引用:王奇,胡春鹤. 基于线段截断与平行约束的点线视觉惯性里程计定位方法[J]. 聊城大学学报(自然科学版),2026,39(6):855-865.

Citation: Wang Qi, Hu Chunhe. Point-line visual-inertial odometry localization method based on line segment truncation and parallel constraints[J]. Journal of Liaocheng University (Natural Science Edition),2026,39(6):855-865.

文章编号 1672-6634(2026)06-0855-11 **DOI** 10.19728/j.issn1672-6634.2025120022

基于线段截断与平行约束的点线视觉惯性里程计定位方法

王奇,胡春鹤

(北京林业大学 工学院, 北京 100083)

摘要 针对低纹理结构化场景下,点线视觉惯性里程计系统中 LSD 算法提取线特征存在短线段碎片化及长线段跨度过大、进而影响系统定位精度的问题,提出一种融合线段截断与平行约束的线特征处理方法。该方法通过线段筛选策略对过长线段进行截断,以提高系统线段处理效率和观测稳定性,并利用截断后长线子线段在方向上的一致性,引入基于曼哈顿世界假设的方向约束增强系统姿态估计的方向稳定性。实验表明,该方法在提高线段观测质量的同时,有助于改善系统在低纹理结构化场景下的定位精度与稳定性。

关键词 视觉惯性里程计;点线特征;线段筛选;曼哈顿世界假设;平行约束

中图分类号 TP242 **文献标志码** A

Point-line visual-inertial odometry localization method based on line segment truncation and parallel constraints

WANG Qi, HU Chunhe

(School of Technology, Beijing Forestry University, Beijing 100083, China)

Abstract To address the problem that, in point-line visual-inertial odometry systems under low-texture structured scenes, the line features extracted by the LSD algorithm suffer from fragmented short line segments and overly large spans of long line segments, which further affect the localization accuracy of the system, a line-feature processing method combining line-segment truncation and parallel constraints is proposed. This method truncates overlong line segments through a line-segment filtering strategy to improve the efficiency of line-segment processing and the stability of observations. In addition, by using the directional consistency of the truncated sub-segments from long lines, direction constraints based on the Manhattan-world assumption are introduced to enhance the directional stability of system pose estimation. Experimental results show that, while improving the quality of line-segment observations, the proposed method also helps improve the localization accuracy and stability of the system in low-texture structured scenes.

Keywords visual-inertial odometry; point-line features; line segment filtering; Manhattan-world assumption; parallel constraint

---

收稿日期:2025-12-29

基金项目:北京林业大学科技创新计划项目(2024XY-G009)资助

通信作者:胡春鹤,男,汉族,博士,副教授,研究方向:机器人导航制导与控制,E-mail:huchunhe@bjfu.edu.cn。

0 引言

同时定位与地图构建(Simultaneous Localization and Mapping, SLAM)技术[1]在移动机器人、自动驾驶及智能制造等领域中发挥着关键作用。移动机器人在未知环境中执行自主任务时,通常依赖 SLAM 技术在运动过程中同步估计自身位姿并构建环境地图,从而为后续任务决策提供关键状态信息。

根据传感器类型的不同,SLAM 研究可分为激光 SLAM 与视觉 SLAM 两个方向。视觉 SLAM 基于摄像头获取的高分辨率图像,具有成本低、部署便捷等优势,在多种环境下可实现有效的位姿估计与环境建图[2]。但纯视觉方法在弱纹理、重复纹理或快速运动等场景中易出现跟踪退化,影响系统的鲁棒性与稳定性。为弥补视觉信息的不足,惯性传感器(Inertial Measurement Unit, IMU)常与视觉传感器融合,通过高频 IMU 信息补充视觉观测的不足,从而构建出视觉惯性里程计(Visual-Inertial Odometry, VIO)或视觉惯性导航系统(VINS)体系[3]。相较于完整 SLAM 系统中对全局一致地图与回环优化的关注,VIO 系统更侧重于在局部时间窗口内融合视觉与 IMU 信息实现稳定的状态估计,相关代表性工作包括 DVIO[4],DM-VIO[5],VI-HSO[6]等。

当前主流 VIO 系统多以点特征作为主要观测信息,但在弱纹理或强结构化场景(如走廊、楼梯间)中,点特征的数量有限,检测稳定性也易受影响。为增强几何观测能力,已有研究[7-8]引入线段作为结构化特征,与点特征互补,以提升系统对场景几何结构的表达能力。在基于点线特征的 VIO 系统中,线段需经过提取、匹配、重建与优化等多个环节,参与状态估计。在线段提取方面,LSD(Line Segment Detector)算法[9]因实现简便、检测效率高,已被广泛应用于点线融合的 VIO 系统。该算法基于图像梯度信息,在局部支持区域内拟合近似共线的梯度方向,从而实现线段的快速提取。

尽管如此,LSD 算法提取的线段在长度与空间分布方面缺乏约束。同一物理边缘常被分割为多条短小线段碎片,这些碎片化观测降低了线段的描述性和匹配质量,进而影响后端优化的稳定性与估计精度[10]。为解决该问题,常通过设定最小长度阈值来剔除冗余线段,并结合线段合并或边缘拟合等策略提升线段完整性[11-12]。现有方法多采用长线段作为线段观测,利用其对场景结构的整体表达能力来提升系统的视觉定位性能。然而,对于图像中跨度较大的结构边缘,长线段往往伴随较高的维护成本以及更为复杂的数据关联过程,从而对系统的运行效率和稳定性产生不利影响。针对上述问题,本文提出对过长线段进行适度截断,将其划分为长度适中的子线段,以在保持结构表达完整性的同时,提高线段匹配与优化过程的效率。

