

控制与决策

Control and Decision

融合距离梯度的单目视觉-惯性-UWB紧耦合导航定位方法

蒋浩然, 谷丰, 滕天启, 何玉庆

引用本文:

蒋浩然, 谷丰, 滕天启, 等. 融合距离梯度的单目视觉-惯性-UWB紧耦合导航定位方法[J]. *控制与决策*, 2025, 40(8): 2566-2578.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2024.1444>

您可能感兴趣的其他文章

Articles you may be interested in

基于视觉引导多AGV系统的改进A*路径规划算法

Improved A* path planning algorithm for vision-guided multi-AGV system

控制与决策. 2021, 36(8): 1881-1890 <https://doi.org/10.13195/j.kzyjc.2019.1670>

面向多目标侦察任务的无人机航线规划

UAV trajectory planning for multi-target reconnaissance missions

控制与决策. 2021, 36(5): 1191-1198 <https://doi.org/10.13195/j.kzyjc.2019.1284>

基于凸面体圆弧航路的无人机自主避障算法

Autonomous obstacle avoidance algorithm designed for UAV based on convex circular trajectory

控制与决策. 2021, 36(3): 653-660 <https://doi.org/10.13195/j.kzyjc.2019.0768>

基于虚拟力移动锚节点的3D-DVHop-ACR定位算法

3D-DVHop-ACR localization algorithm based on virtual force moving anchor nodes

控制与决策. 2021, 36(10): 2409-2417 <https://doi.org/10.13195/j.kzyjc.2020.0323>

分布式无人机的时变编队非线性控制设计

Time-varying formation nonlinear control of distributed multiple UAVs

控制与决策. 2021, 36(10): 2490-2496 <https://doi.org/10.13195/j.kzyjc.2020.0136>

融合距离梯度的单目视觉-惯性-UWB 紧耦合导航定位方法

蒋浩然^{1,2}, 谷丰[†], 滕天启^{1,2}, 何玉庆¹

(1. 中国科学院沈阳自动化研究所 机器人学国家重点实验室, 沈阳 110016;
2. 中国科学院大学, 北京 100049)

摘要: 视觉惯性里程计 (VIO) 是卫星拒止环境下的高效导航定位方法, 但是由于传感器噪声和累计误差的存在, 不可避免地会产生漂移而影响导航定位精度. 针对上述问题, 提出一种融合距离梯度的单目视觉-惯性-UWB 紧耦合导航定位方法. 通过构建超宽带 (UWB) 测距传感器的测量距离及其梯度信息的残差模型, 利用因子图优化方法实现 VIO 与 UWB 的信息融合, 特别是距离梯度信息的引入, 能够实现速度信息的修正, 从而以多传感器紧耦合融合的方式进一步抑制导航系统的漂移并改善导航定位精度. 将所提出方法在 EuRoc 公开数据集以及实际的无人机平台上进行多种飞行模式的实验验证, 实验结果表明: 所提出方法具有良好的可行性和导航定位性能, 与使用相同测量信息的同类方法比较, 导航精度能够提升 13.7%.

关键词: 无人机导航; 多传感器融合; 超宽带测距传感器; 视觉惯性里程计; 因子图优化

中图分类号: TP24

文献标志码: A

DOI: 10.13195/j.kzyjc.2024.1444

引用格式: 蒋浩然, 谷丰, 滕天启, 等. 融合距离梯度的单目视觉-惯性-UWB 紧耦合导航定位方法 [J]. 控制与决策, 2025, 40(8): 2566-2578.

Distance gradient integrated monocular visual-inertial-UWB tightly coupled localization approach

JIANG Hao-ran^{1,2}, GU Feng[†], TENG Tian-qi^{1,2}, HE Yu-qing¹

(1. State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China; 2. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: Visual-inertial odometry (VIO) is an efficient localization method in GPS-denied environments. However, due to sensor noise and accumulated errors, drift inevitably occurs, affecting the accuracy of localization. To address this issue, this paper proposes a monocular visual-inertial-UWB tightly coupled localization method that integrates distance gradient information. By constructing a residual model of the distance and its gradient information from the ultra-wideband (UWB) ranging sensor, the information from VIO and UWB is fused using factor graph optimization. The introduction of distance gradient information helps to correct velocity, thereby further suppressing drift in the navigation system and improving localization accuracy through tight multi-sensor fusion. The proposed method is experimentally validated on the EuRoc public dataset and an actual UAV platform, covering various flight conditions. The results show that the proposed method is highly feasible and demonstrates superior navigation and localization performance, achieving a 13.7% improvement in accuracy compared to similar methods using the same measurement information.

Keywords: UAV navigation; multi-sensor fusion; ultra-wideband sensor; visual inertial odometry; factor graph optimization

0 引言

视觉惯性里程计 (VIO) 是一种重要的导航系统,

广泛应用于室内、地下空间等卫星拒止环境中^[1]. 如

何提升导航精度和稳定性一直是本领域的热点研究

收稿日期: 2024-12-13; 录用日期: 2025-03-17.

基金项目: 国家重点研发计划项目 (2023YFB4704402); 辽宁省科技厅项目 (2023020427-JH1/104); 国家自然科学基金项目 (U22B2041); 中科院青促会优秀会员项目 (Y2022065).

责任编辑: 贾英民.

[†]通信作者. E-mail: fenggu@sia.cn.

问题,对于拓展无人机以及各类无人系统应用场景具有十分重要的意义。

VIO通过融合相机和惯性测量单元(IMU)的信息,能够在不依靠外部传感器设备的情况下完成无人机的高精度定位。国内外学者围绕这一方法开展了广泛的研究,Queralt等^[2]提出了一种多状态约束的卡尔曼滤波方法进行视觉-惯性融合导航,并通过实验验证了该方案用于无人机定位的有效性;Leutenegger等^[3]为提高无人机定位的计算效率和鲁棒性,提出了一种基于关键帧的滑动窗口优化方法进行视觉-惯性信息的融合,并通过飞行实验验证了该系统能够在计算资源占用率较低的情况下保持高精度定位;Qin等^[4]为实现低计算资源高精度的无人机导航,提出了一种基于紧耦合非线性优化的视觉-惯性融合无人机导航方法,并通过室内、室外实验验证了该方法的优越性和鲁棒性;Bloesch等^[5]为提高无人机导航的鲁棒性,将图像块作为地标描述符替代了特征提取和匹配,并提出了一种迭代卡尔曼滤波的方法来处理视觉和惯性信息,通过实验验证了该方法能够有效提升系统鲁棒性;Chen等^[6]利用多状态约束卡尔曼滤波器融合视觉惯性信息,对视觉平面特征进行了规范化处理,使用数据集验证了所提出算法的有效性;Weinstein等^[7]为解决多无人机导航问题,提出了一种基于单目视觉-惯性的多机导航方法,该方法可在不依赖动态捕捉系统、卫星导航的情况下实现多无人机导航,采用最多12架无人机进行实验,验证了该方法的鲁棒性和可扩展性。

尽管视觉惯性里程计能够不依赖全球卫星导航系统实现高精度定位,但是由于缺乏全局传感器进行校准和修正,存在定位漂移的问题。目前,常采用人工视觉标记或使用回环检测法等解决该问题^[8]。上述方法取得了一定的研究进展,但是依然存在各自的局限性。视觉标记法通常受限于视觉传感器的视野,标记物一旦位于视线外便难以被检测到,同时还严重受限于光照环境。而回环检测法则高度依赖于轨迹、环境和任务需求,难以适用于轨迹不重合的应用场景。

利用其他传感器进行校准和修正也是VIO定位漂移问题的有效解决手段,其中UWB是目前常用的工具之一^[9]。传统的UWB定位方法需要在环境中部署UWB基站,通过测量无人机机身标签与基站间的距离,由三角定位原理进行无人机的位置估计。该传感器可提供全局信息,常用于与其他传感器融合进行无人机导航,以解决漂移问题。宁一高等^[10]提出了一种基于IMU-UWB融合的自平衡车导航方

法,基于非奇异终端滑模和线性二次型调节器设计了轨迹跟踪控制器,并通过实验验证了所提出方法的有效性;Strohmeier等^[11]通过扩展卡尔曼滤波,以松耦合的方式融合惯性、UWB、气压计信息,并通过实验验证了该方法能够进一步提高定位精度;You等^[12]为提高卫星拒止环境的无人机导航精度,使用了无迹卡尔曼滤波融合UWB距离和惯性信息,从而避免忽略非线性观测方程的高阶项来提高性能,提高了里程计系统的鲁棒性;Yang等^[13]为解决密闭环境无人机定位问题,用结合惯性和UWB距离的自适应卡尔曼滤波进行状态估计,并开展飞行实验验证了该方法的有效性;Song等^[14]提出了一种基于因子图优化的UWB距离-惯性组合无人机导航方法,并通过实验验证了该方法定位效果优于扩展卡尔曼滤波方法;黄家才等^[15]为改善激光雷达定位方法的累计误差问题,提出了一种局域改进天牛须优化例子滤波的UWB-激光雷达室内定位方法,并通过实验验证了该方法的定位精度以及计算效率相较于原粒子滤波法均有所提升。

