中国科学: 技术科学 2024 年 第 54 卷 第 10 期: 2003 ~ 2016
SCIENTIA SINICA Technologica techcn.scichina.com
《中国科学》杂志社 SCIENCE CHINA PRESS
论 文

基于穿戴式激光头盔的固态激光雷达-惯导三维场景重建方法

古长军[1], 冷佳旭[2], 徐宗懿[2], 高新波[2*]

1. 重庆邮电大学自动化学院, 重庆 400065;
2. 重庆邮电大学计算机科学与技术学院, 重庆 400065
* E-mail: gaoxb@cqupt.edu.cn

收稿日期: 2023-11-05; 接受日期: 2024-03-05; 网络版发表日期: 2024-08-28
重庆市科技创新重大研发项目(编号: CSTB2023TIAD-STX0016)、国家自然科学基金项目(批准号: 62303083, 62221005, U23A20318, 62206033)、重庆市教委科学技术研究项目(编号: KJQN202300626)和重庆邮电大学人才引进项目(编号: E012A2023015)资助

摘要 三维地图构建在无人驾驶、资源勘探等领域具有大量的应用. 穿戴式激光头盔传感器具有低成本、小型化的特点, 可以在GNSS信号缺失或通行性有限的区域实现高精度三维地形重建. 然而, 穿戴式激光头盔传感器在采集数据过程中存在剧烈抖动和快速转弯等问题, 降低了轨迹估计和三维重建结果精度. 为了解决这些挑战, 首先, 本文提出一种基于中间参考点的点云运动畸变补偿方法, 降低单帧点云数据运动畸变; 然后, 本文提出一种基于局部邻域特征一致性判别的误差模型构建方法, 提高传感器轨迹估计和三维场景重建精度. 最后, 本文在设计的穿戴式激光头盔传感器和公开数据集上对本文方法和代表性的固态激光雷达-惯导三维重建方法进行综合对比分析. 实验结果表明, 本文提出的方法在所有对比方法中取得了最优的轨迹估计和三维重建结果.

关键词 穿戴式传感器, 激光头盔, 环境感知, 三维重建, 参数优化

1 引言

三维场景重建是通过多种传感器采集的数据恢复场景的三维结构信息, 已经广泛应用于无人驾驶、资源勘探和智能制造等领域[1~4]. 通过将传感器搭载在不同的移动平台, 主要可以分为机载三维重建传感器、车载三维重建传感器、穿戴式背包和激光头盔传感器等, 其中, 机载三维重建传感器通过将传感器搭载在无人机上[5,6], 在无人机可飞行区域, 实现地面三维场景重建; 车载三维重建传感器通过将传感器搭载在车辆平台上[7,8], 在车辆可通行区域实现三维场景重建; 穿戴式背包和激光头盔传感器通过将设备背在工作人员的背上或者戴在工作人员的头部位置[9,10], 可以工作在GNSS信号缺失或通行性有限的复杂场景区域, 实现快速便捷的三维场景重建. 由于穿戴式激光头盔传感器具有低成本、小型化的优势, 本文主要研究基于穿戴式激光头盔传感器的固态激光雷达-惯性导航系统(简称惯导)三维场景重建方法.

对于穿戴式激光头盔传感器三维场景重建, 现有的方法主要采用基于视觉的三维重建方法和基于多线

引用格式: 古长军, 冷佳旭, 徐宗懿, 等. 基于穿戴式激光头盔的固态激光雷达-惯导三维场景重建方法. 中国科学: 技术科学, 2024, 54: 2003–2016
Gu C J, Leng J X, Xu Z Y, et al. A solid-state lidar-INS 3D scene reconstruction method based on wearable laser helmet (in Chinese). Sci Sin Tech, 2024, 54: 2003–2016, doi: 10.1360/SST-2023-0362

© 2024 《中国科学》杂志社

激光雷达的三维重建方法, 其中, 基于视觉的三维重建方法依靠特征匹配进行场景重建, 三维场景重建结果稀疏, 且容易受到环境亮度变化和图像模糊的影响[11,12]; 基于多线激光雷达的三维重建方法主要采用点云增量式配准方法, 重建三维场景结构信息, 这种方式传感器成本比较高[13,14]. 最近, 由于固态激光雷达传感器具有重量轻和花费低的特点, 基于固态激光雷达的三维重建方法获得了广泛关注[15~17], 例如, Xu等人[16]提出了基于线特征和面特征提取的Fast-LIO方法[15]和不进行特征提取的Fast-LIO2方法, 该方法结合固态激光雷达和惯性测量单元(inertial measurement unit, IMU)传感器, 通过卡尔曼滤波方法融合激光数据特征和IMU数据特征, 实现了实时三维场景重建. 虽然这些方法取得了巨大的进步, 但是现有的固态激光雷达和IMU数据融合的三维重建方法在穿戴式激光头盔传感器上使用仍然存在一些问题[10]. 主要问题总结如下.

(1) 激光头盔工作过程中快速转弯导致单帧点云运动畸变大: 由于单帧固态激光雷达点云数据中的每个点是分时采集的, 数据采集的同时激光头盔传感器发生运动或者快速转弯, 会导致单帧点云数据产生运动畸变.

(2) 传感器工作过程中剧烈抖动导致特征匹配鲁棒性低: 由于固态激光雷达数据配准一般采用点到平面的距离构建误差模型, 对于树林等非结构区域场景, 局部平面的不准确判别将降低系统轨迹估计和三维重建精度.

为了解决这些挑战, 本文提出一种基于穿戴式激光头盔的固态激光雷达-惯导三维重建方法, 提高传感器轨迹估计和三维重建精度. 具体而言, 首先, 本文提出一种基于中间参考点的点云运动畸变补偿方法, 通过将单帧点云向中间时刻位置投影, 降低IMU数据累积误差的影响, 减少激光头盔快速转弯导致的单帧点云运动畸变; 然后, 本文提出一种基于局部邻域特征一致性判别的误差模型构建方法, 通过对局部平面的一致性进行判别, 提高局部平面构建的鲁棒性, 进而, 实现传感器高精度轨迹估计和三维场景重建; 最后, 对本文提出的方法在公开数据集上进行了实验验证, 通过与已有的代表性方法对比, 验证了本文提出方法的有效性. 此外, 本文设计了穿戴式激光头盔传感器, 通过工作人员头戴传感器采集多种场景数据, 进一步验证了本文提出的方法的先进性. 本文的贡献主要包括以下3个方面.

(1) 提出一种基于中间参考点的点云运动畸变补偿方法, 将单帧点云数据投影到中间时刻位置, 减少IMU轨迹估计累积误差的影响, 提高单帧点云数据的畸变校正精度.

(2) 提出一种基于局部邻域特征一致性判别的误差模型构建方法, 对不同近邻范围的局部平面进行一致性判别, 提高局部平面构建的鲁棒性, 进而, 实现鲁棒的误差模型构建.

(3) 设计一种穿戴式激光头盔传感器, 用于进行实时三维场景重建, 验证提出方法的有效性; 同时, 采用WHU-Helmet数据集对本文提出的方法和现有的最先进方法进行实验对比与分析, 结果表明, 本文提出的方法在大多数指标上均取得最优结果.

2 相关工作

2.1 三维场景点云获取传感器

三维场景点云获取传感器在无人驾驶、资源勘探等领域具有重要的作用[18~21], 根据搭载平台不同, 可以分为机载、车载和穿戴式传感器等. 其中, 如图1(a)所示, 车载传感器是将传感器安装在车辆移动平台上[22~26], 例如, 美国卡耐基梅隆大学通过车载视觉传感器和惯性测量传感器进行轨迹估计, 并结合三维点云配准等方法进行三维场景重建[8]; 美国斯蒂文斯理工学院Shan等人[7]通过无人车上的激光雷达数据对地面场景和树林场景进行语义分割, 提高了复杂森林场景三维重建精度. 图1(b)是机载三维点云获取传感器, 该传感器通过无人机搭载传感器进行三维场景重建[5,6,27,28], 例如, 香港科技大学融合无人机平台视觉数据和惯性测量数据, 实现校园场景三维重建[5]; 美国卡耐基梅隆大学采用激光数据增强传统Structure from Motion方法的特征匹配精度, 提高了机载传感器在近距离三维场景重建精度[6]. 图1(c)是穿戴式三维场景点云数据获取方式, 该方法通过将传感器穿戴在工作人员身上, 实现场景三维重建[29~33], 例如, 厦门大学Wang等人[9]通过融合背包传感器采集的激光雷达、惯导和卫星定位等数据, 实现不同场景大规模移动点云扫描; 武汉大学Yang等人[10]采用激光头盔传感器录制了森林、山区、建筑物、地下隧道等多个场景数据集, 并融合多种传感器数据给出了数据的真实轨迹. 对