需要注意的是,若将截断后的子线段作为相互独立的观测特征,可能因缺乏几何关联而导致子线段与周围线段误匹配。实际上,截断得到的子线段在几何上对应同一条三维直线的不同部分,因此应具有严格的平行关系。为增强线段间的结构表达能力,已有研究常在结构化场景中基于曼哈顿世界(Manhattan World)假设[13]引入平行约束,以提升几何一致性与姿态估计的稳定性。曼哈顿世界假设是一种广泛应用于室内和城市环境建模的重要结构先验,StructVIO[14]在该假设下构建线段间的方向一致性约束,通过将多组线段划分为主方向的平行集合,提升了状态估计精度。MSC-VO[15]在融合点与线特征的基础上,引入多视角曼哈顿轴估计方法,并在局部地图优化阶段结合平行与正交的结构约束对线段三维端点进行优化。PLS-VIO[16]将线特征进一步划分为结构线与非结构线,并针对结构线提出基于曼哈顿世界假设的平行一致性建模,有效提升系统在低纹理环境下的鲁棒性。

综上所述,本文面向结构化与弱纹理场景提出一种结合线段截断策略和平行约束的点线 VIO 定位方法。首先,针对 LSD 算法提取的原始线段长度分布不受约束的问题,本文对线段进行质量筛选,通过剔除过短线段并对过长线段进行适度截断,构建更利于稳定跟踪与鲁棒匹配的线段集合。其次,考虑到同一物理长线截断得到的子线段在几何上具有一致的方向属性,本文在曼哈顿世界假设下估计场景主方向,并构建线段三维方向与其所属曼哈顿主方向之间的平行一致性约束,进一步将该约束以因子形式引入后端优化过程,从而提升 VIO 系统在结构化场景中的状态估计精度与鲁棒性。最后,通过在公开数据集上的实验,验证了所提出的方法能够在低纹理结构化场景中有效降低轨迹误差,并提升点线 VIO 系统的定位精度。

1　方法

1.1　系统总体框架

本文在基于点特征的 VINS-MONO[17] 系统框架基础上，进一步引入线特征，并结合本文提出的线段筛选方法，对原有系统进行了结构性改进。改进后的系统如图 1 所示，其整体由数据输入、前端处理和后端优化三个模块组成，红色字体部分为本文的主要创新点。在数据输入阶段，系统通过视觉传感器和 IMU 同步获取图像序列与高频惯性数据，为状态估计提供互为补充的信息来源。

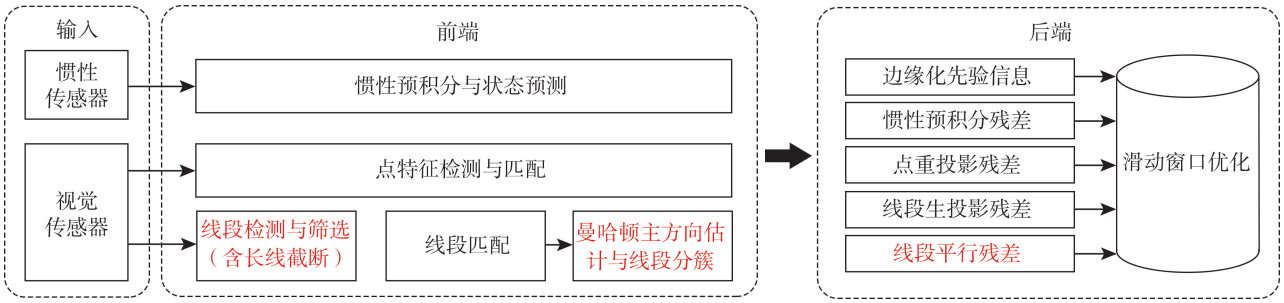


图 1　基于点线特征的视觉惯性里程计系统框架

Fig. 1　Overall framework of the point-line visual-inertial odometry system

前端模块主要负责传感器数据的预处理和初步状态预测。系统首先对 IMU 数据进行预积分，并结合上一帧的状态估计，预测当前帧的位姿、速度和偏置，从而为后端优化提供稳定可靠的初始值。在视觉信息处理方面，系统在图像中同时提取并跟踪点线特征。点特征的提取采用 Shi-Tomasi 算法[18] 在关键帧中检测角点，并通过 KLT 光流法[19] 在相邻图像帧之间进行跟踪，形成稳定的多帧观测轨迹。线特征的处理采用 LSD 检测算法首先提取线段，并通过本文设计的筛选方法优化检测结果。随后利用 LBD 描述子结合几何一致性约束进行线段匹配[20]。

为了在后端引入结构方向约束，系统还需为每条线段分配可靠的方向信息。为此，前端进一步估计场景中的曼哈顿主方向，并根据主方向与线特征之间的关系对线段进行分簇。这一方向分簇结果将作为线段平行残差构建的基础，并与其他观测信息一同传入后端模块。最终，系统将点特征观测、线特征观测及其方向聚类结果，以及 IMU 预积分信息整合后输入后端优化模块，用于联合状态估计。

