

面向大规模地下空间的多智能体端边协作 全局SLAM方法

张奎元^{1,2}, 张启亮¹, 陈朋朋^{2,3}, 高守婉^{1,3*}

(1. 中国矿业大学计算机科学与技术学院/人工智能学院, 江苏徐州 221116; 2. 中国矿业大学深圳研究院, 广东深圳 518057;
3. 矿山数字化教育部工程研究中心, 江苏徐州 221116)

摘 要: 随着地下空间开发不断朝着深部化、大型化与无人化方向发展, 移动机器人在地下探测及救援等方面发挥着重要作用. 即时定位与建图(Simultaneous Localization And Mapping, SLAM)作为移动机器人的基础, 为其自主导航与安全避障提供了可靠支撑. 针对大规模地下空间传感器退化、计算瓶颈以及移动机器人感知范围受限且累积漂移严重等挑战, 提出了超宽带(Ultra-WideBand, UWB)紧耦合的多智能体端边协作SLAM方法(Robots-edge Collaborative SLAM, Re-CoSLAM). 本文在边缘辅助的多模态SLAM框架基础上, 结合误差状态卡尔曼滤波, 设计了UWB紧耦合绝对位姿估计方法, 有效提升了全局定位性能. 进一步, 基于UWB全局定位, 建立了可扩展的多智能体协同SLAM框架与自适应传输机制. 为了保障全局一致性, 根据多智能体之间的UWB距离测量, 提出了相对距离约束的联合位姿图优化方法. 此外, 考虑到边缘节点的计算瓶颈问题, 设计基于请求优先级的任务调度策略, 以减少排队延迟并提高跟踪精度. 本文在3台搭载英伟达板载计算机的移动机器人和1台边缘计算节点上部署Re-CoSLAM, 并在室内走廊、地下车库与地下巷道场景下开展了广泛的实验与评估. 结果表明, Re-CoSLAM可实现7.3 cm的绝对定位精度与13 帧/秒的运行速度, 定位误差比现有方法降低了50%以上.

关键词: 多模态融合; 即时定位与建图; 超宽带定位; 端边协作; 多智能体协同

基金项目: 国家重点研发计划(No.2024YFC3015701); 国家自然科学基金(No.62272462); 江苏省杰出青年基金(No.BK20230045); 深圳市科技计划(No.JCYJ20230807154300002)

中图分类号: TP393 **文献标识码:** A **文章编号:** 0372-2112(2025)11-3852-13

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20250472

Robots-Edge Collaborative Absolute SLAM in Large-Scale Underground Environments

ZHANG Kui-yuan^{1,2}, ZHANG Qi-liang¹, CHEN Peng-peng^{2,3}, GAO Shou-wan^{1,3*}

(1. School of Computer Science and Technology/School of Artificial Intelligence, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China; 2. Shenzhen Research Institute, China University of Mining and Technology, Shenzhen, Guangdong 518057, China;
3. Mine Digitization Engineering Research Center of the Ministry of Education, Xuzhou, Jiangsu 221116, China)

Abstract: With the development of underground exploration towards deep, large, and unmanned, mobile robots have become crucial in underground detection and rescue. As the basis of mobile robots, simultaneous localization and mapping (SLAM) provides reliable support for its autonomous navigation and obstacle avoidance. Due to the sensors degradation, the constrained computing resources, and the limited sensing range and serious cumulative drift of mobile robots in large-scale underground environments, a robots-edge collaborative SLAM (Re-CoSLAM) method via ultra-wideband (UWB) tightly-coupled is proposed. Based on the edge assisted multi-modal SLAM framework, Re-CoSLAM designs a UWB tightly-coupled absolute pose estimation method based on the error state Kalman filter to improve absolute localization performance. Combined with the UWB absolute localization, a scaling up multi-agent collaborative SLAM framework and an adaptive transmission mechanism are further established. To ensure global consistency, Re-CoSLAM proposes a joint pose graph optimization algorithm with UWB relative range constraints between the multiple agents. Besides, considering the

constrained computing resources of the edge server, a task scheduling strategy based on request priority is devised to reduce queuing latency and improve tracking accuracy. In this paper, Re-CoSLAM is fully deployed on three mobile robots equipped with NVIDIA on-board computers and an edge server, and extensive experiments and evaluations are performed in the indoor corridor, underground garage and underground tunnel scenarios. The results indicate that Re-CoSLAM can achieve an absolute localization accuracy of 7.3 cm and a speed of 13 Frames Per Second in various scenarios, with localization errors reduced by more than 50% compared to existing solutions.

Key words: multi-modal fusion; simultaneous localization and mapping; ultra-wideband localization; robot-edge collaborative; multi-agent cooperation

Foundation Item(s): National Key Research and Development Program of China (No.2024YFC3015701); National Natural Science Foundation of China (No.62272462); Jiangsu Province of China for Distinguished Young Scholars (No.BK20230045); Shenzhen Science and Technology Program (No.JCYJ20230807154300002)

1 引言

即时定位与建图 (Simultaneous Localization And Mapping, SLAM) 作为移动机器人自主导航的基础, 对于地下探测与救援等任务尤为重要. 在典型的地下巷道环境中, 通常依赖于激光雷达 (Light Detection And Ranging, LiDAR) 与视觉相机的融合, 使其优势互补, 以解决地下照明不足、纹理稀缺以及结构单一等问题^[1], 从而实现传感器退化场景下的多模态 SLAM. 然而, 现有 SLAM 方案仅实现相对位姿估计, 而缺乏地下绝对位姿参考. 也就是说, 其位姿估计是局部准确的, 随着时间的推移会产生严重的累积误差^[2]. 虽然通过闭环检测方法在一定程度上缓解了 SLAM 的累积漂移问题, 并提高了地图一致性^[3]. 但地下空间错综复杂、多分支、少循环的巷道结构, 极大地限制了移动机器人的运动轨迹, 进而导致多模态 SLAM 的性能急剧降低^[4]. 同时, 随着 SLAM 应用于大规模、大范围的任务场景, 单个机器人面临感知范围受限、建图效率低下且缺乏容错性等问题, 难以实现长期稳定的运行.

在室外场景下, 传统 SLAM 方法通常结合全球导航卫星系统 (Global Navigation Satellite System, GNSS) 以实现全局定位^[5-7]. 但对于全球定位系统 (Global Positioning System, GPS) 拒止的地下环境来说, 基于无线射频的定位方法引起了广泛关注, 如 WiFi^[8]、蓝牙^[9]、LoRa^[10] 以及射频识别^[11]. 与上述方法相比, 超宽带 (Ultra-WideBand, UWB) 采用基于双向飞行时间的测距方法, 具有时空分辨率高、穿透能力强及抗多径效应等优势^[12,13], 不仅能够实现移动机器人全局定位, 使其在复杂地下环境中避免累计漂移, 还可保障多智能体协同的全局一致性. 然而, 由于移动机器人计算资源有限, 难以执行完整的多模态 SLAM. 为此, 集中式协同 SLAM 通过在本地图执行轻量级或时间敏感型任务 (如视觉或激光雷达跟踪), 并将计算密集型任务 (如位姿优化) 卸载至边缘服务器^[14-16], 从而有效缓解移动机器人资源短缺问题^[17].

尽管边缘计算与 UWB 技术促进多智能体协同

SLAM 取得了重大进展, 但对于资源受限的地下环境来说, 多传感器融合^[18]与多智能体协同^[19]加剧了计算与通信资源的急剧消耗, 大量传感数据与优化请求上传至边缘服务器^[20], 易导致无线链路饱和、延迟增加及计算性能瓶颈等问题, 并随着智能体数量的增加, 网络带宽需求与边缘计算负载呈指数级上升^[21,22]. 总的来说, 大规模地下场景中多智能体协同仍面临以下挑战.

(1) 多传感器紧耦合. 现有的松耦合框架难以应对传感器性能严重退化的地下环境, 且分布式多智能体协同 SLAM 方案难以在资源受限的移动机器人上独立执行. 激光雷达、视觉相机、UWB 及惯性测量单元各自具备独特优势, 考虑到传感器差异与计算实时性等问题, 不恰当的融合可能会引入冗余计算, 显著增加算法复杂度, 从而加剧计算资源的消耗.

