

DOI: 10.19650/j.cnki.cjsi.J2514349

基于闭环图像矫正和线特征聚类的改进 PL-VINS*

张原玮¹, 王 祝^{1,2}, 姚万业^{1,2}, 王天宁^{1,2}

(1. 华北电力大学自动化系 保定 071003; 2. 保定市电力系统智能机器人感知与控制重点实验室 保定 071003)

摘 要:在光照变化和重复纹理环境中,现有视觉惯性导航系统(VINS)存在特征提取数量不足和特征误匹配率高等问题,导致位姿估计精度和系统鲁棒性难以满足应用需求。对此,提出了一种改进 PL-VINS 算法,改善光照变化环境下的特征提取性能和重复纹理环境下的特征匹配性能。具体地,在图像预处理模块,提出一种闭环伽马矫正方法对图像亮度进行迭代调整,直至图像亮度达到期望值,以提高可提取到的特征数量,从而增强系统在光照变化环境下的鲁棒性;在线特征检测和跟踪模块,先计算空间平行线段对在图像平面的交点,并对交点进行聚类得到交点簇及其加权中心点,再依据线特征与加权中心点的距离和方向实现线特征的聚类,以提升重复纹理环境下线特征匹配的鲁棒性;在后端优化模块,将同簇线特征的交点作为特征加入到优化中,构建点、线和交点特征融合的重投影残差,以提升重复纹理环境下的位姿估计精度。公开数据集上对比测试结果表明,改进 PL-VINS 在 EuRoC 数据集上的绝对位姿误差平均值相比 PL-VINS 算法降低 17.4%;在 UMA-VI 数据集上的绝对位姿误差平均值相比 SuperVINS 算法降低 12.2%。为了进一步验证算法有效性,基于移动机器人搭建试验平台进行实物测试。实物试验结果表明,改进 PL-VINS 相比对比算法在光照变化和重复纹理环境下表现出更好的准确性和鲁棒性。

关键词:视觉定位;图像矫正;线特征聚类;PL-VINS

中图分类号: TP242 TH701 **文献标识码:** A **国家标准学科分类代码:** 510.80

Improved PL-VINS based on closed-loop image correction and line feature clustering

Zhang Yuanwei¹, Wang Zhu^{1,2}, Yao Wanye^{1,2}, Wang Tianning^{1,2}

(1. Department of Automation, North China Electric Power University, Baoding 071003, China; 2. Baoding Key Laboratory of Intelligent Robot Perception and Control in Electric Power System, Baoding 071003, China)

Abstract:In varying-illumination and repetitive-texture environments, existing visual-inertial navigation systems (VINS) suffer from insufficient feature extraction and high feature mismatch rates, failing to meet application requirements in pose estimation accuracy and system robustness. To address these challenges, an improved PL-VINS is presented to enhance feature extraction in varying-illumination scenes and feature matching in repetitive-texture environments. In the image preprocessing module, a closed-loop gamma correction method iteratively adjusting image brightness until the desired level is proposed to increase the number of extractable features, thereby enhancing system robustness under varying illumination conditions. In the line feature detection and tracking module, the intersection points of spatially parallel line pairs are first calculated in the image plane and clustered to obtain intersection-point clusters and their weighted centers. Then the line features are clustered based on their distance and direction relative to these weighted centers to enhance the robustness of line feature matching in repetitive-texture environments. In the backend optimization module, the intersection points of intra-cluster line features are incorporated into optimization as additional features. Reprojection residuals that jointly fusing point, line, and intersection features are constructed to improve pose estimation accuracy in repetitive texture scenarios. Comparative experiments on public datasets demonstrate that the improved PL-VINS reduces the average absolute pose error by 17.4% on the EuRoC dataset compared to PL-VINS and by 12.2% on the UMA-VI dataset compared to SuperVINS. To further verify the effectiveness of the proposed method, an experimental platform using a mobile robot was constructed for real-world testing. The results indicate that the improved

收稿日期:2025-08-04 Received Date: 2025-08-04

* 基金项目:中央高校基本科研业务费面上项目(2024MS140)资助

PL-VINS exhibits superior accuracy and robustness compared to state-of-the-art algorithms in environments with illumination changes and repetitive textures.

Keywords: visual localization; image correction; line features clustering; PL-VINS

0 引 言

同步定位与建图 (simultaneous localization and mapping, SLAM) 是移动机器人和自动驾驶领域的关键技术之一^[1]。其中,视觉惯性导航系统 (visual-inertial navigation system, VINS) 具有成本低、信息量丰富、使用场景多样的优点,具有良好发展潜力^[2-4]。

VINS 通常分为直接法和特征法。以 DSO^[5] (direct sparse odometry) 为代表的直接法通过使用最小化光度误差直接求解相机位姿。然而,由于该方法依赖梯度优化,在图像质量不佳或相机初始位姿误差较大时,其定位稳定性和准确性难以满足应用需求。特征法则通过图像预处理,可以在原始图像质量不佳的情况下仍具有较好稳定性。但在光照变化大的环境,图像可能出现过曝或欠曝,特征法难以提取足够数量的稳定特征,进而造成定位漂移甚至丢失。同时,在重复纹理场景中,容易出现特征检测和匹配错误,也会造成定位漂移。

针对光照变化大的环境,特征法主要通过图像预处理^[6-7]来改善,处理方法包括:改善图像亮度、改变图像类型和基于深度学习的方法。改善图像亮度的方法中,VINS-MONO^[8]利用直方图均衡化调整图像亮度分布,增强亮区和暗区细节,从而提高系统在光照变化环境中的性能;改变图像类型的方法有高动态测距 (high-dynamic ranging, HDR) 图像方法^[9],例如 Albrecht 等^[10]使用 HDR 图像作为输入,以捕捉更广的亮度范围,减少图像过曝和欠曝,实现更准确的特征提取和匹配;基于深度学习的预处理方法中,

DarkSLAM 等^[11]使用生成对抗网络作为预处理模块,使用反灰度图作为注意力图来提升亮度不均区域的处理效果。上述图像预处理方法虽然能改善图像质量,但缺少对处理后图像的质量评估,没有形成闭环,无法保证改善效果。

针对重复纹理场景的研究主要包括多特征融合法和融合语义的方法^[12-13]。多特征融合法将点特征和线特征融合,例如 Zhi 等^[14]结合低阈值点特征和线特征,增强系统在重复纹理环境中的鲁棒性,缓解了特征丢失问题,但该方法在具有大量单一特征的场景中,线特征匹配效果不理想。融合语义的方法则通过引入语义模块来筛选特征,例如 Li 等^[15]利用多传感器数据和语义信息增强的方法,提高了重复纹理下定位精度和系统鲁棒性。上述研究虽然通过引入线特征或语义信息改善了定位效果,但缺乏对特征误匹配问题的优化。

为了克服上述问题,本文提出一种基于闭环图像矫正和线特征聚类的改进 PL-VINS^[16]。主要工作包括:1) 图像预处理模块提出一种闭环伽马矫正方法以保证改善后图像的质量;2) 线特征检测和跟踪模块依据线段交点对线特征进行聚类,得到相似度高的线段簇以减少误匹配情况;3) 后端优化模块加入交点残差以提升位姿估计的准确性;4) 最后,通过 EuRoC^[17]、UMA-VI^[18]数据集和实际场景对算法有效性和优势进行验证。