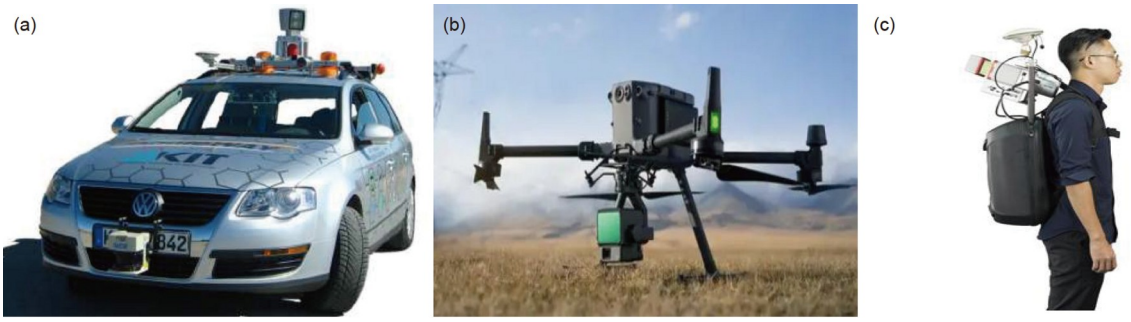


图 1　三维场景点云获取传感器. (a) 车载三维场景点云获取传感器; (b) 机载三维场景点云获取传感器; (c) 穿戴式背包三维场景点云获取传感器

Figure 1　3D scene point cloud acquisition sensor. (a) Vehicle-mounted 3D scene point cloud acquisition sensor; (b) airborne 3D scene point cloud acquisition sensor; (c) wearable backpack 3D scene point cloud acquisition sensor.

于上面三种平台，机载和车载传感器平台存在复杂环境作业困难、复杂环境作业效率低、设备整体体积过大等问题, 限制了这些传感器的使用范围. 穿戴式传感器可以将传感器戴在工作人员身体上，在工作人员可通行区域和GNSS信号缺失的区域，实现三维场景重建. 这种方式能够快速便捷地获取三维场景点云数据. 因此, 设计一种穿戴式三维场景重建传感器, 可以进一步提高三维场景点云获取的效率.

2.2　激光雷达-惯导三维场景重建

激光雷达-惯导三维场景重建主要分为松耦合和紧耦合两种方式[34~38]. 其中，松耦合方式首先对激光数据和IMU测量数据分别进行处理；然后，通过算法对处理后的结果进行融合. 例如，Balazadegan Sarvrood等人[39]提出一种结合视觉-惯导-激光数据的三维重建方法, 该方法通过IMU数据构建重力模型, 提高了视觉-激光三维场景重建的精度. 虽然松耦合方式降低了算法的计算量, 但是, 这种方法忽略了数据之间的相关性. 紧耦合方式对数据间的相关性进行建模, 提高了三维重建算法的精度与鲁棒性[40~42]. 例如, Ye等人[9]提出一种紧耦合的激光-惯导方法, 采用基于旋转矩阵约束的激光-惯导联合优化方法，降低了算法的累计漂移. Shan等人[7]提出紧耦合激光惯导数据融合框架, 构建激光-惯导因子图, 提高了算法的实时性. Xu等人[15]提出一种鲁棒的固态激光雷达-惯导三维重建方法FAST-LIO，采用迭代卡尔曼滤波方法对激光和IMU数据进行联合优化, 提高了三维重建算法的鲁棒性. 为了进一步提高算法的实时性与存储效率, Xu等人[16]提出了FAST-LIO2方法，该方法提出一种直接对点云进行配准的方法和三维场景地图存储数据结构ikd-tree，提高了三维场景地图的存储效率. Gao团队[43]采用一种三维重建方法FASTER-LIO，该方法提出一种ivoxel数据结构存储数据，提高了算法处理速度. Lang等人[44]提出一种连续的紧耦合相机-激光-惯导三维重建方法, 该方法使用非均匀B样条算法动态调整控制点，提高了三维重建的速度和精度.

虽然这些方法能够实现三维场景重建，但是大多数现有的方法主要采用惯导和机械式激光雷达等传感器, 硬件成本高, 采用固态激光雷达可以降低设备的成本[45~49]. 此外，基于穿戴式激光头盔传感器在采集数据过程中存在剧烈抖动和快速转弯等问题，降低了传感器轨迹估计和三维重建结果精度. 因此，本文主要针对基于穿戴式激光头盔的固态激光雷达-惯导三维场景重建算法进行研究.

3　方法

3.1　总体框架

本节给出了基于穿戴式激光头盔的固态激光雷达-惯导三维重建方法. 首先，提出基于中间参考点的点云运动畸变补偿方法，提高单帧点云的畸变校正精度；其次，给出基于局部平面特征一致性判别的误差模型构建方法，提高轨迹估计和三维场景重建精度; 最后，给出基于迭代卡尔曼滤波的三维地图构建方法, 实现大场景高精度三维场景重建.

3.2　基于中间参考点的点云运动畸变补偿方法

激光雷达在进行单帧数据采集的时候，不是同时

采集所有激光点，而是采用了单个点分时采集并按照时间拼接成场景点云的方式. 在激光雷达传感器静止时，这种方式不会产生畸变，如果激光雷达传感器在数据采集过程中发生了运动，单帧激光点云会产生运动畸变，这种现象在传感器快速转弯过程中尤其明显. 为了解决激光数据采集过程中快速转弯导致点云运动畸变大的问题，通过采用IMU数据位置估计方法和单帧激光数据畸变移除方法，减少点云数据获取产生的运动畸变.

3.2.1 IMU数据位置估计

图2展示了IMU位置估计的过程. 为了计算传感器的运动轨迹，本节采用卡尔曼滤波算法计算IMU轨迹. 假设上一次激光扫描结束的状态估计和协方差分别为$\overline{X}_i$和$\overline{P}_i$，当新的一帧IMU数据输入时，状态和协方差预测可以表示为

$$\overline{X}_{i+1} = \overline{X}_i \boxplus (\Delta t f(\overline{X}_i, u_i, 0)), \tag{1}$$

$$\overline{P}_{i+1} = F_{\tilde{x}_i} \overline{P}_i F_{\tilde{x}_i}^{\mathrm{T}} + F_{w_i} Q_i F_{w_i}^{\mathrm{T}}, \tag{2}$$

其中，$\overline{X}_i$和$\overline{X}_{i+1}$表示i和i+1时刻状态变量，u_i表示IMU测量的角速度和加速度数据，$f(\ )$表示单位时间内状态变量的变化量；$\overline{P}_i$和$\overline{P}_{i+1}$表示协方差矩阵；$F_{\tilde{x}_i}$和F_{w_i}分别表示测量模型对误差和噪声的导数；Q_i表示噪声的协方差. 具体参数定义如下:

$$X = [{}^{G}R_I^{\mathrm{T}} \quad {}^{G}P_I^{\mathrm{T}} \quad {}^{G}v_I^{\mathrm{T}} \quad b_\omega^{\mathrm{T}} \quad b_\alpha^{\mathrm{T}} \quad {}^{G}g^{\mathrm{T}} \quad {}^{I}R_L^{\mathrm{T}} \quad {}^{I}P_L^{\mathrm{T}}], \tag{3}$$

$$u = [\omega_m^{\mathrm{T}} \quad \alpha_m^{\mathrm{T}}], \quad w = [n_\omega^{\mathrm{T}} \quad n_\alpha^{\mathrm{T}} \quad n_{b\omega}^{\mathrm{T}} \quad n_{b\alpha}^{\mathrm{T}}], \tag{4}$$

$$f(x,u,w) = \begin{bmatrix} \omega_m - b_\omega - n_\omega \\ {}^{G}v_I + \left({}^{G}R_I(\alpha_m - b_\alpha - n_\alpha) + {}^{G}g\right)\Delta t \\ {}^{G}R_I(\alpha_m - b_\alpha - n_\alpha) + {}^{G}g \\ n_{b\omega} \\ n_{b\alpha} \\ 0_{3\times1} \\ 0_{3\times1} \\ 0_{3\times1} \end{bmatrix}. \tag{5}$$

式(3)表示IMU的状态变量，${}^{G}R_I^{\mathrm{T}}$和${}^{G}P_I^{\mathrm{T}}$分别表示传感器在全局坐标系下的旋转矩阵和位移矩阵；${}^{G}v_I^{\mathrm{T}}$表示速度；b_ω^{T}和b_α^{T}分别表示IMU测量的加速度偏差和角速度偏差；${}^{G}g^{\mathrm{T}}$表示重力加速度；${}^{I}R_L^{\mathrm{T}}$和${}^{I}P_L^{\mathrm{T}}$表示固态激光雷达相对于IMU的外参矩阵；$\omega_m{}^{\mathrm{T}}$和$\alpha_m{}^{\mathrm{T}}$表示IMU测量的加速度和角速度，w表示噪声.