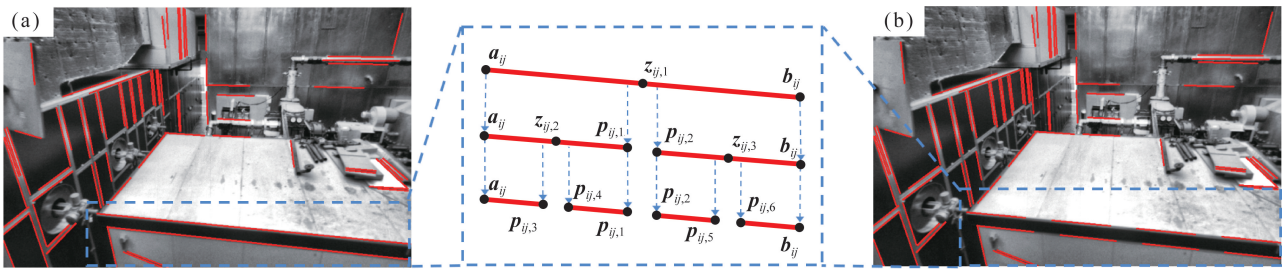
在后端部分，系统采用滑动窗口优化方法[21] 对窗口内的状态量进行联合估计。为将点线特征转化为可用于非线性优化的几何约束，系统首先对这些特征进行三维重建。具体而言，点线特征通过多帧观测完成三角化[22]，以获得其空间位置，并据此构建点线重投影残差，用于关联当前位姿与空间特征点之间的几何关系[23]。在优化目标函数的构建过程中，系统综合考虑了多种约束项。其中，先验信息用于保留历史观测信息并控制滑动窗口的规模；惯性预积分残差用于刻画相邻图像帧之间的运动关系；点线重投影残差则补充了来自视觉观测的几何约束，从而提升整体估计的准确性与一致性。在此基础上，系统进一步引入基于曼哈顿世界假设的线段平行残差，将结构方向信息显式融入优化过程，从而增强系统在结构化场景下方向估计的稳定性与全局一致性。优化完成后，系统对滑窗外的旧状态与观测进行边缘化处理，在保证计算效率的同时维持状态估计的连续性，并输出更新后的相机位姿与相关状态量。

1.2　结构化线特征提取与筛选方法

在本文所构建的点线 VIO 系统中，线特征首先通过 LSD 算法从视觉传感器获取的图像中进行提取。LSD 算法通过分析图像中的梯度信息，识别局部方向一致的像素集合，并将其转化为以端点表示的线特征。该算法具有较高的检测效率，适用于实时系统的需求。然而，LSD 输出的线段在长度和空间分布上缺乏约束。一方面会生成大量长度较短的碎片化线段，稳定性差且易受噪声干扰；另一方面，在结构化场景中常常检测到跨度较大的长线段，这些线段虽然能够表征结构边缘，但在跨帧跟踪和数据关联中维护代价较高，对后端优化的贡献也不稳定。因此，需对 LSD 提取的原始线段进行筛选和规范化处理，以获得更加适用于稳定跟踪与优化的线段集合。

为提升线特征的利用效率和匹配稳定性,本文采用基于长度阈值的线段筛选策略,引入最短线段阈值 $L_{\min}$ 与最长线段阈值 $L_{\max}$(单位为像素),分别用于过滤噪声短线段和截断跨度过长线段。具体而言,线段筛选整体流程遵循"先截断过长线段,再剔除过短线段"的顺序:先对超过 $L_{\max}$ 的线段进行截断,使得到的线段长度不再超出上限;随后再依据 $L_{\min}$ 过滤残余的短线段,以保证最终线段集合的质量与可用性。该处理顺序能够避免截断后产生的子线段再次落入过短范围,从而减少无效线段的产生。

如图 2 所示,为本文所设计系统在 EuRoC 数据集[24]的 MH_05_difficult 序列上运行的一帧结果。其中,图 2(a)给出了仅进行过短线段剔除的结果,此时图像中保留少量跨度较大的过长线段。图 2(b)在短线剔除的基础上进一步对过长线段进行截断。图 2 中间的示意图给出了截断过程的步骤。设在第 i 帧图像检测到的第 j 条线段观测为 l_{ij},其像素坐标系下的两个端点分别为 $\boldsymbol{a}_{ij}=[x_a,y_a]^{\mathrm{T}}$、$\boldsymbol{b}_{ij}=[x_b,y_b]^{\mathrm{T}}$,则该线段长度为 $L_{ij}=\|\boldsymbol{b}-\boldsymbol{a}\|_2$。当 $L_{ij}>L_{\max}$,即该线段为过长线段时,首先计算线段中点 $\boldsymbol{z}_{ij}=(\boldsymbol{a}_{ij}+\boldsymbol{b}_{ij})/2$ 及单位方向向量 $\boldsymbol{\mu}_{ij}=(\boldsymbol{b}_{ij}-\boldsymbol{a}_{ij})/L_{ij}$。为避免截断后两条子线段在后续匹配中发生重叠或过近而导致的误匹配,本文在中点两侧沿线段方向各取距离为 $L_{\min}/2$ 的截断点 $\boldsymbol{p}_{ij,1}=\boldsymbol{z}_{ij}-\boldsymbol{\mu}_{ij}(L_{\min}/2)$ 和 $p_{ij,2}=z_{ij}+\boldsymbol{\mu}_{ij}(L_{\min}/2)$。由此基于截断点和原线段端点,可将原线段截断为两条子线段 $a_{ij}p_{ij,1}$ 和 $p_{ij,2}b_{ij}$,并在这两条子线段之间保留约 $L_{\min}/2$ 的间隔。若生成的子线段仍满足 $L_{ij}>L_{\max}$,则对其继续重复上述截断过程,直至所有子线段长度均不超过 $L_{\max}$,完成截断操作。