1 系统框架

改进 PL-VINS 算法基于 PL-VINS 开发,其系统框架如图 1 所示,图中深色填充部分表示主要改进之处。

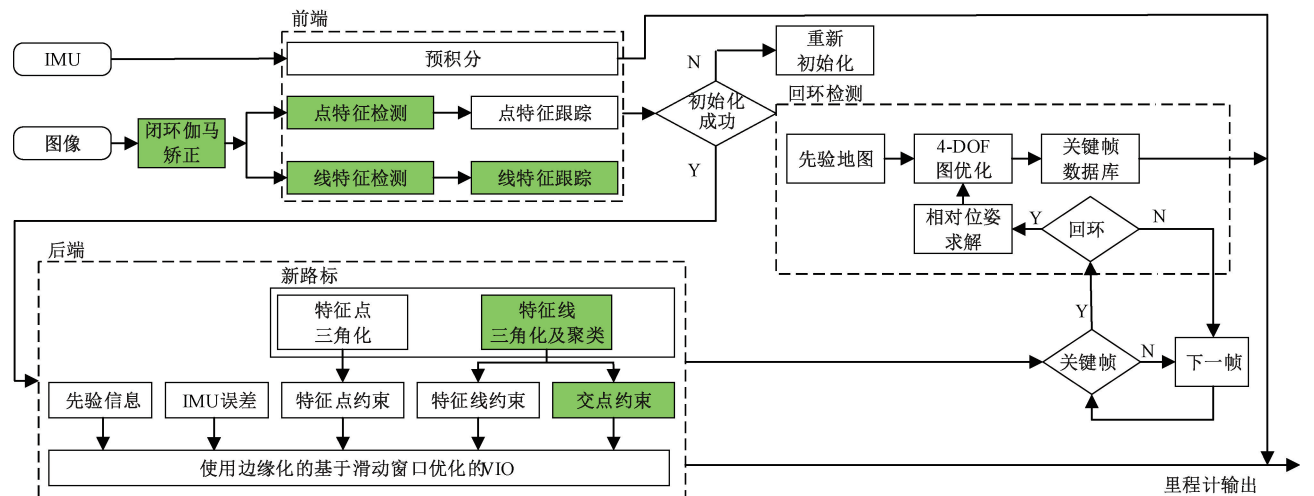


图 1 改进 PL-VINS 的系统框架

Fig. 1 System architecture of improved PL-VINS

改进 PL-VINS 算法包含前端、后端和回环检测 3 个线程。

1) 前端线程:对输入的惯性测量单元 (inertial measurement unit, IMU) 数据进行预积分;对于输入的原始图像,先利用闭环伽马矫正来改善图像质量,再进行点、线特征的检测和跟踪。然后,通过初始化将 IMU 预积分与视觉测量进行全局一致对齐。初始化成功后触发后端线程。

2) 后端线程:采用滑动窗口优化框架,对线特征进行聚类后,将交点约束构建为残差项,加入到图优化模型中。通过联合最小化不同的观测残差,实现对相机位姿与结构特征的紧耦合优化估计。其中,为保证实时性,系统对历史关键帧和特征实施边缘化处理。

3) 回环检测:系统通过与先验地图中的关键帧进行图像和位姿匹配,判断是否形成回环。若存在回环,则通过回环约束得到全局一致的里程计输出。

2 闭环伽马矫正

光照变化会显著影响点、线特征的检测数量和质量,故设计一种闭环伽马矫正模块以减少光照变化对系统的影响。本章首先介绍闭环伽马矫正的方法,然后通过试验测试验证矫正效果。

2.1 闭环伽马矫正模块

闭环伽马矫正根据图像实际亮度和期望亮度的差异调整伽马值,迭代优化图像均值亮度,确保图像均值亮度逐步逼近期望均值亮度。这种闭环设计能够在亮度对比度变化大的场景中更好地优化图像质量。闭环伽马矫正具体步骤为:

1) 计算图像均值亮度值:通过计算图像像素的亮度,得到当前图像均值亮度。

2) 判断亮度值是否符合要求:判断当前图像均值亮度是否满足式(1)所示的收敛条件:若当前图像均值亮度与期望图像均值亮度差值小于收敛阈值 ε ,则执行步骤 5)。否则,执行步骤 3)。

$$|L_m - L^*| \leq \varepsilon \quad (1)$$

式中: L_m 表示当前图像均值亮度; L^* 为图像期望均值亮度。

3) 动态调整伽马值:根据图像当前均值亮度和期望均值亮度间的差异,如式(2)所示计算伽马值。

$$\gamma^* = \frac{\log(L^*)}{\log(L_m)} \quad (2)$$

式中: γ^* 为更新的伽马值。

4) 执行图像矫正:根据步骤 3) 得到的伽马值,按照式(3)中的公式对图像亮度进行矫正^[19],得到矫正后图像。随后,返回执行步骤 1)。

$$L_{out}(x, y) = L_{in}(x, y)^{\gamma^*} \quad (3)$$

式中: $L_{in}(x, y)$ 表示当前输入图像各像素的亮度; $L_{out}(x, y)$ 是输出图像各像素的亮度。

5) 输出图像:输出矫正后满足要求的图像,结束闭环伽马矫正流程。

2.2 闭环伽马矫正效果测试

1) 闭环伽马矫正的收敛性测试

为了验证闭环伽马矫正的收敛性,从 EuRoC 数据集的 V1_03 数据序列中均匀抽取 11 张图像进行测试。闭环伽马矫正的最大迭代次数设为 10 次,期望均值亮度设为 128,得到如图 2 所示的均值亮度和伽马值变化曲线。从图 2 可以看出,随着迭代次数的增加,图像实际均值亮度逐步接近期望均值亮度,并且在第 5 次迭代时,图像实际均值亮度与期望均值亮度之差均达到 0.01 以内。试验结果表明,闭环伽马矫正能够将图像实际均值亮度收敛到预期效果。

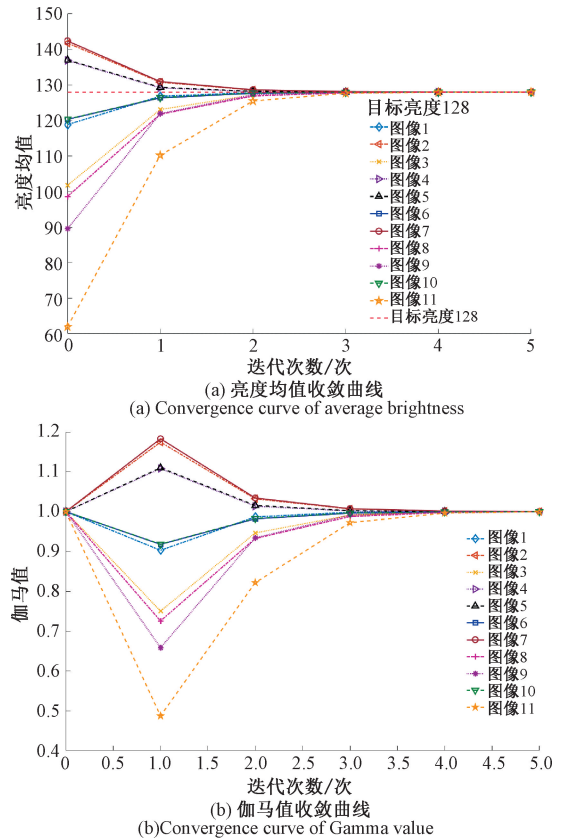


图 2 闭环伽马矫正收敛测试结果

Fig. 2 Convergence test of closed loop Gamma correction

2) 闭环伽马矫正的有效性测试

为检验闭环伽马矫正有效性,基于 EuRoC 数据集内厂房场景中部分亮区和暗区,将闭环伽马矫正与直方图均衡化、一般伽马矫正进行对比。试验中期望均值亮度为 128,最大迭代次数为 10,收敛阈值 ε 为 0.01。

