

# 控制与决策

Control and Decision

## 一种退化环境下多传感器融合的SLAM算法

彭雯宇, 齐咏生, 刘利强, 苏建强, 张丽杰

引用本文:

彭雯宇, 齐咏生, 刘利强, 等. 一种退化环境下多传感器融合的SLAM算法[J]. *控制与决策*, 2026, 41(5): 1348-1358.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0527>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 天临空协同对地观测任务规划模型与并行竞争模因算法

Planning model and parallel competing memetic algorithm for space–near space–air based cooperative earth observation missions

*控制与决策*. 2021, 36(3): 523–533 <https://doi.org/10.13195/j.kzyjc.2020.0732>

#### 尺度自适应的多特征融合相关滤波目标跟踪算法

Scale adaptation and multi–feature fusion correlation filtering object tracking algorithm

*控制与决策*. 2021, 36(2): 429–435 <https://doi.org/10.13195/j.kzyjc.2019.0445>

#### 一种自适应拟牛顿–状态转移混合智能优化算法及应用

A hybrid state transition optimization algorithm based on adaptive quasinewton method and its application

*控制与决策*. 2021, 36(10): 2451–2458 <https://doi.org/10.13195/j.kzyjc.2020.0214>

#### 有向切换拓扑条件下多航天器分组姿态协同控制

Group attitude coordinated control of multi–spacecraft with directed switching topologies

*控制与决策*. 2021, 36(10): 2389–2398 <https://doi.org/10.13195/j.kzyjc.2020.0311>

#### 基于协同聚类和权重注意力稀疏自编码网络的变化检测方法

Change detection approach based on cooperative clustering and weighted attention sparse autoencoder

*控制与决策*. 2021, 36(10): 2442–2450 <https://doi.org/10.13195/j.kzyjc.2019.1633>

# 一种退化环境下多传感器融合的 SLAM 算法

彭雯宇<sup>1,2</sup>, 齐咏生<sup>1,2†</sup>, 刘利强<sup>1,2</sup>, 苏建强<sup>1,2</sup>, 张丽杰<sup>1,2</sup>

(1. 内蒙古工业大学 电力学院, 呼和浩特 010080; 2. 大规模储能技术教育部研究中心, 呼和浩特 010080)

**摘要:** 针对单一传感器同步定位与地图构建 (SLAM) 技术在退化环境下定位精度低、地图漂移和可靠性差等问题, 提出一种基于 R3LIVE 框架改进的多传感器融合的 SLAM 算法 RMF-SLAM(refined multi-modal fusion SLAM)。首先, 设计一种随机过程增强的运动学模型, 将 IMU 测量作为输出建模, 即使在 IMU 测量运动饱和的情况下, 所提出算法也能对激烈运动进行精确定位和可靠映射; 其次, 构建一种基于 Hessian 矩阵特征值退化判别的 LiDAR 和视觉退化感知模块, 通过实时评估系统状态和传感器可靠性来动态调整不同传感器信息权重比例和筛选高价值视觉观测帧, 在视觉和 LiDAR 均极度退化时, 系统沉睡当前地图, 防止定位失败, 当传感器再次正常工作时重新激活沉睡地图; 最后, 提出一种采用全局描述符对地图进行相似性检测的方法, 将相应的睡眠地图集成到当前活跃地图中, 从而在系统运行完成后形成高度精确的全局地图。通过在公开数据集与经典的 SLAM 算法进行对比, 并在私有数据集及真实场景中验证算法能有效抑制退化环境对轨迹估计和地图构建的负面影响, 提升算法的精度和可靠性。

**关键词:** 同步定位与地图构建; 多传感器融合; 退化判别; 沉睡地图; 退化环境; 真实场景

**中图分类号:** TP394.41 **文献标志码:** A

**DOI:** 10.13195/j.kzyjc.2025.0527

**引用格式:** 彭雯宇, 齐咏生, 刘利强, 等. 一种退化环境下多传感器融合的 SLAM 算法 [J]. 控制与决策, 2026, 41(5): 1348-1358.

## A SLAM algorithm for multi-sensor fusion in designed environments

PENG Wen-yu<sup>1,2</sup>, QI Yong-sheng<sup>1,2†</sup>, LIU Li-qiang<sup>1,2</sup>, SU Jian-qiang<sup>1,2</sup>, ZHANG Li-jie<sup>1,2</sup>

(1. School of Electric Power, Inner Mongolia University of Technology, Hohhot 010080, China; 2. Research Center for Large-scale Energy Storage Technology of Ministry of Education, Hohhot 010080, China)

**Abstract:** Aiming at the problems such as low positioning accuracy, map drift and poor reliability of single-sensor simultaneous localization and mapping (SLAM) technology in designed environments, this paper proposes a refined multi-sensor fusion SLAM (RMF-SLAM) algorithm based on the R3LIVE framework. Firstly, a kinematic model enhanced by stochastic processes is designed, and the IMU measurement is modeled as the output. This method can accurately locate and reliably map the intense motion even when the IMU measurement motion is saturated. Secondly, a LiDAR and visual degradation perception module based on the discrimination of eigenvalue degradation of the Hessian matrix is constructed. This module dynamically adjusts the weight ratio of different sensor information and screens high-value visual observation frames by evaluating the system status and sensor reliability in real time. When both vision and LiDAR are extremely degraded, the system slumps the current map preventing positioning failure, and reactivates the dormant map when the sensor works normally again. Finally, a method for similar detection of the map using global descriptors is proposed, integrating the corresponding sleeping map into the current active map, thereby forming a highly accurate global map after the system operation is completed. By comparing with the classic SLAM algorithm on the public dataset, and verifying in the private dataset and real scenarios, the proposed algorithm can effectively suppress the negative impact of the degraded environment on trajectory estimation and map construction, and its accuracy and reliability are superior.

**Keywords:** simultaneous localization and mapping; multi-sensor fusion; degradation discrimination; sleeping map; degraded environments; real-world scenarios

收稿日期: 2025-05-21; 录用日期: 2025-11-12.

基金项目: 国家自然科学基金项目 (62363029); 内蒙古科技计划项目 (2021GG0256); 内蒙古自然科学基金项目 (2022MS06018); 高校院所协同创新项目 (XTCX2023-16, 2023RC-联合体-10).

责任编辑: 张雪波.

†通信作者. E-mail: qys@imut.edu.cn.

## 0 引言

同步定位与地图构建 (SLAM) 作为实现自主导航和环境理解的关键技术<sup>[1]</sup>, 一直是智能机器人<sup>[2]</sup>、自动驾驶<sup>[3]</sup>、增强现实<sup>[4]</sup>等领域的研究热点. 传统单一的传感器 SLAM 技术, 如视觉 SLAM<sup>[5]</sup> 和 LiDAR SLAM<sup>[6-7]</sup>, 在理想条件下可达到较高精度, 但在现实复杂退化环境中却常常面临诸多挑战. 退化环境是指一种或多种传感器的有效信息量显著下降, 导致观测矩阵秩降低、系统状态估计约束不足的场景. 典型退化类型与示例有视觉退化: 低纹理 (纯色墙面、长走廊)、低光照 (夜间、地下室)、强反射/眩光 (玻璃幕墙、阳光直射) 和 LiDAR 退化: 点云稀疏 (远距离开阔场)、重复结构 (隧道、管道)、回波信号衰减 (雨雾、强阳光干扰). 由于传感器退化导致多自由度退化, 部分方向信息严重不足, 如在长走廊中横向约束充分但纵向约束缺失, 或在空旷场中多方向同时退化, 需要其他未退化的传感器及其算法去约束退化, 完成地图构建. 视觉 SLAM 对光照变化高度敏感, 在强光、暗光或纹理稀疏的场景下容易出现特征匹配<sup>[8]</sup>失败, 导致系统漂移甚至定位丢失. LiDAR SLAM 虽然具备较强的几何结构<sup>[9]</sup>感知能力, 但在结构单一或空旷场景中, 容易遭遇退化现象, 严重影响稳定性.