(2) 全局地图一致性. 在边缘辅助框架下, 多智能体协同 SLAM 的全局一致性主要依赖于边缘优化结果. 然而, 在复杂地下场景中, 由于多径效应和非视距传播的普遍存在, 导致上传至边缘服务器的全局位姿估计存在不同程度的偏差. 同时, UWB 仅服务于单一智能体的局部优化, 使得多智能体之间缺乏直接的相对约束以及足够的共享观测, 从而影响全局一致性.

(3) 计算资源受限性. 在集中式协同架构下, 边缘服务器接收大量来自移动机器人的传感数据及其优化请求, 但考虑到地下空间有限的通信资源与计算瓶颈, 并且随着移动机器人规模的扩展, 对于通信与计算资源的需求呈指数增长, 而不同运行状态的移动机器人对等待延迟的敏感程度不同, 传统的先来先服务策略不可避免地加剧了时间敏感型任务的排队延迟与定位误差.

本文面向大规模复杂地下场景, 提出 UWB 紧耦合的多智能体端边协作 SLAM 方法 (Robots-edge Collaborative SLAM, Re-CoSLAM). 在边缘辅助的多模态 SLAM 框架下, 结合误差状态卡尔曼滤波 (Error State Kalman Filter, ESKF), 提出了 UWB 紧耦合绝对位姿估计方法. 基于此, 将其扩展至多智能体协同 SLAM 并设计了自适应传输机制. 同时, 提出了相对距离约束的联合位姿图优

化方法以提高全局一致性. 考虑到地下通信资源受限性以及边缘节点的计算瓶颈, 设计了基于请求优先级的任务调度策略, 从而降低排队延迟并提升系统可扩展性. 本文将 Re-CoSLAM 部署在 3 台搭载英伟达 Jetson Xavier NX 的移动机器人上, 在室内走廊、地下车库以及地下巷道等实际场景开展实验, 并与鲁棒、实时、辐射场重建的激光雷达-惯性-视觉状态估计器 (Robust, Real-Time, Radiance Reconstruction Package with LiDAR-Inertial-Visual State Estimator, R³LIVE++)^[23], 快速的激光雷达-惯性-视觉里程计 (Fast LiDAR-Inertial-Visual Odometry, FAST-LIVO)^[24] 及基于无迹卡尔曼滤波的 UWB 融合定位算法 (Unscented Kalman Filter-Ultra WideBand, UKF-UWB)^[25] 对比以验证其有效性.

2 多智能体端边协作 SLAM 框架

考虑到多模态 SLAM 难以直接在计算资源受限的移动机器人上完整地实时运行. 为此, 本文基于边缘辅助的多模态 SLAM 框架 (Edge-aided Multi-modal Collaborative SLAM, EM-CoSLAM)^[26], 如图 1 所示, 在移动机器人端执行激光雷达跟踪与局部建图, 在边缘服务器端执行耗时的视觉优化与全局建图, 包括光流跟踪、最小化重投影误差的帧间状态更新以及最小化光度误差的帧到地图状态更新. 移动机器人通过选取数据帧上传至边缘服务器, 双方发生通信, 边缘服务器将视觉优化结果下发至移动机器人更新位姿与局部地图.




图1 边缘辅助的多模态SLAM框架

面向大规模地下场景, 本文在边缘辅助的多模态 SLAM 基础上, 提出了 UWB 紧耦合的多智能体端边协作 SLAM 方法, 旨在扩展移动机器人的规模. 针对传感器退化、全局一致性以及计算资源受限问题, 本文提出了以下 3 个关键设计: (1) 结合误差状态卡尔曼滤波, 设计了 UWB 紧耦合绝对位姿估计方法, 以减小累计漂移误差, 为多智能体协同奠定基础; (2) 基于多智能体之间的 UWB 距离测量, 设计了相对距离约束的联合位姿图优化方法, 以保障全局一致性; (3) 通过评估智能体的运行状态, 设计了基于请求优先级的任务调度策略, 并建立多级队列以降低排队延迟并提高跟踪精度, 具体如图 2 所示.

移动机器人: 在激光雷达移动跟踪的基础上, 基于 UWB 距离测量并结合误差状态卡尔曼滤波实现 UWB

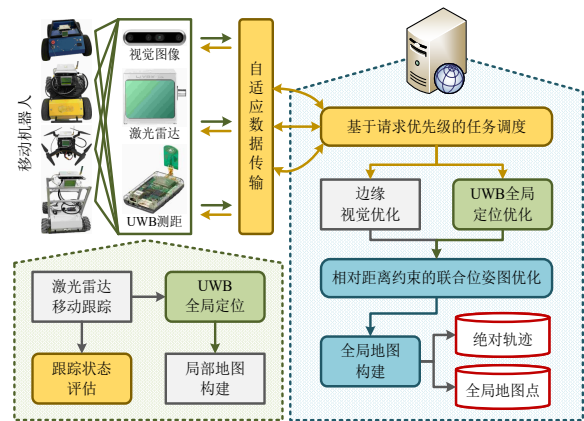


图2 UWB紧耦合的多智能体端边协作SLAM框架

紧耦合绝对位姿估计. 同时, 跟踪移动机器人的运行状态, 并将数据帧 (包括激光雷达点云、视觉图像、UWB 距离测量) 自适应上传至边缘服务器. 移动机器人根据边缘服务器下发的优化结果更新位姿与局部地图. 不同的是, 移动机器人在最大传输延迟约束下, 有效降低了网络带宽消耗. 通过向边缘服务器提供运行状态信息, 为其建立多级任务队列提供划分依据, 从而缓解边缘节点的计算瓶颈.

边缘服务器: 根据各移动机器人上传的运行状态及数据帧, 动态评估任务的紧急程度, 并基于请求优先级划分多级队列. 进而, 基于优先级调度策略执行优化任务, 包括边缘视觉优化、UWB 全局定位优化以及联合位姿图优化. UWB 全局定位优化通过最小化 UWB 距离测量残差以实现单个移动机器人的位姿优化. 而基于多智能体之间的相对距离测量, 可实现相对距离约束的多智能体联合位姿图优化. 需要特别指出的是, 鉴于联合位姿图优化过程复杂且耗时, 故与边缘视觉优化及 UWB 全局定位优化并行运行. 对于参与联合位姿图优化的移动机器人, 其全局位姿由联合优化直接确定, 无需参与单个移动机器人的 UWB 全局定位优化. 随后, 边缘服务器下发全局位姿与局部地图, 以提升本地跟踪的准确性.

自适应传输: 移动机器人与边缘服务器之间采用基于传输控制协议 (Transmission Control Protocol, TCP) 的套接字实现数据交互. 移动机器人上传至边缘服务器的数据帧包括 3 种类型: 激光雷达点云、视觉图像以及 UWB 距离测量. 对于处于异常状态, 即跟踪丢失、速度突变、UWB 测量失效的移动机器人, 优先上传其对应优化请求的数据帧, 以确保全局定位的准确性与实时性. 对于处于正常状态的移动机器人, 则综合考虑网络延迟、网络带宽、请求优先级、优化贡献度以及实时性要求, 在满足最大传输延迟约束的前提下, 自适应上传数据帧, 从而在保障实时跟踪与边缘优化的同时显著降低通信链路负载.