不同图像预处理后的点、线特征的检测结果如图 3~6 所示。图中圆点代表检测到的点特征,线段代表检测到的线特征。由图 3~6 可知,闭环伽马矫

正所得图像相比于直方图均衡化和一般伽马矫正所得图像,在明亮和黑暗场景中均能获得更好的特征提取效果。




图 3 明亮环境下 3 种图像预处理后的点特征检测结果

Fig. 3 Point feature detection results of three algorithms in bright environments

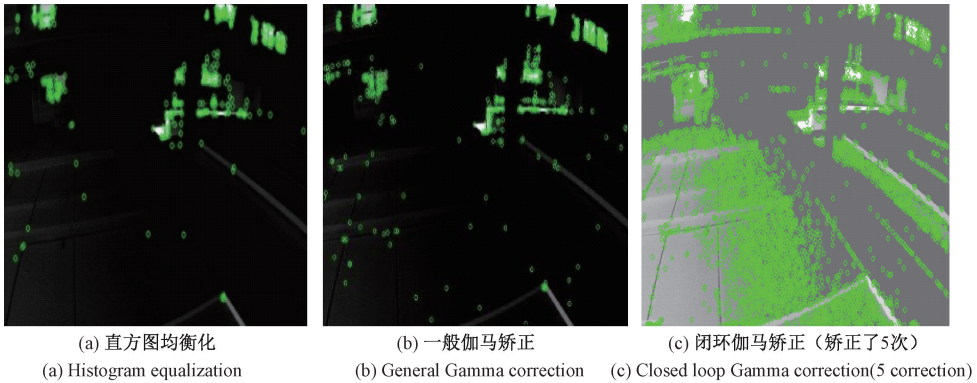


图 4 黑暗环境下 3 种图像预处理后的点特征检测结果

Fig. 4 Point feature detection results of three algorithms in dark environments




图 5 明亮环境下 3 种图像预处理后的线特征检测结果

Fig. 5 Line feature detection results of three algorithms in bright environments

表 1 给出了不同图像预处理算法所得图像对应特征检测的具体结果。对于点特征检测,明亮环境下,图像经闭环伽马矫正后检测到的特征数比直方图均衡化提升约

139.00%,比一般伽马矫正提升约 76.64%;黑暗环境下,图像经闭环伽马矫正后检测到的特征数相比直方图均衡化提升约 1 383.75%,相比一般伽马矫正提升约

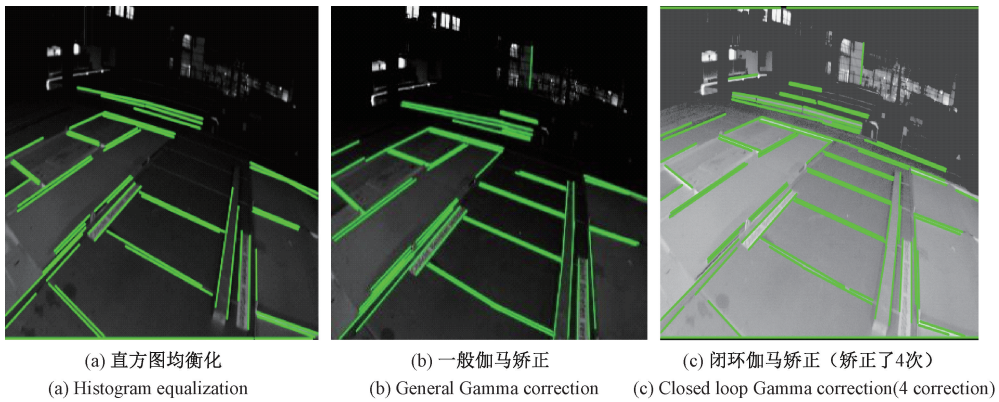


图6 黑暗环境下3种图像预处理后的线特征检测结果

Fig. 6 Line feature detection results of three algorithms in dark environments

表1 厂房场景中点、线特征检测的平均数量

Table 1 Average number of detected point and line features in the factory scenario (个)

场景	特征数量	直方图均衡化	一般伽马矫正	闭环伽马矫正
明亮	点特征	1 658	2 243	3 962
	线特征	59	79	89
黑暗	点特征	320	484	4 748
	线特征	50	56	76

880.99%。对于线特征检测,明亮环境下,图像经闭环伽马矫正算法矫正后检测到的特征数比直方图均衡化提升约50.85%,比一般伽马矫正提升约12.66%;黑暗环境下,图像经闭环伽马矫正算法矫正后检测到的特征数较直方图均衡化和一般伽马矫正分别提升了52.00%和35.71%。

表2给出了分别采用伽马矫正和闭环伽马矫正的PL-VINS在EuRoC全数据序列上的绝对位姿误差均方根误差(root mean square error of absolute pose error, APE RMSE)结果,表中闭环伽马矫正数值后方的箭头向上表示轨迹误差较伽马矫正增大,向下表示轨迹误差较伽马矫正减小。

由表2可知,闭环伽马矫正能稳定提升系统的定位精度,尤其是在V1_02_medium序列,定位精度相比伽马矫正提升了86.70%。由于伽马矫正的伽马值是预设的,所以图像矫正效果也是固定的,而每张图像亮度不同,无法保证对连续图像的矫正效果。而闭环伽马矫正可以根据每张图像的亮度进行自适应矫正,能够更好地保证矫正效果,提高定位精度。

表2 采用伽马矫正和闭环伽马矫正的PL-VINS轨迹误差对比

Table 2 Comparison of trajectory errors for PL-VINS using Gamma correction and closed-loop Gamma correction (m)

数据序列	伽马矫正	闭环伽马矫正
MH_01_easy	0.197	0.191 ↓
MH_02_easy	0.205	0.188 ↓
MH_03_medium	0.210	0.201 ↓
MH_04_difficult	0.268	0.234 ↓
MH_05_difficult	0.294	0.236 ↓
V1_01_easy	0.080	0.067 ↓
V1_02_medium	0.737	0.098 ↓
V1_03_difficult	0.186	0.135 ↓
V2_01_easy	0.091	0.080 ↓
V2_02_medium	0.130	0.103 ↓
V2_03_difficult	0.210	0.188 ↓

3 基于线段交点的线特征聚类

本章提出一种基于线段交点的线特征聚类方法,首先计算空间平行线段投影到图像平面的交点,并聚类得到若干交点簇,进而计算交点簇的加权中心点;然后根据线特征与交点簇加权中心点的欧式距离和方向相似性,对线特征进行聚类,以减少重复纹理引起的线特征误匹配,从而提高定位精度。

3.1 空间平行线段图像平面交点检测

由于非平行线段在3D空间中的方向不同,其在图像平面中的交点位置不具有稳定的几何意义,难以用于空间约束优化。因此,本节首先通过最小长度阈值和角度

阈值筛选具备平行关系的线段对;然后对于筛选得到的线段对,将其在图像平面上的投影用直线方程进行表示,进而计算其交点。与单条线段相比,多线段聚合而成的交点具有更高的几何辨识度,能够减少因重复纹理、平行结构等造成的匹配歧义。