为应对这些挑战, 近年来多传感器融合<sup>[10]</sup>成为 SLAM 研究的重要方向. 多传感器集成的策略能够发挥各自传感器的优势, 极大提高 SLAM 算法在面对复杂情境的鲁棒性和定位精度, 特别是在单一传感器可能受限<sup>[11]</sup>或提供的信息不全时. 在双传感器融合<sup>[12-13]</sup>的众多方案中, FAST-LIO2<sup>[14]</sup>作为 LiDAR-IMU 融合系统的典型代表, 虽然在动态场景适应方面表现出色, 但在一些激光雷达回波信号受干扰严重的场景中仍存在挑战, 导致 LiDAR 数据质量下降, 使算法的定位精度和稳定性受到影响. ORB-SLAM 系列<sup>[15-16]</sup>则是视觉惯性 SLAM 系统的典范之作, 但是系统在动态环境中容易建图失败且计算复杂度较高, 而且在处理高分辨率图像或大规模场景时, 需要消耗大量的计算资源和时间, 可能导致定位误差增大甚至定位失败. 进一步拓展到多传感器融合层面, 将 LiDAR、视觉传感器和 IMU 多种传感器的数据相结合, 使用其他传感器去约束发生退化的传感器, 可实现退化场景<sup>[17]</sup>下各传感器优势互补, 从而全方位提升系统性能. 以 R2LIVE<sup>[18]</sup>为例, 在激光雷达退化时依赖视觉特征点进行位姿优化, 避免纯激光匹配失败. R3LIVE<sup>[19]</sup>则另辟蹊径, 在精简计算路径的同时, 通过显色机制优化可视化效果, 并舍弃图优化

但保留激光雷达的直接配准, 在视觉失效时仍能维持基础定位. LVI-SAM<sup>[20]</sup>则通过级联的视觉惯性和激光惯性子系统实现多模态传感器的深度耦合视觉特征的 BA 优化与基于激光雷达的 ICP 配准相互校正机制. FAST-LIVO<sup>[21]</sup>与 FAST-LIVO2<sup>[22]</sup>同样表现出色, 它们巧妙集成视觉信息, 在帧间匹配时联合优化多源数据, 提升退化场景下的稳定性. 这些先进的融合技术和算法不断推动着 SLAM 技术在各种退化环境下的应用与发展. 尽管如此, 在真实退化环境中, 经常会出现多种传感器同时退化的情况, 比如在强暗光环境下纹理缺失的长走廊, 强暗光环境下的空旷校园场景等. 这些场景经常会导致严重的漂移问题, 本文将其归类为过度退化<sup>[23]</sup>的情况. 现有的基于多传感器融合的 SLAM 对于过度退化的场景并没有简单的解决方案.

针对上述问题, 本文提出一种基于 R3LIVE 框架的多传感器融合 SLAM 系统 RMF-SLAM. 该方法首先设计一种随机过程增强的运动学模型, 在进行状态估计之前, 对 IMU 数据进行动态饱和检测, 并结合系统状态反馈对数据偏差进行修正, 有效规避因 IMU 异常输入导致的系统漂移问题. 其次, 构建一种 LiDAR 和视觉退化感知模块, 由于多传感器融合的 SLAM 算法在强光照、长走廊、平坦墙面等场景下, 纹理和几何特征不足, 导致建图失败. 退化感知模块通过信息对贡献分析去评估 Hessian 矩阵<sup>[24]</sup>特征值, 实时监测 LiDAR 和相机的退化程度来动态调整地图构建, 显著增强系统在退化场景中的鲁棒性. 此外, 退化感知模块还可直接触发视频帧关键点筛选, 无需额外设计检测逻辑筛选高价值的视频帧, 在保证建图精度的同时节省算力, 显著提升算法的运行帧数. 得益于此, RMF-SLAM 能够在嵌入式设备上实现流畅运行. 最后, 提出采用全局描述符对地图进行相似性检测, 从而实现相同区域的识别, 当识别出相似度时, 使用多地图融合策略将相应的睡眠地图集成到当前活跃地图中, 从而在系统运行完成后形成高度精确的全局地图. 将所提出算法在 NTU-VIRAL 公开数据集、私有数据集上进行对比实验, 并移植到嵌入式设备上进行测试, 验证算法的可行性和有效性.

## 1 多传感器融合的 RMF-SLAM 算法

RMF-SLAM 算法框架由 5 个模块组成: IMU 运动学模型构建、LIO 子系统、VIO 子系统、退化感知模块和地图融合模块. 本文算法根据 R3-LIVE 算法框架进行修改, 与 R3-LIVE 算法的不同之处在于: 1) 在算法前端加入一种新颖的建模方法实现对

IMU 信息的饱和度检测, 在饱和区域结合系统状态反馈对数据残差进行修正, 获得精确的惯性测量数据; 2) 在数据融合后端使用一种新的退化检测方法来识别退化场景, 并通过退化感知模块筛选高价值视觉帧产生的纹理信息来增强地图; 3) 在检测到过

度退化场景后, 活跃地图被存储到睡眠地图中, 并且在未来遇到类似的区域时被重新激活, 将相应的睡眠地图集成到当前活跃地图中, 从而在系统运行完成后构建可用于机器人导航、环境感知和后续任务规划的稠密彩色点云地图. 算法框架如图 1 所示.

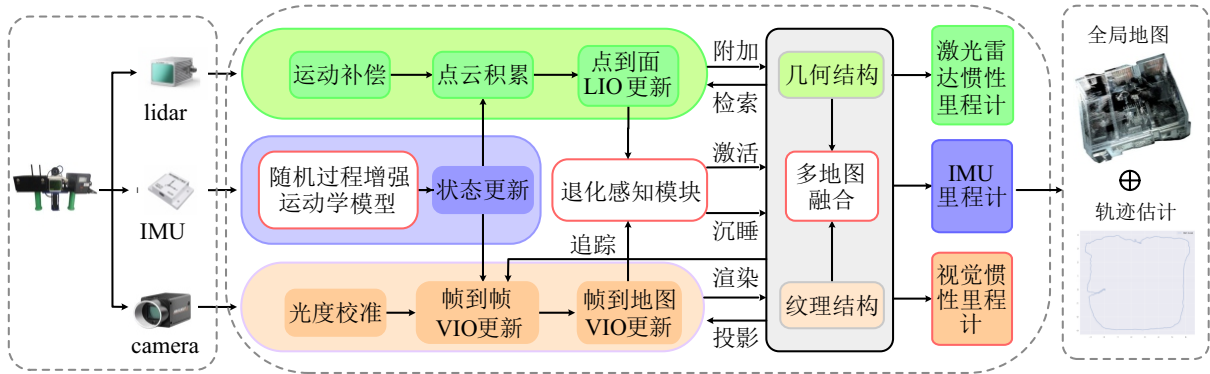


图1 算法框架

## 1.1 随机过程增强的运动学模型

### 1.1.1 饱和度检测

当前多传感器测频与测绘多基于帧扫描, 容易受到帧内运动失真影响. 为纠正这种畸变, 通常需要补偿方法. 大多数方法是通过假设帧内的等速运动来补偿运动畸变, 但对于在扫描过程中速度发生变化的剧烈运动, 等速方法通常会导致较大的漂移, 甚至在里程计中失败. 针对上述问题, 本文提出利用 IMU 测量值构造运动学模型解决剧烈运动补偿问题. 其核心思想为: 在真实采样时间融合每个单独的测量点, 而不将点累积到帧中. 具体而言, 该模型通过检测 IMU 的角速度  $\omega_k(i)$  是否超过其物理量程阈值  $\omega_{\max}(i)$  来判断传感器是否饱和. 为每个通道索引生成一个饱和标志  $\text{sat}_k(i)$ , 当标志为 1 时, 表示该通道在时刻  $k$  处于饱和状态.