注:(a) 过短线段剔除;(b) 过短线段剔除和过长线段截断。

图 2 线段截断方法

Fig. 2 Line segments truncation method

1.3 曼哈顿主方向估计与线段聚类

在曼哈顿世界假设下,结构化场景中的线段大多与三组互相垂直的主方向之一近似平行。对第 i 帧,设其三组主方向在相机坐标系 $\{c\}$ 下对应的单位方向向量为 $\boldsymbol{mh}_{i,k}^{c}\in\mathbf{R}^3(k=1,2,3)$。当完成特征匹配后,图像中的线特征仍然表现为二维图像平面上的线段,无法直接获得对应的三维主方向。然而,根据透视投影模型的原理,空间中同一组三维平行线在图像平面上会交于同一个汇聚点,该汇聚点即为消失点。因此,消失点可视为三维主方向在图像平面上的投影表示。对第 i 帧,记第 k 个消失点的图像坐标为 $\boldsymbol{vp}_{i,k}=[x_k,y_k]^{\mathrm{T}}$,其齐次坐标形式为 $\widetilde{\boldsymbol{vp}_{i,k}}=[x_k,y_k,1]^{\mathrm{T}}$。根据投影几何关系,将该消失点转换为相应主方向的单位向量,具体表示为 $\boldsymbol{mh}_{i,k}^{c}=(\boldsymbol{K}^{-1}\widetilde{\boldsymbol{vp}_{i,k}})/(\|\boldsymbol{K}^{-1}\widetilde{\boldsymbol{vp}_{i,k}}\|)$。其中 $\boldsymbol{K}^{-1}\widetilde{\boldsymbol{vp}_{i,k}}$ 表示由图像像素坐标反投影到归一化成像平面上的方向(仅确定方向,不含尺度信息),再通过归一化操作得到单位方向向量。由于空间直线方向存在正负不确定性,后续计算中通常将 $\boldsymbol{mh}$ 与 $-\boldsymbol{mh}$ 视为等价方向。

为在结构化场景中获得稳定的曼哈顿主方向,本文在每帧图像中基于筛选后的线段集合,采用 2-line 消失点估计方法[25]思路生成消失点候选。具体地,对第 i 帧,属于同一平行线族的两条线段,其延长线应在同一消失点处相交。通过随机采样两条线段并计算其延长线交点,可得到一组消失点候选 $\boldsymbol{vp}_{i,1}$。在曼哈顿世界假设下,三组主方向两两正交。利用该约束,从候选中搜索并评估三消失点组合。首先选取第一主方向的候选消失点 $\boldsymbol{vp}_{i,1}$;再在其正交方向范围内生成第二主方向候选 $\boldsymbol{vp}_{i,2}$;最后根据两者确定第三主方向 $\boldsymbol{vp}_{i,3}$。为高效筛选结果,该方法依据线段方向一致性及线段长度等信息对候选进行加权评分,选取得分最高的组合作为最终的曼哈顿方向估计结果。最终,可得到三组消失点 $\{\boldsymbol{vp}_{i,1},\boldsymbol{vp}_{i,2},\boldsymbol{vp}_{i,3}\}$ 及其在相机坐标系下对应的单位方向向量 $\{\boldsymbol{mh}_{i,1}^{c},\boldsymbol{mh}_{i,2}^{c},\boldsymbol{mh}_{i,3}^{c}\}$。

在获得三组主方向对应的消失点后，需要对当前帧的每条线段观测 l_{ij} 进行方向分簇，并输出其方向标签用于后续平行残差构建。同一主方向平行的三维直线在图像中将趋于经过同一消失点，因此可通过“消失点到线段延长线的距离”度量线段与某主方向的一致性。