3 多智能体端边协作SLAM关键方法

3.1 UWB 紧耦合绝对位姿估计

本文通过建立 UWB 绝对坐标系以实现移动机器人全局定位与建图. 首先, 在多模态 SLAM 状态向量^[27]的基础上, 定义如下移动机器人全局状态向量:

$$\mathbf{x} = \left({}^G \mathbf{p}_I^T, {}^G \mathbf{R}_I^T, {}^G \mathbf{v}^T, \mathbf{b}_g^T, \mathbf{b}_a^T, {}^I \mathbf{p}_C^T, {}^I \mathbf{R}_C^T, {}^I \mathbf{p}_U^T \right)^T \quad (1)$$

其中, ${}^I \mathbf{p}_U$ 为 UWB 坐标系与惯性测量单元 (Inertial Measurement Unit, IMU) 坐标系的相对变换, 其余变量及 \boxplus 和 \boxminus 的定义与鲁棒、实时的激光雷达-惯性-视觉状态估计器 (Robust, Real-Time LiDAR-Inertial-Visual State Estimator, R²LIVE)^[28] 保持一致. 根据 IMU 运动模型, 可建立如下移动机器人全局状态传播模型:

$$\mathbf{x}_{k+1} = \mathbf{x}_k \boxplus \left(\Delta t \cdot f(\mathbf{x}_k, \mathbf{u}_k, \mathbf{w}_k) \right) \quad (2)$$

$$\mathbf{u}_k = \left(\boldsymbol{\omega}_k^T, \mathbf{v}_k^T \right)^T, \mathbf{w}_k = \left(\mathbf{n}_{g_k}^T, \mathbf{n}_{a_k}^T, \mathbf{n}_{b_{g_k}}^T, \mathbf{n}_{b_{a_k}}^T \right)^T \quad (3)$$

$$f(\mathbf{x}_k, \mathbf{u}_k, \mathbf{w}_k) = \begin{bmatrix} {}^G \mathbf{v}_k \\ \boldsymbol{\omega}_k - \mathbf{b}_{g_k} - \mathbf{n}_{g_k} \\ {}^G \mathbf{R}_{I_k} \left(\mathbf{v}_k - \mathbf{b}_{a_k} - \mathbf{n}_{a_k} \right) + {}^G \mathbf{g} \\ \mathbf{n}_{bg_k} \\ \mathbf{n}_{ba_k} \\ \mathbf{0}_{3 \times 1} \\ \mathbf{0}_{3 \times 1} \\ \mathbf{0}_{3 \times 1} \end{bmatrix} \quad (4)$$

其中, $(\boldsymbol{\omega}_k^T, \mathbf{v}_k^T)$ 为陀螺仪与加速度计测量; $(\mathbf{n}_{g_k}^T, \mathbf{n}_{a_k}^T)$ 表示惯性测量白噪声; $(\mathbf{n}_{b_{g_k}}^T, \mathbf{n}_{b_{a_k}}^T)$ 为陀螺仪与加速度计偏差. 通过误差状态卡尔曼滤波^[29] 估计状态向量 \mathbf{x}_k , 其状态估计误差 $\delta \hat{\mathbf{x}}_k$ 可由状态估计 $\hat{\mathbf{x}}_k$ 表示如下:

$$\begin{aligned} \delta \hat{\mathbf{x}}_k &\triangleq \mathbf{x}_k \boxminus \hat{\mathbf{x}}_k \\ &= \left({}^G \delta \hat{\mathbf{p}}_{I_k}^T, {}^G \delta \hat{\mathbf{r}}_{I_k}^T, {}^G \delta \hat{\mathbf{v}}_k^T, \delta \hat{\mathbf{b}}_{g_k}^T, \delta \hat{\mathbf{b}}_{a_k}^T, {}^I \delta \hat{\mathbf{p}}_{C_k}^T, {}^I \delta \hat{\mathbf{r}}_{C_k}^T, {}^I \delta \hat{\mathbf{p}}_{U_k}^T \right)^T \\ &\sim \mathcal{N} \left(\mathbf{0}_{24 \times 1}, \sum_{\delta \hat{\mathbf{x}}_k} \right) \end{aligned} \quad (5)$$

其中, $\delta \hat{\mathbf{x}}_k \in \mathbb{R}^{24}$ 表示系统状态向量的维度为 24, 其协方差为 $\sum_{\delta \hat{\mathbf{x}}_k}$, 且 $\delta \hat{\mathbf{r}}_k^T = \log(\hat{\mathbf{R}}_k^T \mathbf{R}_k)$.

状态预测: 在 IMU 预测过程中, 通过将过程噪声 \mathbf{w}_k 设为 0, 得到移动机器人的全局状态 $\bar{\mathbf{x}}_k$ 传播如下:

$$\begin{aligned} \delta \bar{\mathbf{x}}_{k+1} &= \mathbf{x}_{k+1} \boxminus \bar{\mathbf{x}}_{k+1} \\ &= \left(\mathbf{x}_k \boxplus \left(\Delta t \cdot f(\mathbf{x}_k, \mathbf{u}_k, \mathbf{w}_k) \right) \right) \boxminus \left(\bar{\mathbf{x}}_k \boxplus \left(\Delta t \cdot f(\bar{\mathbf{x}}_k, \mathbf{u}_k, \mathbf{0}) \right) \right) \\ &\approx \mathbf{F}_{\delta \bar{\mathbf{x}}} \delta \bar{\mathbf{x}} + \mathbf{F}_w \mathbf{w}_k \\ &\sim \mathcal{N} \left(\mathbf{0}_{24 \times 1}, \sum_{\delta \bar{\mathbf{x}}_{k+1}} \right) \end{aligned} \quad (6)$$

进而, 状态估计误差传播可计算如下:

$$\begin{aligned} \delta \bar{\mathbf{x}}_{k+1} &= \mathbf{x}_{k+1} \boxminus \bar{\mathbf{x}}_{k+1} \\ &= \left(\mathbf{x}_k \boxplus \left(\Delta t \cdot f(\mathbf{x}_k, \mathbf{u}_k, \mathbf{w}_k) \right) \right) \boxminus \left(\bar{\mathbf{x}}_k \boxplus \left(\Delta t \cdot f(\bar{\mathbf{x}}_k, \mathbf{u}_k, \mathbf{0}) \right) \right) \\ &\approx \mathbf{F}_{\delta \bar{\mathbf{x}}} \delta \bar{\mathbf{x}} + \mathbf{F}_w \mathbf{w}_k \\ &\sim \mathcal{N} \left(\mathbf{0}_{24 \times 1}, \sum_{\delta \bar{\mathbf{x}}_{k+1}} \right) \end{aligned} \quad (7)$$

其中, $\sum_{\delta \bar{\mathbf{x}}_{k+1}}$, $\mathbf{F}_{\delta \bar{\mathbf{x}}}$ 以及 \mathbf{F}_w 可由 R²LIVE^[28] 得到.

UWB 更新: 根据所提供的 UWB 基站与移动节点之间的距离测量, 其测量模型定义如下:

$$z_k = h \left({}^U \mathbf{p}_k, {}^U \mathbf{p}_0 \right) + n_k, \quad n \sim \mathcal{N} \left(0, \sigma_n^2 \right) \quad (8)$$

其中, ${}^U \mathbf{p}_k$ 表示 UWB 全局定位系统中移动节点的坐标位置, 也就是移动机器人的全局坐标位置; ${}^U \mathbf{p}_0$ 为 UWB 基站的全局坐标; n 为测量噪声; $h(\cdot)$ 表示距离函数, 用于计算 UWB 移动节点与基站之间距离:

$$\begin{aligned} h \left({}^U \mathbf{p}_k, {}^U \mathbf{p}_0 \right) \\ = \sqrt{\left({}^U p_{k_x} - {}^U p_{0_x} \right)^2 + \left({}^U p_{k_y} - {}^U p_{0_y} \right)^2 + \left({}^U p_{k_z} - {}^U p_{0_z} \right)^2} \end{aligned} \quad (9)$$

假设 $\hat{\mathbf{x}}_k$ 是当前迭代中 \mathbf{x}_k 的状态估计, 则 ${}^U \mathbf{p}_k$ 的位置估计 ${}^U \hat{\mathbf{p}}_k$ 如下:

$${}^U \hat{\mathbf{p}}_k = {}^G \hat{\mathbf{R}}_{I_k} {}^I \hat{\mathbf{p}}_{U_k} + {}^G \hat{\mathbf{p}}_{I_k} \quad (10)$$

进而可得到 k 时刻 UWB 测量矩阵计算如下:

$$\mathbf{H}_k^u = \frac{\partial h}{\partial \delta \mathbf{x}_k} = \frac{\partial h}{\partial {}^U \mathbf{p}_k} \cdot \frac{\partial {}^U \mathbf{p}_k}{\partial \mathbf{x}_k} \cdot \frac{\partial \mathbf{x}_k}{\partial \delta \mathbf{x}_k} \quad (11)$$