IMU数据位置估计的结果不仅可以用于单帧点云

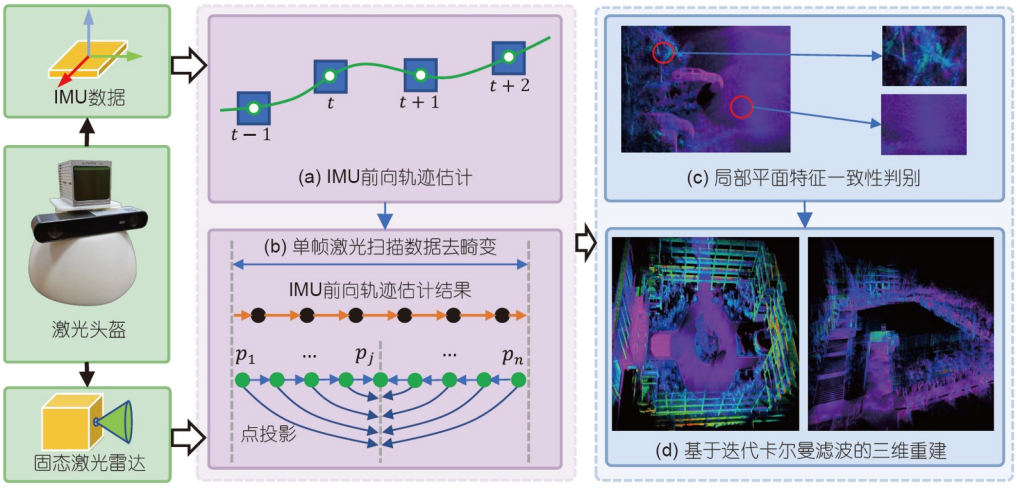


图 2 基于穿戴式激光头盔的固态激光雷达-惯导三维重建方法整体框架. (a) IMU前向轨迹估计; (b) 单帧激光扫描数据去畸变; (c) 局部平面特征一致性判别; (d) 基于迭代卡尔曼滤波的三维重建

Figure 2 Overall framework of solid LIDAR-Inertial 3D reconstruction method based on the wearable laser helmet. (a) IMU forward propagation; (b) de-distortion of single laser scanning data; (c) discrimination of consistency of local planar features; (d) 3D reconstruction based on iterative Kalman filtering.

畸变校正, 还可以作为三维重建过程中的先验信息, 利用IMU数据的优势提高三维地图重建的精度. IMU先验信息约束如下:

$$R_{\mathrm{IMU}} = X_k \boxminus \overline{X}_k = (\overline{X}_k^h \boxplus \tilde{X}_k^h)\overline{X}_k = \overline{X}_k^h \boxminus \overline{X}_k + J^h \tilde{X}_k^h, \quad (6)$$

其中, k表示第k次激光扫描数据; h表示对第k次激光扫描数据的第h次状态参数更新; X_k表示k时刻的真实值, 可以由k时刻第h次的迭代更新值$\overline{X}_k^h$加上第h次的误差$\tilde{X}_k^h$得到; $\overline{X}_k$表示k时刻IMU数据位置估计结果; J^h表示参数在第h次迭代时对误差$\tilde{X}_k^h$的偏导.

3.2.2　单帧激光数据畸变移除

为了降低单帧点云的运动畸变, 通过采用IMU估计的轨迹来对点云的运动畸变进行补偿. 针对这个问题, 现有的方法是将所有的三维点投影到单帧点云的末端位置, 这种方法忽略了IMU轨迹累积误差的影响. 如图2(b)所示, 本节将三维点投影到单帧点云采集的中间时刻, 以降低IMU轨迹累积误差对点云畸变的影响.

运动畸变校正主要分为三部分: 首先, 将单帧点云按照采集时间分成两部分, 初始时刻、中间时刻和末端时刻分别表示为t_{start}, t_{mid}和t_{end}, 对于采集时间在(t_{start}, t_{mid})和(t_{mid}, t_{end})时间范围内的特征点${}^{L}p_{f_i}$, 采用固态激光雷达和IMU的外参矩阵${}^{I}T_L$将点${}^{L}p_{f_i}$转到IMU参考坐标系; 然后, 用矩阵T_{e_i}移除点云的运动畸变; 最后, 采用当前时刻到t_{mid}时刻的转换矩阵${}^{I_{\mathrm{mid}}}T_{I_i}$将激光点转换到$t_{\mathrm{mid}}$时刻, 并采用固态激光雷达和IMU的外参矩阵${}^{I}T_L$将点${}^{L}p_{f_i}$转到激光雷达参考坐标系, 公式表示如下:

$${}^{L_{\mathrm{mid}}}p_{f_i} = {}^{I}T_L^{-1}\,{}^{I_{\mathrm{mid}}}T_{I_i}T_{e_i}\,{}^{I}T_L\,{}^{L}p_{f_i}, \quad (7)$$

其中, ${}^{L}p_i$表示当前帧第i个特征点; L表示激光雷达坐标系; I表示IMU坐标系. 畸变移除矩阵表示如下:

$$T_{e_i} = [R_{e_i} \quad t_{e_i}], \quad (8)$$

$$R_{e_i} = R_{\mathrm{mid}}^{-1} R_i \mathrm{e}^{(\omega_i, \mathrm{d}t)}, \quad (9)$$

$$t_{e_i} = P_i + v_i \mathrm{d}t + 0.5\alpha_i \mathrm{d}t^2 - P_{\mathrm{mid}}. \quad (10)$$

式(8)表示畸变移除矩阵, 包括旋转矩R_{e_i}和平移矩阵t_{e_i}两部分, 定义见式(9)和(10); R_{mid}和P_{mid}分别表示在t时刻IMU积分得到的旋转矩阵和平移矩阵; P_i, R_i, v_i, α_i和ω_i分别表示IMU在t_i时刻的位置、旋转、速度、加速度和角速度; $\mathrm{d}t$表示当前激光点和最近IMU时间戳的差值. 对于当前帧的每一个激光特征点, 采用式(7)进行去畸变处理, 可以提高当前帧点云数据的精度.

3.3　基于局部邻域特征一致性判别的误差模型构建方法

为了提高穿戴式激光头盔传感器轨迹估计和三维重建的精度, 通过构建基于局部邻域特征一致性判别模型, 降低点云配准的误差. 图2(c)展示了地面区域和树林区域的点云结构, 对于地面区域, 在已经构建完成的全局地图中寻找当前帧特征点的k_1邻域和k_2邻域, 其中$k_2-k_1>10$, 两个邻域点集合计算的法线方向是一致的, 或者存在一个小角度偏差; 对于树林区域, 在已经构建完成的全局地图中寻找当前帧特征点的k_1邻域和k_2邻域, 由于树林区域构建的三维点云是非结构区域, 两个邻域点集合估计的法线方向, 通常会存在比较大的偏差. 基于这个假设, 本节提出基于局部邻域特征一致性判别的误差模型构建方法.

首先, 本节采用k近邻算法提取当前特征点在地图中的k_1邻域和k_2邻域, 得到两个数量为m_1和m_2的点集; 然后, 采用奇异值分解方法对两个点集进行三维平面拟合, 得到平面的法线方向n_1和n_2, 以及点集的中心点q_1和q_2; 最后, 基于平面的法线方向n_1和n_2, 计算两个法线方向的夹角θ. 公式表示如下:

$$\theta = \arccos\left(\frac{n_1 . n_2}{|n_1 \| n_2|}\right). \quad (11)$$

基于两个局部平面方向的夹角, 估计每个特征点测量模型的权重系数, 对于位于地面等结构性区域的点, 赋予较高的权重; 对于位于树林等非结构性区域的点, 赋予较低的权重, 权重构建方式如下:

$$w = (1 + \cos(\theta))^2. \quad (12)$$

为了对状态参数进行优化, 需要构建激光特征点测量误差模型E_j. 本节假设当前扫描帧的激光特征点${}^{L}p_j$经过投影后位于全局地图的一个局部平面上, 公式表示如下:

$$E_j(X_k, {}^{L}n_j) = {}^{G}u_j^{\mathrm{T}}({}^{G}T_{I_k}^{I}T_L({}^{L}p_j + {}^{L}n_j) - {}^{G}q_j), \quad (13)$$

其中, ${}^{G}u_j$和${}^{G}q_j$分别表示全局地图中局部平面的法线方向和中心点; ${}^{L}p_j$表示当前帧第j个激光特征点; ${}^{L}n_j$表示噪声; ${}^{G}T_{I_k}$表示k时刻相对于全局坐标系的转换矩阵. 式(13)表示当前帧的激光特征点经过转换矩阵转到全局坐标系下, 并与全局地图局部平面中心点构成连线, 和局部平面的法线方向正交.