为便于构建直线方程，需要将像素点扩展为齐次坐标形式。对第 i 帧中第 j 条线段 l_{ij}，其线段端点的齐次形式为 $\widetilde{\boldsymbol{a}_{ij}}=[x_a,y_a,1]^{\mathrm{T}}$、$\widetilde{\boldsymbol{b}_{ij}}=[x_b,y_b,1]^{\mathrm{T}}$，则线段的齐次表示为 $\boldsymbol{l}_{ij}=\widetilde{\boldsymbol{a}_{ij}}\times\widetilde{\boldsymbol{b}_{ij}}=[l_{ij,1},l_{ij,2},l_{ij,3}]^{\mathrm{T}}$，其中 $[\boldsymbol{l}_{ij,1},\boldsymbol{l}_{ij,2},\boldsymbol{l}_{ij,3}]^{\mathrm{T}}$ 表示该直线参数向量的三个分量，对任意位于该直线上的齐次点 $\tilde{\boldsymbol{q}}=[x,y,1]^{\mathrm{T}}$，均有 $\boldsymbol{l}_{ij}^{\mathrm{T}}\tilde{\boldsymbol{q}}=\boldsymbol{l}_{ij,1}u+\boldsymbol{l}_{ij,2}v+\boldsymbol{l}_{ij,3}=0$。通过该直线方程，对第 k 个主方向对应的消失点 $\boldsymbol{vp}_{i,k}$，有消失点到线段延长线的距离为 $e_{ij,k}=(|\boldsymbol{l}_{ij}^{\mathrm{T}}\boldsymbol{vp}_{i,k}|)/(\sqrt{l_{ij,1}^2+l_{ij,2}^2})$。$e_{ij,k}$ 越小，表示线段 l_{ij} 的延长线越接近通过消失点 $\boldsymbol{vp}_{i,k}$，该线段越可能与第 k 个主方向平行。据此，对每条线段分别计算三个方向下的距离 $\{e_{ij,1},e_{ij,2},e_{ij,3}\}$，并以最小距离对应的方向作为其分簇结果，即 $k_{ij}=\mathrm{argmin}e_{ij,k}$。考虑到噪声线段或非结构线段可能无法可靠对应任一主方向，本文设置消失点一致性距离阈值 τ_{vp} 进行剔除：若最小距离 $e_{ij,k_{ij}}<\tau_{\mathrm{vp}}$，则将线段划分到第 k_{ij} 个方向簇，此时 $k_{ij}=k\in\{1,2,3\}$；若 $e_{ij,k_{ij}}\geqslant\tau_{\mathrm{vp}}$ 则将其标记为未分类（记为 $k_{ij}=0$），不参与后续平行残差构建。最终，每条满足条件的线段都会输出方向标签 $k_{ij}(k)$，并关联其对应的曼哈顿主方向向量 $\boldsymbol{mh}_{i,k}^{\mathrm{c}}$（由消失点通过内参变换得到），用于后续平行残差的构建。

1.4　线段平行残差构建

为进一步利用线段在结构化场景中的平行属性，本文在后端优化中引入基于曼哈顿世界假设的线段平行残差。该残差在保留线段重投影约束的基础上，显式利用场景中常见的三组正交主方向先验，将每条线段对应的三维方向与其所属主方向进行一致性约束，从而在弱纹理或点特征稀疏区域为系统提供稳定的方向信息补充。

线段的三维方向来源于线特征的空间重建结果，即线段在多帧观测条件下完成三角化后获得其在世界坐标系中的空间直线表达。由于直线具有不同的参数化方式，为兼顾几何计算便利性与优化求解效率，本文采用普朗克（Plücker）坐标与正交表示相结合的线特征建模策略。具体来讲，在坐标变换与残差构建中使用 Plücker 坐标表示以便进行几何计算；在非线性优化过程中采用四维正交参数对直线进行最小化表达，以降低参数冗余并提升优化的数值稳定性与收敛性能[26]。其中残差构建采用 Plücker 坐标表示法，第 i 帧中的第 j 条线段 l_{ij} 三角化为世界坐标系下的三维直线后，可表示为六维向量 $\mathcal{L}_{ij}^{\mathrm{w}}=[(\boldsymbol{n}_{ij}^{\mathrm{w}})^{\mathrm{T}},(\boldsymbol{d}_{ij}^{\mathrm{w}})^{\mathrm{T}}]^{\mathrm{T}}\in\mathbf{R}^6$，其中 $\boldsymbol{n}_{ij}^{\mathrm{w}}\in\mathbf{R}^3$ 为力矩向量，$\boldsymbol{d}_{ij}^{\mathrm{w}}\in\mathbf{R}^3$ 为该 3D 直线的方向向量，这两个向量满足 $(\boldsymbol{n}_{ij}^{\mathrm{w}})^{\mathrm{T}}\boldsymbol{d}_{ij}^{\mathrm{w}}=0$。设直线上任意两点 $\boldsymbol{q}_1$、$\boldsymbol{q}_2$，其方向向量和力矩向量可分别定义为 $\boldsymbol{d}_{ij}^{\mathrm{w}}=\boldsymbol{q}_1-\boldsymbol{q}_2$，$\boldsymbol{n}_{ij}^{\mathrm{w}}=\boldsymbol{q}_1\times\boldsymbol{d}$。

由于线段观测位于相机坐标系中，为确保方向一致性，需要将三角化后的 3D 线特征从世界坐标系转换至相机坐标系。设第 i 帧相机位姿为 $\boldsymbol{T}_i^{\mathrm{wc}}=(\boldsymbol{R}_i^{\mathrm{wc}},\boldsymbol{t}_i^{\mathrm{wc}})$，其中 $\boldsymbol{R}_i^{\mathrm{wc}}$ 表示相机坐标系相对于世界坐标系的旋转矩阵，$\boldsymbol{t}_i^{\mathrm{wc}}$ 表示相机坐标系原点在世界坐标系中的平移向量。此处平行残差的构建仅需要方向向量 $\boldsymbol{d}_{ij}^{\mathrm{w}}$，因此取世界坐标系到相机坐标系的旋转为 $\boldsymbol{R}_i^{\mathrm{cw}}=(\boldsymbol{R}_i^{\mathrm{wc}})^{\mathrm{T}}$，线特征在相机坐标系下的方向向量可表示为 $\boldsymbol{d}_{ij}^{\mathrm{c}}=\boldsymbol{R}_i^{\mathrm{cw}}\boldsymbol{d}_{ij}^{\mathrm{w}}$。