1) 线段筛选

为了减少遮挡和反射导致的交点误检测,根据最小长度和线段夹角^[20]来筛选有效线段。其中,通过三维重建^[21]获取图像中线段的空表示,并表示为普朗克坐标 $L_y = [n_y^T, d_y^T]^T$,其中 d_y 表示方向向量, n_y 表示法向量。重建失败的线段视为异常值予以剔除。

最小长度筛选条件如式(4)所示,设定最小长度阈值,仅保留长度符合条件的线段。

$$\Theta_L: p_{\max} - p_{\min} > e_L \quad (4)$$

式中: p_{\max} 和 p_{\min} 分别表示线段在 x 轴上投影的最大值和最小值; e_L 表示最小长度阈值。

线段角度筛选条件如式(5)所示。若两条线段的夹角小于临界角 u ,则认为相互平行,可构成一组平行线段对 (l_α, l_β) ,如式(5)所示。

$$\Theta_A: \left(\frac{d_\alpha \cdot d_\beta}{\|d_\alpha\| \|d_\beta\|} \right)^2 > \cos^2(u) \quad (5)$$

式中: d_α 和 d_β 分别表示线段 l_α 和线段 l_β 的方向向量; u 为角度阈值。由于角度阈值对定位精度具有较大影响,通过测试选择合适值。图7给出了针对 EuRoC 数据集定位精度随角度阈值的变化关系,定位精度使用均方根误差表示。由图7可知,当角度阈值为 4° 时,定位精度最好,因此设定 $u=4^\circ$ 。




图7 角度阈值对定位精度的影响

Fig. 7 Impact of angle threshold on localization error

2) 线段交点计算

将满足上述筛选条件的平行线段对 (l_α, l_β) 构成的集合表示为 P ,如式(6)所示。

$$P = \{ (l_\alpha, l_\beta) \mid l_\alpha \in \Theta_L \cap \Theta_A, l_\beta \in \Theta_L \cap \Theta_A, l_\alpha \neq l_\beta \} \quad (6)$$

针对每组平行线段对 (l_α, l_β) ,用标准直线方程表示后,通过求解直线方程组,可得交点坐标 (x, y) 。

通过计算所有线段对的交点,可得到一系列交点坐标,作为后续交点聚类的基础。

3.2 空间平行线段图像平面交点的聚类

由于实际环境中存在噪声和异常值,会导致交点检测存在误差,为了减小上述影响,对交点进行聚类^[22]处理:通过比较交点间的位置关系,计算它们的相似性,然后将相似性高的交点归为一簇,并生成每一簇的加权中心点。

首先,根据3.1节得到的空间平行线段在图像平面的交点 $v_i = (x_i, y_i)$ (记为原始交点),计算不同原始交点间的距离,构建相似性矩阵 S ,并根据相似性矩阵,选择合适的相似性阈值 η ,通过聚类算法将相似性高的原始交点分配到同一簇,从而形成多个由原始交点组成的交点簇 C_k 。其中,相似性矩阵元素 S_{ij} 表征了原始交点 v_i 和 v_j 的几何一致性,其表达式如式(7)所示。

$$S_{ij} = e^{-\frac{\|v_i - v_j\|^2}{\sigma^2}} \quad (7)$$

式中: $\|v_i - v_j\|$ 是原始交点 v_i 和 v_j 之间的欧氏距离; σ 是控制相似性衰减的参数。

然后,遍历交点簇 C_k 内所有原始交点,若其中任意两个原始交点 v_i^k 与 v_j^k 间的距离小于设定阈值 ω ,则将其进行合并,得到若干合并交点 \tilde{v}_i^k ,如式(8)所示。

$$\tilde{v}_i^k = (v_i^k + v_j^k) / 2, \quad \|v_i^k - v_j^k\| \leq \omega \quad (8)$$

最后,根据式(9)中公式计算所有合并交点 \tilde{v}_i^k 的加权平均值 v_k ,作为每个交点簇 C_k 的加权中心点。

$$v_k = \frac{\sum_{\tilde{v}_i^k \in C_k} w_i \tilde{v}_i^k}{\sum_{\tilde{v}_i^k \in C_k} w_i} \quad (9)$$

式中: \tilde{C}_k 为所有合并交点 \tilde{v}_i^k 构成的交点簇; w_i 表示权重,其计算方法如式(10)所示。

$$w_i = \frac{1}{d(v_i, \bar{v}_k) + \delta} \quad (10)$$

式中: δ 为用来避免分母为0的常数,取值为1; \bar{v}_k 为原始交点簇 C_k 的几何中心,其表达式如式(11)所示。

$$\bar{v}_k = \frac{1}{n_{C_k}} \sum_{v_i \in C_k} v_i \quad (11)$$

式中: n_{C_k} 是交点簇 C_k 中的交点数量。

3.3 线特征聚类

根据各个线特征 l_i 与不同交点簇加权中心点 v_k 间的距离及方向,计算如式(12)所示的代价值,并将线特征分配给代价值最小的加权中心点,实现线特征聚类。

$$v_i^* = \operatorname{argmin}_{v_k} K(v_k, l_i) \quad (12)$$

式中:代价值 $K(v_k, l_i)$ 的表达式如式(13)所示。

$$K(v_k, l_i) = \alpha \cdot d(v_k, l_i) + \beta \cdot (1 - |\cos \theta|) \quad (13)$$

式中: α 和 β 为权重; $d(v_k, l_i)$ 表示加权中心点 v_k 到线特征 l_i 的垂直距离, 如式(14)所示。其计算如式(15)所示。

$$d(v_k, l_i) = \frac{|m_i x_k + n_i y_k + c_i = 0|}{\sqrt{m_i^2 + n_i^2}} \quad (14)$$

$$\cos \theta = \frac{d_i \cdot \vec{v}_k}{\|d_i\| \|\vec{v}_k\|} \quad (15)$$

式中: $\cos \theta$ 表示线特征中点到加权中心点的方向向量 \vec{v}_k 与线特征方向向量 d_i 之间的夹角余弦值。

此外, 为了确保相同的线特征在不同帧中仍然属于同一聚类, 聚类的线特征至少要在滑动窗口中跟踪5次, 并且线特征在连续帧中的聚类ID一致。

最终, 将所有线特征聚类至距离与方向一致的加权中心点上, 实现空间结构信息的显式建模, 聚类效果如图8所示, 属于同一聚类簇的线特征已用矩形框标出。




图8 线特征聚类结果

Fig. 8 Line feature clustering results

4 考虑线段交点约束的后端优化

在后端优化中, 通过对点、线和交点特征的持续跟踪, 构建点、线和交点特征重投影残差, 对点、线和交点残差函数利用非线性优化求解位姿。将交点这一几何约束加入到后端优化中, 提高系统在重复纹理环境中的鲁棒性和精度。