由于VIO与UWB传感器具有优势互补的特点,一些学者使用UWB距离信息融合视觉惯性信息,以满足更高的导航需求。Lin等^[16]通过将多基站UWB的全局定位信息与VIO进行松耦合融合,在提高定位精度的同时保证了定位轨迹的平滑;Shin等^[17]针对VIO在特征稀疏环境的视觉退化问题,提出了使用UWB传感器来辅助VIO进行无人机导航,并将UWB距离数据融入初始化过程,实验验证了该方法的定位精度和初始化鲁棒性均取得了一定提升;Fan等^[18]提出了一种即插即用的视觉-惯性-UWB多传感器融合系统,并将UWB基站坐标作为参数进行实时估计,提高了系统的鲁棒性和适应性;Goudar等^[19]提出了一种基于固定时滞平滑器的UWB-VIO融合架构,使用两个时滞平滑器分别用于传感器融合和VIO平滑校正,在微型飞行器进行的飞行实验验证了其有效性;Hu等^[20]为拓展导航系统应用场景,提出了一种基于视觉目标检测法的UWB基站初始化方法,并将该方法应用于视觉-惯性-UWB融合导航系统中,实验结果表明了该方法在基站位置估计和定位精度方面的有效性。鉴于UWB基站需要预先部署,其应用范围受到一定限制,因此,有研究者将UWB传感器安装在多架无人机,用于解决多无人机间的相对状态估计问题。Guo等^[21]提出了一种基于一致性的多无人机相对位置估计方法,结合了UWB和里程计数据进行多机导航,并应用于多机编队控制;Xu等^[22]和Nguyen等^[23]将视觉-

惯性定位方法与 UWB 传感器数据相融合,应用于多无人机的相对定位,有效解决了视觉方法对特征的依赖以及 VIO 存在的漂移问题。

上述研究主要针对多基站 UWB 辅助其他定位方式进行无人机导航,只有在至少 4 个基站的情况下才能正常使用^[24]。多基站限制了相关方法的应用场景,因为工作环境必须具有足够的空间支持 UWB 基站的部署,且在更换环境时,需要重新部署 UWB 基站。在如隧道或走廊等空间较为狭窄的环境中,由于不具备足够的条件安装 UWB 基站,会导致导航系统失效。因此,也有一些学者对于 UWB 基站退化(基站小于 4 个)场景下的无人机导航方法进行了研究。如 Cao 等^[25]提出了一种单基站距离信息与视觉惯性信息相结合的传感器融合方法,并采用了长-短滑动窗口策略进行优化,飞行实验证实了其定位精度相较于 VIO 有显著提升;Nguyen 等^[26]在单 UWB 基站与 VIO 结合的基础上,提出了一种距离聚焦方法,利用 VIO 中的 IMU 预积分和等速假设计算每个 UWB 时间戳对应的无人机位置来构建 UWB 残差,将所有 UWB 数据加以利用,从而进一步提高了定位精度。上述方法研究了如何高效利用单基站 UWB 数据辅助 VIO 进行无人机定位,但是,由于需要 UWB 测距信息和速度构建优化所需的残差模型,对于速度的估计精度要求较高,当速度估计不准确时,会导致定位精度降低。

本文针对上述问题,提出一种融合距离梯度的单目视觉-惯性-UWB 紧耦合融合定位方法,创新性地构建基于 UWB 测距的距离梯度因子,即在距离信息中提取梯度,并基于因子图优化方法将距离梯度信息与无人机的位置、速度相结合来构建残差模型。所提出方法具有如下优势:1) 引入高频的 UWB 测距信息,可有效抑制 VIO 普遍存在的定位漂移;2) 基于 UWB 测距信息构建描述距离变化趋势的残差项,能够深入发掘数据的动态信息;3) 通过构建的距离梯度因子,在优化过程中对速度进行修正,从而提升定位精度。

1 问题描述

首先介绍本文所使用符号的定义,然后对本文所要解决的问题进行详细阐述。

1.1 符号定义

所提出无人机导航系统由单目相机、IMU 和 UWB 测距仪 3 种传感器组成,UWB 基站被放置于环境中的已知位置,飞行环境以及传感器构成如图 1 所示。图 2 为本文所使用的坐标系定义。其中:包含

与 IMU 坐标系重合的机体坐标系 $\{B\}$ 、相机坐标系 $\{C\}$ 和世界坐标系 $\{W\}$; ${}^w(\cdot)$ 、 ${}^B(\cdot)$ 和 ${}^C(\cdot)$ 分别为世界坐标系、机体坐标系和相机坐标系下的无人机状态;对于 UWB 传感器, ${}^w p$ 为 UWB 基站在世界坐标系的位置; $(\hat{\cdot})$ 为带噪声的测量值或状态估计结果。




图1 本文导航系统传感器构成




图2 本文坐标系定义

由于所提出方法需要对优化模型关键帧间的 UWB 数据进行处理,定义 t_c 、 t_i 和 t_j 分别为相机、IMU 和 UWB 测距的时间戳, t_k 为滑动窗口中任一关键帧的时间戳。对于导航系统的非线性优化模型,仅当满足某些标准时才会选择相机帧作为关键帧,这可能会导致两个连续的关键帧间被多个相机帧分隔。因此,在两个关键帧间可用的 UWB 数据数量通常在滑动窗口中不是均匀分布的。

1.2 导航系统框架

所提出融合距离梯度的单目视觉-惯性-UWB 紧耦合导航方法包括前端数据预处理、初始化、后端非线性优化 3 部分,通过环境特征信息、IMU 导航信息、测距信息的融合来实现无人机在环境中的导航定位,如图 3 所示。

初始化过程: 利用运动恢复结构算法 (SFM)^[27] 获取未知尺度的相机和特征位置,并对系统初始阶段的视觉特征信息、预积分信息进行视觉惯导对齐,为后端非线性优化提供初始速度、重力矢量、陀螺仪偏差、尺度等信息。

前端数据预处理: 对相机采集的图像进行特征提取和特征跟踪,得到多个图像中环境特征的像素坐标;同时,在两个连续帧间对 IMU 测量值进行预

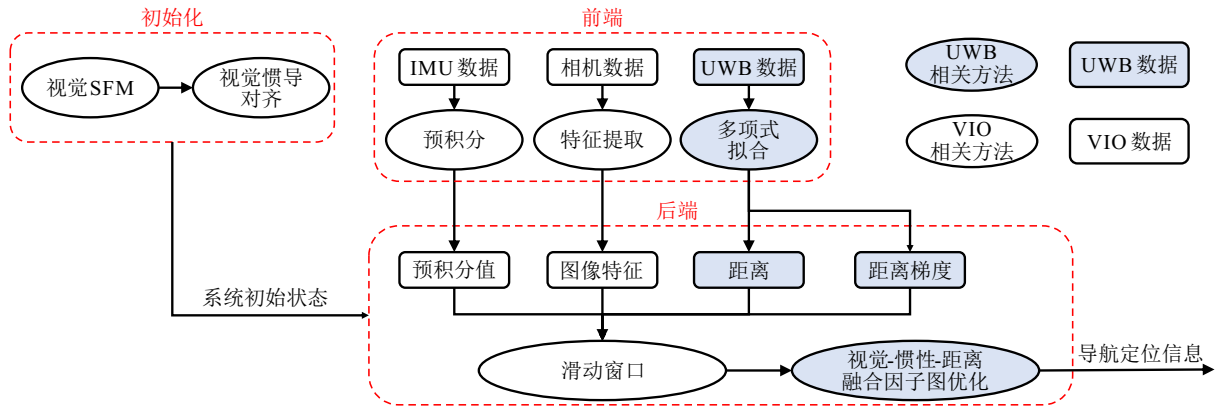


图3 融合距离梯度的单目视觉-惯性-UWB紧耦合导航系统框架

积分处理,得到连续帧间的位姿变化关系;并用多项式拟合方法来处理UWB原始数据,得到平滑的距离、距离梯度测量值。

后端优化:采用基于滑动窗口法的因子图优化方法,融合前端输出的IMU预积分、特征提取和跟踪结果、UWB距离和距离梯度信息,优化无人机状态并输出位姿估计结果,作为无人机的定位信息供规划、控制等系统使用。

在现有单目视觉-惯性-UWB紧耦合融合导航方法中,由于UWB的测距频率远高于单目相机,通常只使用部分UWB测距信息与视觉-惯性信息融合,导致高频UWB数据难以被充分利用,限制了导航系统性能的提升。因此,如何设计一种能够充分利用高频UWB测距信息的优化模型,并将其高效地融入多传感器融合导航系统,是本文需要解决的关键技术难点之一。在文献[26]的导航方法中,使用距离聚焦的方法构建距离残差模型进行UWB距离与视觉惯性数据的融合,考虑UWB数据帧与关键帧间的时间差,对所有UWB距离数据建立优化模型进行联合优化,在一定程度上解决了高频距离数据利用不完全的问题,残差模型如下所示:

$$r_{\mathcal{R}}(\hat{z}_k^j, \mathcal{X}) = \hat{d}_j - \|\mathbf{p}_j^w - \mathbf{p}^w\|, \forall \hat{d}_j. \quad (1)$$

其中: $r_{\mathcal{R}}(\hat{z}_k^j, \mathcal{X})$ 为UWB残差; \hat{d}_j 为距离测量值; \mathbf{p}^w 为基站位置; \mathbf{p}_j^w 为UWB采样时刻无人机位置,由相机采样时刻位置 \mathbf{p}_k^w 、速度 \mathbf{v}_k^w 和预积分 $\Delta \hat{\mathbf{p}}_j^k$ 计算得到,如下所示:

$$\mathbf{p}_j^w := \mathbf{p}_k^w + \frac{1}{2} \Delta \hat{\mathbf{p}}_j^k + \frac{1}{2} \mathbf{v}_k^w \Delta t_j. \quad (2)$$

但是,上述方法通过UWB测距信息和速度构建优化所需的残差模型,对于速度的估计精度要求较高,当速度估计不准确时,会导致定位精度降低。

本文在UWB距离残差的基础上,基于距离数据提取距离梯度信息,并使用该信息与无人机的位置、速度相结合,基于距离梯度构建优化模型,进一

步抑制了导航系统的漂移并改善导航定位精度。将上述UWB距离、距离梯度与视觉、惯性信息进行紧耦合融合,即将UWB的距离、距离梯度信息所构建的残差加入联合优化过程中,实现了多传感器融合定位。所提出方法充分利用了UWB的高频测距信息,深入发掘了UWB测距数据中的动态信息,引入的距离梯度信息在优化过程中对速度进行修正,提升了速度的估计精度,能够进一步提升无人机的导航定位精度。