为了便于计算, 对式(13)进行一阶泰勒展开, 将原公式对状态变量的直接估计转为对状态变量误差的估计:

$$E_j(X_k, {}^{L}n_j) \approx E_j(\overline{X}_k^h, 0) + F_j^h \widetilde{X}_k^h, \tag{14}$$

其中, F_j^h表示测量模型对误差$\widetilde{X}_k^h$的偏导; $E_j(X_k, 0)$表示没有噪声干扰的测量模型; 基于式(12)和(14), 激光特征点测量误差模型可以表示为

$$R_L \approx \sum_{j=1}^{m} w \left\| E_j\left(\overline{X}_k^h, 0\right) + F_j^h \widetilde{X}_k^h \right\|. \tag{15}$$

结合式(6)和(15), 可以得到最大似然估计模型:

$$\min_{\widetilde{X}_k^h}\left(\| R_{\text{IMU}} \|^2 + R_L \right). \tag{16}$$

3.4 基于迭代卡尔曼滤波的三维重建方法

为了求解式(16), 本节采用迭代卡尔曼滤波方法进行状态变量估计, 卡尔曼滤波增益K和状态变量更新表示如下:

$$K = PH^{\mathrm{T}}(HPH^{\mathrm{T}} + R)^{-1}, \tag{17}$$

$$\begin{aligned} \overline{X}_k^{h+1} = \overline{X}_k^h \boxplus \Big(& -KE_j\left(\overline{X}_k^h, 0\right) \\ & -(I - KH)(J^h)^{-1}\left(\overline{X}_k^h \boxminus \overline{X}_k\right)\Big), \end{aligned} \tag{18}$$

其中, H表示测量模型对误差$\widetilde{X}_k^h$的偏导; R表示测量误差的协方差矩阵; P为先验的协方差矩阵. 在式(17)中, 为了更新卡尔曼增益K, 需要求解$(HPH^{\mathrm{T}}+R)$的逆矩阵, 由于$(HPH^{\mathrm{T}}+R)$矩阵的维度和测量数据的维度一致, 测量数据的维度很大, 因此, 求解矩阵$(HPH^{\mathrm{T}}+R)$的逆矩阵计算量很大. 为了降低计算量, 卡尔曼增益K可以表示为式(19), 式(19)中逆矩阵$(H^{\mathrm{T}}R^{-1}H+P^{-1})^{-1}$维度为状态变量的维度, 降低了算法的计算量.

$$K = (H^{\mathrm{T}}R^{-1}H + P^{-1})^{-1}H^{\mathrm{T}}R^{-1}. \tag{19}$$

基于Xu等人[15,16]的工作, 给出式(17)和(19)等价的理论分析: 基于矩阵求逆公式, 将矩阵$(H^{\mathrm{T}}R^{-1}H+P^{-1})^{-1}$展开得到式(20).

$$(H^{\mathrm{T}}R^{-1}H + P^{-1})^{-1} = P - PH^{\mathrm{T}}(HPH^{\mathrm{T}} + R)^{-1}HP. \tag{20}$$

将式(20)代入式(19), 可得

$$\begin{aligned} K &= (H^{\mathrm{T}}R^{-1}H + P^{-1})^{-1}H^{\mathrm{T}}R^{-1} \\ &= PH^{\mathrm{T}}R^{-1} - PH^{\mathrm{T}}(HPH^{\mathrm{T}} + R)^{-1}HPH^{\mathrm{T}}R^{-1}. \end{aligned} \tag{21}$$

将矩阵$HPH^{\mathrm{T}}R^{-1}$表示为$(HPH^{\mathrm{T}}+R)R^{-1}-I$, 代入式(21), 可以得

$$\begin{aligned} K &= PH^{\mathrm{T}}R^{-1} - PH^{\mathrm{T}}(HPH^{\mathrm{T}} + R)^{-1}HPH^{\mathrm{T}}R^{-1} \\ &= PH^{\mathrm{T}}R^{-1} - PH^{\mathrm{T}}R^{-1} + PH^{\mathrm{T}}(HPH^{\mathrm{T}} + R)^{-1} \\ &= PH^{\mathrm{T}}(HPH^{\mathrm{T}} + R)^{-1}. \end{aligned} \tag{22}$$

式(20)~(22)证明了式(17)和(19)等价性. 上述过程不断重复直到收敛, 误差函数收敛后, 得到最优状态估计$\overline{X}_k$和协方差$\overline{P}_k$如下:

$$\overline{X}_k = \overline{X}_k^{h+1}, \quad \overline{P}_k = (1 - KH)P. \tag{23}$$

基于迭代卡尔曼滤波估计的最优状态变量, 可以得到每个时刻激光点的全局位置, 结合位置和对应的点云信息, 可以将当前帧激光雷达点云转换到全局坐标系下, 公式表示为

$${}^{G}p_j = {}^{G}T_{I_k}\,{}^{I}T_{L_k}\,{}^{L}p_j. \tag{24}$$

通过式(24), 可以将当前帧的激光扫描点云转换到全局坐标系中, 并将当前扫描的三维场景点添加到地图中, 实现穿戴式激光头盔大场景三维重建. 具体方法如算法1所示.

4 实验

为了验证本文提出算法的有效性, 本节首先在公开数据集上对算法进行验证, 通过与代表性的方法进行对比, 验证提出算法的有效性; 然后, 为了进一步验证算法在实际场景的性能, 本节设计了一种基于穿戴式激光头盔的固态激光雷达-惯导三维重建传感器, 通过对真实环境进行三维重建, 验证本文提出算法在实际场景的有效性.

算法1 基于穿戴式激光头盔的固态激光雷达-惯导三维重建算法

输入: 上次更新的状态变量$\overline{X}_k$和协方差$\overline{P}_k$, 当前帧激光数据, IMU数据;
1: IMU数据位置估计
2: 单帧激光数据畸变移除
3: h=−1 $\overline{X}_k^h = \overline{X}_k$

主迭代:
4: while(1) do
5: h=h+1;
6: if h < 迭代次数N then
7: 局部邻域特征一致性判别, 计算权重w;
8: 计算测量模型误差: $\| R_{\text{IMU}} \|^2 + R_L$;
9: 采用公式19和18更新参数K和$\overline{X}_k^{h+1}$;
10: else
11: 退出循环;
12: end if
13: end while
14: 得到最优状态估计$\overline{X}_k$和协方差$\overline{P}_k$;
15: 更新地图${}^G p_j$;
输出: 轨迹$\overline{X}_k^{h+1}$和三维重建地图点${}^G p_j$

4.1 实验设置

数据集: 本文采用WHU-Helmet数据集验证提出算法的有效性. WHU-Helmet数据集是通过穿戴式激光头盔采集的数据集, 激光头盔传感器搭载固态激光雷达、IMU、相机和光纤惯导等传感器, 其中, 固态激光雷达采用的是Livox-MID70或者Livox-AVIA. WHU-Helmet数据集是由工作人员头戴传感器进行数据采集, 该数据集包含大量的快速转弯和抖动场景. 数据集主要包括森林场景、校园场景、地下空间场景、马路场景和建筑物等场景, 该数据集结合地理测绘的方法给出了轨迹估计的真实值, 轨迹的距离为355~3000 m.

评价标准: 本文采用SLAM领域普遍使用的评价指标绝对位姿误差APE(absolute pose error), 用于评价整条轨迹的全局一致性. 基于APE计算得到的数据, 可以得到误差最大值(Max)和误差平均值(Mean), 同时可以计算轨迹位置误差的均方根RMSE(root mean squared error), 公式表示如下:

$$\text{RMSE} = \sqrt{\left(\frac{1}{N}\sum_{0<i<N} \text{APE}_i^2\right)}. \tag{25}$$

实验参数设置: 本文在参数设置方面设置了固态激光雷达和IMU的外参, 该参数由WHU-Helmet数据集提供; 设置了基于局部邻域特征一致性判别模型参数: k_1=5, k_2=15; 固态激光雷达数据和IMU数据外部参数设为固定参数.

4.2 对比实验

4.2.1 对比方法

为了验证本文方法的准确性与鲁棒性, 本节将本文提出的方法与代表性的三维重建方法进行综合分析与对比测试, 其中包括Fast-LIO2特征提取方法、Fast-LIO2不进行特征提取方法和Livox-Mapping方法, 下面将分别对其进行介绍.

Fast-LIO2在进行场景重建时, 使用了两种方法: 第一种是对点云数据提取平面点特征和边缘点特征, 在表格里面标记为Fast-LIO2; 第二种是直接对点云进行配准的方法, 将所有点当作特征点, 不需要对激光数据进行特征提取, 在表格里面标记为Fast-LIO2-NO. 在参数优化模块, Fast-LIO2采用卡尔曼滤波方法融合固态激光雷达数据和IMU数据; 在数据存储方面, Fast-LIO2采用ikd-tree数据结构存储场景地图数据.