4.1 状态向量定义

在后端优化中, 使用 $(\cdot)^w$ 、 $(\cdot)^c$ 和 $(\cdot)^b$ 分别表示世界坐标系、相机坐标系和机体坐标系。

本研究中优化的状态向量如式(16)所示。

$$\begin{cases} \chi = [x_0, \dots, x_n, x_c^b, \lambda_0, \dots, \lambda_m, \mathbf{O}_0, \dots, \mathbf{O}_n] \\ \mathbf{x}_k = [p_{b_k}^w, v_{b_k}^w, q_{b_k}^w, b_a, b_g], \quad k \in [0, n] \\ \mathbf{x}_c^b = [p_c^b, q_c^b] \\ \mathbf{O}_\gamma = [\psi_\gamma, \phi_\gamma], \quad \gamma \in [0, n] \end{cases} \quad (16)$$

式中: χ 表示所有状态; \mathbf{x}_k 表示第 k 张图像时刻的IMU状

态, 其包含IMU在世界坐标系下的位置 $p_{b_k}^w$ 、速度 $v_{b_k}^w$ 和姿态 $q_{b_k}^w$, 以及IMU在机体坐标系下的加速度计零偏 b_a 和陀螺仪零偏 b_g ; n 表示滑动窗口中关键帧数量; λ_l 表示特征点逆深度, $l \in [0, m]$; m 表示滑动窗口中特征点总数量; \mathbf{x}_c^b 表示相机到IMU的外参, 其取值通过标定确定; \mathbf{O}_γ 表示正交表示法对应的3D直线参数^[23], 其中 ψ_γ 是3D直线坐标系相对于相机坐标系的旋转矩阵, ϕ_γ 表示3D直线到相机中心的最小距离。

4.2 交点残差计算

在第3节获得线段交点后, 本节计算图像平面上的交点残差, 用于后端优化。针对每簇线段, 其交点残差向量 \mathbf{e}_v 的计算公式如式(17)所示。

$$\mathbf{e}_v = \mathbf{p}_v - [v_1 \ v_2]^T / v_3 \quad (17)$$

式中: \mathbf{p}_v 为线段簇的交点观测值, 其取值为交点簇的加权中心点 v_k ; $[v_1 \ v_2]^T / v_3$ 为交点估计值, 通过3D直线方向向量 \mathbf{d}^c 在图像平面的投影并归一化得到, 如图9所示。




图9 交点残差

Fig. 9 Intersection residual

图9中 c 为光心, 直线 ca 表示以 c 为投影中心经过图像平面上加权中心点 v_k 的观测线, 直线 cb 表示从光心 c 出发沿3D直线方向向量 \mathbf{d}^c 延伸的投影射线与图像平面的交线; v_1 、 v_2 和 v_3 是无穷远点在3D直线上的投影点 \mathbf{v}^c , 其表达式如式(18)所示。

$$\mathbf{v}^c = \begin{bmatrix} v_1 \\ v_2 \\ v_3 \end{bmatrix} = \lim_{t \rightarrow \infty} \mathbf{P}(\mathbf{V}_0 + t\mathbf{D}) = \mathbf{K}\mathbf{d}^c = \mathbf{d}^c \quad (18)$$

式中: $\mathbf{P} = \mathbf{K}[\mathbf{I} | \mathbf{0}]$ 表示相机投影矩阵; \mathbf{V}_0 表示齐次坐标表示的3D直线上一点; \mathbf{D} 为3D直线方向向量 \mathbf{d}^c 的齐次坐标表示形式。 \mathbf{V}_0 和 \mathbf{D} 的表达式如式(19)所示。

$$\begin{cases} \mathbf{V}_0 = [x_0 \ y_0 \ z_0 \ 1]^T \\ \mathbf{D} = [\mathbf{d}^{cT}, 0]^T = [d_1, d_2, d_3, 0]^T \end{cases} \quad (19)$$

式中: d_1 、 d_2 和 d_3 为3D直线方向向量 \mathbf{d}^c 的分量。

4.3 后端优化

为了对式(16)中的变量实现紧耦合优化, 构造最小二乘目标函数, 如式(20)所示。

$$\min_{\chi} (\|r_p - J_p \chi\|^2 + \sum_{k \in B} \|e_b(\hat{\mathbf{u}}_{k+1}^k, \chi)\|^2 w_{k+1}^k +$$

$$\sum_{(p,i) \in C_p} \|e_{C_p}(\hat{z}_p^i, \mathcal{X})\|_{Q_p^i}^2 + \sum_{(l,j) \in C_L} \|e_{C_L}(\hat{z}_l^j, \mathcal{X})\|_{L_l^j}^2 + \sum_{(v,j) \in C_V} \|e_{C_V}(\hat{z}_v^j, \mathcal{X})\|_{V_v^j}^2 \quad (20)$$

式中: r_p 、 e_b 、 e_{C_p} 、 e_{C_L} 和 e_{C_V} 分别表示边缘化、IMU、点、线和交点观测残差向量; J_p 表示每次边缘化对应的雅可比矩阵; \hat{u}_{k+1}^k 、 \hat{z}_p^i 、 \hat{z}_l^j 和 \hat{z}_v^j 分别表示 IMU、点、线和交点的估计值; B 是滑动窗口中所有预积分 IMU 观测值的集合; C_p 、 C_L 和 C_V 是当前帧追踪的点、线和交点观测值的集合; W_{k+1}^k 、 Q_p^i 、 L_l^j 和 V_v^j 分别表示 IMU、点、线和交点观测协方差矩阵。

针对上述构建的优化模型,使用 CERES 求解器进行优化,可得包含关键帧位姿、三维地图点位置以及线段交点结构约束在内的联合最优解,进而完成系统状态的全局一致性优化。

在式(20)中,本文延用 PL-VINS 中点、线残差之间的权重分配,而交点约束的权重通过敏感性分析试验确定。交点约束权重在 0.1~0.9 之间均值采样,得到不同交点约束权重下系统的定位误差,见表 3。可以看出,在交点约束权重为 0.6 时,系统定位误差最低,故本文交点约束权重设为 0.6。

表 3 不同交点约束权重下的 APE RMSE

Table 3 APE RMSE under different intersection constraint weights (m)

交点约束 权重	constraint weights				
	MH_01	MH_02	MH_03	MH_04	MH_05
0.1	0.225	0.187	0.192	0.287	0.279
0.2	0.220	0.175	0.185	0.268	0.267
0.3	0.206	0.168	0.177	0.259	0.255
0.4	0.198	0.162	0.180	0.252	0.241
0.5	0.189	0.159	0.169	0.241	0.234
0.6	0.191	0.151	0.162	0.233	0.227
0.7	0.197	0.166	0.172	0.241	0.246
0.8	0.203	0.170	0.179	0.288	0.267
0.9	0.265	0.201	0.218	0.296	0.277

5 公开数据集测试结果

为验证本文算法在光照变化大和重复纹理环境中的准确性和鲁棒性,在 EuRoC 全数据序列和 UMA-VI 部分序列上进行试验,以评估本文算法在提高系统定位精度和鲁棒性方面的效果。为验证闭环伽马矫正模块和线特征聚类的有效性,设计消融试验进行测试。测试平台的 CPU 为 AMD Ryzen 5 7500F, 3.7 GHz, 所有试验在带有

ROS(robot operating system) Noetic 的 Ubuntu20.04 操作系统上完成。算法采用相同的关键参数:每帧提取角点数量 ≤ 150 个,每帧检测跟踪直线 ≥ 50 条,关键帧之间特征平均视差 ≥ 10 pixels,滑动窗口中包含 10 个关键帧。

5.1 EuRoC 数据集对比试验验证

将本文算法与 VINS-MONO、VINS-FUSION^[24]、PL-VINS、PLF-VINS^[20] 和 PL-SLAM^[25] 在 EuRoC 全数据序列上进行对比试验,评价标准为 APE RMSE。