本文主要工作是设计一种融合距离梯度信息的视觉-惯性-UWB紧耦合融合无人机导航系统。具体地,开发基于UWB测距传感器的距离梯度提取方法,并设计UWB距离梯度优化模型的构建方法。通过深入挖掘UWB传感器测距的动态信息,充分利用了高频UWB数据,并将其与视觉和惯性信息进行紧耦合融合,以提升无人机在室内复杂环境中的导航性能,其中初始化部分沿用了文献[4]中的单目视觉里程计的初始化方法。因此,本文后续主要对所提出系统的前端传感器数据预处理和后端非线性优化模型做详细介绍。

2 前端数据预处理

本节介绍所提出导航系统的前端传感器数据预处理方法,详细阐述IMU预积分、图像特征提取以及UWB距离梯度拟合方法及其原理。

2.1 IMU预积分

无人机姿态和速度相对于世界坐标系的运动学模型如下所示:

$$\dot{\mathbf{q}}_t = \mathbf{q}_t \circ \begin{bmatrix} 0 \\ \boldsymbol{\omega}_t \end{bmatrix}, \dot{\mathbf{p}}_t = \mathbf{v}_t, \dot{\mathbf{v}}_t = \mathbf{R}_t \mathbf{a}_t. \quad (3)$$

其中: \mathbf{q}_t 、 \mathbf{p}_t 、 \mathbf{v}_t 分别为 t 时刻无人机在世界坐标系下的姿态、位置和速度, \mathbf{R}_t 为无人机 t 时刻姿态的旋转矩阵。但是,实际上,系统只能得到存在噪声和偏置的IMU测量值,如下所示:

$$\hat{\omega}_t = \omega_t + \mathbf{b}_t^\omega + \boldsymbol{\eta}_t^\omega, \quad (4)$$

$$\hat{\mathbf{a}}_t = \mathbf{a}_t + \mathbf{R}_t^T \mathbf{g} + \mathbf{b}_t^a + \boldsymbol{\eta}_t^a, \quad (5)$$

$$\hat{\mathbf{b}}_t^\omega = \boldsymbol{\eta}_t^{b\omega}, \quad \hat{\mathbf{b}}_t^a = \boldsymbol{\eta}_t^{ba}. \quad (6)$$

这里: ω_t 和 \mathbf{a}_t 分别为 t 时刻无人机在机体坐标系所测量的角速度和线加速度; $\mathbf{g} = [0, 0, g]^T$ 为重力加速度; \mathbf{b}_t^ω 、 \mathbf{b}_t^a 分别为螺仪以及加速度的固有测量偏置; $\boldsymbol{\eta}_t^\omega$ 、 $\boldsymbol{\eta}_t^a$ 、 $\boldsymbol{\eta}_t^{b\omega}$ 、 $\boldsymbol{\eta}_t^{ba}$ 分别为各测量值所对应零均值高斯噪声, 方差分别为 $\sigma_{\eta_t^\omega}$ 、 $\sigma_{\eta_t^a}$ 、 $\sigma_{\eta_t^{b\omega}}$ 、 $\sigma_{\eta_t^{ba}}$.

本文遵循了文献 [28] 中 IMU 预积分的连续时间四元数推导方法. 对于两个连续帧 k 和 $k+1$, 在 $[t_k, t_{k+1}]$ 之间存在若干惯性测量值. 给定偏置估计后, 可对上述测量值进行积分得到旋转增量 $\boldsymbol{\gamma}_{k+1}^k$ 、速度增量 $\boldsymbol{\beta}_{k+1}^k$ 、位置增量 $\boldsymbol{\alpha}_{k+1}^k$, 即

$$\boldsymbol{\gamma}_{k+1}^k \triangleq \int_{s=t_k}^{t_{k+1}} \frac{1}{2} \boldsymbol{\Omega}(\omega_s - \mathbf{b}_s^\omega - \boldsymbol{\eta}_s^\omega) \mathbf{q}_s = \mathbf{q}_k^{-1} \circ \mathbf{q}_{k+1}, \quad (7)$$

$$\boldsymbol{\beta}_{k+1}^k \triangleq \int_{s=t_k}^{t_{k+1}} \frac{B_k}{B_s} \mathbf{R}(\mathbf{a}_s - \mathbf{b}_s^a - \boldsymbol{\eta}_s^a) ds = {}^w \mathbf{R}_k^{-1}(\mathbf{v}_{k+1} - \mathbf{v}_k + \mathbf{g} \Delta t_k), \quad (8)$$

$$\boldsymbol{\alpha}_{k+1}^k \triangleq \int_{s=t_k}^{t_{k+1}} \int_{t_k}^u \frac{B_k}{B_s} \mathbf{R}(\mathbf{a}_s - \mathbf{b}_s^a - \boldsymbol{\eta}_s^a) ds du = {}^w \mathbf{R}_k^{-1} \left(\mathbf{p}_{k+1} - \mathbf{p}_k - \mathbf{v}_k \Delta t_k + \frac{1}{2} \mathbf{g} \Delta t_k^2 \right). \quad (9)$$

其中: $\int_{\mathcal{M}} (\cdot)$ 为流形的积分算子, $\frac{B_k}{B_s} \mathbf{R}$ 为机体坐标系下 k 时刻到 s 时刻的旋转矩阵, ${}^w \mathbf{R}_k$ 为世界坐标系下 k 时刻的无人机姿态旋转矩阵. $\boldsymbol{\Omega}(\omega)$ 为公式简写, Δt_k 为连续两帧间的时间差, $[\omega]_x$ 为斜对称矩阵, 上述符号定义如下所示:

$$\boldsymbol{\Omega}(\omega) \triangleq \begin{bmatrix} 0 & -\omega^T \\ \omega & -[\omega]_x \end{bmatrix}, \quad \Delta t_k \triangleq t_{k+1} - t_k, \\ [\omega]_x = \begin{bmatrix} 0 & -\omega_z & \omega_y \\ \omega_z & 0 & -\omega_x \\ -\omega_y & \omega_x & 0 \end{bmatrix}.$$

由此可得到 IMU 预积分值与无人机状态变量的关系, 为 IMU 后端优化模型奠定了基础.

2.2 图像特征提取

在数据预处理部分, 首先对图像进行特征提取, 将提取的特征点用于构建后端视觉残差模型. 在视觉特征提取和跟踪的过程中, 首先利用 KLT 稀疏光流算法^[29] 来追踪图像序列中的现有特征, 同时通过检测新的角点特征^[30] 来维持每张图像中至少有 100 ~ 300 个特征. 为了实现特征的均匀分布, 在检测算法中设置了最小像素距离, 以确保相邻特征间有足够的间隔. 在特征处理阶段, 首先对二维特征进

行去畸变处理, 然后通过 RANSAC 算法^[31] 结合基本矩阵模型来剔除异常值, 并将这些特征投影到单位球面上, 以提高特征的准确性.

导航系统仅对关键帧对应的无人机状态进行优化, 该关键帧在视觉数据帧中挑选得到, 其选择有如下标准: 1) 考虑与前一个关键帧间的平均视差, 若当前帧与最新关键帧间的跟踪特征的平均视差超过了预设的阈值, 则当前帧会被标记为新的关键帧. 这一标准不仅考虑了平移引起的视差, 也包括了旋转的影响. 为了准确计算视差, 本文采用陀螺仪的短期积分数据来补偿旋转, 这种补偿只用于关键帧的选择过程, 并不会影响优化部分的旋转计算. 2) 根据跟踪质量来确定关键帧. 若跟踪到的特征数量提升至某个阈值以上, 则将当前帧视为新的关键帧. 这一策略有助于避免特征跟踪的完全丢失, 确保了特征跟踪的连续性和稳定性.

将图像特征提取的特征像素坐标、特征跟踪的像素对应关系输出, 作为后端视觉优化模型的基础.

2.3 UWB 距离数据的梯度拟合

对于 UWB 测距传感器, 所提出方法需要距离、距离梯度两种数据. 由于该传感器的测量值为距离数据, 需要从距离数据中提取距离梯度数据, 用于后端优化的距离梯度残差模型构建.

UWB 具有如下特点: 1) 数据频率较高, 最高可达 200 Hz, 在一定时间中具备足够的数据量; 2) 噪声水平较低, 所采用 linktrack UWB 模块噪声方差约为 0.03; 3) 由于无人机运动轨迹的物理特性, 距离测量值为平滑数据; 4) 由于存在信号强度数据, 异常值便于剔除. 基于上述特点, 选择基于最小二乘法的多项式拟合方法进行距离梯度的提取.

算法需要多帧 UWB 测量信息进行拟合, UWB 距离数据量会随无人机飞行时间积累, 导致拟合占用计算资源增大, 因此采用滑动窗口法, 对有限时间内的 UWB 距离数据进行 3 次多项式拟合, 由拟合所得多项式求导得到距离和距离梯度值. 对于滑动窗口内的 UWB 距离数据, 构建如下优化问题:

$$\mathcal{X} = \arg \min_{\mathcal{X}} \sum_{j \in \mathcal{V}} \|r_{\mathcal{V}}(\hat{z}_j, \mathcal{X})\|^2. \quad (10)$$

其中: \mathcal{V} 为滑动窗口内 UWB 测量值的集合; \mathcal{X} 为待优化变量; \hat{z}_j 为观测信息; $r_{\mathcal{V}}(\hat{z}_j, \mathcal{X})$ 为残差模型, 其定义如下所示:

$$\hat{z}_j = \hat{d}_{t_j}, \quad \mathcal{X} = [a, b, c, e], \\ r_{\mathcal{V}}(\hat{z}_j, \mathcal{X}) = at_j^3 + bt_j^2 + ct_j + e - \hat{d}_{t_j}.$$

这里: a 、 b 、 c 、 e 为 3 次多项式参数, \hat{d}_{t_j} 为 j 时刻带

噪声的距离测量值. 将多项式拟合结果的距离数据及其一阶梯度输出, 作为后端 UWB 残差模型的基础, 有

$$\hat{d} = at_k^3 + bt_k^2 + ct_k + e, \quad (11)$$

$$\hat{\dot{d}} = 3at_k^2 + 2bt_k + c. \quad (12)$$

3 后端非线性优化

本节主要介绍所提出导航系统的后端非线性优化部分, 简述所使用基于因子图的非线性优化方法, 并详细介绍视觉、惯性、UWB 因子的构建方式.