$$\text{sat}_k(i) = \begin{cases} 1, & |\omega_k(i)| \geq \omega_{\max}(i); \\ 0, & \text{otherwise.} \end{cases} \quad (1)$$

通过滑动窗口统计  $T$  个时间步内饱和标志的出现频率  $\text{sat}_k(i)$ , 可以判断通道是否持续饱和. 滑动窗口的设计如下:

$$p_{\text{sat}}(i) = \frac{1}{N} \sum_{k=j}^{T+j} \text{sat}_k(i). \quad (2)$$

其中:  $N$  是窗口内的总样本数;  $p_{\text{sat}}(i)$  为通道在窗口内饱和标志的饱和比例, 若该比例超过阈值, 则判定该通道进入持续饱和状态.

### 1.1.2 残差修正

噪声协方差矩阵  $R_{\text{IMU}}(i)$  影响状态更新的权重. 当通道饱和时, 通过膨胀系数来降低该通道的权重,

减少异常数据对状态估计的影响. 动态调整 IMU 噪声协方差矩阵, 使得饱和通道的权重降低, 非饱和通道保持正常权重.

$$R_{\text{IMU}}(i) = \begin{cases} \lambda R_{\text{IMU,def}}(i), & \text{sat}_k(i) = 1; \\ R_{\text{IMU,def}}(i), & \text{otherwise.} \end{cases} \quad (3)$$

当通道持续饱和时, 直接使用原始测量值可能导致估计错误. 通过预测值替换饱和值, 可以避免异常输入对状态估计的影响. 利用历史状态和角速度的变化预测当前角速度, 作为饱和时的替代测量值, 即

$$\hat{\omega}_k(i) = \omega_{k-1}(i) + \int_{t_{k-1}}^{t_k} \dot{\omega} dt. \quad (4)$$

其中:  $\hat{\omega}_k(i)$  为时刻  $k$  通道  $i$  的预测角速度值,  $\omega_{k-1}(i)$  为时刻  $k-1$  通道  $i$  的角速度测量值,  $\dot{\omega}$  为角速度的变化率. 残差函数  $r_{\text{IMU}}(i)$  用于计算预测值与观测值之间的差异, 通过抑制饱和通道的残差, 可以减少异常数据对状态更新的影响. 对饱和通道的残差进行零权重处理, 避免其影响状态更新, 从而提高状态估计的准确性, 有

$$r_{\text{IMU}}(i) = H \delta x + D n_{\text{IMU}}. \quad (5)$$

其中:  $H$  为观测矩阵,  $D n_{\text{IMU}}$  为 IMU 测量噪声的线性组合. 式 (5) 将状态误差向量  $\delta x$  映射到残差空间  $r_{\text{IMU}}(i)$ , 在状态更新过程中考虑饱和和信息.

## 1.2 退化感知模块构建

在 RMF-SLAM 系统中, 退化感知模块是提升系统在退化环境中鲁棒性与适应性的关键组件. 通过联合评估 LiDAR 与视觉传感器在复杂环境中的退化情况, 动态调整状态估计策略与信息融合方式, 从

而增强系统在场景退化下的精度与稳定性. 该模块主要包括3项核心功能: 信息对贡献分析、基于 Hessian

矩阵的退化评估以及状态调整与更新机制. 退化感知模块结构如图2所示.

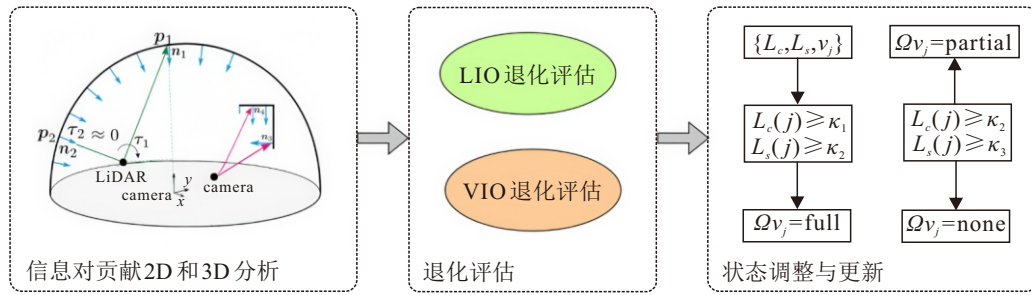


图2 退化感知模块结构

### 1.2.1 信息对贡献分析

在实际状态估计过程中, 需对退化检测信息进行处理分析, 辅助退化评估与状态更新. 本文基于 X-ICP<sup>[25]</sup> 引入信息对贡献的概念, 定义为  $(L_P, L_n)$ , 建立信息对与优化成本的关系, 评估信息对对成本的贡献程度. 值得注意的是, X-ICP 以 LiDAR 单一模态为输入, 依赖点到平面以及点到线的几何约束构建 Hessian 矩阵, 并通过特征值谱分析退化方向, 其核心是为 LiDAR 在极端几何场景下提供稳健性保证. 而本文方法以多传感器信息对 LiDAR-IMU 和 Camera-IMU 为基本单元建立信息贡献模型, 当某一传感器发生退化时, 系统仍能依靠状态更新互补维持约束, 显著增强多传感器融合 SLAM 在极端几何场景以及纹理场景下的全局鲁棒性. 类比经典力学, 优化雅可比矩阵可测量每个信息对局部引起的贡献大小. 对单个扭矩向量进行归一化后, 堆叠所有可用信息对形成旋转信息矩阵  $\mathcal{F}_r \in R \times 3$  和平移信息矩阵  $\mathcal{F}_t \in R \times 3$ .

$$\mathcal{F}_r = \begin{bmatrix} \frac{p_1 \times n_1}{\|p_1 \times n_1\|_2} & \frac{p_2 \times n_2}{\|p_2 \times n_2\|_2} & \cdots & \frac{p_N \times n_N}{\|p_N \times n_N\|_2} \end{bmatrix}^T, \quad \mathcal{F}_t = [n_1 \quad n_2 \quad \cdots \quad n_N]^T. \quad (6)$$

通过对  $\mathcal{F}_r$  和  $\mathcal{F}_t$  进行特征分解, 可进一步量化系统在不同主方向上的约束贡献, 并得到方向先验约束指数  $s_{dir}$  为后续退化判别提供先验信息, 帮助系统判断观测在特定状态维度的可定位性.