Livox-Mapping采用了LOAM算法结构, 该方法主要用于解决多线激光雷达的三维重建问题. 在特征提取模块, 提取单帧激光点云数据的平面特征和边缘点特征; 在单帧点云畸变去除模块, 由于没有IMU数据, 采用激光点云估计的轨迹数据对点云进行畸变处理; 在后端优化模块, 构建点到平面和点到线的距离代价函数, 采用最小二乘优化方法进行参数优化.

4.2.2 WHU-Helmet数据集实验对比

本文使用WHU-Helmet数据集进行实验对比, 在5个不同的场景数据上进行实验, 分别是Roadside场景、Mountain场景、Tunnel场景、Infrustracture场景和Heritage场景. 具体而言, Roadside场景包含地面和树林场景, 快速转弯比较多; Mountain场景属于树林场景, 路线呈曲线状, 快速转弯动作比较少; Tunnel场景属于地下隧道场景, 拥有很长的直隧道, 这种场景容易出现特征退化; Infrustracture场景结构信息比较丰富; Heritage场景是重建一个古建筑, 该场景激光雷达距离目标物体比较近, 因此, 算法很容易失败.

表1~3给出了提出方法和代表性方法的实验结果对比. 如表1所示, 在均方根误差(RMSE)指标上, 本文提出的方法在Roadside场景、Mountain场景、Tunnel场景和Heritage场景取得了最好的结果; 如表2所示, 在

表 1 WHU-Helmet数据集不同场景上均方根误差(RMSE)对比实验结果

Table 1 Comparision of different scenarios of WHU-Helmet data set in root mean square error (RMSE)

场景	Fast-LIO2-NO (2022)[16]	Fast-LIO2 (2021)[15]	Livox-Mapping (2020)a)	Ours
Roadside	5.724	5.952	Failed	4.794
Mountain	12.822	15.555	87.628	11.243
Tunnel	4.714	8.935	Failed	3.817
Infrustracture	3.253	2.946	Failed	3.164
Heritage	Failed	Failed	Failed	7.540

a) Livox-Mapping数据来源于https://github.com/PJLab-ADG/Livox-Mapping

表 2 WHU-Helmet数据集不同场景下平均误差(Mean)对比实验结果

Table 2 Comparision of different scenarios of WHU-Helmet data set in mean error

场景	Fast-LIO2-NO (2022)[16]	Fast-LIO2 (2021)[15]	Livox-Mapping (2020)a)	Ours
Roadside	5.253	5.420	Failed	4.293
Mountain	10.429	13.001	85.421	9.760
Tunnel	3.958	7.524	Failed	2.975
Infrustracture	2.956	2.672	Failed	2.878
Heritage	Failed	Failed	Failed	5.786

a) Livox-Mapping数据来源于https://github.com/PJLab-ADG/Livox-Mapping

表 3 WHU-Helmet数据集不同场景下最大误差(Max)对比实验结果

Table 3 Comparision of different scenarios of WHU-Helmet data set in max error

场景	Fast-LIO2-NO (2022)[16]	Fast-LIO2 (2021)[15]	Livox-Mapping (2020)a)	Ours
Roadside	11.981	12.420	Failed	9.350
Mountain	27.576	37.206	114.733	25.450
Tunnel	10.240	23.287	Failed	9.435
Infrustracture	6.807	6.600	Failed	6.694
Heritage	Failed	Failed	Failed	26.596

a) Livox-Mapping数据来源于https://github.com/PJLab-ADG/Livox-Mapping

平均误差指标上, 本文提出的方法在Roadside场景、Mountain场景、Tunnel场景和Heritage场景取得了最好的结果; 如表3所示, 在最大误差指标上, 本文提出的方法在Roadside场景、Mountain场景和Heritage场景取得了最好的结果, 实验结果表明, 本文提出的方法能有效降低单帧点云的运动畸变, 提高固态激光雷达-IMU三维重建轨迹的精度. 此外, 在Tunnel场景中, 由于Tunnel场景是光滑的隧道场景, 属于特征退化场景, 因此, 带特征提取的Fast-LIO2方法结果比不带特征提取的Fast-LIO2-NO方法轨迹估计精度差; 本文提出的基于中间参考点的点云运动畸变补偿方法可以提高Tunnel场景的轨迹估计精度. 然而, 基于局部邻域特征一致性判别的误差模型对 Tunnel场景效果不明显, 主要原因在于Tunnel场景属于平坦光滑的场景, 不同局部邻域法线方向差异性不大.

在Heritage场景中, Fast-LIO2-NO, Fast-LIO2和Livox-Mapping方法均出现失败, 本文提出的方法能对这个场景进行重建, 实验结果如图3所示. 图3(a)是采用Fast-LIO2-NO重建方法的结果, 从实验结果可以看出, 重建的地形存在很大的变形, 难以分辨出建筑物的形状; 图3(b)是采用Fast-LIO2重建方法的结果, 从实验结果可以看出, 由于这个场景传感器距离建筑物比较近,

算法重建失败; 图3(c)是采用Livox-Mapping重建方法的结果, 从实验结果可以看出, 重建的地形同样难以分辨出建筑物的形状; 图3(d)是本文提出方法的重建结果, 重建的结果可以明显看出工作人员行走的路径近似矩形形状. 以上实验表明, 本文提出的方法, 通过降低单帧点云的运动畸变和提高误差函数的鲁棒性, 改善了固态激光雷达-IMU三维重建算法的结果.

图4和5给出了算法在Roadside场景数据上的运行结果. 图4(a)和5(a)是Fast-LIO2-NO方法估计的结果; 图4(b)和5(b)是Fast-LIO2方法估计的结果; 图4(c)和5(c)是Livox-Mapping方法估计的结果; 图4(d)和5(d)是本文提出方法估计的结果. 从实验结果对比可得, 由于Fast-LIO2-NO和本文提出的方法, 没有进行特征提取, 采用直接法进行计算, 因此, 图4(a)和(d)三维地图重建的细节比图4(b)更丰富. 图4(c)三维重建失败, 该方法只使用了固态激光雷达数据, 系统稳定性差. 实验结果表明, IMU数据能够提高系统的稳定性. 图5(a)~(d)给出了4种方法得出的APE误差, 从图中可以看出, 本文提出的方法获得了最优结果. 此外, 从图5(a)~(d)中可以看出, 在传感器转弯的位置, 轨迹估计的误差比较大, 这说明了传感器剧烈抖动和快速转弯等问题会影响轨迹估计的精度, 进而降低三维重建精度.

4.2.3　传感器采集数据实验对比

为了进一步验证算法在实际场景的有效性, 本文设计了穿戴式激光头盔传感器, 传感器如图6(a)所示, 它包括固态激光雷达、IMU和双目相机等传感器, 本文的实验只使用了固态激光雷达和IMU两种传感器, 其中, 固态激光雷达传感器的型号是Livox-Avia, 最大探测距离450 m, 数据采集频率为10 Hz; IMU传感器的型号为XSENS-300, 可以采集加速度和角速度数据, 采集频率为 200 Hz. 对于传感器数据的采集方式, 如图6(b)所示, 工作人员头戴激光头盔传感器在不同的校园场景采集数据, 主要包括教学楼、马路、图书馆、足球场、树林场景等.

图7给出了穿戴式激光头盔传感器重建复杂校园场景的结果, 这些实验结果都由本文提出的方法得出. 其中, 图7(a)重建的是学校的教学楼内部场景, 图7(b)和(c)重建的是学校的马路场景, 该场景拥有树林和马路; 图7(d)重建的是学校的足球场, 该场景地面比较

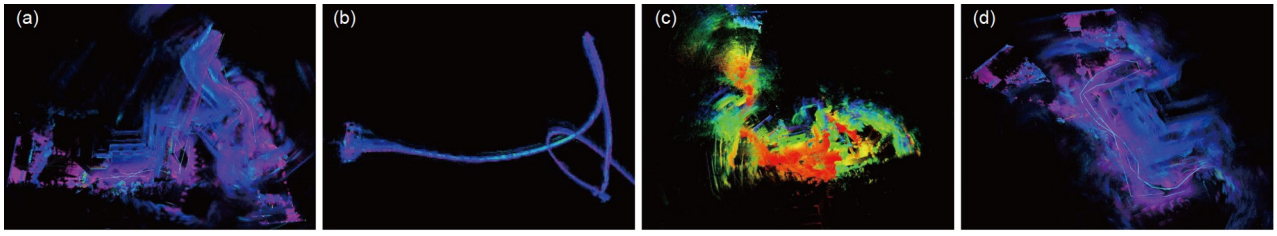


图 3　Heritage场景三维重建结果. (a) Fast-LIO2-NO方法的三维场景重建结果; (b) Fast-LIO2方法的三维场景重建结果; (c) Livox-Mapping方法的三维场景重建结果; (d) 本文提出方法的三维场景重建结果

Figure 3　3D reconstruction results of the Heritage scene. (a) 3D reconstruction result of the Fast-LIO2-NO method with no feature extraction; (b) 3D reconstruction result of the Fast-LIO2 method with featrue extraction; (c) 3D reconstruction result of the Livox-Mapping method; (d) 3D reconstruction result of our proposed method.