3.1 因子图优化方法

3.1.1 因子图优化概述

因子图优化是一种用于解决后端大规模稀疏非线性定位问题的方法, 该方法采用一种图结构, 由节点和边组成. 其中节点表示状态变量(待优化变量)和观测模型, 边表示各节点间的约束关系. 本文融合前端输出的图像特征坐标、IMU 预积分、UWB 测距的距离及其梯度来表示约束条件, 通过最小化所有测量残差与先验残差的马哈拉诺比斯距离的和获得最大后验估计. 利用因子图优化构建优化模型, 表述为如下非线性优化问题:

$$\mathcal{X} = \arg \min_{\mathcal{X}} \sum_{i=1}^n \|h_i(x_i) - z_i\|_{\Sigma_i}^2. \quad (13)$$

其中: Σ_i 为各观测模型所对应的协方差矩阵, $h_i(x_i)$ 为相关因子所对应观测模型, z_i 为观测值.

3.1.2 本文导航系统因子图优化模型

根据所提出方法, 构建如图 4 所示的因子图.




图4 本文方法对应因子图优化模型

对导航系统建立如下优化模型:

$$\mathcal{X} = \arg \min_{\mathcal{X}} \{E_{VI}(\mathcal{X}) + E_{\mathcal{R}}(\mathcal{X})\}, \quad (14)$$

其中 \mathcal{X} 为待优化变量, 称为状态变量. 其定义如下所示:

$$\begin{aligned} \mathcal{X} &= [x_0, x_1, \dots, x_n, {}^B_C \mathbf{x}, \lambda_0, \lambda_1, \dots, \lambda_m]; \\ \mathbf{x}_k &= [{}^W_B \mathbf{p}_k, {}^W_B \mathbf{v}_k, {}^W_B \mathbf{q}_k, \mathbf{b}^a, \mathbf{b}^\omega], k \in [0, n]; \\ {}^B_C \mathbf{x} &= [{}^B_C \mathbf{p}, {}^B_C \mathbf{q}]. \end{aligned}$$

这里: 在状态变量中, \mathbf{x}_k 为第 k 个关键帧的 IMU 状态, 其分量包含世界坐标系下的位置 ${}^W_B \mathbf{p}_k$ 、速度 ${}^W_B \mathbf{v}_k$ 、姿态 ${}^W_B \mathbf{q}_k$ 以及机体坐标系中加速度、角速度偏置 \mathbf{b}^a 、 \mathbf{b}^ω ; n 为滑动窗口内的关键帧总数量; λ_l 为第 l 个特征首次被观测的逆深度; m 为滑动窗口内总视觉特征数量; ${}^B_C \mathbf{x}$ 为相机在机体坐标系下的位置; ${}^B_C \mathbf{p}$ 、 ${}^B_C \mathbf{q}$ 分别为相机在机体坐标系下的位置和姿态.

$E_{VI}(\mathcal{X})$ 为视觉、惯性残差模型, 其定义如下所示:

$$\begin{aligned} E_{VI}(\mathcal{X}) &= \sum_{k \in \mathcal{B}} \|r_{\mathcal{B}}({}^B \hat{z}_{k+1}^k, \mathcal{X})\|_{P_{k+1}^{b_k}}^2 + \\ &\sum_{(l,j) \in \mathcal{C}} \rho(\|r_{\mathcal{C}}({}^C \hat{z}_l^j, \mathcal{X})\|_{P_l^{c_j}}^2). \end{aligned} \quad (15)$$

其中: $r_{\mathcal{B}}({}^B \hat{z}_{k+1}^k, \mathcal{X})$ 和 $r_{\mathcal{C}}({}^C \hat{z}_l^j, \mathcal{X})$ 分别为惯性残差和视觉残差, \mathcal{B} 为所有 IMU 预积分测量值的集合, \mathcal{C} 为在滑动窗口内被观测到两次以上的特征的集合, ${}^B \hat{z}_{k+1}^k$ 和 ${}^C \hat{z}_l^j$ 分别为惯性、视觉的观测信息. Huber 损失函数^[32] 被应用于视觉残差, 以减小跟踪异常值对系统的影响, 其定义如下所示:

$$\rho(s) = \begin{cases} s, & s \leq 1; \\ 2\sqrt{s} - 1, & s > 1. \end{cases}$$

$E_{\mathcal{R}}(\mathcal{X})$ 为 UWB 残差模型, 其定义如下所示:

$$\begin{aligned} E_{\mathcal{R}}(\mathcal{X}) &= \gamma_r \sum_{k \in \mathcal{R}} \sum_{j \in \mathcal{J}_k} \|r_{\mathcal{R}}(\hat{z}_k^j, \mathcal{X})\|_{P_k^{r_j}}^2 + \\ &\gamma_d \sum_{k \in \mathcal{D}} \|r_{\mathcal{D}}(\hat{z}_k, \mathcal{X})\|_{P_k}^2. \end{aligned} \quad (16)$$

这里: $r_{\mathcal{R}}(\hat{z}_k^j, \mathcal{X})$ 、 $r_{\mathcal{D}}(\hat{z}_k, \mathcal{X})$ 分别为距离、距离梯度残差, \mathcal{J}_k 为两帧间距离测量值的集合, \mathcal{R} 为滑动窗口中 \mathcal{J}_k 的集合, \mathcal{D} 为距离梯度测量值的集合, \hat{z}_k^j 、 \hat{z}_k 分别为距离、距离梯度观测信息, γ_r 、 γ_d 为 UWB 权重参数. 由此构成如下优化模型:

$$\begin{aligned} \mathcal{X} &= \arg \min_{\mathcal{X}} \left\{ \sum_{k \in \mathcal{B}} \|r_{\mathcal{B}}({}^B \hat{z}_{k+1}^k, \mathcal{X})\|_{P_{k+1}^{b_k}}^2 + \right. \\ &\sum_{(l,j) \in \mathcal{C}} \rho(\|r_{\mathcal{C}}({}^C \hat{z}_l^j, \mathcal{X})\|_{P_l^{c_j}}^2) + \\ &\gamma_r \sum_{k \in \mathcal{R}} \sum_{j \in \mathcal{J}_k} \|r_{\mathcal{R}}(\hat{z}_k^j, \mathcal{X})\|_{P_k^{r_j}}^2 + \\ &\left. \gamma_d \sum_{k \in \mathcal{D}} \|r_{\mathcal{D}}(\hat{z}_k, \mathcal{X})\|_{P_k}^2 \right\}. \end{aligned} \quad (17)$$

3.2 IMU 预积分因子

对于滑动窗口中的两个连续关键帧 b_k 和 b_{k+1} , IMU 预积分模型对应的残差由下式定义:

$$r_B({}^B \hat{z}_{k+1}^k, \mathcal{X}) = \begin{bmatrix} \delta \alpha_{k+1}^k \\ \delta \beta_{k+1}^k \\ \delta \gamma_{k+1}^k \\ \delta b^a \\ \delta b^g \end{bmatrix} = \begin{bmatrix} {}^{b_k} R \left({}^w R \left({}^w \mathbf{p} - {}^w \mathbf{p} + \frac{1}{2} {}^w \mathbf{g} \Delta t_k^2 - {}^w \mathbf{v} \Delta t_k \right) - \hat{\alpha}_{k+1}^k \right) \\ {}^{b_k} R \left({}^w R \left({}^w \mathbf{v} + {}^w \mathbf{g} \Delta t_k - {}^w \mathbf{v} \right) - \hat{\beta}_{k+1}^k \right) \\ 2 [{}^{w-1} \mathbf{q} \otimes {}^w \mathbf{q} \otimes (\hat{\gamma}_{k+1}^k)^{-1}]_{xyz} \\ b_{b_{k+1}}^a - b_{b_k}^a \\ b_{b_{k+1}}^w - b_{b_k}^w \end{bmatrix}. \quad (18)$$

其中: $\delta \alpha_{k+1}^k$ 、 $\delta \beta_{k+1}^k$ 分别为位置增量残差和速度增量残差, $\delta \gamma_{k+1}^k$ 为姿态四元数增量的三维残差, δb^a 和 δb^w 分别为加速度计、陀螺仪固有测量偏置的残差, $[\cdot]_{xyz}$ 表示提取四元数 q 的向量部分用于误差状态表示, $\hat{\alpha}_{k+1}^k$ 、 $\hat{\beta}_{k+1}^k$ 、 $\hat{\gamma}_{k+1}^k$ 为两个连续帧间的预积分测量值, $b_{b_k}^a$ 、 $b_{b_k}^w$ 分别为 k 时刻机体坐标系下的加速度计和陀螺仪的偏置。