其中,

$$\frac{\partial h}{\partial {}^U \mathbf{p}_k} = \left(\frac{{}^U \hat{\mathbf{p}}_{k_x} - {}^U p_{0_x}}{h({}^U \hat{\mathbf{p}}_k, {}^U \mathbf{p}_0)}, \frac{{}^U \hat{\mathbf{p}}_{k_y} - {}^U p_{0_y}}{h({}^U \hat{\mathbf{p}}_k, {}^U \mathbf{p}_0)}, \frac{{}^U \hat{\mathbf{p}}_{k_z} - {}^U p_{0_z}}{h({}^U \hat{\mathbf{p}}_k, {}^U \mathbf{p}_0)} \right) \quad (12)$$

$$\frac{\partial {}^U \mathbf{p}_k}{\partial {}^G \mathbf{p}_k} \cdot \frac{\partial {}^G \mathbf{p}_k}{\partial {}^G \delta \mathbf{p}_k} = \mathbf{I}_3 \quad (13)$$

$$\frac{\partial {}^U \mathbf{p}_k}{\partial {}^G \mathbf{R}_{I_k}} \cdot \frac{\partial {}^G \mathbf{R}_{I_k}}{\partial {}^G \delta \mathbf{r}_{I_k}} = - {}^G \mathbf{R}_{I_k} \left[{}^I \mathbf{p}_{U_k} \right] \quad (14)$$

$$\frac{\partial {}^U \mathbf{p}_k}{\partial {}^I \mathbf{p}_{U_k}} \cdot \frac{\partial {}^I \mathbf{p}_{U_k}}{\partial {}^I \delta \mathbf{p}_{U_k}} = {}^G \mathbf{R}_{I_k} \quad (15)$$

进一步, 图 3 说明了基于误差状态卡尔曼滤波的多传感器测量更新过程与频率, 其中 IMU、相机、激光雷达与 UWB 的更新频率, 也就是采样频率, 分别为 100、30、10 以及 40 Hz.

基于上述 UWB 测量模型以及激光雷达与视觉测量模型进行移动机器人全局状态与误差状态更新. 需要说明的是, 在本文中, 激光雷达与视觉测量更新与 R³LIVE^[27] 一致, 而 UWB 测量更新过程类似于 ESKF-Fusion^[30]. 由于多传感器之间缺乏严格的时间同步, 本




图3 误差状态卡尔曼滤波测量更新说明

文采用异步测量更新机制,即每接收到一个传感器的测量数据,便进行一次测量更新.因此,不同传感器(如UWB、激光雷达、视觉相机、IMU)的测量数据具有相同的权重,即更新增益仅由测量噪声决定.针对传感器退化场景,本文根据卡尔曼滤波的时序更新特性,当某一传感器在当前时刻出现退化(如UWB信号遮挡、点云稀疏或图像纹理缺失),导致测量更新失败或精度下降时,利用随后时间点接收到来自另一传感器的有效测量来修正状态估计误差.通过多传感器在时间序列上的互补,实现了UWB紧耦合绝对位姿估计,而不是通过同一时刻的权重分配.

3.2 相对距离约束的位姿优化

为进一步实现可扩展的多智能体协同SLAM,本文在UWB紧耦合绝对位姿估计的基础上,设计了相对距离约束的位姿优化方法,以提高全局定位精度并保障全局地图一致性.在本文所提出的多智能体端边协作SLAM框架中,边缘服务器不仅可以获取移动机器人与UWB基站之间的绝对距离测量,还可获取与其他智能体之间的相对距离测量.因此,对于 k 时刻移动机器人的UWB距离测量,其测量残差可表示为

$$\mathbf{r}_u(\bar{\mathbf{x}}_k, \mathbf{z}_{k,i}) = \mathbf{z}_{k,i} - h(\mathbf{p}_k, \mathbf{p}_{k,i}) \quad (16)$$

其中, $\mathbf{p}_{k,0}$ 和 $\mathbf{z}_{k,0}$ 分别为 k 时刻UWB基站的全局坐标及其之间的距离测量; $\mathbf{p}_{k,i}$ 和 $\mathbf{z}_{k,i}$, $i=1,2,\dots,n$ 表示第 i 个智能体的全局坐标及与其之间的距离测量; $\bar{\mathbf{x}}_k$ 为 \mathbf{x}_k 的最大后验分布.由UWB测量方程可知残差模型的一阶泰勒展开式为

$$\mathbf{0} = \mathbf{r}_u(\mathbf{x}_k, \mathbf{z}_{k,i}^{\text{gt}}) \approx \mathbf{r}_u(\bar{\mathbf{x}}_k, \mathbf{z}_{k,i}) + \mathbf{H}_{k,i}^u \delta \bar{\mathbf{x}}_k + \mathbf{n}_{k,i} \quad (17)$$

其中, $\mathbf{H}_{k,i}^u$ 的计算与上述 \mathbf{H}_k^u 一致.

进一步,结合IMU的先验分布以及UWB距离测量,移动机器人的最大后验估计 $\delta \bar{\mathbf{x}}_k$ 可计算如下:

$$\min_{\delta \bar{\mathbf{x}}_k} \left\{ \left\| \bar{\mathbf{x}}_k \boxminus \hat{\mathbf{x}}_k + \mathcal{H} \delta \bar{\mathbf{x}}_k \right\|_{\Sigma}^2 + \sum_{i=0}^n \left\| \mathbf{r}_u(\bar{\mathbf{x}}_k, \mathbf{z}_{k,i}) + \mathbf{H}_{k,i}^u \delta \bar{\mathbf{x}}_k \right\|_{\Sigma_i}^2 \right\} \quad (18)$$

其中, \mathcal{H} 以及 $\|\mathbf{x}\|_{\Sigma}^2$ 的计算与R²LIVE^[28]保持一致.令

$$\mathbf{H} = [\mathbf{H}_0^u \mathbf{T} \dots \mathbf{H}_n^u \mathbf{T}]^T \quad (19)$$

$$\mathbf{R} = \text{diag} \left[\sum_{n_0} \dots \sum_{n_n} \right] \quad (20)$$

$$\bar{\mathbf{z}}_k = \left(\mathbf{r}_u(\bar{\mathbf{x}}_k, \mathbf{z}_{k,0}), \dots, \mathbf{r}_u(\bar{\mathbf{x}}_k, \mathbf{z}_{k,n}) \right)^T \quad (21)$$

$$\mathbf{P} = (\mathcal{H})^{-1} \sum_{\delta \bar{\mathbf{x}}_k} (\mathcal{H})^{-T} \quad (22)$$

根据快速的激光雷达-惯性里程计(Fast Direct LiDAR-Inertial Odometry, FAST-LIO2)^[29],卡尔曼滤波的增益矩阵可通过如下计算:

$$\mathbf{K} = (\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H} + \mathbf{P}^{-1})^{-1} \mathbf{H}^T \mathbf{R}^{-1} \quad (23)$$

进而,基于UWB相对距离约束的移动机器人全局状态估计更新如下:

$$\hat{\mathbf{x}}_k = \bar{\mathbf{x}}_k \boxplus \left(-\mathbf{K} \bar{\mathbf{z}}_k - (\mathbf{K} - \mathbf{K} \mathbf{H}) (\mathcal{H})^{-1} (\bar{\mathbf{x}}_k \boxminus \hat{\mathbf{x}}_k) \right) \quad (24)$$

由于上述UWB相对距离测量仅服务于单一移动机器人自身的局部优化,多智能体之间仍缺乏直接的相对位姿约束以及足够的共享观测,难以保障全局一致性.为此,本文在单目视觉-惯性状态估计器(Monocular Visual-Inertial State Estimator, VINS-Mono)^[31]的基础上,提出了相对距离约束的多智能体联合位姿图优化方法,如图4所示.