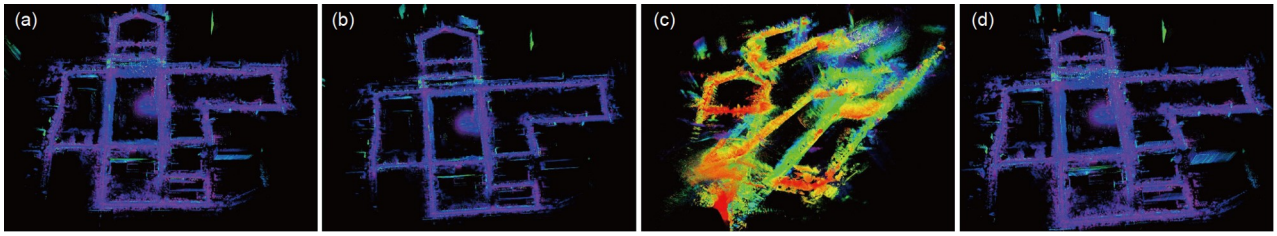


图 4　Roadside场景三维重建结果. (a) Fast-LIO2-NO方法的三维重建结果; (b) Fast-LIO2方法的三维重建结果; (c) Livox-Mapping方法的三维重建结果; (d) 本文提出方法的三维重建结果

Figure 4　3D reconstruction results of the Roadside scene. (a) 3D reconstruction result of the Fast-LIO2-NO method; (b) 3D reconstruction result of the Fast-LIO2 method; (c) 3D reconstruction result of the Livox-Mapping method; (d) 3D reconstruction result of our proposed method.

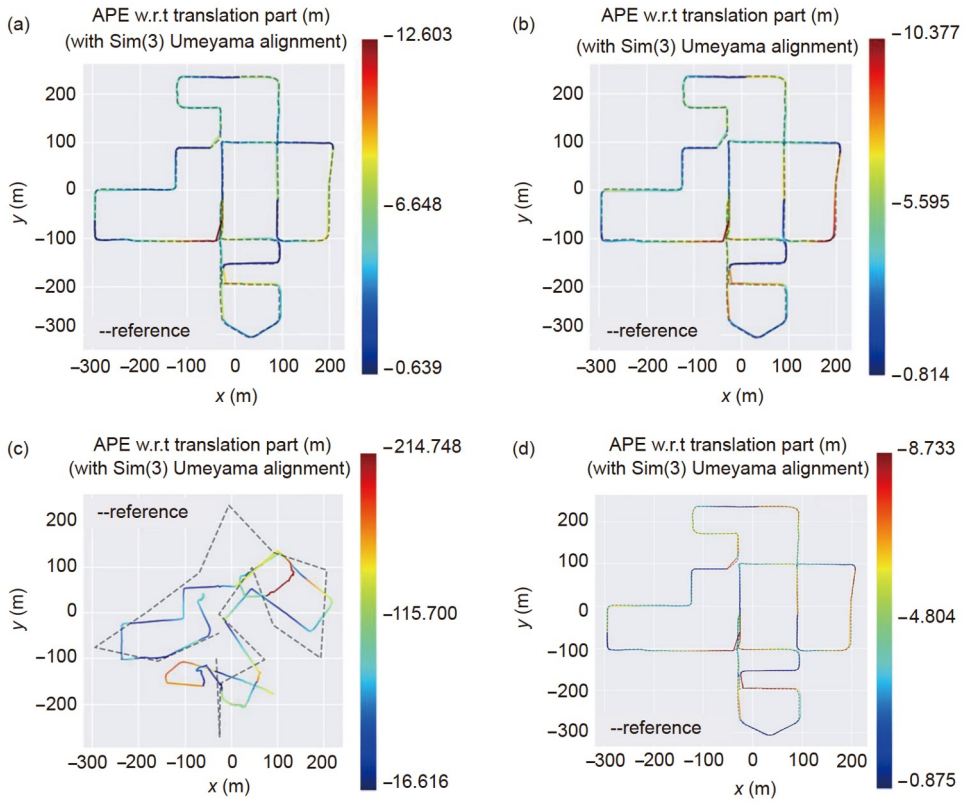


图 5 Roadside场景轨迹估计比较. (a) Fast-LIO2-NO方法的轨迹估计结果; (b) Fast-LIO2方法的轨迹估计结果; (c) Livox-Mapping方法的轨迹估计结果; (d) 本文提出方法的轨迹估计结果

Figure 5 Trajectory estimation comparison in the Roadside scene. (a) Trajectory estimation result of the Fast-LIO2-NO method; (b) trajectory estimation result of the Fast-LIO2 method; (c) trajectory estimation result of the Livox-Mapping method; (d) trajectory estimation result of our proposed method.

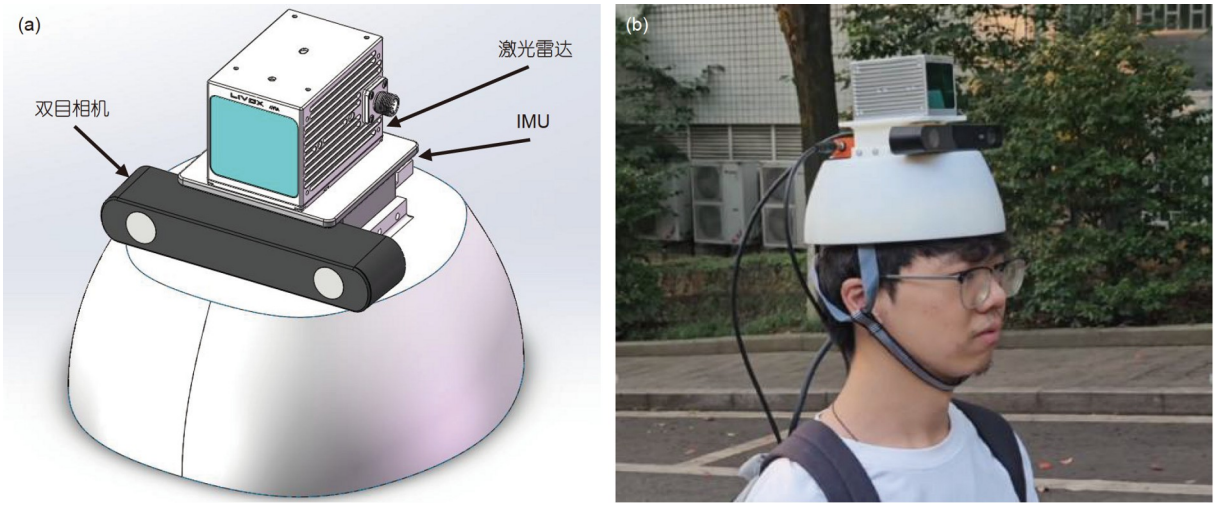


图 6 穿戴式激光头盔传感器与数据采集. (a) 穿戴式激光头盔传感器的传感器分布图; (b) 工作人员头戴激光头盔传感器进行数据采集

Figure 6 Wearable laser helmet sensor and data collection. (a) Sensor structure of the wearable laser helmet sensor; (b) sensor data collection of the laser helmet sensor worn by the staff.

多; 图7(e)和(f)重建学校的树林场景和图书馆场景, 该场景的特点是树木比较多. 通过这些重建结果可以得出, 本文设计的穿戴式激光头盔传感器能够很好地应用于实际场景.

图8展示了穿戴式激光头盔传感器重建结构化阶梯场景的结果. 图8(a)是Fast-LIO2-NO方法的三维场景重建结果, 由于该方法没有进行点云特征提取, 导致三维重建结果存在很大的畸变; 图8(b)是Fast-LIO2方法的三维场景重建结果, 该方法对点云进行平面特征和边缘特征提取, 能够很好地对点云匹配进行约束, 三维重建质量比较好; 图8(c)是Livox-Mapping方法的三维场景重建结果, 由于该方法没有使用IMU数据, 导致该方法在大场景上的重建效果比较差; 图8(d)是本文提出方法的三维重建结果, 该方法和Fast-LIO2-NO方法一样, 没有对点云进行特征提取, 从实验结果可以看出, 本文提出的方法重建的阶梯场景和Fast-LIO2方法接近, 且本文提出的方法场景的细节更丰富. 实验结果表明, 本文提出的方法从单帧数据畸变移除和局部平面一致性判别两个方面出发, 通过去除单帧点云运动畸变和提高误差模型的鲁棒性, 提高固态激光雷达-IMU三维重建算法的重建质量.