3.3 视觉因子

与传统的针孔相机模型在广义图像平面上定义的重投影误差不同, 本文在单位球面上定义相机测量残差. 几乎所有类型的相机, 包括广角、鱼眼或全向相机的光学系统, 均可建模为连接单位球面表面的单位光线. 考虑第 l 个特征在第 i 张图像中首次被观察到, 该特征在第 j 张图像中的观测残差定义为

$$r_c({}^C \hat{z}_i^j, \mathcal{X}) = [b_1 \quad b_2]^T \cdot \left({}_i^c \hat{\mathcal{P}} - \frac{{}_i^c \mathcal{P}}{\|{}_i^c \mathcal{P}\|} \right), \quad (19)$$

$${}_i^c \hat{\mathcal{P}} = \pi_c^{-1} \left(\begin{bmatrix} {}_i^c \hat{u} \\ {}_i^c \hat{v} \end{bmatrix} \right), \quad (20)$$

$${}_i^c \mathcal{P} = {}_b^c R \left({}_w^b R \left({}_{b_i}^w R \left({}_c^b R \left(\frac{1}{\lambda_l} \pi_c^{-1} \left(\begin{bmatrix} {}_i^c \hat{u} \\ {}_i^c \hat{v} \end{bmatrix} \right) \right) + {}_c^b \mathbf{p} \right) + {}_b^w \mathbf{p} - {}_{b_j}^w \mathbf{p} \right) - {}_c^b \mathbf{p} \right). \quad (21)$$

其中: ${}_i^c \hat{\mathcal{P}}$ 为在相机坐标系下, 第 j 个图像中观测到的第 l 个特征的方向单位向量; b_1 和 b_2 为两个任意选择的正交基; $[_i^c \hat{u} \quad {}_i^c \hat{v}]^T$ 为第 i 个图像中的第 l 个特征的首次观测坐标; $[_i^j \hat{u} \quad {}_i^j \hat{v}]^T$ 为在第 j 个图像中观测到的相同特征; π_c^{-1} 为反投影函数, 其利用相机内参将像素位置转换为单位向量; λ_l 为第 l 个特征的逆深度. 视觉图像坐标为二维, 残差的自由度为二, 因此, 将残差向量投影到切平面上. 方差 $P_i^{c_j}$ 也从像素坐标转换到单位球面上.

3.4 UWB 距离因子

UWB 距离因子的基本构建方式是采用状态向量中的位置分量与临近距离测量值相结合, 并未考虑相机帧与距离数据间的时间偏差, 忽略了关键帧间的距离数据. 本文参考文献 [26] 所提出的距离聚焦方法, 使用 IMU 预积分消除距离数据与关键帧对应时间戳间的偏差, 进行 UWB 距离残差构建.

用 IMU 预积分计算每个距离数据时间戳的位置信息, 并利用该位置信息与距离数据构建残差, 有

$$r_{\mathcal{R}}(\hat{z}_j^j, \mathcal{X}) = \hat{d}_j - \| {}_B^W \mathbf{p}_j - {}_a^W \mathbf{p} \|, \quad \forall \hat{d}_j. \quad (22)$$

其中: \hat{d}_j 为距离测量值; ${}_a^W \mathbf{p}$ 为基站在世界坐标系下的位置; ${}_B^W \mathbf{p}_j$ 为任意 j 时刻的位置, 由该时刻相邻关键帧的位置 ${}_B^W \mathbf{p}_k$ 计算得到, 有如下两种计算方式:

$${}_B^W \mathbf{p}_j := {}_B^W \mathbf{p}_k + {}_B^W \mathbf{v}_k \Delta t_j, \quad (23)$$

$${}_B^W \mathbf{p}_j := {}_B^W \mathbf{p}_k + \Delta \hat{\mathbf{p}}_j^k. \quad (24)$$

这里: 式 (23) 使用状态变量中的位置 ${}_B^W \mathbf{p}_k$ 和速度 ${}_B^W \mathbf{v}_k$, 结合 k 、 j 两时刻的时间差 Δt_j 计算得到 ${}_B^W \mathbf{p}_j$. 该方法将 ${}_B^W \mathbf{p}_k$ 、 ${}_B^W \mathbf{v}_k$ 与距离测量值相结合, 由于 ${}_B^W \mathbf{v}_k$ 为状态变量中的分量, 避免了过拟合问题, 但是该方法基于等速模型进行位置预测, 在高机动场景以及 Δt_j 较大的情况下效果不佳. 式 (24) 使用预积分方法计算 $\Delta \mathbf{p}$ 与 $\Delta \mathbf{v}$ 间的位置变化量, 将该变化量结合 ${}_B^W \mathbf{p}_j$ 从而得到 ${}_B^W \mathbf{p}_k$, 但是使用该方法时, ${}_B^W \mathbf{p}_k$ 需要与多个 UWB 测量值建立残差, 由于 IMU 与 UWB 存在测量噪声, 易产生过拟合问题. 本文结合上述两种方法, 并对两种方法进行加权求和作为距离测量时刻的位置预测模型, 如下所示:

$${}_B^W \mathbf{p}_j := {}_B^W \mathbf{p}_k + \frac{1}{2} \Delta \hat{\mathbf{p}}_j^k + \frac{1}{2} {}_B^W \mathbf{v}_k \Delta t_j. \quad (25)$$

3.5 UWB 距离梯度因子

在传统的 UWB 相关导航系统中, 通常将 UWB 传感器的距离测量值 \hat{d}_k 作为观测数据, 并与无人机到基站的欧氏距离作差, 从而构建如下残差:

$$r_{\mathcal{R}}(\hat{z}_k^j, \mathcal{X}) = \hat{d}_k - \| {}_B^W \mathbf{p}_k - {}_a^W \mathbf{p} \|, \quad \forall \hat{d}_k. \quad (26)$$

这类方法将距离测量值与状态向量中的位置信息相结合, 仅利用距离观测值对无人机的位置状态进行优化. 本文提出了一种融合距离梯度的残差构建方法. 考虑距离测量的零均值高斯噪声 $\eta_u \sim \mathcal{N}(0, \sigma_u^2)$, 利用第 j 时刻的距离测量值 d_j 与节点-基站相对位置关系 ${}_B^W \mathbf{p}_j - {}_a^W \mathbf{p}$ 构建下式:

$$d_j = \| {}_B^W \mathbf{p}_j - {}_a^W \mathbf{p} \| + \eta_u. \quad (27)$$

将式 (27) 对时间求梯度, 可得到

$$\frac{\partial d_j}{\partial t} = \frac{\partial \| {}_B^W \mathbf{p}_j - {}_a^W \mathbf{p} \|}{\partial t} + \eta_u,$$

$$\dot{d}_j = \frac{{}^W \mathbf{v}_j ({}^W \mathbf{p}_j - {}^W \mathbf{a} \mathbf{p})^T}{\|{}^W \mathbf{p}_j - {}^W \mathbf{a} \mathbf{p}\|} + \eta_v. \quad (28)$$

其中: ${}^W \mathbf{v}_j$ 为无人机运动速度; $\eta_v \sim \mathcal{N}(0, \sigma_v^2)$ 为距离梯度测量值高斯噪声; \dot{d}_j 为 j 时刻距离数据相对时间的梯度(即距离梯度), 由多项式后拟合滑动窗口内的距离数据恢复得到. 由此可得到距离梯度残差项

$$r_{\mathcal{D}}(\hat{z}_k, \mathcal{X}) = \hat{d}_j - \frac{{}^W \mathbf{v}_j ({}^W \mathbf{p}_j - {}^W \mathbf{a} \mathbf{p})^T}{\|{}^W \mathbf{p}_j - {}^W \mathbf{a} \mathbf{p}\|}. \quad (29)$$

所提出方法在利用距离与位置紧耦合融合的同

$$r_{\mathcal{B}}({}^B \hat{z}_{k+1}^k, \mathcal{X}) = \begin{bmatrix} \delta \alpha_{k+1}^k \\ \delta \beta_{k+1}^k \\ \delta \gamma_{k+1}^k \\ \delta b^a \\ \delta b^g \end{bmatrix} = \begin{bmatrix} {}^{b_k} \mathbf{R} \left({}^{w_{b_{k+1}}} \mathbf{p} - {}^{w_{b_k}} \mathbf{p} + \frac{1}{2} {}^w \mathbf{g} \Delta t_k^2 - {}^{w_{b_k}} \mathbf{v} \Delta t_k \right) - \hat{\alpha}_{k+1}^k \\ {}^{b_k} \mathbf{R} \left({}^{w_{b_{k+1}}} \mathbf{v} + {}^w \mathbf{g} \Delta t_k - {}^{w_{b_k}} \mathbf{v} \right) - \hat{\beta}_{k+1}^k \\ 2 \left[{}^{w_{b_k}^{-1}} \mathbf{q} \otimes {}^{w_{b_{k+1}}} \mathbf{q} \otimes (\hat{\gamma}_{k+1}^k)^{-1} \right]_{xyz} \\ b_{b_{k+1}}^a - b_{b_k}^a \\ b_{b_{k+1}}^g - b_{b_k}^g \end{bmatrix}, \quad (30)$$

$$r_{\mathcal{C}}({}^C \hat{z}_l^j, \mathcal{X}) = [b_1 \quad b_2]^T \cdot \left(\boldsymbol{\pi}_c^{-1} \left(\begin{bmatrix} c_l^j \hat{u} \\ c_l^j \hat{v} \end{bmatrix} \right) - \frac{c_l^j \mathcal{P}}{\|c_l^j \mathcal{P}\|} \right), \quad (31)$$

$$r_{\mathcal{R}}(\hat{z}_k^j, \mathcal{X}) = d_j - \left\| {}^W \mathbf{p}_k + \frac{1}{2} \Delta \hat{\mathbf{p}}_j^k + \frac{1}{2} {}^W \mathbf{v}_k \Delta t_j - {}^W \mathbf{a} \mathbf{p} \right\|, \quad (32)$$

$$r_{\mathcal{D}}(\hat{z}_k, \mathcal{X}) = \hat{d}_j - \frac{{}^W \mathbf{v}_j ({}^W \mathbf{p}_j - {}^W \mathbf{a} \mathbf{p})^T}{\|{}^W \mathbf{p}_j - {}^W \mathbf{a} \mathbf{p}\|}. \quad (33)$$

将上述构建的视觉特征、惯性、距离和距离梯度残差模型, 即式(30)~(33)代入(17), 通过在线迭代优化, 获得实时导航定位信息. 特别地, 在优化过程中, 式(33)表征的距离梯度因子包含了无人机的位置变化趋势, 从而提供部分无人机速度的测量信息, 能够实现对无人机速度的修正, 提升了速度估计精度. 在因子图优化过程中, 式(30)表述的IMU预积分因子构建方法与式(32)表述的UWB距离因子构建方法均与无人机速度密切相关, 因此, 对速度进行修正后可使得上述残差模型的构建更加准确, 从而进一步提高了导航系统的定位精度.