$$s_{dir} = \min(\lambda_{\min}(\mathcal{F}_r^T \mathcal{F}_r), \lambda_{\min}(\mathcal{F}_t^T \mathcal{F}_t)). \quad (7)$$

### 1.2.2 基于 Hessian 矩阵的退化评估

在完成局部信息对贡献分析之后, 本文进一步在统一的优化框架下构建整体 Hessian 矩阵, 以对视觉和 LiDAR 的退化程度进行定量评估. 具体而言, 将各信息对贡献矩阵线性叠加, 并通过视觉重投影误差与 LiDAR 点云误差计算导数项, 得到整体 Hessian 为退化分析提供数值基础. 以视觉观测为例, 其重投影误差  $r_{pnp}$  可表示为

$$r_{pnp} = z_{obs} - \pi(T_{cw} P_w). \quad (8)$$

其中:  $n$  为相机投影模型,  $z_{obs}$  为图像上的观测像素坐标,  $T_{cw}$  为相机到世界坐标系的变换矩阵,  $P_w$  为地图点坐标. 通过误差状态迭代卡尔曼滤波 (ESIKF) 最小化重投影误差, 得到初步的位姿估计. 视觉观测的重投影误差构建残差函数. LiDAR 的残差  $r_{lidar}$  点到平面的距离定义为

$$r_{lidar} = n^T(T_{lw} P_w - P). \quad (9)$$

其中:  $n^T$  为局部平面法向量,  $P$  为参考平面上的一点,  $T_{lw}$  为激光雷达位姿. 随后两类残差统一进入 Hessian 的构建框架

$$H = J^T \Sigma^{-1} J = \Sigma \left( \frac{\partial r_i}{\partial x} \right)^T \Sigma_i^{-1} \left( \frac{\partial r_i}{\partial x} \right). \quad (10)$$

对优化问题的 Hessian 矩阵进行特征值分解, 有

$$H = V \Lambda V^T, \quad (11)$$

其中  $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_6)$ , 每一个特征值-特征向量对  $(\lambda_i, v_i)$  对应状态空间中的一个主方向 (即一个自由度或自由度组合) 上的信息强度. 如果  $\lambda_{(t, \min)} / \text{tr}(\Lambda_t) < \varepsilon_t$ , 则沿  $v_{t, \min}$  方向平移退化, 即 3 个平移自由度  $(x, y, z)$ ; 如果  $\lambda_{(r, \min)} / \text{tr}(\Lambda_r) < \varepsilon_r$ , 则绕  $v_{r, \min}$  方向旋转退化, 即 3 个旋转自由度 (滚转, 俯仰, 偏航). 因此, 基于 Hessian 特征分解的方法本质上覆盖了 6 自由度的所有可能方向, 既能够识别单一自由度退化, 也能够检测多自由度耦合退化. 若某一自由度 (如  $z$  轴平移或偏航旋转) 因传感器数据退化而缺乏约束, 则其对应的特征值会显著变小, 从而被系统检测到. 在退化检测中, 本文采用了“两层次判别机制”. 首先, 在局部层面, 将单个信息对的雅可比矩阵进行归一化投影, 量化其在平移与旋转自由度上的约束能力, 构建方向先验约束指数, 以刻画不同主方向的可定位性强弱. 随后, 在全局层面, 将所有信息对贡献线性叠加, 并结合视觉重投影误差与 LiDAR 点云误差统一进入 Hessian 构建, 对其特征值谱进行分

解. 若最小特征值趋近于零, 则说明系统在对应自由度方向发生退化. 最终, 退化分数综合了局部先验约束指数与全局 Hessian 分解结果, 既保留了细粒度的贡献分析, 又保证了整体一致性, 从而实现更稳健的退化判别. 视觉和 LiDAR 退化分数为

$$\{S_{\text{deg}}^{\text{vis}}, S_{\text{deg}}^{\text{lidar}}\} = \max(s_t, s_r) + s_{\text{dir}}. \quad (12)$$

其中:  $s_t = 1 - \lambda_{(t, \min)} / \lambda_{(t, \max)}$ ,  $s_r = 1 - \lambda_{(r, \min)} / \lambda_{(r, \max)}$ . 该退化分数为后续权重调整与状态更新提供度量基础.

### 1.2.3 状态调整与更新

基于过滤后的结果, 依据退化分数判断系统退化情况. 当分类结果显示大量信息属于低贡献类别且退化分数达到启动机制阈值时, 系统会调整 LiDAR 和视觉的权重, 对退化方向施加零空间约束等操作, 优化状态估计过程. 当检测到特定方向上的观测约束失效时, 通过退化分数对该方向的估计进行加权调整, 提升整体鲁棒性. 本文对视觉权重进行动态调整, 具体通过对视觉观测协方差逆进行缩放处理. 进行调整后的视觉协方差矩阵为

$$\Sigma_{\text{visual}}^{-1} \leftarrow \Sigma_{\text{visual}}^{-1} (1 - \alpha S_{\text{deg}}). \quad (13)$$

其中:  $S_{\text{deg}}$  为退化分数,  $\alpha$  为增益系数. 随着  $S_{\text{deg}}$  的变化, 视觉信息在系统状态估计中的权重也相应变化.

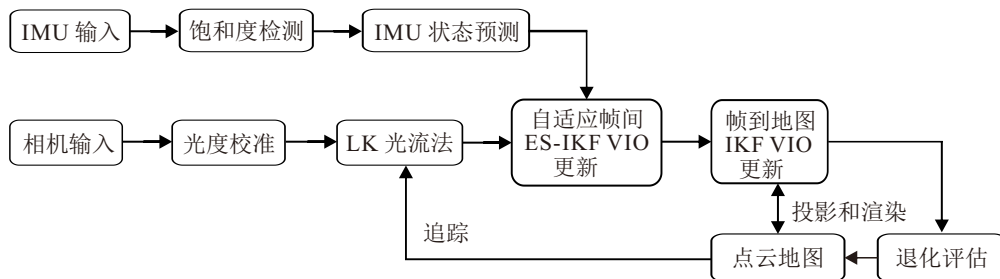


图3 RMF-SLAM 的 VIO 子系统

在 RMF-SLAM 框架中, VIO 子系统联合优化光流追踪点的 PnP 重投影误差  $r_{\text{pnp}}$  与光度误差  $r_{\text{photo}}$ , 其联合残差形式如下:

$$r_{\text{visual}} = \begin{bmatrix} r_{\text{pnp}} \\ r_{\text{photo}} \end{bmatrix}, \quad \Sigma_{\text{visual}} = \begin{bmatrix} \Sigma_{\text{pnp}} & 0 \\ 0 & \Sigma_{\text{photo}} \end{bmatrix}. \quad (15)$$

光度误差以像素灰度值为约束项构建,  $I_{\text{ref}}(x)$  设为参考图像在像素位置处  $x$  的灰度值,  $I_{\text{cur}}(T(x))$  为当前图像经变换  $T$  后对应像素位置的灰度值, 则单点的光度误差定义为

$$e_{\text{photo}}(x) = I_{\text{ref}}(x) - I_{\text{cur}}(T(x)). \quad (16)$$

为提升约束信息密度, 本文不再仅依赖关键点提取结果, 而是在全图范围内选择更多像素点来参与光度误差计算. 设像素点集合为  $P$ , 每个像素点的

当视觉和 LiDAR 均退化时, 为防止误导信息对系统造成累计误差, 系统将暂时沉睡当前地图, 即冻结当前全局地图更新与状态传播. 针对已判定为退化的状态变量方向 (如平移或旋转某一主方向), 系统采用零空间投影方式对雅可比矩阵进行修正, 避免无效方向对估计结果的干扰, 即

$$J \leftarrow J(I - v_{\text{deg}} v_{\text{deg}}^T), \quad (14)$$

其中  $v_{\text{deg}}$  为退化方向对应的特征向量. 该处理方式本质上将优化投影到有效子空间中, 从而抑制退化方向上不可靠的信息更新.