EuRoC 数据集中, MH_01~MH_05 具有光照变化和重复纹理特点,这些场景通常包含大量的相似结构和表面,如金属板、管道等,容易导致特征匹配错误,并且该场景中存在许多亮区和暗区,增加了特征检测和匹配难度;而 V1_01~V2_03 受光照变化的影响较大,尤其是在不同房间或窗口照明条件下,光照随着时间或角度的变化而变化。

表 4 为不同算法在 EuRoC 全数据序列上的 APE RMSE 结果。从表 4 可见,本文算法在全部 11 个数据序列中取得了 8 个最优,3 个次优的结果。本文算法的定位误差平均值较 VINS-MONO 下降 26.42%,较 VINS-FUSION 下降 30.39%,较 PL-VINS 下降 17.44%,较 PLF-VINS 下降 11.80%,较 PL-SLAM 下降 12.88%。本文算法的平均误差(Mean)为 0.142 m,表现最优。在困难等级序列 MH_05_difficult 中,本文算法定位精度分别较 VINS-MONO、VINS-FUSION、PL-VINS、PLF-VINS 和 PL-SLAM 提高 31.32%、31.53%、18.86%、12.31% 和 4.2%。

图 10 列出了不同算法在部分数据序列中绝对位姿误差的柱状图和箱型图对比。在两个困难等级的数据序列上,本文算法的均方根误差最低,且轨迹误差波动较小。这是由于闭环伽马矫正改善了特征提取的质量和数量,同时线特征聚类减少了线特征间的误匹配,增强了系统的鲁棒性。

5.2 UMA-VI 数据集对比结果分析

为了更好地评估本文算法在光照变化环境中的鲁棒性,试验场景选择 UMA-VI 数据集中的重复纹理场景 class-csc2、室内外切换的动态光照场景 two-floors-csc1 和室内光照变化场景 conference-csc1。

表 5 为本文算法和 VINS-MONO、PL-VINS、PL-SLAM、SuperVINS^[26] 在上述场景中的 APE RMSE 对比。表中, F 表示跟踪丢失或 APE RMSE 超过 10 m。根据表 5,本文算法取得两个最优和一个次优结果;而 VINS-MONO、PL-VINS 和 PL-SLAM 均存在失败情况;SuperVINS 使用深度学习进行特征提取,在光照变化环境下表现较好,在上述场景中均成功定位。

表4 不同算法在 EuRoC 全数据序列的 APE RMSE

Table 4 APE RMSE of different algorithms on the EuRoC dataset sequence

(m)

数据序列	VINS-MONO	VINS-FUSION	PL-VINS	PLF-VINS	PL-SLAM	本文算法
MH_01_easy	0.191	0.224	0.229	0.143	0.194	0.190
MH_02_easy	0.167	0.168	0.177	0.178	0.162	0.140
MH_03_medium	0.218	0.222	0.214	0.221	0.198	0.162
MH_04_difficult	0.338	0.237	0.245	0.240	0.265	0.223
MH_05_difficult	0.331	0.333	0.281	0.260	0.238	0.228
V1_01_easy	0.079	0.104	0.074	0.069	0.087	0.061
V1_02_medium	0.117	0.100	0.118	0.099	0.093	0.095
V1_03_difficult	0.192	0.162	0.163	0.166	0.170	0.110
V2_01_easy	0.085	0.071	0.085	0.083	0.078	0.072
V2_02_medium	0.122	0.331	0.115	0.125	0.112	0.101
V2_03_difficult	0.287	0.295	0.192	0.183	0.198	0.177
Mean	0.193	0.204	0.172	0.161	0.163	0.142

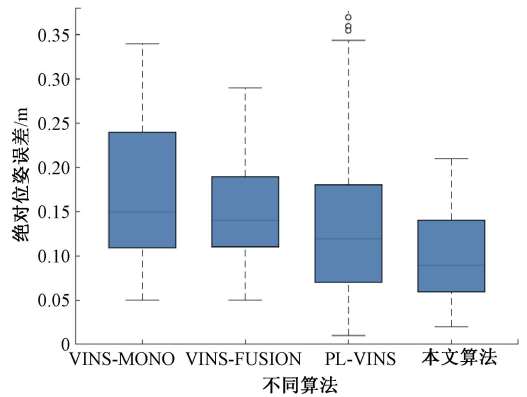
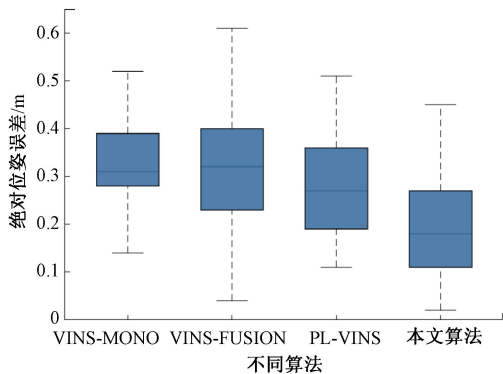
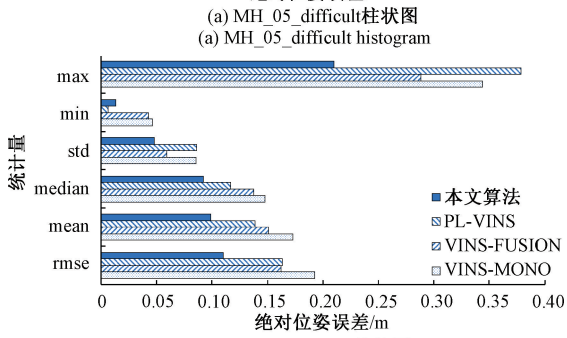



图10 EuRoC 部分数据序列上不同算法绝对位姿误差
Fig. 10 Absolute pose errors for different algorithms on partial data sequences of EuRoC dataset

表5 不同算法在 UMA-VI 数据集的 APE RMSE

Table 5 APE RMSE of different algorithms on the

UMA-VI dataset

(m)

数据序列	class-csc2	two-floors-csc1	conference-csc1
VINS-MONO	F	F	9.345
PL-VINS	0.569	F	1.776
PL-SLAM	0.989	0.536	F
SuperVINS	0.598	0.446	1.428
本文算法	0.401	0.329	1.441

本文算法在 class-csc2 上定位精度较 PL-VINS、PL-SLAM 和 SuperVINS 分别提高 29.53%、59.45% 和

32.94%; 在 two-floors-csc1 上, 本文算法定位精度较 PL-SLAM 和 SuperVINS 分别提高 38.62% 和 26.23%; 在 conference-csc1 上, 本文算法定位精度较 VINS-MONO 和 PL-VINS 分别提高 84.58% 和 18.86%, 较 SuperVINS 下降 0.91%。可见, 本文算法在重复纹理和光照变化场景中均表现出良好的适应性和鲁棒性。

5.3 消融试验分析

为评估算法各组成部分的效果, 基于 EuRoC 数据集开展消融试验。试验结果见表 6, 试验评价指标采用 APE RMSE。表中, PL-VINS-Gamma 表示仅引入闭环伽马矫正模块, PL-VINS-Line 表示仅增加线特征聚类, 表中 PL-VINS-Gamma、PL-VINS-Line 和本文算法数值后方的箭头向上表示定位误差较 PL-VINS 增大, 向下表示定位误差较 PL-VINS 减小。