所提出算法的伪代码如下.

输入: 滑动窗口内的图像数据、IMU数据、UWB距离数据, 无人机状态 \mathcal{X} ;

输出: 下一时刻的无人机状态估计 \mathbf{x}_k .

1. 计算IMU预积分 $\gamma_{k+1}^k, \beta_{k+1}^k, \alpha_{k+1}^k$
2. 提取图像特征 $[c_l^j \hat{u}, c_l^j \hat{v}]$, 判断是否为关键帧
3. 拟合UWB距离数据, 得到距离 d 、距离梯度 \dot{d}
4. 进行初始化, 得到重力矢量、陀螺仪偏置、尺度
5. if 该帧为关键帧 then

时, 进一步在UWB数据中提取了距离梯度信息, 用距离梯度数据作为新的观测量与无人机的位置、速度构建UWB距离梯度残差, 并将这种新残差作为因子纳入联合优化过程中.

综上所述, 由第3.2节~第3.5节阐述的残差模型构建方法, 得到惯性残差 $r_{\mathcal{B}}({}^B \hat{z}_{k+1}^k, \mathcal{X})$ 、视觉残差 $r_{\mathcal{C}}({}^C \hat{z}_l^j, \mathcal{X})$ 、UWB距离残差 $r_{\mathcal{R}}(\hat{z}_k^j, \mathcal{X})$ 、距离梯度残差 $r_{\mathcal{D}}(\hat{z}_k, \mathcal{X})$, 如下所示:

6. 由IMU预积分得到 \mathbf{x}_k 初值
7. 增加初值 \mathbf{x}_k , 剔除旧值, 更新滑动窗口
8. 由式(30), 计算IMU残差 $r_{\mathcal{B}}({}^B \hat{z}_{k+1}^k, \mathcal{X})$
9. 由式(31), 计算视觉残差 $r_{\mathcal{C}}({}^C \hat{z}_l^j, \mathcal{X})$
10. 由式(32), 计算UWB距离残差 $r_{\mathcal{R}}(\hat{z}_k^j, \mathcal{X})$
11. 由式(33), 计算UWB距离梯度残差 $r_{\mathcal{D}}(\hat{z}_k, \mathcal{X})$
12. 由式(17), 构建优化模型, 进行迭代优化, 输出 \mathbf{x}_k
13. end if

4 实验

本节对实验方案设计和实验结果进行介绍和分析. 基于四旋翼无人机采集的公开数据集以及真实环境的飞行实验数据, 对基于单目视觉-惯性的VINS-Mono^[4]、基于单目视觉-惯性-单基站UWB的VIR-SLAM^[25]、距离聚焦方法^[26]以及所提出方法开展对比分析, 以验证所提出方法的有效性.

4.1 数据集实验

本文首先使用EuRoc公共数据^[33]进行实验验证, 该数据集主要包含无人机在室内环境中飞行时的IMU数据、单目视觉数据以及通过Vicon运动捕捉系统获得的真实轨迹数据. 基于上述数据, 利用上述4种方法实时估计无人机的位置, 通过分析定位误差来验证所提出算法的可行性和有效性. 绝对轨迹误差(ATE)是评估无人机定位系统的标准方法, 本文将用于评估里程计系统的性能.

目前, 缺乏同时包含视觉-惯性和UWB数据的数据集, 因此, UWB基站分别模拟放置在轨迹原点和轨迹中心, 根据动态捕捉系统测量的轨迹真值反算出UWB传感器测量值, 反算公式如下所示:

$$d = \|\mathbf{p}_t^w - \mathbf{p}_a^w\|. \quad (34)$$

其中: d 为反算距离, \mathbf{p}_B^w 、 \mathbf{p}_a^w 分别为 UWB 标签和基站的位置. 在模拟的 UWB 距离数据中添加方差为 0.03 的高斯白噪声. UWB 传感器数据以 38 Hz 的频率发布. 在 ROS 环境中进行无人机里程计系统模拟实验, 并使用 evo 工具分析实验结果.

实验的估计轨迹和真实轨迹如图 5 所示. 第 4 组实验结果的箱型图如图 6 所示. 分析图 6 结果可知, VIR_SLAM、距离聚焦以及所提出方法的定

位精度均高于 VINS-Mono, 这是由于上述方法在优化过程中增加了包含全局信息的 UWB 测距信息, 有效校准了无人机定位漂移, 从而减小了累计误差对定位精度的影响. 对比绝对轨迹误差结果如表 1 所示. 由表 1 可见, 与其他方法对比, 所提出方法具有较高的定位精度. 在 10 组实验中, 所提出算法的定位精度均最高, 与距离聚焦方法相比, 平均定位精度提高了 17.9%, 验证了所提出算法的有效性.

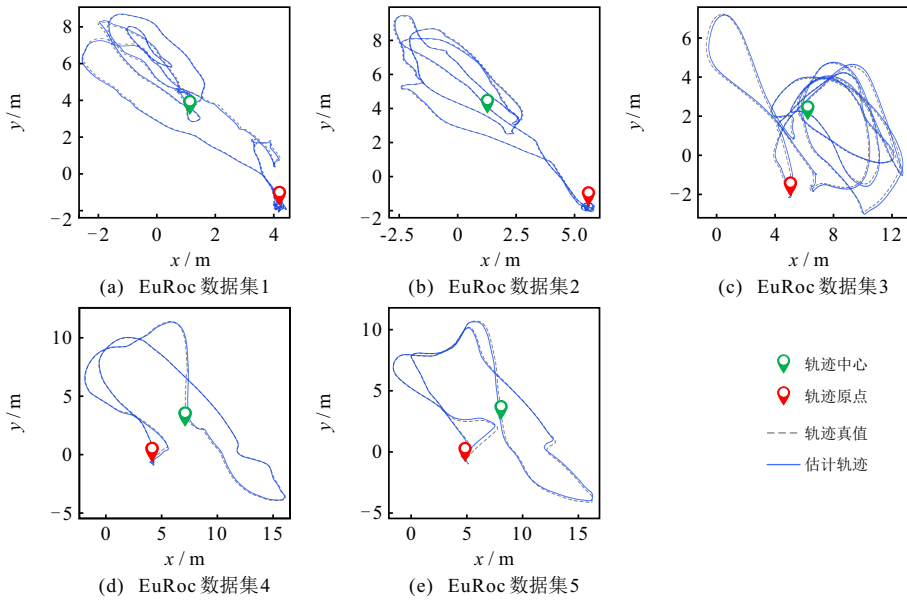


图5 EuRoC 数据集中的估计轨迹和真实轨迹




图6 MH_04 中不同方法的误差箱型图

4.2 飞行实验

4.2.1 飞行实验环境

为验证所提出视觉-惯性-UWB 融合无人机导航方法在定位精度、鲁棒性等方面的性能, 搭建了四旋翼无人机实验平台开展飞行实验. 将所提出方法与 VINS_Mono、VIR_SLAM、距离聚焦方法进行对比, 并评估所提出方法在位置估计、速度估计、漂移抑制等方面的综合性能.

如图 7 所示的四旋翼无人机搭载 ICM-20602 惯性测量单元、realsense D435 相机 (仅使用单目)、

LinkTrack AOA UWB 模块, 其板载 PC 为英伟达 NX origin, 配备 Core i5 处理单元以及 16 GB 内存. 相机采集图形分辨率为 640×480 , 采样频率为 20 Hz, IMU 采样频率为 200 Hz, UWB 采样频率为 200 Hz. 无人机导航系统在 Linux 系统下的开源机器人操作系统 (ROS) 进行开发, 相机、IMU、UWB 传感器接入 ROS 系统, 传感器数据包含时间戳信息, 由传感器的 ROS 驱动进行时间对齐.



图7 四旋翼无人机实验平台

表1 各方法在 EuRoc 数据集的均方根误差

数据集编号	基站位置	VINS_Mono	VIR_SLAM	距离聚焦方法	本文方法
MH_01	轨迹原点	0.181 604	0.162 571	0.105 745	0.083 951
	轨迹中心	0.181 604	0.160 147	0.119 196	0.095 684
MH_02	轨迹原点	0.167 242	0.112 530	0.106 147	0.088 813
	轨迹中心	0.167 242	0.110 358	0.102 547	0.099 312
MH_03	轨迹原点	0.217 986	0.152 399	0.144 513	0.128 880
	轨迹中心	0.217 986	0.154 395	0.143 875	0.138 756
MH_04	轨迹原点	0.359 462	0.218 051	0.167 883	0.109 310
	轨迹中心	0.359 462	0.200 543	0.181 007	0.113 734
MH_05	轨迹原点	0.330 961	0.175 423	0.164 651	0.162 484
	轨迹中心	0.330 961	0.169 354	0.191 846	0.181 707

无人机飞行环境为实验室车间,飞行区域大小为 $6\text{ m} \times 6\text{ m} \times 4\text{ m}$ 。飞行场地被如图8所示的动态捕捉系统覆盖,为无人机导航对比实验提供轨迹真值,并由差分求得速度真值。该系统型号为 Optitrack PrimeX 13W,其具体参数如表2所示。世界坐标系定义在无人机起飞位置,UWB 基站被提前布置于轨迹后方固定位置。