### 1.2.4 基于退化感知算法的视频帧关键点筛选

算法框架中的视觉-惯性里程计 (VIO) 子系统, 主要通过最小化图像的光度误差来估计系统状态, 并为构建带纹理的全局地图提供高精度位姿估计. 在帧间 VIO 阶段, 系统首先从前一帧图像中提取关键点, 为提高计算效率并避免冗余, 本文引入基于退化感知机制的稀疏策略, 对关键点进行有选择性筛选. 之后, 采用光流法将这些关键点从参考帧追踪到当前帧, 并通过与全局地图中已知 3D 点建立匹配, 构建 2D-3D 点对以用于 PnP 重投影误差的计算. 如图 3 所示, 其核心分为帧间 VIO 和帧到地图 VIO.

权重为  $w(x)$ , 该权重依据像素梯度、图像边缘特性与跟踪稳定性等因素设定. 最终的光度误差目标函数为

$$E_{\text{photo}} = \sum_{x \in P} w(x) e_{\text{photo}}^2(x). \quad (17)$$

在帧到地图 (frame-to-map) 优化阶段, 系统利用地图点的颜色属性来计算光度残差. 这些颜色值作为地图点的固有属性, 具有视角不变性, 所以能够有效约束相机位姿变化.

基于退化感知机制的稀疏策略触发条件为系统通过退化感知模块判定当前观测在某些自由度上存在约束不足. 当检测到某些方向的 Hessian 特征值  $\lambda_j$  趋于 0 时, 表明该方向存在潜在退化, 此时稀疏策

略被触发,以避免在退化维度上继续引入冗余信息.稀疏筛选方式为在视觉-惯性里程计(VIO)子系统中,关键点通常均匀分布在图像上.但其对位姿估计的约束作用存在差异.定义每个关键点*i*的贡献权重为

$$w_i = \|J_i v_j\|^2. \quad (18)$$

其中: $J_i$ 为第*i*个关键点的雅可比矩阵, $v_j$ 为Hessian分解得到的特征向量.基于退化感知机制的稀疏筛选策略, $v_j$ 的核心思想是在低贡献方向(退化维度),对应于长走廊等场景中的纵向特征点,若其对位姿估计的贡献度(通过雅可比投影衡量)较低,则降低其保留比例;若 $v_j$ 属于退化方向,则在高贡献方向对那些在横向或深度方向仍具备有效约束的关键点,

优先保留以保证系统的可观测性.筛选后的关键点将通过光流法从参考帧追踪到当前帧,并与全局地图中已知3D点建立匹配,构建2D-3D点对用于PnP重投影误差计算.该稀疏策略不仅降低了关键点数量,提升了前端计算效率,还增强了系统在退化场景下的鲁棒性,避免了冗余或不可靠特征对状态估计的干扰.

### 1.3 多地图融合

在RMF-SLAM系统中,地图构建聚焦于将多个经历退化处理后的地图片段进行有效拼接,最终生成一张高精度、鲁棒性强的全局地图.该过程主要包括相似性检测和地图融合策略两个核心环节,如图4所示.

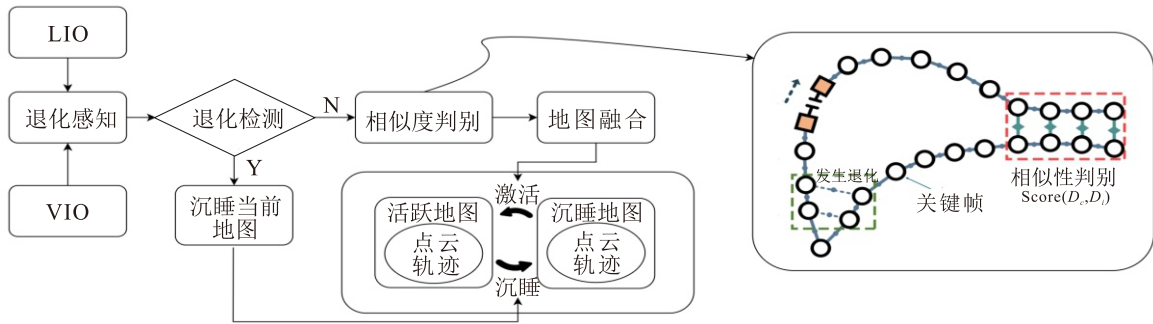


图4 RMF-SLAM的多地图融合

#### 1.3.1 相似性检测

为实现地图之间的闭环连接与拼接,系统进行地图相似度匹配.设当前帧的描述子为 $\mathcal{D}_c$ ,历史地图片段中第*i*张睡眠地图的描述子为 $\mathcal{D}_i$ ,则相似性得分可定义为

$$\text{Score}(\mathcal{D}_c, \mathcal{D}_i) = 1 - \frac{\|\mathcal{D}_c - \mathcal{D}_i\|_1}{\|\mathcal{D}_c\|_1 + \|\mathcal{D}_i\|_1}. \quad (19)$$

为避免误匹配带来的错误闭环,本文引入时间一致性判据.考虑到真实的闭环往往在时间上具有连续性,系统要求相似性得分连续超过阈值 $\epsilon_{\text{sim}}$ 达到 $\tau_{\text{con}}$ 帧以上,才视为有效匹配.

$$\sum_{k=t-\tau_{\text{con}}}^t I(\text{Score}(\mathcal{D}_c^k, \mathcal{D}_i^k) > \epsilon_{\text{sim}}) \geq \tau_{\text{con}}. \quad (20)$$

该机制为确保相似性检测的稳定性与可靠性,显著降低了误闭环率.满足上述条件后,系统将匹配到的地图从睡眠状态激活,纳入后续的地图融合流程.

#### 1.3.2 全局地图融合策略

地图融合依托于系统维护的地图数据库 $\{M\} = \{M_{\text{active}}, M_{\text{sleeping}}\}$ ,活动地图 $M_{\text{active}}$ 是系统当前维护与更新的地图,包含实时点云、轨迹图.睡眠地图

$M_{\text{sleeping}}$ 是由历史活动地图中剥离出的子地图单元,处于非更新状态,等待被激活.每个地图 $M_i$ 均由两部分组成:点云数据 $p_i = \{p_1, \dots, p_n\}$ 和轨迹 $\mathcal{T}_i = \{\mathcal{T}_0, \dots, \mathcal{T}_m\}$ .在系统运行过程中,当VIO与LIO子系统完成状态估计后,融合模块对激光点云进行颜色渲染,利用图像帧的颜色信息增强点云的可读性.设投影变换为 $\pi$ ,图像颜色为 $C(u, v)$ ,则每个点的颜色为

$$\text{Color}(p_i) = C(\pi(kT_{\text{cam}}p_i)). \quad (21)$$

随着系统运行,地图将持续接收测程约束与闭环约束,通过全局图优化对轨迹图进行更新,进而修正地图漂移误差.当检测到视觉与激光雷达均严重退化时,当前地图将进入沉睡模式,系统暂停其更新以防止错误信息污染整体地图.

$$\text{if } S_{\text{deg}}^{\text{vis}} > \epsilon_{\text{vis}} \wedge S_{\text{deg}}^{\text{lidar}} > \epsilon_{\text{lidar}} \Rightarrow \text{Sleep}(M_{\text{active}}). \quad (22)$$

一旦退化解除,传感器状态恢复正常,系统将重新激活沉睡地图.

$$\text{if sensors healthy} \Rightarrow \text{Activate}(M_{\text{sleeping}}). \quad (23)$$

最后,系统通过对地图使用全局描述子进行地图间相似性检测,将满足条件的地图融合入全局地

图, 实现地图拼接.