5　结论

本文提出一种基于穿戴式激光头盔的固态激光雷达-惯导三维场景重建方法, 通过降低点云运动畸变,

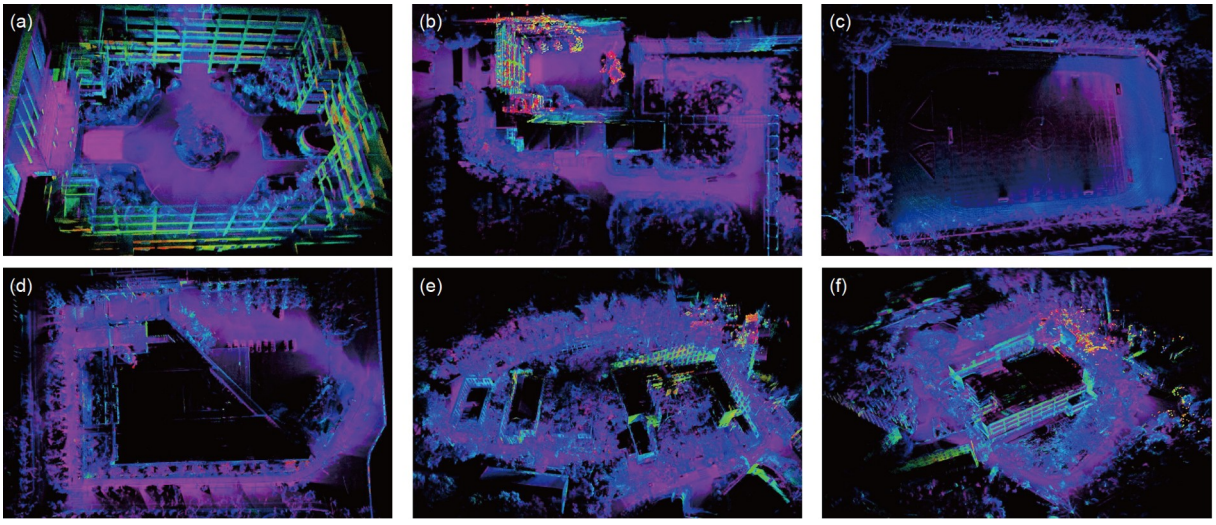


图 7　穿戴式激光头盔传感器三维重建结果图. (a) 穿戴式激光头盔传感器扫描的教学楼内部场景; (b), (c) 穿戴式激光头盔传感器扫描的马路场景; (d) 穿戴式激光头盔传感器扫描的校园足球场景; (e), (f) 穿戴式激光头盔传感器扫描的树林场景

Figure 7　3D reconstruction results of the Roadside scene. (a) Interior scene of the teaching building scanned by the wearable laser helmet sensor; (b), (c) road scene scanned by the wearable laser helmet sensor; (d) football field scanned by the wearable laser helmet sensor; (e), (f) a forest scene scanned by a wearable laser helmet sensor.

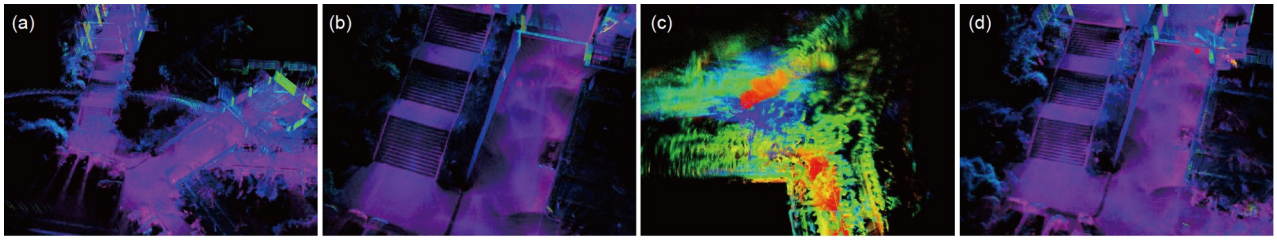


图 8　结构化阶梯场景三维重建结果. (a) Fast-LIO2-NO方法的三维场景重建结果; (b) Fast-LIO2方法的三维场景重建结果; (c) Livox-Mapping方法的三维场景重建结果; (d) 本文提出方法的三维场景重建结果

Figure 8　3D reconstruction results of the structured staircase scene. (a) 3D reconstruction result of the Fast-LIO2-NO method; (b) 3D reconstruction result of the Fast-LIO2 method; (c) 3D reconstruction result of the Livox-Mapping method; (d) 3D reconstruction result of our proposed method.

增加误差模型参数优化的鲁棒性，有效提高了传感器三维场景重建精度. 概括起来，本文首先提出了一种基于中间参考点的点云运动畸变补偿方法，该方法将单帧点云投影到数据的中间参考点，减少IMU累积误差的影响, 提高单帧点云数据的精度; 然后, 本文提出一种基于局部邻域特征一致性判别的误差模型构建方法，该方法将不同稳定程度的局部平面赋予不同的权重系数, 以提高误差模型构建的鲁棒性. 另外, 本文提出的方法在设计的穿戴式激光头盔传感器和公开数据集上进行了验证, 经过大量的对比实验, 充分证明了本文提出方法的有效性和先进性. 在未来的工作中, 计划探索固态激光雷达-惯导三维重建方法在火星复杂场景的应用，以提高火星复杂场景机器人自主探索的能力.

参考文献

1 Shi D X, Tong Z H, Yang S W, et al. Dynamic adaptive simultaneous localization and mapping technique for scene change (in Chinese). Sci Sin Tech, 2018, 48: 1373–1391 [史殿习, 童哲航, 杨绍武, 等. 面向场景变化的动态自适应同时定位与地图构建. 中国科学: 技术科学, 2018, 48: 1373–1391]

2 Lyu Y, Kang T, Pan Q, et al. UAV sense and avoidance: Concepts, technologies, and systems (in Chinese). Sci Sin Inf, 2019, 49: 520–537 [吕洋, 康童娜, 潘泉, 等. 无人机感知与规避: 概念、技术与系统. 中国科学: 信息科学, 2019, 49: 520–537]

3 Chen J, Peng L X, Qiu X L, et al. A 3D building reconstruction method for SAR images based on deep neural network (in Chinese). Sci Sin Inf, 2019, 49: 1606–1625 [陈健, 彭凌霄, 仇晓兰, 等. 基于深度神经网络的SAR建筑目标三维重建方法. 中国科学: 信息科学, 2019, 49: 1606–1625]

4 Liu Y J, Yu M, Ye Z, et al. Path planning for self-reconfigurable modular robots: A survey (in Chinese). Sci Sin Inf, 2018, 48: 143–176 [刘永进, 余婧, 叶子鹏, 等. 自重构模块化机器人路径规划方法综述. 中国科学: 信息科学, 2018, 48: 143–176]

5 Qin T, Li P, Shen S. VINS-Mono: A robust and versatile monocular visual-inertial state estimator. IEEE Trans Robot, 2018, 34: 1004–1020

6 Zhen W, Hu Y, Yu H, et al. LiDAR-enhanced structure-from-motion. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Paris: IEEE, 2020. 6773–6779

7 Shan T, Englot B. LeGO-LOAM: Lightweight and ground-optimized lidar odometry and mapping on variable terrain. In: Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Madrid: IEEE, 2018. 4758–4765

8 Zhang J, Singh S. Laser-visual-inertial odometry and mapping with high robustness and low drift. J Field Robot, 2018, 35: 1242–1264

9 Ye H, Chen Y, Liu M. Tightly coupled 3D lidar inertial odometry and mapping. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Montreal: IEEE, 2019. 3144–3150

10 Li J, Wu W, Yang B, et al. WHU-Helmet: A helmet-based multisensor SLAM dataset for the evaluation of real-time 3-D mapping in large-scale GNSS-denied environments. IEEE Trans Geosci Remote Sens, 2023, 61: 1–16

11 Mur-Artal R, Montiel J M M, Tardos J D. ORB-SLAM: A versatile and accurate monocular SLAM system. IEEE Trans Robot, 2015, 31: 1147–1163

12 Campos C, Elvira R, Rodriguez J J G, et al. ORB-SLAM3: An accurate open-source library for visual, visual-inertial, and multimap SLAM. IEEE Trans Robot, 2021, 37: 1874–1890

13 Hess W, Kohler D, Rapp H, et al. Real-time loop closure in 2D LIDAR SLAM. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Stockholm: IEEE, 2016. 1271–1278

14 Zhang J, Singh S. LOAM: Lidar odometry and mapping in real-time. In: Robotics: Science and Systems. 2014, 2: 1–9

15 Xu W, Zhang F. FAST-LIO: A fast, robust LiDAR-inertial odometry package by tightly-coupled iterated kalman filter. IEEE Robot Autom Lett, 2021, 6: 3317–3324