图8 无人机飞行实验环境

表2 Optitrack PrimeX 13W 系统参数

分辨率	帧速	视场角	捕捉距离/m
1280×1024	240	82×70	9

4.2.2 飞行实验结果分析

分别对 VINS_Mono、VIR_SLAM、距离聚焦方法、所提出方法开展飞行实验,以验证所提出算法在位置估计、速度估计以及漂移抑制方面的性能,在室内实验室环境中对所提出方法进行评估。基站被提前布置于实验场景中的无人机起飞位置附近,其位置的三维坐标已知。无人机在室内进行直线、三角、矩形、圆形轨迹等多组轨迹飞行,飞行轨迹示意如图9所示。无人机平均飞行速度为 0.5 m/s 。由动态捕捉系统获取无人机的定位数据,作为飞行实验真值用于多种方法的对比实验。

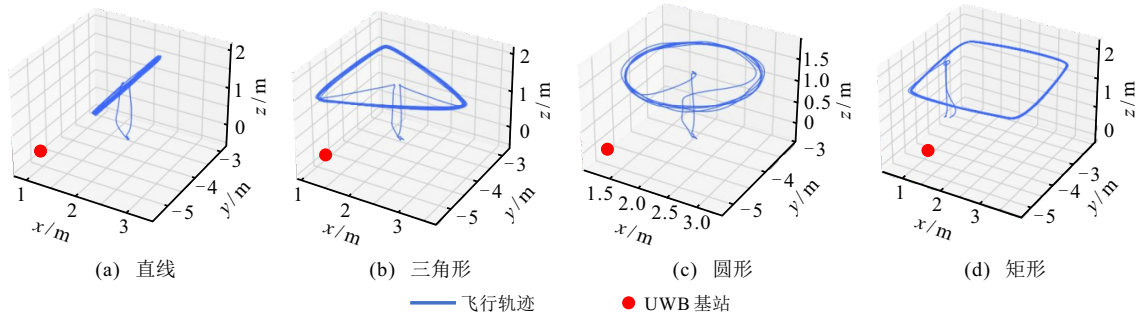


图9 无人机飞行实验轨迹

图10以三角形轨迹飞行实验为例展示了所提出方法与距离聚焦方法的估计轨迹对比情况。分析估计轨迹与真实轨迹情况可得到,两种方法在 x 轴的漂移均得到了显著抑制,但是在 y 轴仍然存在一定的漂移情况,这是由于单基站 UWB 数据的漂移抑制效果有限,其主要对沿 UWB 基站到标签的矢量方向的漂移进行抑制。而所提出方法相较于距离聚焦法的轨迹在大部分区域更加接近于动态捕捉系统所提供的真实轨迹,验证了所提出算法在漂移抑制方面具有更好的性能。

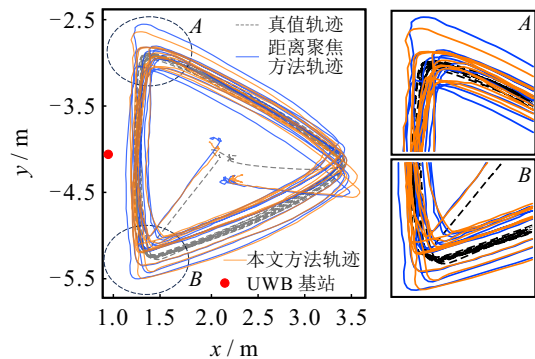


图10 不同方法在三角形轨迹中的定位结果

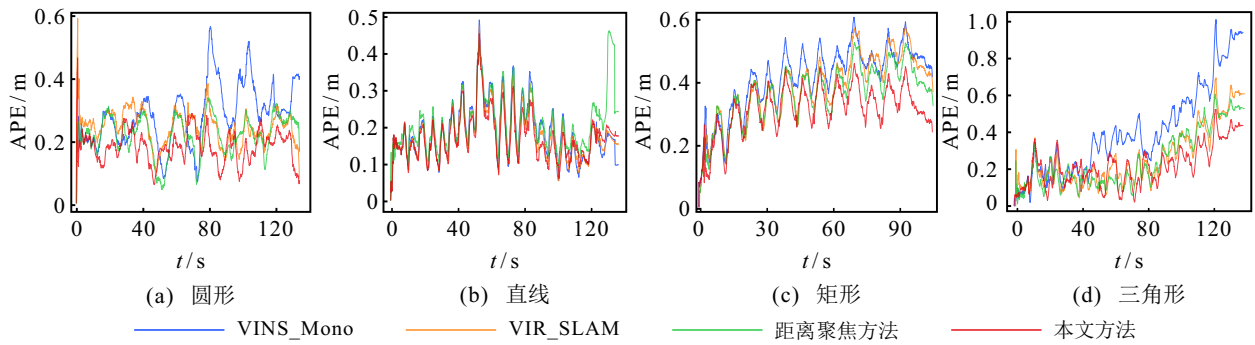


图11 不同方法的绝对轨迹误差

图 11 为 4 种方法的误差变化, 其中红色所表示的所提出方法的误差均为最低. 由 VIO 的误差曲线分布可得到, 由于累计误差产生的漂移没有得到有效地纠正和补偿, 导致误差快速增大. VIR_SLAM、距离聚焦以及所提出方法由于加入了 UWB 全局传感器, 使得无人机定位累计误差有所减小, 且所提出融合距离梯度方法显然在所有导航系统中效果最佳.

表 3 为 VINS-Mono、VIR-SLAM、距离聚焦以及所提出方法在上述场景下进行飞行实验的位置、速度的均方根误差, 每组定位精度最高数据加粗表示. 由表 3 中数据分析可得到, 在速度估计方面, 相较于 VIO 方法, VIR-SLAM 和距离聚焦方法速度估计精度分别提升了 2.61% 和 2.43%, 速度估计精度并无明显变化. 而所提出方法速度估计精度提升了 15.60%, 这是由于所提出距离梯度法将含有部分速度测量信息的距离梯度引入优化过程, 从而对速度进行了修正, 而其他使用 UWB 测距信息进行导航定位的方法均未使用距离梯度信息, 无法对速度进行优化. 上述 4 种方法在多组轨迹进行定位实验的误差算数平均分别为 0.342 306 m、0.291 623 m、0.268 606 m、0.232 694 m, 所提出方法在 4 组轨迹中定位精度均最高. 相较于 VIO, 所提出方法的定位精

度提升了 32.02%, 而 VIR-SLAM 和距离聚焦方法仅提升了 14.81% 和 21.51%.

所提出方法引入了距离梯度对速度的修正, 将距离梯度与无人机位置、速度紧耦合融合, 提升了速度估计精度, 进而提高了定位精度. 相较于相同测量条件下的距离聚焦方法定位系统, 所提出方法的速度估计精度同比提升了 13.4%, 由此带来的定位精度同比提升了 13.7%. 对每种轨迹使用不同方法进行 20 组离线验证实验, 对定位结果进行显著统计性检验, 所提出方法与距离聚焦方法在直线、三角形、矩形、圆形的 p 值分别为 0.009, 0.010, 0.007, 0.012, 均小于 0.05, 由此表明两种方法间存在显著差异, 验证了融合距离梯度的单目视觉-惯性-UWB 紧耦合导航定位方法的可行性和有效性.

表 4 为多种方法在第 4.2.1 节所述的板载 PC 运行不同导航系统的单次优化时间. 由表 4 可见, 相较于仅使用视觉-惯性融合的 VINS_Mono, 使用视觉-惯性-UWB 融合的 VIR_SLAM、距离聚焦、所提出方法的计算时间分别提升了 12.8%、2.8%、3.4%. 所提出梯度拟合方法仅在滑动窗口内运行, 从而节省了计算资源, 耗时仅为 0.099 2 ms, 同时, UWB 的观测信息为一维的距离、距离梯度数据, 优化模型资源

表3 各方法在不同飞行实验中的均方根误差

飞行实验	误差项	VINS_Mono	VIR_SLAM	距离聚焦方法	本文方法
直线	位置	0.206 857	0.231 552	0.197 558	0.187 919
	速度	0.043 548	0.042 564	0.039 541	0.034 132
三角形	位置	0.433 761	0.283 281	0.271 878	0.227 214
	速度	0.045 146	0.041 654	0.042 546	0.035 486
矩形	位置	0.432 483	0.403 727	0.378 648	0.328 264
	速度	0.041 563	0.043 654	0.045 412	0.040 368
圆形	位置	0.296 121	0.247 932	0.226 343	0.187 378
	速度	0.054 135	0.051 572	0.052 415	0.048 654
误差均值	位置	0.342 306	0.291 623	0.291 623	0.232 694
	速度	0.046 098	0.044 861	0.044 978	0.038 907
位置估计误差相较于VIO误差变化/%			-14.81	-21.51	-32.02
速度估计误差相较于VIO误差变化/%			-2.61	-2.43	-15.60

占用较低,因此,所提出方法单次优化时间相较于 VINS_Mono 并无明显提升,验证了所提出方法的实时性能。

表4 单次优化计算时间 ms

VINS_Mono	VIR_SLAM	距离聚焦	本文方法
35.1426	39.6512	36.1248	36.3514

UWB 传感器可根据信号强度指标检测测距数据是否存在遮挡,因此,在原实验数据中随机删除若干时间段的 UWB 测距数据,可模拟 UWB 传感器的动态遮挡场景.在上述情况下对 VIR_SLAM、距离聚焦以及所提出方法开展对比实验,实验结果的绝对轨迹误差以及在多组轨迹进行实验的定位误差算数平均值如表 5 所示,其中定位精度最高的数据加粗表示.分析表 5 中数据可知,各种方法的定位精度相较于无遮挡情况均有所降低,但是仍然高于仅使用视觉-惯性融合定位的 VINS_Mono 方法.在 4 组不同轨迹的实验数据中,所提出方法定位精度均最高,与 VINS_Mono、距离聚焦方法相比,定位精度分别提升了 21.9%、7.9%,验证了所提出方法具有一定的鲁棒性。