图4 相对距离约束的多智能体联合位姿图优化

对于同一移动机器人的顺序边与闭环边的测量残差 $\mathbf{r}_{m,n}(\mathbf{p}, \mathbf{t})$ 与VINS-Mono^[31]基本一致,其中 \mathbf{p} 和 \mathbf{t} 分别为机器人的位置和姿态.对于跨机器人边,机器人 i 和 j 的距离测量残差 $r_{i,j}(\mathbf{p}, \mathbf{t})$ 可计算如下:

$$r_{i,j}(\mathbf{p}, \mathbf{t}) = h(\mathbf{p}_i, \mathbf{p}_j) - \mathbf{z}_{i,j} \quad (25)$$

其中, \mathbf{p}_i 和 \mathbf{p}_j 分别为机器人 i 和 j 的位置估计; $\mathbf{z}_{i,j}$ 表示机器人 i 和 j 之间的相对距离测量.进而,通过最小化如下代价函数可实现多智能体联合位姿图优化:

$$\min_{\mathbf{p}, \mathbf{t}} \left\{ \sum_{(m,n) \in \mathcal{S}} \|\mathbf{r}_{m,n}\|^2 + \sum_{(m,n) \in \mathcal{L}} \rho(\|\mathbf{r}_{m,n}\|^2) + \sum_{(i,j) \in \mathcal{I}} \|r_{i,j}\|^2 \right\} \quad (26)$$

其中, $\mathbf{r}_{m,n}$ 为移动机器人帧 m 和 n 之间的测量残差; \mathcal{S} 、 \mathcal{L} 和 \mathcal{I} 分别是顺序边、闭环边以及跨机器人边的集合; ρ 表示Huber范数.上述多智能体联合位姿图优化为非线性最小二乘优化问题,可通过Levenberg-Marquardt算

法^[32]求解,其收敛性与初始值相关,在大多数情况下可收敛到正确解.随着时间的推移及移动机器人规模的扩大,其算法复杂度可能会呈指数级增长.为此,本文引入了基于滑动窗口的优化方法以降低计算复杂度.基于上述多智能体联合位姿图优化保障了边缘服务器端的全局一致性,并将优化结果下发至各移动机器人,从而提高了跟踪性能.

3.3 基于请求优先级的任务调度

由于地下巷道结构单一且电磁干扰严重,移动机器人在实际作业过程中面临累积漂移及UWB测量丢失,从而导致全局定位精度急剧下降.在端边协作的多智能体协同SLAM框架下,移动机器人的定位精度依赖于边缘服务器的优化质量.然而,随着参与多智能体协同SLAM的移动机器人数量逐渐增多,其优化请求同时集中至边缘服务器易造成计算瓶颈,进而引发额外的任务排队延迟.更为关键的是,由于不同运行状态的移动机器人对于等待延迟的容忍程度存在差异,传统先来先服务的任务调度策略可能会严重影响时间敏感型移动机器人的跟踪精度.

为此,受SwarmMap^[21,22]启发,本文设计了基于请求优先级的任务调度策略,旨在降低排队延迟并提升多智能体协同SLMA的可扩展性,如图5所示.移动机器人的优化请求包括3种类型:视觉优化、UWB全局定位优化和联合位姿图优化.边缘服务器根据移动机器人的运行状态将其划分为紧急组和非紧急组,并采取以下原则对任务请求重新排序:(1)对于紧急组的移动机器人,其优化请求分为视觉优化与UWB全局优化,其中优先考虑视觉优化请求,以防止跟踪丢失;(2)对于非紧急组的移动机器人,优先考虑视觉优化请求以保障跟踪实时性,其次考虑联合位姿图优化请求以提升全局地图的一致性.在实际运行过程中,各移动机器人周期性地上传其运行状态至边缘服务器,边缘服务器通过评估其运行状态将对应任务请求划分至多级队列,并按照队列优先级实现基于请求优先级的任务调度,具体如下.

移动机器人:为了保障边缘服务器了解移动机器人的运行状态变化,在其定期上传数据帧的同时发送其状态描述指标,具体定义如下.

(1)跟踪状态:采用1位布尔值表示移动机器人是否跟踪丢失.若可拟合最近平面的激光雷达特征点数量不足(通常特征点数量不少于150个),则将移动机器人的跟踪状态设置为0,表示激光雷达跟踪丢失;否则,将移动机器人的跟踪状态设置为1,表示激光雷达跟踪正常.

(2)UWB测量:采用1位布尔值表示移动机器人是否能够接收UWB基站的距离测量.若在连续多个采样

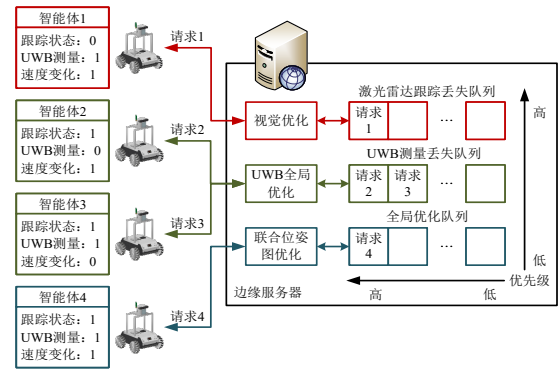


图5 基于请求优先级的任务调度

周期内未接收到有效距离测量(通常不超过连续10个采样周期),可能导致全局定位性能下降,则将UWB测量设置为0,表示距离测量丢失;否则,将UWB测量设置为1,表示距离测量正常.

(3)速度变化:采用1位布尔值表示移动机器人的速度(包括线速度与角速度)是否突然变化,速度突变导致点云畸变、图像模糊,进而可能会造成激光雷达跟踪失败或视觉优化失效.若当前运动速度相较于最近多帧的平均速度高出20%以上,则将速度变化设置为0,表示移动机器人速度突变;否则,将速度变化设置为1,表示移动机器人稳定运行.

边缘服务器:根据移动机器人上传的状态描述指标,评估任务紧急程度并将其对应的优化请求分配至以下具有不同优先级的任务队列中.

(1)激光雷达跟踪丢失队列:若移动机器人的跟踪状态被标记为1,则将其视觉优化请求分配至此队列中.边缘服务器通过地图点投影,帧间光流法跟踪及帧到地图最小化光度误差进行视觉优化,以修正激光雷达位姿估计,并将其优化结果下发至对应的移动机器人进行更新.

(2)UWB测量丢失队列:若移动机器人存在速度突变或UWB测量丢失,则将其UWB全局定位优化请求分配到此队列中.边缘服务器根据当前移动机器人与其他机器人之间的相对距离测量,采用误差状态卡尔曼滤波进行全局定位优化,并将结果反馈至对应的移动机器人.

(3)全局优化队列:对于运行状态稳定的移动机器人,则将其优化请求分配到此队列中,包括视觉优化以及联合位姿图优化,其中队列排序优先考虑视觉优化,其次为联合位姿图优化任务.尽管联合位姿图优化计算代价较高,但其能够实现多智能体间的协同优化,并将优化结果分发至各移动机器人,从而有效降低了单独执行UWB全局定位优化的计算负担并提高了全局一致性.

在上述队列中,激光雷达跟踪丢失队列的任务优

优先级最高,其次是UWB测量丢失队列和全局优化队列.边缘服务器接收到移动机器人的优化请求后,根据其状态描述指标将优化任务分配至相应队列中,并按优先级顺序依次执行,从而在边缘节点出现计算瓶颈时避免排队延迟并提升定位性能.

4 实验与评估

4.1 实验设置与部署

实验设置.本文在端边协作多模态SLAM算法EM-CoSLAM^[26]的基础上,严格遵循边缘端全局优化与移动端实时跟踪,进而实现了多智能体端边协作SLAM.Re-CoSLAM具备良好的通用性与扩展性,可适配其他多模态SLAM算法,如FAST-LIVO^[24].考虑到边缘服务器的计算资源受限性,基于Ubuntu20.04操作系统,边缘端部署在边缘计算节点(AMD Ryzen7 4800HS CPU与16 GB RAM)上,承担边缘视觉优化、全局地图构建、联合位姿图优化等计算密集型任务.移动端则部署在3台搭载英伟达Jetson Xavier NX板载计算机(ARM v8 CPU与8 GB RAM)的移动机器人上,用于实现激光雷达点云、视觉图像、UWB与IMU等多模态数据采集以及绝对位姿估计与局部地图构建等实时任务,并通过Wi-Fi与边缘服务器通信.此外,每台移动机器人均搭载UWB移动节点,可获取与UWB基站及其他移动机器人之间的距离.

实验场景与设备.基于上述实验设置,本文分别在典型室内走廊、地下车库以及传感器退化的地下实验室巷道场景中开展实验与评估,如图6所示.在不同场景下均布设了4个由时域公司(Time Domain)生产的P440 UWB基站,用于建立统一的全局坐标系.同时,为了获取移动机器人的位姿真值,本文采用度量科技公司(NOKOV)的三维光学动作捕捉系统,通过红外光学镜头捕获反光标志点位置,以其提供的亚毫米级定位精度评估所提方法的性能,而影响其定位精度的因素主要包括镜头分辨率、镜头视场、标定质量以及镜头数量.在本实验中,采用了8个红外光学镜头,其分辨率和视场分别为 $1\,280 \times 1\,024$ 与 $56^\circ \times 46^\circ$.