## 2 实验分析

### 2.1 实验准备

本次实验的平台配置及实验安排如下: 本文使用如图5所示自己制作的手持平台进行数据集采集. 数据采集器采用搭载 NVIDIA Jetson Orin NX 控制器, 配备海康威视工业相机与 Avia 激光雷达组成的传感器套件. 服务器平台硬件为 Intel i5-12400kF CPU 和 NVIDIA RTX 3060 GPU, 系统是 Ubuntu 20.04 LTS 与 ROS noetic. 嵌入式设备部署实验则使用云深处 Lite3 机器狗实验平台, 在室外校园环境完成. 通过在开源数据集、私有数据集以及真实场景中进行验证, 以此全面验证 RMF - SLAM 系统性能.




图5 手持平台

### 2.2 开源数据集实验

本研究所提出算法在大规模多模态多场景数据集 NTU-VIRAL<sup>[26]</sup> 上开展全面测试. NTU-VIRAL 数据集采集自南洋理工大学校园, 借助航空平台收集, 覆盖丰富多样的场景, 蕴含着独特的航空操作挑战. 本实验选用数据集中的 9 个序列, 即 eee\_01、eee\_02、

eee\_03、nay\_01、nay\_02、nay\_03、sbs\_01、sbs\_02 和 sbs\_03 来综合考量算法性能. 表 1 显示各算法在这些序列上的平均绝对轨迹误差 (ATE).

“eee”和“nya”序列对于 LiDAR SLAM 而言, 半透明表面会干扰点云数据的采集与处理; 对于视觉 SLAM 来说, 复杂的飞行动态以及低光照条件严重影响特征提取与匹配. “sbs”序列的视觉和激光雷达特征存在显著噪声, 且仅能从远处物体获取, 为感知算法带来极大困难. 如表 1 所示, 在 NTU-VIRAL 数据集的 9 个序列中, 本文的方法在所有序列中的整体精度最高, 平均 ATE 为 0.063 m, 并且在大多数序列中均取得最佳结果. 在停车场和室内礼堂等小规模“eee”和“nya”序列中图像极为昏暗且模糊且负优化尤为严重, 本文依赖于退化感知自适应策略, 在全局绝对轨迹精度方面相比其他算法显著提升. 相比之下, LVI-SAM 的 ATE 可达 0.75 m, 表明系统发生严重发散. 在复杂的大规模序列校园前广场“sbs”序列中, 与目前先进的算法 fast-livo2 的 ATE 精度差异也仅在厘米级别. 本文算法在移除饱和修正后平均误差约 0.072 m, 算法在移除退化感知后的平均误差约 0.083 m, 绝对轨迹误差降低较为明显, 说明退化感知模块对系统精度提升更显著.

综上所述, 相较于其他算法, RMF-SLAM 算法在绝对轨迹误差 (ATE) 方面显著降低, 验证了本文算法在提升复杂场景下状态估计精度和鲁棒性方面的有效性. 为进一步研究 IMU 饱和度修正机制、退化感知算法以及自适应帧间关键点方法不同模块的有效性, 本文在采集的私有数据集上进行全面研究.

表1 NTU-VIRAL 数据集 ATE 对比结果

单位: m

算法序列	fast-lio2 <sup>[14]</sup>	orb-slam3 <sup>[16]</sup>	lvi-sam <sup>[17]</sup>	fast-livo2 <sup>[22]</sup>	R3LIVE <sup>[19]</sup>	RMF-SLAM	RMF-SLAM (w/o SC)	RMF-SLAM (w/o DA)
eee_01	0.212	0.608	3.901	0.068	0.072	0.064	0.071	0.082
eee_02	0.172	0.506	0.182	0.051	0.059	0.057	0.065	0.075
eee_03	0.213	0.494	0.287	0.068	0.078	0.064	0.072	0.081
nay_01	0.141	0.397	0.205	0.073	0.080	0.065	0.073	0.084
nay_02	0.212	0.424	1.296	0.075	0.084	0.065	0.074	0.088
nay_03	0.133	0.787	0.176	0.059	0.079	0.060	0.069	0.080
sbs_01	0.184	0.508	0.254	0.062	0.075	0.070	0.078	0.089
sbs_02	0.161	0.564	0.221	0.061	0.076	0.068	0.076	0.087
sbs_03	0.142	0.878	0.309	0.060	0.070	0.062	0.071	0.083
Average	0.174	0.574	0.759	0.065	0.074	0.063	0.072	0.083

### 2.3 私有数据集实验

为验证本文算法在退化环境中的有效性, 制作了更为严苛的多传感器数据集. 本小节通过数据集 indoor\_01、indoor\_02 对 RMF-SLAM 算法的性能进行评估. 数据集均采用高精度 RTK 和 IMU 数据融

合的方式获取真值轨迹. 实验在内蒙古工业大学金川校区格物楼 A 楼 307 内进行. 所采集的数据集涉及挑战性的运动模式, 如快速旋转、玻璃窗户强光照以及长走廊等传感器退化场景. 对建图效果以及轨迹进行分析, 图 6 和图 7 分别展示了实验室室内和

走廊的平面布局.

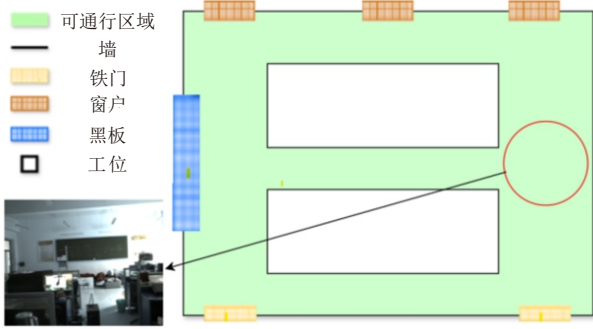


图6 室内实验室的平面布局






图7 室内走廊的平面布局

### 2.3.1 IMU 饱和修正的消融实验

实验设置在相同的室内场景下,使用装备多传感器的手持平台运行 RMF-SLAM 算法. 一组开启 IMU 饱和度修正机制,另一组关闭该机制,其他条件保持一致. 在实验室工位上进行快速旋转,在运行过程中,记录两组实验构建过程中的点云数据. 如图 8 所示,对比两组实验构建的地图,关闭 IMU 饱和度修正算法的地图出现如重影、运动模糊、不清晰以及旋转过程中严重错位等现象,而开启该算法的地图有所改善,整体实验室工位轮廓基本可辨,表明



(a) 饱和修正前



(b) 饱和修正后

图8 饱和修正构建地图对比

IMU 饱和度修正机制对提升地图构建质量和系统稳定性具有重要作用.