至此，对于系统前端在第 i 帧提取到的第 j 条线段特征 l_{ij}，若其存在与之相近似的曼哈顿主方向，本文基于该线段特征在相机坐标系下的方向 $\boldsymbol{d}_{ij}^{\mathrm{c}}$，与该线段对应的曼哈顿主方向 $\boldsymbol{mh}_{i,k}^{\mathrm{c}}$ 可以构建线段平行残差为 $\boldsymbol{r}_{\parallel}^{i,j}=\arccos\{[|(\boldsymbol{d}_{ij}^{\mathrm{c}})^{\mathrm{T}}\boldsymbol{mh}_{i,k}^{\mathrm{c}}|]/[\|\boldsymbol{d}_{ij}^{\mathrm{c}}\|\|\boldsymbol{mh}_{i,k}^{\mathrm{c}}\|]\}$。其中 $\boldsymbol{r}_{\parallel}^{i,j}$ 为线段平行残差，该残差以线段方向与曼哈顿主方向之间的夹角偏差作为误差度量。考虑到三维直线方向存在符号不确定性，为避免符号差异对残差计算造成影响，本文在构建过程中采用点积的绝对值形式进行约束。当 $\boldsymbol{d}_{ij}^{\mathrm{c}}$ 与 $\boldsymbol{mh}_{i,k}^{\mathrm{c}}$ 平行时，该残差为 0，在后续优化中通过最小化该残差来优化当前状态。

1.5　滑动窗口优化

在滑动窗口中，系统采用基于光束平差法（Bundle Adjustment，BA）[27]的非线性优化框架，将 IMU 预积分残差、点线特征的重投影残差以及边缘化得到的先验信息共同纳入联合优化。进一步地，本文将基于曼哈顿世界假设构建的线段平行残差一并融入优化过程，从而增强姿态估计的稳定性与整体方向一致性。

设滑动窗口内包含从第 i 帧到第 $i+I$ 帧的关键帧状态。窗口内的待估计状态变量统一记为 $\boldsymbol{\chi}=[\boldsymbol{\lambda}_i,\boldsymbol{\lambda}_{i+1},\cdots,\boldsymbol{\lambda}_{i+I},\ \{\boldsymbol{\delta}_f\}_{f=1}^{NP},\ \{\boldsymbol{\xi}_j\}_{j=1}^{NL}]^{\mathrm{T}}$。其中 $\boldsymbol{\chi}$ 表示状态变量的集合,$\boldsymbol{\lambda}_i$ 为第 i 帧的 IMU 状态,具体定义为 $\boldsymbol{\lambda}_i=[s_i^{\mathrm{w}},o_i^{\mathrm{w}},v_i^{\mathrm{w}},h_i^{\mathrm{a}},h_i^{\mathrm{g}}]^{\mathrm{T}}$。其中 s_i^{w} 为 IMU 在世界坐标系下的位置,o_i^{w} 为姿态,v_i^{w} 为速度,h_i^{a} 和 h_i^{g} 分别为加速度计与陀螺仪零偏。参数 δ_f 表示第 f 个空间点特征的参数(本文沿用逆深度参数化),NP 为窗口内参与优化的点特征数量;ξ_j 表示第 j 条三维直线的优化参数(采用正交表示),NL 为窗口内参与优化的线特征数量。在滑动窗口内,系统通过最小化多类残差的加权和来联合估计窗口状态变量 χ,公式如下

$$\min_{\chi}\{\rho(\|\boldsymbol{r}_{\mathrm{pri}}(\boldsymbol{\chi})\|^2)+\sum_{m=i}^{i+I-1}\rho(\|\boldsymbol{r}_{\mathrm{imu}}^{m}(\boldsymbol{\lambda}_m,\boldsymbol{\lambda}_{m+1})\|^2_{w_{\mathrm{imu}}^{m}})+\sum_{(m,f)\in O_{\mathrm{pt}}}\rho(\|\boldsymbol{r}_{\mathrm{pt}}^{m,f}(\boldsymbol{\lambda}_m,\boldsymbol{\delta}_f)\|^2_{w_{\mathrm{pt}}^{m,f}})$$
$$+\sum_{(m,j)\in O_{\mathrm{ln}}}\rho(\|\boldsymbol{r}_{\mathrm{ln}}^{m,j}(\boldsymbol{\lambda}_m,\boldsymbol{\xi}_j)\|^2_{w_{\mathrm{ln}}^{m,j}})+\sum_{(m,j)\in O_{\parallel}}\rho(\|(\boldsymbol{r}_{\parallel}^{m,j})\|^2)\},$$