NOKOV的部署主要在于使用前的镜头标定,以捕获反光标志点在全局坐标系的位置.根据标定结果,其




图6 不同实验场景与设备

定位误差不超过2 mm.由于红外光学镜头数量有限,导致其捕获位姿真值的范围受限,其最大范围不超过10 m.本实验旨在验证多智能体协同SLAM的可扩展性,随着智能体数量的增加,其场景规模与作业效率也随之扩大.此外,本文所搭建的移动机器人SLAM平台如图7所示,搭载了P440 UWB移动节点、英特尔RealSense D455相机、LIVOX AVIA激光雷达及其内置IMU,其采样频率分别40、30、10以及100 Hz.

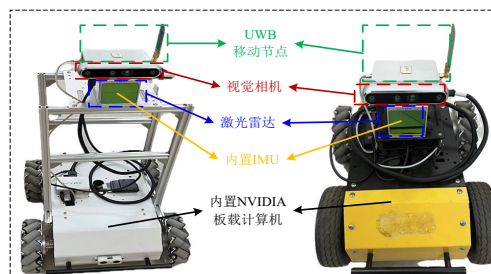


图7 移动机器人平台与传感器

4.2 性能对比与评估

由于单个智能体的建图效率与覆盖范围有限,引入多智能体协同可在相同的作业时间内显著提升建图效率,并随着智能体数量的增加可进一步扩大其作业范围.不同场景下不同移动机器人的地图构建,如图8所示.移动机器人3号单独完成场景建图可能耗时60 s,而通过移动机器人1号与移动机器人2号的协同,整个场景的建图时间将显著降低.为了直观地描述Re-CoSLAM的定位性能,对比不同场景下不同移动机器人的绝对定位轨迹,如图9所示.可以看出,Re-CoSLAM在常规室内走廊及地下车库场景下实现了准确的多智能体协同定位,更重要的是,在传感器特征退化的地下巷道中依然保持了稳定、可靠的定位性能,显著降低了传统SLAM算法中的累积漂移,验证了Re-CoSLAM在复杂环境中的有效性和鲁棒性.

如图10(a)所示,其中Re-CoSLAM对应80%的绝对定位误差保证在15 cm以内,显著优于其他方法.相较之下, $R^3LIVE++$ ^[23]及FAST-LIVO^[24]为典型的相对定位算法,易产生累积漂移,即使通过坐标变换将其转换至绝对坐标系,其对应80%的误差仍远超30 cm.而UKF-UWB作为绝对定位算法^[25],提供了仅次于Re-CoSLAM的绝对轨迹误差,其对应80%误差在30 cm以内.图10(b)进一步揭示了不同场景下绝对轨迹误差统计.结果表明,Re-CoSLAM在地下巷道中的平均定位误差仅为6.5 cm,与室内走廊和地下车库场景相比,定位精度分别提高11%与19.8%,凸显了其在传感器退化场景下的优势.由于缺乏全局约束,多模态SLAM算法 $R^3LIVE++$ 与FAST-LIVO的累积漂移问题在退化场景中持续扩大.与其相比,Re-CoSLAM

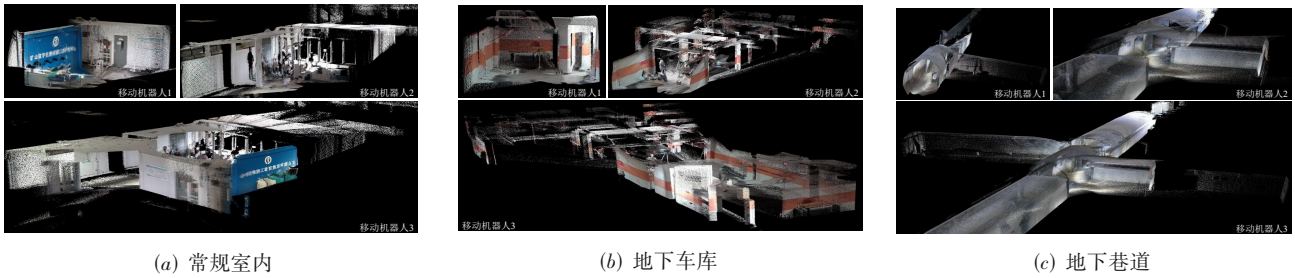


图8 不同场景下不同移动机器人的地图构建

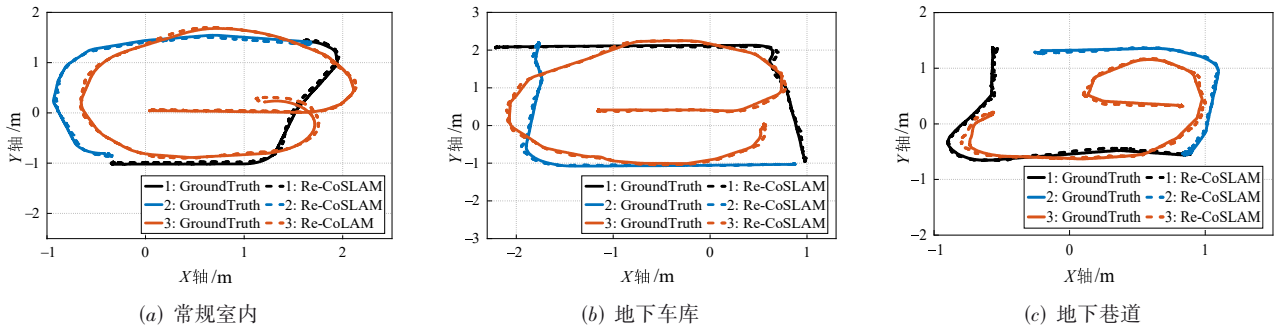


图9 不同场景下不同移动机器人的绝对定位轨迹

的定位精度提升了75%以上.与绝对定位算法UKF-UWB相比,Re-CoSLAM的性能仍提升了53.5%.

此外,不同算法在不同场景下的系统延迟,如图10(c)所示.由图可知,相较于R³LIVE++提供的161.2 ms系统延迟,Re-CoSLAM将视觉优化与多智能体联合优化任务卸载至边缘服务器,使其在提升性能的同时,系统延迟降低了50%以上,与FAST-LIVO仅相差10 ms以内.值得注意的是,在地下巷道场景中,由于激光雷达点云与视觉图像的有效特征较少,整体计算负载下降,使得系统延迟相较于室内走廊与地下车库场景有所

降低.UKF-UWB采用低计算复杂度的无迹卡尔曼滤波算法,使其能够在UWB采样周期内完成一次定位,故其系统延迟与UWB采样周期一致,仅25 ms,但由于缺乏环境感知能力,难以满足地下探测与救援任务需求.

表1总结了不同场景下不同算法的定位精度与系统延迟.总的来说,Re-CoSLAM实现了7.3 cm的平均绝对轨迹误差以及13 帧/秒的运行速度.与基线方法R³LIVE++相比,性能提升了50%以上,与FAST-LIVO相比,定位精度提高了81.6%,而系统运行速度仅降低了15.7%.