### 2.3.2 退化感知模块的消融实验

在 indoor\_01 数据集上分别运行具有退化感知 RMF-SLAM 算法和不具有退化感知模块的 R3LIVE 算法. 记录两种情况下系统的状态估计数据以及地图构建过程中的点云数据. 为验证本文的退化感知算法的有效性,本文将图 6 第 1 个窗户处的窗帘打开,其余窗帘关闭,在玻璃窗外,实验中将激光雷达和相机正对太阳光停留 5 s. 如图 9 所示,由于实验室退化环境的存在,去除退化感知的系统所运行轨迹始终无法形成一个完整的回环,本文算法估计的轨迹很好地形成了一个回环. 对比两组地图,如图 10 所示,去除退化感知功能的系统算法在状态估计时出现较大偏差,在地图构建中无法有效处理退化区域,导致点云地图不准确、不完整. 反映出本文算法的准确性且能更好地适应退化场景,准确检测退化

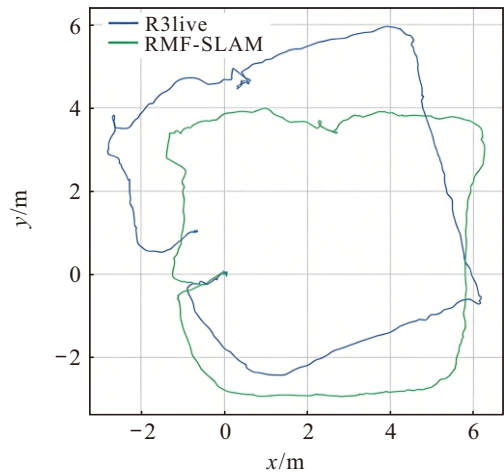




图9 indoor\_01 数据集下轨迹估计对比结果



(a) R3LIVE 算法



(b) RMF-SLAM 算法

图10 indoor\_01 数据集下算法构建的地图对比

并调整状态估计和地图构建策略,表明退化感知的系统对提升系统在复杂环境下的适应性和定位精度至关重要.

2.3.3 自适应关键帧选择的 VIO 系统的消融实验

分别运行包含自适应视觉帧关键点选择策略的 RMF-SLAM 算法和对所有帧进行稠密光流跟踪的 R3LIVE 算法.记录不同算法在运行过程中的每一帧处理时间,对比两组实验结果.如表 2 所示,采用固定视觉帧选择方式的算法存在算力浪费,定位精度下降,地图纹理信息质量不佳,而具有视觉帧关键点选择策略的算法能够根据传感器运动状态和环境结构变化自主筛选高价值视觉观测帧, VIO 运行时间显著下降,在保证定位精度的同时提高运行效率,增强了地图纹理信息,在 VIO 前端阶段直接完成关键帧判定,从源头上压缩视觉数据冗余,提高了系统整体的实时性.

2.3.4 对比实验

本节通过数据集 indoor\_02 对 RMF-SLAM 算

表2 算法运行时间

单位: m

运行算法	VIO			Total	
	320×256	640×512	LIO	320×256	640×512
	R3LIVE(pc)	34.05	53.04	20.39	54.47
RMF-SLAM(pc)	20.36	24.21	23.24	42.60	46.45
RMF-SLAM(arm)	57.05	82.54	34.53	91.58	117.07

法的性能进行对比评估.该数据集是一个强光环境下长走廊的实验环境.图 11 显示 R3LIVE、fast-livo2 以及 RMF-SLAM(本方法)在室内数据集上的点云建图结果.在该数据集的测试过程中,R3LIVE 和 fast-livo2 算法均出现重影且有些退化区域的点云信息没有被保留.与其他稠密建图方法不同,具有退化感知的 RMF-SLAM 系统在退化区域保留大量信息,本文方法对比其他算法建立完整且清晰的点云地图,使得 RMF-SLAM 算法生成的点云地图更加丰富.如表 3 所示,在加入 IMU 饱和修正和退化感知模块后, RMF-SLAM 的相对轨迹误差和绝对轨迹误差显著优于对比方法.




图11 indoor\_02 数据集下算法构建的地图对比

表3 绝对轨迹和相对轨迹误差对比

单位: m

运行算法序列	R3LiVE		Fast-livo2		RFM-SLAM	
	ATE/RSME	Median	ATE/RSME	Median	ATE/RSME	Median
Indoor_01	×	×	0.116/0.128	0.121	0.061/0.069	0.058
Indoor_02	0.092/0.105	0.091	0.090/0.084	0.085	0.073/0.082	0.062

图 12 展示了不同方法在室内数据集上的轨迹结果.机器人行驶在长的退化走廊环境中.在这种延

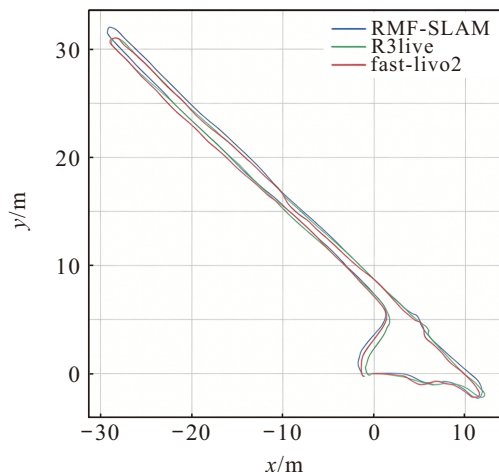


图12 indoor\_02 数据集下轨迹估计对比结果

长走廊环境下,由于可识别特征点数量有限,SLAM 算法往往会低估实际行驶距离,导致里程计测得的距离偏小,几何或视觉约束不足,估计精度降低.

在 indoor\_02 长走廊数据集中 R3LIVE 估计的总行驶距离仅为 67.48 m. FAST-LIVO2 估计的行驶距离则为估计距离为 53.64 m. 本文算法 RMF-SLAM 估计的行驶距离则为 74.67 m. 观察轨迹发现,IMU 饱和修正机制使得运动轨迹更加平滑.本方法相较于其他方法取得更高的轨迹精度.

2.4 嵌入式平台实验

绝影 Lite 3 作为新一代智能机器狗,具备强大的驱动力、灵活的越障能力、高速实时数据传输能力以及多模块扩展功能,是一种先进的仿生机器人.在本文的实验中,使用绝影 Lite 3 的基础版本,并在其

基础上集成 NVIDIA ORIN NX 机载计算机、LS-C16 激光雷达和 Realsense D435i 摄像头, 如图 13 所示。




图13 移动机器人平台

室外实验在大规模半结构化环境中进行, 为验证算法在退化环境下的鲁棒性和环境适应性, 本文在夜晚环境下模拟机器狗自主导航的真实场景. 机器狗以 2.5 m/s 的速度远程控制, 在开放区域中绕实验楼 A 座移动一圈后回到原点. 图 14 展示了机器狗室外夜晚环境中的建图结果. 从图中观察可以看出即使在夜晚室外环境中本文算法 RMF-SLAM 生成的全局地图依旧保留完整的细节, 彩色点云图的放大视图与实际 RGB 图像相似。



(a) 实验室卫星地图


(b) 本文方法在夜晚环境下的建图结果



(c) 图(a)中I点

(d) 图(a)中II点

(e) 图(a)中III点



(f) 图(b)中I点

(g) 图(b)中II点

(h) 图(b)中III点

图14 移动机器人室外环境中的建图结果

### 3 结论

本文提出一种新的多传感器融合 RMF-SLAM 算法, 旨在解决退化场景下 SLAM 面临的定位精度低、地图漂移和可靠性差等难题. 通过 IMU 饱和度修正、传感器退化评估以及多地图融合等方法, 有效提升了系统的定位精度和鲁棒性. 最后, 将所提出方法与其他经典算法在全局轨迹一致性、绝对轨迹误差和地图构建精度等方面进行比较, 结果表明, 在传感器过度退化、几何结构复杂或高速旋转等复杂退化环境下, 该算法均展现出良好的精度与适应性, 在挑战性的真实场景中也表现出较高的实用性, 具有

较好的应用价值.