式中,第一项 $\rho(\|\boldsymbol{r}_{\mathrm{pri}}(\boldsymbol{\chi})\|^2)$ 为先验信息,其中 $\rho(\cdot)$ 为鲁棒核函数,用于抑制误匹配与异常观测对优化结果的影响;$\boldsymbol{r}_{\mathrm{pri}}(\boldsymbol{\chi})$ 表示边缘化得到的先验残差,用于在固定窗口规模下保留历史信息并约束当前窗口内的状态。第二项为 IMU 预积分残差的加权代价,其中 $\boldsymbol{r}_{i\mathrm{mu}}^{m}(\boldsymbol{\lambda}_m,\boldsymbol{\lambda}_{m+1})$ 描述第 m 帧与第 $m+1$ 帧之间由 IMU 测量得到的运动一致性关系;$\|\cdot\|^2_{w_{i\mathrm{mu}}^{m}}$ 表示基于 IMU 预积分不确定性的 $w_{i\mathrm{mu}}^{m}$ 协方差矩阵所构造的加权平方范数,用于衡量该残差的置信度;$w_{i\mathrm{mu}}^{m}$ 为 IMU 残差的权重,由预积分过程中计算得到的协方差确定,该协方差由 IMU 噪声参数给定,并随时间间隔及运动状态的变化而自适应更新。

第三项为点特征重投影残差,$(m,f)\in O_{\mathrm{pt}}$ 表示空间点 f 在第 m 帧具有的有效观测;$\boldsymbol{r}_{\mathrm{pt}}^{m,f}$ 刻画由当前位姿 $\boldsymbol{\lambda}_m$ 与点参数 $\boldsymbol{\delta}_f$ 预测的像素投影与实际观测之间的差异;$w_{\mathrm{pt}}^{m,f}$ 为点特征残差的权重,由于点重投影残差在归一化成像平面上计算,而像素观测噪声以像素为单位给定,本文将像素测量噪声的标准差设定为 $\sigma_{\mathrm{img}}=1.5$ pix,则权重具体定义为 $w_{\mathrm{pt}}^{m,f}=\mathrm{focal_length}/\sigma_{\mathrm{img}}$,其中 focal_length=460 为相机的有效焦距,由相机内参给定,用于将像素级测量噪声映射到归一化成像平面上的尺度转换。在后续实验中,点特征重投影残差的权重均按照上述设置保持不变。第四项为线特征重投影残差,$(m,j)\in O_{\mathrm{ln}}$ 表示空间直线 j 在第 m 帧具有的有效线段观测;$\boldsymbol{r}_{\mathrm{ln}}^{m,j}$ 用于度量由 $\boldsymbol{\lambda}_m$ 与直线参数 $\boldsymbol{\xi}_j$ 预测得到的投影直线与观测线段之间的几何误差;$w_{\mathrm{ln}}^{m,j}$ 为线特征残差的权重,该权重取值与点特征残差权重保持一致。最后一项为本文引入的线段平行残差,$\boldsymbol{r}_{\parallel}^{m,j}$ 为第 m 帧中第 j 条线段在相机坐标系下的方向与其对应主方向之间的夹角误差。

通过联合最小化上述残差项,系统能够在保留先验信息的同时融合 IMU、点、线及结构方向约束,实现对窗口内状态的稳健估计。

2 实验

2.1 实验设置

为验证本文提出的方法在弱纹理环境下的有效性,重点评估所引入截断策略与平行约束对姿态估计稳定性与整体定位精度的提升作用。本文选取 TUM-VI 数据集的走廊序列对不同线段筛选方法进行分析,随后选取 EuRoC 数据集对系统整体进行实验分析。TUM-VI[28] 数据集包含多种典型室内外场景,其中的走廊序列具有低纹理、重复结构等特征,能够有效检验算法在弱纹理环境下的鲁棒性与方向估计稳定性。EuRoC 数据集涵盖工业厂房与机库等结构化场景,适用于评估视觉惯性系统在复杂空间与不同运动模式下的定位性能。实验所用真实轨迹均由数据集官方提供。所有实验均在 Ubuntu 18.04 系统上进行,运行平台为 Intel Core i7-4700MQ @ 2.40 GHz CPU,算法以单线程模式执行,以确保结果的公平性。

2.2 线段筛选方法对比实验

为验证所提出的线段特征筛选策略的有效性,并重点分析线段截断策略对系统性能的影响,本文设计了三种对比方案:(1) 仅使用原始 LSD 算法提取线段;(2) 在 LSD 基础上剔除过短线段;(3) 在 LSD 基础上同时剔除过短线段并截断过长线段。实验中三种方案均集成到本文构建的点线视觉惯性里程计系统中,参数配置保持一致。同时,为确保对比结果能反映剔除与截断策略的直接影响,本实验未引入平行约束残差,以

避免额外结构约束对结果造成干扰。实验选取 TUM-VI 数据集中的 5 个走廊序列进行测试，该序列具有低纹理与重复结构等典型特征，适用于评估筛选策略在弱纹理条件下对系统稳定性与定位精度的影响。

实验中线段剔除与截断策略均采用正文中的阈值法实现。最短线段长度阈值 $L_{\min}$ 与最长线段长度阈值 $L_{\max}$ 根据输入图像帧的对角线长度 L_{d} 自适应计算，具体设定为：$L_{\min}=\alpha L_{\mathrm{d}}$，$L_{\max}=\beta L_{\mathrm{d}}$，其中 α 用于控制最短线段阈值，抑制 LSD 输出的噪声短线；β 用于限制过长线段，避免长线段跨越较大，线段处理效率低。本文取 $\alpha=0.055$、$\beta=0.25$，该参数组合通过在少量代表性序列上的小范围参数测试确定，在保证线段数量的同时兼顾特征匹配稳定性。为保证实验对比公平性与参数一致性，后续实验中涉及线段剔除与截断时亦统一采用相同的 α 和 β 设定。