表 6 消融试验结果
Table 6 Ablation experiment results (m)

数据序列	PL-VINS	PL-VINS-Gamma	PL-VINS-Line	本文算法
MH_01_easy	0.229	0.191 ↓	0.214 ↓	0.190 ↓
MH_02_easy	0.177	0.188 ↑	0.172 ↓	0.140 ↓
MH_03_medium	0.214	0.201 ↓	0.195 ↓	0.162 ↓
MH_04_difficult	0.245	0.234 ↓	0.241 ↓	0.223 ↓
MH_05_difficult	0.281	0.236 ↓	0.292 ↑	0.228 ↓
V1_01_easy	0.074	0.067 ↓	0.072 ↓	0.061 ↓
V1_02_medium	0.118	0.098 ↓	0.098 ↓	0.095 ↓
V1_03_difficult	0.163	0.135 ↓	0.169 ↑	0.110 ↓
V2_01_easy	0.085	0.080 ↓	0.084 ↓	0.072 ↓
V2_02_medium	0.115	0.103 ↓	0.110 ↓	0.101 ↓
V2_03_difficult	0.192	0.188 ↓	0.198 ↑	0.177 ↓

由表 6 可知, 本文算法在所有数据序列上的定位误差最低, PL-VINS-Gamma 平均误差较 PL-VINS 下降 9.3%, PL-VINS-Line 平均误差较 PL-VINS 下降 2.54%, 两者组合后的平均误差较 PL-VINS 下降 17.44%。

对于 MH_05_difficult、V1_03_difficult 和 V2_03_difficult 序列, 虽然仅引入线特征聚类后的效果略差于 PL-VINS, 但闭环伽马矫正和线特征聚类组合后的效果优于 PL-VINS, 这是因为闭环伽马矫正能够改善图像质量, 有益于更好地线特征聚类, 进而提升特征匹配成功率, 所以组合效果要优于单独使用。

6 实际场景测试结果

为验证本文算法在实际场景中的有效性和鲁棒性, 搭建试验平台, 在具有光照变化和重复纹理环境的长走

廊场景中, 如图 11 所示, 对本文算法进行测试。



图 11 长走廊场景

Fig. 11 Long corridor scenario

本章搭建的试验平台如图 12 所示, 其中底盘为松灵移动机器人, 机器人搭载 realsense D435i 相机和 livox avia 激光雷达。D435i 相机用于采集 IMU 和图像信息, 激光雷达用于生成移动机器人的参考位置。参考位置生成选用 FAST-LIO^[27] 算法。




图 12 试验平台

Fig. 12 Experimental platform

表 7 为本文算法与 VINS-MONO、VINS-FUSION 和 PL-VINS 在长走廊场景下的 APE RMSE 对比, 真值采用激光雷达定位结果。其中, 本文算法的定位精度最高, 分别较 VINS-MONO、VINS-FUSION 和 PL-VINS 提高 55.44%、44.05% 和 53.18%。

表 7 长走廊场景下各算法 APE RMSE

Table 7 APE RMSE algorithms in long corridor scenarios (m)

评价指标	VINS-MONO	VINS-FUSION	PL-VINS	本文算法
APE RMSE	0.992	0.790	0.944	0.442

图 13 为 VINS-MONO、VINS-FUSION、PL-VINS 和本文算法在长走廊场景下的绝对位姿误差对比。本文算法轨迹误差的最大值和中间值均优于对比算法。图 14 为不同算法在长走廊场景下的定位效果对比。从图中局部轨迹可以看出, 在转弯处, 面对窗外光线直射情况下, 对比算法较参考轨迹都出现了较大偏移, 而本文算法偏移较小, 表现出更好的鲁棒性。

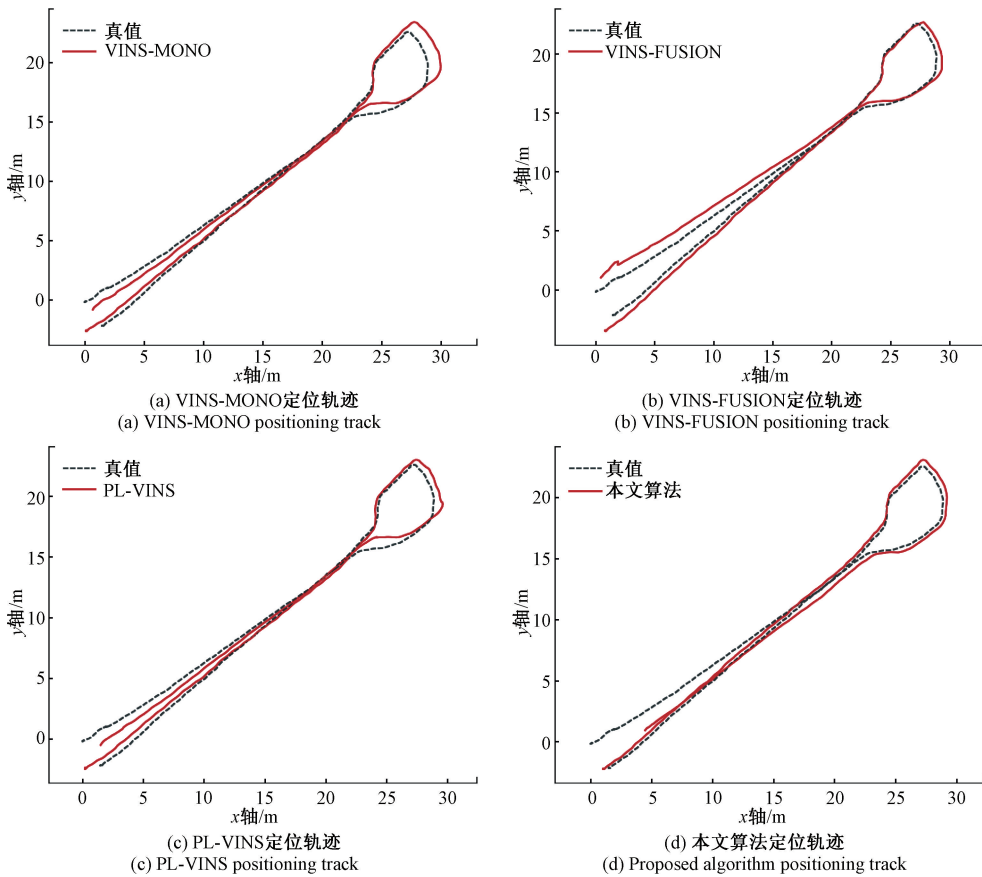


图 13 不同算法在长走廊中的定位轨迹对比

Fig. 13 Comparison of positioning trajectories of different algorithms in long corridors




图 14 长走廊场景下不同算法局部定位轨迹对比

Fig. 14 Comparison of local positioning trajectories of different algorithms in long corridor

提取效果;其次,提出一种基于线段交点的线特征聚类的方法,降低重复纹理环境下线特征误匹配;最后,将线段交点约束加入后端优化,提高定位鲁棒性。试验结果表明,相比 VINS-MONO、VINS-FUSION、PL-VINS、PLF-SLAM 和 PL-SLAM,本文算法在 EuRoC 数据集的 8 个数据序列中,均获得最低的 APE RMSE,且定位精度平均提高 20.49%;在 UMA-VI 数据集中,本文算法在 3 个序列上均定位成功且平均定位误差最低。实际的长走廊场景下的试验进一步验证了本文算法在光照变化大和重复纹理环境中的定位鲁棒性。然而,在复杂的动态环境中,单一视觉信息可能无法满足高精度定位的需求,未来可以探讨融合更多传感器数据(如激光雷达等),进一步提高系统的鲁棒性。

参考文献

[1] 纪泽源,于潇颖,付文兴. 基于图神经网络特征点匹配的视觉 SLAM 算法[J]. 仪器仪表学报, 2024, 45(9): 34-43.

