosystems Engineering, 2024, 243: 57 - 69.
[16] JIANG T, XIE X, LI Y. RTMW: real-time multi-person 2D and 3D whole-body pose estimation[J]. arXiv Preprint, arXiv: 2407.08634, 2024.
[17] LI Y, FENG Q, ZHANG Y, et al. Peduncle collision-free grasping based on deep reinforcement learning for tomato harvesting robot[J]. Computers and Electronics in Agriculture, 2024, 216: 108488.
[18] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 390 - 391.
[19] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1251 - 1258.
[20] LI Y, YANG S, LIU P, et al. Simcc: a simple coordinate classification perspective for human pose estimation[C]//European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2022: 89 - 106.
[21] MEHTA S, RASTEGARI M. MobileVit: light-weight, general-purpose, and mobile-friendly vision transformer[J]. arXiv Preprint, arXiv:2110.02178, 2021.
[22] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30:5998 - 6008.
[23] HUA W, DAI Z, LIU H, et al. Transformer quality in linear time[C]// International Conference on Machine Learning. PMLR, 2022: 9099 - 9117.
[24] ZHANG F, ZHU X, DAI H, et al. Distribution-aware coordinate representation for human pose estimation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 7093 - 7102.
[25] MARTINEZ J, HOSSAIN R, ROMERO J, et al. A simple yet effective baseline for 3D human pose estimation[C]// Proceedings of the IEEE International Conference on Computer Vision, 2017: 2640 - 2649.
[26] DING X, LI Q, CHENG Y, et al. Local keypoint-based Faster R - CNN[J]. Applied Intelligence, 2020, 50(10): 3007 - 3022.

(上接第 126 页)

[22] ZHENG C, ZHU Q, XU W, et al. FAST-LIVO: fast and tightly-coupled sparse-direct lidar-inertial-visual odometry[C]// 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2022: 4003 - 4009.
[23] ZHENG C, XU W, ZOU Z, et al. FAST-LIVO2: fast, direct lidar-inertial-visual odometry[J]. IEEE Transactions on Robotics, 2025, 41: 326 - 346.
[24] ZERMAS D, IZZAT I, PAPANIKOLOPOULOS N. Fast segmentation of 3D point clouds: a paradigm on LiDAR data for autonomous vehicle applications[C]// 2017 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2017: 5067 - 5073.
[25] 郑立华,麦春艳,廖崴,等. 基于 Kinect 相机的苹果树三维点云配准[J]. 农业机械学报,2016,47(5):9 - 14.
ZHENG Lihua, MAI Chunyan, LIAO Wei, et al. 3D point cloud registration of apple trees based on Kinect camera[J]. Transactions of the Chinese Society of Agricultural Machinery,2016,47(5):9 - 14. (in Chinese)
[26] 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. IEEE, 2012: 3354 - 3361.
[27] ZHANG Y, SHI P, LI J. LiDAR-based place recognition for autonomous driving: a survey[J]. ACM Computing Surveys, 2024, 57(4): 1 - 36.