### 参考文献 (References)

- [1] Yarovoi A, Cho Y K. Review of simultaneous localization and mapping (SLAM) for construction robotics applications[J]. *Automation in Construction*, 2024, 162: 105344.
- [2] Licardo J T, Domjan M, Orehovački T. Intelligent robotics — A systematic review of emerging technologies and trends[J]. *Electronics*, 2024, 13(3): 542.
- [3] Zhao J Y, Zhao W Y, Deng B, et al. Autonomous driving system: A comprehensive survey[J]. *Expert Systems with Applications*, 2024, 242: 122836.
- [4] Dargan S, Bansal S, Kumar M, et al. Augmented reality:

- A comprehensive review[J]. *Archives of Computational Methods in Engineering*, 2023, 30(2): 1057-1080.
- [5] Cai D P, Li R Q, Hu Z H, et al. A comprehensive overview of core modules in visual SLAM framework[J]. *Neurocomputing*, 2024, 590: 127760.
- [6] Chan S H, Wu P T, Fu L-C. Robust 2D indoor localization through laser SLAM and visual SLAM fusion[C]. 2018 IEEE International Conference on Systems, Man, and Cybernetics. Miyazaki, 2018: 1263-1268. DOI: 10.1109/smc.2018.00221.
- [7] 汪湘川, 张辉, 陈波, 等. 基于扫描上下文优化的紧耦合激光 SLAM 方法[J]. *控制与决策*, 2024, 39(10): 3234-3242.  
(Wang X C, Zhang H, Chen B, et al. Tightly-coupled laser SLAM method based on scan context optimization[J]. *Control and Decision*, 2024, 39(10): 3234-3242.)
- [8] Sarlin P E, DeTone D, Malisiewicz T, et al. SuperGlue: Learning feature matching with graph neural networks[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020: 4938-4947.
- [9] Kulvicius T, Zhang D J, Poustka L, et al. Deep learning empowered sensor fusion boosts infant movement classification[J]. *Communications Medicine*, 2025, 5: 16.
- [10] 李荣华, 谢辉, 韩兴元, 等. 弱纹理场景下无人机边缘化加速定位方法[J]. *控制与决策*, 2024, 39(10): 3253-3260.  
(Li R H, Xie H, Han X Y, et al. Accelerated localization method with marginalization for UAV in weak-texture scenes[J]. *Control and Decision*, 2024, 39(10): 3253-3260.)
- [11] Alaerjan A. Towards sustainable distributed sensor networks: An approach for addressing power limitation issues in WSNs[J]. *Sensors*, 2023, 23(2): 975.
- [12] 贾嫣晗, 邹凤山, 徐方, 等. 完全在线的双目直接法视觉 SLAM 算法[J]. *控制与决策*, 2023, 38(11): 3093-3102.  
(Jia Y H, Zou F S, Xu F, et al. Fully online binocular direct visual SLAM algorithm[J]. *Control and Decision*, 2023, 38(11): 3093-3102.)
- [13] 刘辉, 张雪波, 李如意, 等. 双目视觉辅助的激光惯导 SLAM 算法[J]. *控制与决策*, 2024, 39(6): 1787-1800.  
(Liu H, Zhang X B, Li R Y, et al. Laser inertial navigation SLAM algorithm assisted by binocular vision[J]. *Control and Decision*, 2024, 39(6): 1787-1800.)
- [14] Xu W, Cai Y X, He D J, et al. FAST-LIO2: Fast direct LiDAR-inertial odometry[J]. *IEEE Transactions on Robotics*, 2022, 38(4): 2053-2073.
- [15] Yang G C, Chen Z J, Li Y, et al. Rapid relocation method for mobile robot based on improved ORB-SLAM2 algorithm[J]. *Remote Sensing*, 2019, 11(2): 149.
- [16] Campos C, Elvira R, Rodriguez J J G, et al. ORB-SLAM3: An accurate open-source library for visual, visual-inertial, and multimap SLAM[J]. *IEEE Transactions on Robotics*, 2021, 37(6): 1874-1890.
- [17] Li C, Pan W B, Yuan X W, et al. High-precision map construction in degraded long tunnel environments of urban subways[J]. *Remote Sensing*, 2024, 16(5): 809.
- [18] Lin J R, Zheng C R, Xu W, et al. R<sup>2</sup> LIVE: A robust, real-time, LiDAR-inertial-visual tightly-coupled state estimator and mapping[J]. *IEEE Robotics and Automation Letters*, 2021, 6(4): 7469-7476.
- [19] Lin J R, Zhang F. R<sup>3</sup>LIVE: A Robust, Real-time, RGB-colored, LiDAR-Inertial-Visual tightly-coupled state Estimation and mapping package[C]. 2022 International Conference on Robotics and Automation. Philadelphia, 2022: 10672-10678.
- [20] Shan T X, 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. Xi'an, 2021: 5692-5698.
- [21] Zheng C R, Zhu Q Y, 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. Kyoto, 2022: 4003-4009.
- [22] Zhou B, Zheng C, Wang Z, et al. FAST-LIVO2 on resource-constrained platforms: LiDAR-inertial-visual odometry with efficient memory and computation[J/OL]. 2025, arXiv: 2501.13876.
- [23] Hassan M U, Khan T, Zafar T, et al. Degradation prognostics of aerial bundled cables based on multi-sensor data fusion[J]. *Nondestructive Testing and Evaluation*, 2025, 40(2): 489-507.
- [24] Kaur S, Cohen J, Lipton Z C. On the maximum hessian eigenvalue and generalization[J/OL]. 2023, arXiv: 2206.10654.
- [25] Tuna T, Nubert J, Nava Y, et al. X-ICP: Localizability-aware LiDAR registration for robust localization in extreme environments[J]. *IEEE Transactions on Robotics*, 2024, 40: 452-471.
- [26] Nguyen T M, Yuan S H, Cao M Q, et al. NTU VIRAL: A visual-inertial-ranging-lidar dataset, from an aerial vehicle viewpoint[J]. *The International Journal of Robotics Research*, 2022, 41(3): 270-280.

## 作者简介

彭雯宇 (2000-), 男, 硕士生, 主要研究方向为机器人、机器视觉, E-mail: 15296600487@163.com;

齐咏生 (1975-), 男, 教授, 博士, 博士生导师, 主要研究方向为深度学习、机器视觉, E-mail: qys@imut.edu.cn;

刘利强 (1975-), 男, 教授, 博士, 主要研究方向为深度学习、机器视觉, E-mail: llqiang@imut.edu.cn;

苏建强 (1983-), 男, 副教授, 博士, 主要研究方向为深度学习、机器视觉, E-mail: sujianqiang1983@163.com;

张丽杰 (1972-), 女, 教授, 博士, 主要研究方向为深度学习、机器视觉, E-mail: zhanglijie@imut.edu.cn.