16 Xu W, Cai Y, He D, et al. FAST-LIO2: Fast direct LiDAR-inertial odometry. IEEE Trans Robot, 2022, 38: 2053–2073

17 Zheng C, Zhu Q, Xu W, et al. FAST-LIVO: Fast and tightly-coupled sparse-direct LiDAR-inertial-visual odometry. In: Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Kyoto: IEEE, 2022. 4003–4009

18 Cong Y, Gu C, Zhang T, et al. Underwater robot sensing technology: A survey. Fundamental Res, 2021, 1: 337–345

19 Gu C, Cong Y, Sun G. Three birds, one stone: Unified laser-based 3-D reconstruction across different media. IEEE Trans Instrum Meas, 2021, 70: 1–12

20 Gu C, Cong Y, Sun G, et al. MedUCC: Medium-driven underwater camera calibration for refractive 3-D reconstruction. IEEE Trans Syst Man Cybern Syst, 2022, 52: 5937–5948

21 Gu C, Cong Y, Sun G. Environment driven underwater camera-IMU calibration for monocular visual-inertial SLAM. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Montreal: IEEE, 2019. 2405–2411

22 Chen L, Li Y, Huang C, et al. Milestones in autonomous driving and intelligent vehicles: Survey of surveys. IEEE Trans Intell Veh, 2022, 8: 1046–1056

23 Wei Y, Zhao L, Zheng W, et al. SurroundOcc: Multi-camera 3D occupancy prediction for autonomous driving. In: Proceedings of the IEEE/CVF International Conference on Computer Vision. Paris: IEEE, 2023. 21729–21740

24 Almalioglu Y, Turan M, Trigoni N, et al. Deep learning-based robust positioning for all-weather autonomous driving. Nat Mach Intell, 2022, 4: 749–760

25 Li Z, Li L, Zhu J. READ: Large-scale neural scene rendering for autonomous driving. AAAI, 2023, 37: 1522–1529

26 Liu Y, Zhu K, Wu G, et al. MV-DeepSDF: Implicit modeling with multi-sweep point clouds for 3D vehicle reconstruction in autonomous driving. In: Proceedings of the IEEE/CVF International Conference on Computer Vision. Paris: IEEE, 2023. 8306–8316

27 Marks E, Magistri F, Stachniss C. Precise 3D reconstruction of plants from UAV imagery combining bundle adjustment and template matching. In: Proceedings of the IEEEInternational Conference on Robotics and Automation (ICRA). Philadelphia: IEEE, 2022. 2259–2265

28 Hardouin G, Moras J, Morbidi F, et al. Next-Best-View planning for surface reconstruction of large-scale 3D environments with multiple UAVs. In: Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Las Vegas: IEEE, 2020. 1567–1574

29 Hyyppä E, Yu X, Kaartinen H, et al. Comparison of backpack, handheld, under-canopy UAV, and above-canopy UAV laser scanning for field reference data collection in boreal forests. Remote Sens, 2020, 12: 3327

30 Gong Z, Li J, Luo Z, et al. Mapping and semantic modeling of underground parking lots using a backpack LiDAR system. IEEE Trans Intell Transp Syst, 2019, 22: 734–746

31 Shamim S, Yasir S M, Ahmed S, et al. Low cost backpack scanning and mapping system for indoor environments. In: Proceedings of the IEEE International Conference on Robotics and Automation in Industry (ICRAI). Rawalpindi: IEEE, 2021. 1–6

32 Wu B, Yang L, Wu Q, et al. A stepwise minimum spanning tree matching method for registering vehicle-borne and backpack LiDAR point clouds. IEEE Trans Geosci Remote Sens, 2022, 60: 1–13

33 Pan D, Shao J, Zhang S, et al. SLAM-based forest plot mapping by integrating IMU and self-calibrated dual 3-D laser scanners. IEEE Trans Geosci Remote Sens, 2023, 61: 1–13

34 Lin J, Zhang F. R^3LIVE: A robust, real-time, RGB-colored, LiDAR-inertial-visual tightly-coupled state estimation and mapping package. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Philadelphia: IEEE, 2022. 10672–10678

35 Shan T, Englot B, Meyers D, et al. LIO-SAM: Tightly-coupled lidar inertial odometry via smoothing and mapping. In: Proceedings of the IEEE/RSJ international conference on intelligent robots and systems (IROS). Las Vegas, 2020. 5135–5142

36 Li L, Kong X, Zhao X, et al. SA-LOAM: Semantic-aided LiDAR SLAM with loop closure. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Xi'an: IEEE, 2021. 7627–7634

37 Lin J, Zhang F. Loam livox: A fast, robust, high-precision LiDAR odometry and mapping package for LiDARs of small FoV. In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Paris: IEEE, 2020. 3126–3131

38 Shan T, Englot B, Ratti C, et al. LVI-SAM: Tightly-coupled lidar-visual-inertial odometry via smoothing and mapping. In: Proceedings of the IEEE international conference on robotics and automation (ICRA). Xi'an, 2021. 5692–5698

39 Balazadegan Sarvrood Y, Hosseinyalamdary S, Gao Y. Visual-LiDAR odometry aided by reduced IMU. Int J Geo-Inf, 2016, 5: 3

40 Huang J, Wen S, Liang W, et al. VWR-SLAM: Tightly coupled SLAM system based on visible light positioning landmark, wheel odometer, and RGB-D camera. IEEE Trans Instrum Meas, 2023, 72: 1–12

41 Wang Z, Zhang L, Shen Y, et al. D-LIOM: Tightly-coupled direct LiDAR-inertial odometry and mapping. IEEE Trans Multimedia, 2023, 25: 3905–3920

42 Shi P, Zhu Z, Sun S, et al. Invariant extended Kalman filtering for tightly coupled LiDAR-inertial odometry and mapping. IEEE ASME Trans Mechatron, 2023, 28: 2213–2224

43 Bai C, Xiao T, Chen Y, et al. Faster-LIO: Lightweight tightly coupled lidar-inertial odometry using parallel sparse incremental voxels. IEEE Robot Autom Lett, 2022, 7: 4861–4868

44 Lang X, Chen C, Tang K, et al. Coco-LIC: Continuous-time tightly-coupled LiDAR-inertial-camera odometry using non-uniform b-spline. IEEE Robot Autom Lett, 2023, 8: 7074–7081

45 Wang H, Wang C, Xie L. Lightweight 3-D localization and mapping for solid-state LiDAR. IEEE Robot Autom Lett, 2021, 6: 1801–1807

46 Xu J, Li R, Huang S, et al. R^2DIO: A robust and real-time depth-inertial odometry leveraging multimodal constraints for challenging environments. IEEE Trans Instrum Meas, 2023, 72: 1–11

47 Liu H, Liu R, Yang K, et al. HIDA: Towards holistic indoor understanding for the visually impaired via semantic instance segmentation with a wearable solid-state LiDAR sensor. In: Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2021. 1780–1790

48 Zhang Y, Tosi F, Mattoccia S, et al. GO-SLAM: Global optimization for consistent 3D instant reconstruction. In: Proceedings of the IEEE the IEEE/CVF International Conference on Computer Vision. Paris: IEEE, 2023. 3727–3737

49 Ebadi K, Bernreiter L, Biggie H, et al. Present and future of SLAM in extreme environments: The DARPA SubT challenge. IEEE Trans Robot, 2024, 40: 936–959

A solid-state lidar-inertial 3D scene reconstruction method based on wearable laser helmet

GU ChangJun[1], LENG JiaXu[2], XU ZongYi[2] & GAO XinBo[2]

[1] *School of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;*
[2] *School of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China*

3D reconstruction is widely used in autonomous driving, resource exploration, etc. Wearable laser helmet sensor can achieve high-precision 3D reconstruction performance in areas without GNSS signals or limited access, due to its low-cost and miniaturized. However, during the data collection process, the wearable laser helmet sensor is prone to problems, such as severe jitter and rapid turns, which reduce the accuracy of trajectory estimation and 3D reconstruction results. To address these challenges, we first develop a point cloud motion compensation method based on intermediate reference points, which can reduce the motion distortion of point cloud data. Then, to improve the robustness, we propose an error model construction method based on local neighborhood feature consistency discrimination, which further improve the accuracy of sensor trajectory estimation and 3D reconstruction. Finally, we conducte a comprehensive comparative analysis of the method with the representative methods in public data sets, and designe a wearable laser helmet sensor to validate the effectiveness of the proposed method. Experimental results show that the proposed method achieves the best trajectory estimation and 3D reconstruction performance.

wearable sensor, laser helmet, environment perception, 3D reconstruction, parameter optimization

doi: 10.1360/SST-2023-0362