Ji Z Y, Yu X Y, Fu W X. Visual SLAM algorithm

7 结 论

本文在 PL-VINS 算法基础上开展研究,首先在前端构建闭环伽马矫正模块,改善光照变化场景下点、线特征

- based on graph neural network feature point matching[J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 34-43.
- [2] ALMALIOGLU Y, TURAN M, SAPUTRA M R U, et al. SelfVIO: Self-supervised deep monocular visual-inertial odometry and depth estimation [J]. Neural Networks, 2022, 150: 119-136.
- [3] 张耀, 吴一全, 陈慧娴. 基于深度学习的视觉同时定位与建图研究进展 [J]. 仪器仪表学报, 2023, 44(7): 214-241.
- ZHANG Y, WU Y Q, CHEN H X. Research progress of visual simultaneous localization and mapping based on deep learning[J]. Chinese Journal of Scientific Instrument, 2023, 44(7): 214-241.
- [4] 叶俊强, 尤睿, 于明鑫, 等. 基于稀疏直接法的特征增强视觉 SLAM 算法 [J]. 仪器仪表学报, 2023, 44(6): 205-212.
- YE J Q, YOU R, YU M X, et al. Feature-enhanced visual SLAM algorithm based on the sparse direct method[J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 205-212.
- [5] ENGEL J, KOLTUN V, CREMERS D. Direct sparse odometry[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(3): 611-625.
- [6] JANG Y, KIM C, KIM J H. A survey on vision-based navigation systems robust to illumination changes [C]. 2022 International Conference on Electronics, Information, and Communication, 2022: 1-4.
- [7] ZHOU R X. A visual SLAM algorithm based on multi-feature optimization for indoor environments [C]. 2023 42nd Chinese Control Conference, 2023: 3929-3934.
- [8] QIN T, LI P L, SHEN SH J. VINS-MONO: A robust and versatile monocular visual-inertial state estimator[J]. IEEE Transactions on Robotics, 2018, 34(4): 1004-1020.
- [9] LI H F, Y ZH M, ZHANG Y F, et al. Single-image HDR reconstruction assisted ghost suppression and detail preservation network for multi-exposure HDR imaging[J]. IEEE Transactions on Computational Imaging, 2024, 10: 429-445.
- [10] ALBRECHT A, HEIDE N F. Improving feature-based visual SLAM in person indoor navigation with HDR imaging [C]. 2019 IEEE 2nd International Conference on Information Communication and Signal Processing, 2019: 369-373.
- [11] SAVINYKH A, KURENKOV M, KRUSHKOV E, et al. DarkSLAM: Gan-assisted visual SLAM for reliable operation in low-light conditions [C]. 2022 IEEE 95th Vehicular Technology Conference, 2022: 1-6.
- [12] JIAO S M, LI Y, SHAN ZH W. DFS-SLAM: A visual SLAM algorithm for deep fusion of semantic information[J]. IEEE Robotics and Automation Letters, 2024, 9(12): 11794-11801.
- [13] MU Q, DU K, LIU ZH X, et al. Mesh-based multi-degree feature matching method under dense repetitive textures [C]. 2024 9th International Conference on Computer and Communication Systems, 2024: 155-161.
- [14] ZHI M Y. Robust key-frame stereo visual SLAM with low-threshold point and line features[J]. ArXiv preprint arXiv:2207.05244, 2022.
- [15] LI Y, YANG W CH, LIN D K, et al. AVM-SLAM: Semantic visual SLAM with multi-sensor fusion in a bird's eye view for automated valet parking [C]. 2024 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2024: 7937-7943.
- [16] FU Q, WANG J L, YU H SH, et al. PL-VINS: Real-time monocular visual-inertial SLAM with point and line features[J]. ArXiv preprint arXiv:2009.07462, 2022.
- [17] 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.
- [18] ZUÑIGA-NOËL D, JAENAL A, GOMEZ-OJEDA R, et al. The UMA-VI dataset: Visual-inertial odometry in low-textured and dynamic illumination environments[J]. The International Journal of Robotics Research, 2020, 39(9): 1052-1060.
- [19] LI X SH, LIU M L, LING Q. Pixel-wise Gamma correction mapping for low-light image enhancement[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2024, 34(2): 681-694.
- [20] HE Y J, ZHAO J, GUO Y, et al. PL-VIO: Tightly-coupled monocular visual-inertial odometry using point and line features[J]. Sensors, 2018, 18(4): 1159.
- [21] LEE J, PARK S Y. PLF-VINS: Real-time monocular visual-inertial SLAM with point-line fusion and parallel-line fusion[J]. IEEE Robotics and Automation Letters,

- 2021, 6(4): 7033-7040.
- [22] LIM H, JEON J, MYUNG H. UV-SLAM: Unconstrained line-based SLAM using vanishing points for structural mapping[J]. IEEE Robotics and Automation Letters, 2022, 7(2): 1518-1525.
- [23] BARTOLI A, STURM P. Structure-from-motion using lines: Representation, triangulation, and bundle adjustment[J]. Computer Vision and Image Understanding, 2005, 100(3): 416-441.
- [24] QIN T, CAO SH Z, PAN J, et al. A general optimization-based framework for global pose estimation with multiple sensors [J]. ArXiv preprint arXiv: 1901.03642, 2019.
- [25] PUMAROLA A, VAKHITOV A, AGUDO A, et al. PL-SLAM: Real-time monocular visual SLAM with points and lines [C]. 2017 IEEE International Conference on Robotics and Automation, 2017: 4503-4508.
- [26] LUO H K, LIU Y, GUO CH, et al. SuperVINS: A real-time visual-inertial SLAM framework for challenging imaging conditions [J]. IEEE Sensors Journal, 2025, 25(13): 26042-26050.
- [27] XU W, ZHANG F. FAST-LIO: A fast, robust LiDAR-inertial odometry package by tightly-coupled iterated

Kalman filter [J]. IEEE Robotics and Automation Letters, 2021, 6(2): 3317-3324.

作者简介



张原玮, 2023 年于山东交通学院获得学士学位, 现为华北电力大学(保定)硕士研究生, 主要研究方向为机器人自主导航与智能感知。

E-mail: 470825612@qq.com

Zhang Yuanwei received his B. Sc. degree from Shandong Jiaotong University in 2023. He is currently a master's student at North China Electric Power University (Baoding). His main research interests include autonomous robot navigation and intelligent perception.



王天宁(通信作者), 2011 年于北京理工大学获得学士学位, 2018 年于北京理工大学获得博士学位, 现为华北电力大学(保定)讲师, 主要研究方向为机器人自主导航。

E-mail: wangtianning1989@126.com

Wang Tianning (Corresponding author) received her B. Sc. and Ph. D. degrees both from Beijing Institute of Technology in 2011 and 2018. She is currently a lecturer at North China Electric Power University (Baoding). Her main research interest includes robot autonomous navigation.