图10 不同场景下不同算法的性能对比

4.3 不同因素的影响

4.3.1 智能体规模的影响

本文在地下巷道场景中对Re-CoSLAM的可扩展性及多智能体协同策略的有效性进行了评估.图11(a)描


述了不同移动机器人数量下绝对轨迹误差的累积分布函数.可以看出,随着移动机器人数量的增加,相对距离约束逐渐增强,进而Re-CoSLAM能够通过联合位姿图优化显著提升定位精度.与单个移动机器人定位相

表 1 不同场景下不同算法的性能


单位: $\text{cm}\cdot\text{ms}^{-1}$

不同算法	室内走廊		地下车库		地下巷道	
	平均误差	系统延迟	平均误差	系统延迟	平均误差	系统延迟
FAST-LIVO	29.7	66.3	48.0	72.2	42.8	50.4
R ³ LIVE++	24.7	195.4	34.8	162.5	38.9	125.7
UKF-UWB	14.8	25.0	16.9	25.0	15.1	25.0
SUM-SLAM	7.3	78.6	8.1	75.2	6.5	65.1

比,当扩展至3台移动机器人协同工作时,定位误差下降了25.5%。然而,移动机器人规模的扩大也会带来额外的计算开销。不同移动机器人数量对系统延迟的影响,如图11(b)所示。结果表明,Re-CoSLAM在降低定位误差的同时也增加了系统延迟,与单个移动机器人58.8 ms的系统延迟相比,3台移动机器人的平均系统延迟仅增加了12.4%,仍保持在可接受范围内。这说明了Re-CoSLAM具备良好的计算可扩展性,适用于多智能体协同的地下作业任务。



(a) 不同移动机器人数量下绝对轨迹误差的 CDF




(b) 不同移动机器人数量下的系统延迟

图 11 不同移动机器人数量下的系统性能评估


4.3.2 不同优化策略的影响

图12(a)揭示了不同场景下不同移动机器人的绝对轨迹误差统计。由图可知,Re-CoSLAM通过联合位姿图优化使得不同移动机器人之间的误差明显降低,尤其在地下车库与地下巷道场景中,其定位精度的差异不超过1 cm,显著提升了全局一致性。不同场景下不同

移动机器人的系统延迟,如图12(b)所示。对于单个移动机器人,联合位姿图优化方法在提升性能的同时优化并下发3台移动机器人位姿,使得其系统延迟相差不超过10 ms。




(a) 移动机器人的绝对轨迹误差




(b) 移动机器人的系统延迟

图 12 不同场景下不同移动机器人的性能

不同定位优化策略对于定位性能以及计算延迟的影响,如图13所示。图13(a)表明,通过结合UWB全局定位,使得绝对轨迹误差降低了60%以上。在此基础上,Re-CoSLAM引入了相对距离约束的联合位姿图优化方法,定位精度进一步提升了28.6%。此外,联合位姿图优化问题的规模对于计算延迟的影响,如图13(b)所示,其中分别表示仅两台移动机器人存在1组相对距离约束、3台机器人存在2组相对距离约束以及3台机器人存在3组相对距离约束。结果表明,得益于滑动窗口的优化策略,使得计算延迟随着时间的推移逐渐保持稳定。同时,相对距离约束条件的增加未引入显著的额外延迟,不同约束规模下的计算延迟差异较小。



(a) 不同定位优化策略下的 CDF




(b) 不同距离约束下的计算延迟

图 13 不同定位优化策略的影响


随着移动机器人规模的扩展,边缘服务器的优化请求量呈指数级增长,造成优化线程排队等待,从而导致移动机器人跟踪性能下降.图 14(a)对比了先来先服务调度与请求优先级调度策略在系统性能上的差异.可以看出,基于请求优先级的任务调度显著提高了资源分配效率,其绝对轨迹误差与系统延迟分别为 6.8 cm 与 61.9 ms.相较于先来先服务调度策略,请求优先级调度策略的定位性能提升了 38.9%,且系统延迟降低了 21.2%,验证了其在多智能体协同场景下有效性.移动机器人数量的增加同样加剧了网络传输带宽的需求.图 14(b)揭示了不同网络传输策略下的性能评估.结果表明,在最大传输延迟约束下,自适应传输策略使得网络带宽消耗相较于传统的周期性传输策略降低了 32.8%,且传输延迟降低了 35.5%,有效缓解了网络带宽压力,保障了移动机器人与边缘服务器之间的通信效率.

4.3.3 网络传输条件的影响

在地下场景中,Wi-Fi链路的传输速率对系统性能同样有着显著影响.不同网络传输条件对系统性能的影响,如图 15所示.由于传感器的时间异步性,不同时刻上传至边缘服务器的传感器数据存在传输延迟差异.从图 15(a)可以看出,Wi-Fi 2.4 G 下的传输延迟显著增加.所提出的端边协作框架可有效降低传输延迟对系统性能的影响.不同网络条件下的绝对轨迹误差与系统延迟,如图 15(b)所示.结果表明,尽管 Wi-Fi



(a) 不同调度策略下的系统性能



(b) 不同传输策略下系统性能

图 14 不同协同策略下的系统性能对比

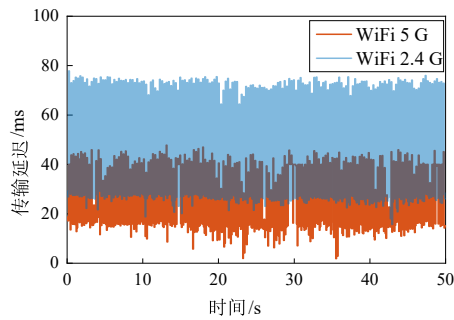
2.4 G 条件下的传输延迟远高于 Wi-Fi 5 G,但其绝对轨迹误差及系统延迟的差异仅在 0.5 cm 与 10 ms 以内.上述实验表明了所提出优化策略的有效性及其对于无线链路的鲁棒性.

4.3.4 算力分析与评估


面对地下空间中计算资源有限的移动机器人,也就是在内存与 CPU 算力受限条件下,本文所提出的 Re-CoSLAM 旨在提升多智能体协同的准确性与实时性.为验证其有效性,图 16 揭示了不同设备下基线方法 R³LIVE++ 与 Re-CoSLAM 的内存占用情况.结果表明,R³LIVE++ 在移动机器人上的内存占用率随时间呈线性增长,且 70% 以上.由于地图存储与维护作为内存消耗的主要来源,Re-CoSLAM 仅在移动机器人上进行局部建图,故而有效降低了内存消耗,其内存占用率逐渐稳定在 50%.同时,Re-CoSLAM 在边缘服务器上进行全局建图,其内存占用率逐渐稳定在 70%.

此外,不同方法下不同设备的 CPU 占用率,如图 17 所示.可以看出,R³LIVE++ 与 Re-CoSLAM 在移动机器人上的 CPU 占用率均达到了 90% 以上,这是由于 SLAM 属于 CPU 密集型任务.尽管 Re-CoSLAM 通过卸载部分任务至边缘服务器,缓解了移动机器人的计算压力,但为了进一步降低系统延迟,其 CPU 仍保持高负载运行以实时处理传感数据与跟踪任务.

为了验证 Re-CoSLAM 的稳定性,本文在不同场景




(a) 不同网络条件下的传输延迟




(b) 不同网络条件下的系统性能

图 15 不同网络传输条件的影响




(a) R³LIVE++




(b) Re-CoSLAM

图 17 不同方法下不同设备的CPU占用率



(a) R³LIVE++



(b) Re-CoSLAM

图 16 不同方法下不同设备的内存占用率

表 2 不同场景下所提方法的定位误差统计 单位: cm

不同场景	平均误差	均方根误差
室内走廊	7.43 ± 0.42	10.3 ± 0.79
地下车库	8.17 ± 0.31	10.77 ± 0.25
地下巷道	6.6 ± 0.27	8.53 ± 0.32

5 结论

本文提出了面向大规模地下空间的多智能体端边协作 SLAM 方法, Re-CoSLAM. 针对地下场景中 SLAM 的累计漂移且缺乏全局指导问题, 在端边协作的多模态 SLAM 基础上, 结合误差状态卡尔曼滤波, 提出了 UWB 紧耦合绝对位姿估计方法. 考虑到单一移动机器人感知范围受限, 基于 UWB 全局坐标系, 本文建立了多智能体协同 SLAM 框架与自适应传输机制, 并利用多智能体之间的相对距离约束, 提出了联合位姿图优化方法以提高全局定位精度并保障了全局地图一致性. 此外, 由于移动机器人规模的扩展加剧了边缘服务器的计算资源消耗, 进而设计了基于请求优先级的任务调度策略, 有效降低了任务排队延迟并提高了资源利用效率. 本文在不同场景下实现了 Re-CoSLAM 的部署并进行了广泛的实验与评估, 与现有方法相比, Re-CoSLAM 的全局定位性能提升了 50% 以上.

参考文献

[1] WISTH D, CAMURRI M, DAS S, et al. Unified multi-

下开展了多次实验以表明定位结果的可靠性. 如表 2 所示. 不同场景下平均绝对轨迹误差的标准差在 0.5 cm 以内, 均方根误差的标准差不超过 0.8 cm.