表5 动态遮挡条件下各方法的均方根误差

飞行实验	VIR_SLAM	距离聚焦方法	本文方法
直线	0.241254	0.201257	0.199523
三角形	0.312547	0.281239	0.279524
矩形	0.421475	0.415698	0.400125
圆形	0.294254	0.254129	0.200124
误差均值	0.302021	0.299963	0.257415

在 UWB 频率降低至 50 Hz 的情况下对各导航系统开展对比实验,实验结果如表 6 所示.相较于 UWB 频率为 200 Hz 的实验结果, VIR_SLAM 的定位精度变化最小,误差仅提升了 2.1%,而距离聚焦方法与所提出方法的定位误差分别提升了 6.6% 和 9.3%.这是由于距离聚焦方法利用了高频的 UWB 数据构建优化项,而本文在此基础上利用高频 UWB 数据拟合了距离梯度,进一步充分利用了 UWB 测距的动态信息,定位精度对于频率有一定的敏感性.所提出方法即使会受到频率降低的影响,但是仍然利用 UWB 的测距动态信息修正位置和速度,因此,

表6 UWB 降频至 50 Hz 条件下各方法的均方根误差

飞行实验	VIR_SLAM	距离聚焦方法	本文方法
直线	0.240825	0.235479	0.207479
三角形	0.284125	0.281428	0.242478
矩形	0.410571	0.392695	0.351247
圆形	0.254125	0.251475	0.219547
误差均值	0.300145	0.295635	0.251235

定位精度在多组实验中均为最高,相较于距离聚焦方法提升了 12.7%,验证了所提出方法在低频 UWB 测距条件下的有效性。

5 结论

针对基于 VIO 导航方法所存在的定位漂移问题,本文提出了一种融合距离梯度的单目视觉-惯性-UWB 紧耦合导航定位方法,通过构建 UWB 测距及其梯度信息的残差模型,利用因子图优化方法实现了 VIO 与 UWB 的信息融合,利用距离及其梯度数据对无人机的位置、速度信息进行了修正.所提出方法在 EuRoc 数据集以及实际无人机系统进行了多种飞行模式的实验验证,实验结果表明了所提出方法的可行性和有效性.相较于视觉-惯性-UWB 传感器融合导航的最新方法,导航定位精度提升了 13.7%。

参考文献 (References)

- [1] Yang Y L, Geneva P, Huang G Q. Multi-visual-inertial system: Analysis, calibration, and estimation[J]. *The International Journal of Robotics Research*, 2024, 43(13): 1995-2026.
- [2] Queralta J P, Taipalmaa J, Pullinen B C, et al. Collaborative multi-robot search and rescue: Planning, coordination, perception, and active vision[J]. *IEEE Access*, 2020, 8: 191617-191643.
- [3] Leutenegger S, Lynen S, Bosse M, et al. Keyframe-based visual-inertial odometry using nonlinear optimization[J]. *The International Journal of Robotics Research*, 2015, 34(3): 314-334.
- [4] 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.
- [5] Bloesch M, Burri M, Omari S, et al. Iterated extended Kalman filter based visual-inertial odometry using direct photometric feedback[J]. *The International Journal of Robotics Research*, 2017, 36(10): 1053-1072.
- [6] Chen C C, Geneva P, Peng Y X, et al. Monocular visual-inertial odometry with planar regularities[C]. *IEEE International Conference on Robotics and Automation*. London, 2023: 6224-6231.
- [7] Weinstein A, Cho A, Loianno G, et al. Visual inertial odometry swarm: An autonomous swarm of vision-based quadrotors[J]. *IEEE Robotics and Automation Letters*, 2018, 3(3): 1801-1807.
- [8] 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.
- [9] Yang B Y, Yang E F. A survey on radio frequency based precise localisation technology for UAV in GPS-denied environment[J]. *Journal of Intelligent & Robotic Systems*, 2021, 103: 38.
- [10] 宁一高, 岳明, 许媛, 等. 基于 IMU/UWB 的两轮自平衡车轨迹跟踪控制器设计与实现[J]. *控制与决策*, 2019, 34(12): 2635-2641.
(Ning Y G, Yue M, Xu Y, et al. Design and

- implementation of trajectory tracking controller for two-wheeled self-balancing vehicles based on IMU/UWB[J]. *Control and Decision*, 2019, 34(12): 2635-2641.)
- [11] Strohmeier M, Walter T, Rothe J, et al. Ultra-wideband based pose estimation for small unmanned aerial vehicles[J]. *IEEE Access*, 2018, 6: 57526-57535.
- [12] You W D, Li F B, Liao L Q, et al. Data fusion of UWB and IMU based on unscented Kalman filter for indoor localization of quadrotor UAV[J]. *IEEE Access*, 2020, 8: 64971-64981.
- [13] Yang B Y, Yang E F, Yu L J, et al. Adaptive extended Kalman filter-based fusion approach for high-precision UAV positioning in extremely confined environments[J]. *IEEE/ASME Transactions on Mechatronics*, 2022, 28(1): 543-554.
- [14] Song Y, Hsu L T. Tightly coupled integrated navigation system *via* factor graph for UAV indoor localization[J]. *Aerospace Science and Technology*, 2021, 108: 106370.
- [15] 黄家才, 王徐寅, 高芳征, 等. 基于改进天牛须优化粒子滤波的 UWB/LiDAR 室内定位方法[J]. *控制与决策*, 2024, 39(10): 3261-3269.
(Huang J C, Wang X Y, Gao F Z, et al. UWB/LiDAR indoor positioning method based on improved beetle antennae search algorithm optimized particle filter[J]. *Control and Decision*, 2024, 39(10): 3261-3269.)
- [16] Lin H Y, Zhan J R. GNSS-denied UAV indoor navigation with UWB incorporated visual inertial odometry[J]. *Measurement*, 2023, 206: 112256.
- [17] Shin S, Lee E, Choi J, et al. MIR-VIO: Mutual information residual-based visual inertial odometry with UWB fusion for robust localization[C]. *Proceedings of the 21st International Conference on Control, Automation and Systems*. Jeju, 2021: 91-96.
- [18] Fan G J, Wang Q, Yang G C, et al. RFG-TVIU: Robust factor graph for tightly coupled vision/IMU/UWB integration[J]. *Frontiers in Neurorobotics*, 2024, 18: 1343644.
- [19] Goudar A, Zhao W D, Schoellig A P. Range-visual-inertial sensor fusion for micro aerial vehicle localization and navigation[J]. *IEEE Robotics and Automation Letters*, 2023, 9(1): 683-690.
- [20] Hu C, Huang P, Wang W. Tightly coupled visual-inertial-UWB indoor localization system with multiple position-unknown anchors[J]. *IEEE Robotics and Automation Letters*, 2024, 9(1): 351-358.
- [21] Guo K X, Li X X, Xie L H. Ultra-wideband and odometry-based cooperative relative localization with application to multi-UAV formation control[J]. *IEEE Transactions on Cybernetics*, 2019, 50(6): 2590-2603.
- [22] Xu H, Zhang Y C, Zhou B Y, et al. Omni-swarm: A decentralized omnidirectional visual-inertial-UWB state estimation system for aerial swarms[J]. *IEEE Transactions on Robotics*, 2022, 38(6): 3374-3394.
- [23] Nguyen T H, Nguyen T M, Xie L H. Flexible and resource-efficient multi-robot collaborative visual-inertial-range localization[J]. *IEEE Robotics and Automation Letters*, 2021, 7(2): 928-935.
- [24] Fernando E, De Silva O, Mann G K I, et al. Observability analysis of position estimation for quadrotors with modified dynamics and range measurements[C]. *IEEE/RSJ International Conference on Intelligent Robots and Systems*. Macau, 2019: 2783-2788.
- [25] Cao Y J, Beltrame G. VIR-SLAM: Visual, inertial, and ranging SLAM for single and multi-robot systems[J]. *Autonomous Robots*, 2021, 45: 905-917.
- [26] Nguyen T H, Nguyen T M, Xie L H. Range-focused fusion of camera-IMU-UWB for accurate and drift-reduced localization[J]. *IEEE Robotics and Automation Letters*, 2021, 6(2): 1678-1685.
- [27] Nister D. An efficient solution to the five-point relative pose problem[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004, 26(6): 756-770.
- [28] Shen S J, Michael N, Kumar V. Tightly-coupled monocular visual-inertial fusion for autonomous flight of rotorcraft MAVs[C]. *IEEE International Conference on Robotics and Automation*. Seattle, 2015: 5303-5310.
- [29] Lucas B D, Kanade T. An iterative image registration technique with an application to stereo vision[C]. *Proceedings of the 7th International Joint Conference on Artificial Intelligence*. Vancouver, 1981: 674-679.
- [30] Shi J B, Tomasi. Good features to track[C]. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Seattle, 1994: 593-600.
- [31] Hartley R, Zisserman A. *Multiple view geometry in computer vision*[M]. The 2nd edition. Cambridge: Cambridge University Press, 2003.
- [32] Huber P J. Robust estimation of a location parameter[J]. *The Annals of Mathematical Statistics*, 1964, 35(1): 73-101.
- [33] Burri M, Nikolic J, Gohl P, et al. The EuRoC micro aerial vehicle datasets[J]. *The International Journal of Robotics Research*, 2016, 35(10): 1157-1163.

作者简介

蒋浩然 (2000–), 男, 硕士生, 主要研究方向为无人机导航、多传感器融合, E-mail: jianghaoran@sia.cn;

谷丰 (1982–), 男, 研究员, 博士, 主要研究方向为移动机器人自主行为、多机器人协同、无人机系统, E-mail: fenggu@sia.cn;

滕天启 (2001–), 男, 硕士生, 主要研究方向为多传感器融合, E-mail: tengtianqi@sia.cn;

何玉庆 (1980–), 男, 研究员, 博士, 主要研究方向为行为智能、跨域协同、特种机器人系统, E-mail: heyuqing@sia.cn.