- modal landmark tracking for tightly coupled LiDAR-visual-inertial odometry[J]. *IEEE Robotics and Automation Letters*, 2021, 6(2): 1004-1011.
- [2] ZHOU H Y, YAO Z, LU M Q. LiDAR/UWB fusion based SLAM with anti-degeneration capability[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(1): 820-830.
- [3] LISO L, SANDSTRÖM E, YUGAY V, et al. Loopy-SLAM: Dense neural SLAM with loop closures[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2024: 20363-20373.
- [4] WANG Y S, LOU Y D, SONG W W, et al. A LiDAR-inertial SLAM tightly coupled with dropout-tolerant GNSS fusion for autonomous mine service vehicles[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 1-15.
- [5] HE G J, YUAN X D, ZHUANG Y, et al. An integrated GNSS/LiDAR-SLAM pose estimation framework for large-scale map building in partially GNSS-denied environments[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-9.
- [6] GONG Z, YING R D, WEN F, et al. Tightly coupled integration of GNSS and vision SLAM using 10-DoF optimization on manifold[J]. *IEEE Sensors Journal*, 2019, 19(24): 12105-12117.
- [7] LIU T X, LI B F, CHEN G E, et al. Tightly coupled integration of GNSS/UWB/VIO for reliable and seamless positioning[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(2): 2116-2128.
- [8] SUN Y M, HE Y, ZHANG J C, et al. Exploiting dispersion effect of signals for accurate indoor WiFi localization[J]. *ACM Transactions on Sensor Networks*, 2025, 21(3): 1-21.
- [9] LUO Z Q, LI W M, WU Y J, et al. Accurate indoor localization for bluetooth low energy backscatter[J]. *IEEE Internet of Things Journal*, 2025, 12(2): 1805-1816.
- [10] LIN J K, XIONG R Q, XU Z Q, et al. Multi-node concurrent localization in LoRa networks: Optimizing accuracy and efficiency[C]//IEEE INFOCOM 2024 - IEEE Conference on Computer Communications. Piscataway: IEEE, 2024: 1091-1100.
- [11] ZHANG J W, LIU X L, CHEN S, et al. Toward robust RFID localization via mobile robot[J]. *IEEE/ACM Transactions on Networking*, 2024, 32(4): 2904-2919.
- [12] CHEN Y J, WANG J L, YANG J. Exploiting anchor links for NLOS combating in UWB localization[J]. *ACM Transactions on Sensor Networks*, 2024, 20(3): 1-22.
- [13] NGUYEN T M, CAO M Q, YUAN S H, et al. VIRAL-Fusion: A visual-inertial-ranging-LiDAR sensor fusion approach[J]. *IEEE Transactions on Robotics*, 2022, 38(2): 958-977.
- [14] SCHMUCK P, CHLI M. Multi-UAV collaborative monocular SLAM[C]//2017 IEEE International Conference on Robotics and Automation. Piscataway: IEEE, 2017: 3863-3870.
- [15] KARRER M, SCHMUCK P, CHLI M. CVI-SLAM: Collaborative visual-inertial SLAM[J]. *IEEE Robotics and Automation Letters*, 2018, 3(4): 2762-2769.
- [16] LAJOIE P Y, BELTRAME G. Swarm-SLAM: Sparse decentralized collaborative simultaneous localization and mapping framework for multi-robot systems[J]. *IEEE Robotics and Automation Letters*, 2024, 9(1): 475-482.
- [17] SCHMUCK P, CHLI M. CCM-SLAM: Robust and efficient centralized collaborative monocular simultaneous localization and mapping for robotic teams[J]. *Journal of Field Robotics*, 2019, 36(4): 763-781.
- [18] 袁国帅, 齐咏生, 刘利强, 等. 一种基于因子图消元优化的激光雷达视觉惯性融合SLAM方法[J]. *电子学报*, 2023, 51(11): 3042-3052.
- YUAN G S, QI Y S, LIU L Q, et al. An fusion SLAM method for LiDAR visual and IMU based on factor map elimination optimization[J]. *Acta Electronica Sinica*, 2023, 51(11): 3042-3052. (in Chinese)
- [19] 陈阳, 皮德常, 代成龙, 等. 多无人机协同陆地设施辅助移动边缘计算的系统能耗最小化方法[J]. *电子学报*, 2023, 51(4): 984-992.
- CHEN Y, PI D C, DAI C L, et al. Energy minimization for multi-UAVs cooperative ground access points assisted mobile edge computing[J]. *Acta Electronica Sinica*, 2023, 51(4): 984-992. (in Chinese)
- [20] AHMAD F, QIU H, EELLS R, et al. CarMap: Fast 3D feature map updates for automobiles[C]//17th USENIX Symposium on Networked Systems Design and Implementation (NSDI 20). Berkeley: USENIX Association, 2020: 1063-1081.
- [21] XU J G, CAO H, YANG Z, et al. SwarmMap: Scaling up real-time collaborative visual SLAM at the edge[C]//19th USENIX Symposium on Networked Systems Design and Implementation (NSDI 22). Berkeley: USENIX Association, 2022: 977-993.
- [22] CAO H, XU J G, YANG Z, et al. Scaling up edge-assisted real-time collaborative visual SLAM applications[J]. *IEEE/ACM Transactions on Networking*, 2023, 32(2): 1823-1838.
- [23] LIN J R, ZHANG F. R³LIVE++: A robust, real-time, radiance reconstruction package with a tightly-coupled LiDAR-

- inertial-visual state estimator[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12): 11168-11185.
- [24] 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. Piscataway: IEEE, 2022: 4003-4009.
- [25] FENG D Q, WANG C Q, HE C L, et al. Kalman-filter-based integration of IMU and UWB for high-accuracy indoor positioning and navigation[J]. IEEE Internet of Things Journal, 2020, 7(4): 3133-3146.
- [26] ZHANG K Y, GAO S W, CHEN P P, et al. Edge-aided multi-modal collaborative SLAM for resource-constrained underground robots[C]//IEEE INFOCOM 2025 - IEEE Conference on Computer Communications. Piscataway: IEEE, 2025: 1-10.
- [27] LIN J R, ZHANG F. R³LIVE: A robust, real-time, RGB-colored, LiDAR-inertial-visual tightly-coupled state estimation and mapping package[C]//2022 International Conference on Robotics and Automation. Piscataway: IEEE, 2022: 10672-10678.
- [28] LIN J R, ZHENG C R, XU W, et al. R³LIVE: A robust, real-time, LiDAR-inertial-visual tightly-coupled state estimator and mapping[J]. IEEE Robotics and Automation Letters, 2021, 6(4): 7469-7476.
- [29] 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.
- [30] LI M G, ZHU H, YOU S Z, et al. UWB-based localization system aided with inertial sensor for underground coal mine applications[J]. IEEE Sensors Journal, 2020, 20(12): 6652-6669.
- [31] QIN T, LI P L, SHEN S J. VINS-Mono: A robust and versatile monocular visual-inertial state estimator[J]. IEEE Transactions on Robotics, 2018, 34(4): 1004-1020.
- [32] KÜMMERLE R, GRISETTI G, STRASDAT H, et al. G2o: A general framework for graph optimization[C]//2011 IEEE International Conference on Robotics and Automation. Piscataway: IEEE, 2011: 3607-3613.

作者简介



张奎元 男,1997年1月出生于江苏省徐州市. 现为中国矿业大学计算机科学与技术学院/人工智能学院博士研究生. 主要研究方向为移动边缘计算与智能无线感知.
E-mail: zhangky@cumt.edu.cn



张启亮 男,1979年11月出生于山东省菏泽市. 现为中国矿业大学计算机科学与技术学院/人工智能学院兼职教授. 主要研究方向为工业互联网、计算机视觉与智慧矿山.
E-mail: zql@xcmg.com



陈朋朋 男,1983年11月出生于山东省济宁市. 现为中国矿业大学计算机科学与技术学院/人工智能学院教授、博士生导师. 主要研究方向为物联网与大数据建模.
E-mail: henp@cumt.edu.cn



高守婉 女,1982年10月出生于山东省烟台市. 现为中国矿业大学计算机科学与技术学院/人工智能学院副教授、硕士生导师. 主要研究方向为信号估计与群智感知.
E-mail: gaoshouwan@cumt.edu.cn