为全面评估不同线段筛选策略对系统性能的影响，本文从计算效率、特征数量和定位精度三个方面进行定量分析。在计算效率方面，采用平均每帧线段处理时间作为指标。该时间统计涵盖线段检测、筛选与描述符计算三个过程，并对所有帧结果取平均值。相较于仅评估线段提取时间，该指标统计的是线段检测后至匹配前的全部处理过程，更能全面反映不同筛选策略对系统整体效率的影响。在特征数量方面，使用平均每帧有效线段数量作为指标。通过对每条线特征进行筛选后，统计每帧保留的线段数量，以反映系统的特征稀疏程度。在定位精度方面，采用绝对轨迹误差（Absolute Trajectory Error，ATE）的均方根误差（Root Mean Square Error，RMSE）作为评价指标，RMSE 越低，代表轨迹误差越小，即定位精度越高。本文使用开源工具 Evo[29] 对估计轨迹与真值轨迹进行时间关联与刚体对齐，并计算 RMSE。最后，对所有指标在多个序列上的结果计算平均值，以获得不同筛选策略在整体性能上的综合表现。

实验结果如表 1 所示，本文提出的线段筛选策略在定位精度与计算开销两方面均带来了明显影响。首先，从五个走廊序列的 RMSE 平均值来看，短线剔除与长线截断的组合策略取得了最低的 RMSE，并且在多数序列下本文方法均达到最低的结果。结果表明本文方法在不引入额外结构约束的条件下，仍能够提升点线 VIO 的状态估计精度与轨迹一致性。相较之下，仅进行短线剔除虽在部分序列上带来一定改善，但整体平均 RMSE 仍高于本文的“剔除与截断”组合方案。

表 1　线段筛选方法对比

Tab. 1　Comparison of line segment filtering strategies

序列	LSD			短线剔除			短线剔除与长线截断（本文方法）		
	时间/ms	数量	RMSE/m	时间/ms	数量	RMSE/m	时间/ms	数量	RMSE/m
Corridor1	56.18	370	0.545 7	39.60	50	**0.526 3**	38.66	54	0.526 4
Corridor2	57.03	367	0.637 7	40.13	51	**0.633 5**	39.69	55	0.634 7
Corridor3	54.91	345	0.710 6	38.30	49	0.664 3	37.75	52	**0.651 7**
Corridor4	55.65	351	0.248 5	38.88	49	0.239 5	39.37	53	**0.206 4**
Corridor5	55.23	355	0.476 3	39.42	51	0.474 2	39.01	55	**0.463 4**
平均值	55.80	358	0.523 8	39.26	50	0.507 6	38.89	54	**0.496 5**

在线段处理效率与有效线段数量方面，仅使用原始 LSD 时，系统平均每帧需处理约 358 条线段，对应的线段处理时间为 55.80 ms。引入短线剔除后，平均有效线段数量显著下降至 50 条，处理时间降低至 39.26 ms，说明大量短碎线段会显著增加线段检测后的描述符计算与匹配负担，而剔除短线能够有效减少冗余观测并提升前端处理效率。在此基础上进一步对长线进行截断后，平均有效线段数量为 54 条，较短线剔除方案仅小幅增加，这主要是因为原始 LSD 在该场景中检测到的超长线段数量本身有限，截断产生的子线段对总数量的影响较小。值得注意的是，尽管引入了额外的截断操作，平均线段处理时间仍进一步下降至 38.89 ms。该现象是由于本实验统计的时间不仅包含线段检测与筛选，还包含对筛选后线段的 LBD 描述符计算等步骤。长线段像素跨度较大，线段处理代价相对更高，而截断后子线段长度更适中，有助于降低单条线段的描述与匹配开销，从而在总体上进一步改善前端运行效率。

综合而言，短线剔除与长线截断策略通过在保证特征质量的前提下控制线段数量，有效平衡了系统精度与计算效率。该策略不仅显著降低了特征处理时间，还提升了系统在多序列、多场景下的整体稳定性与轨迹

一致性,并且为后续在结构化场景中进一步引入平行残差奠定了坚实基础。

2.3 系统整体性能对比实验

在完成线段筛选策略的对比验证后,为进一步评估本文方法在完整点线视觉惯性里程计系统中的实际效果,本节开展系统整体性能验证与分析。实验以基于点特征的 VINS-Mono 以及现有点线方法 PL-VINS[30]作为对比基线。同时,本实验引入上一节的对比配置,即仅启用短线剔除与长线截断而不引入平行残差的方法,用于评估在此基础上进一步加入平行约束后对系统性能的增益。实验 EuRoC 数据集的工厂于室内序列上进行,从而在不同结构化场景下对定位精度与运行表现进行综合评估。

对于本文系统的两种配置,即引入平行约束与不引入平行约束方法,线段前端筛选方法中的最长和最短线段阈值均采用与上一节一致的设定。对于引入平行约束的配置,线段聚类阶段的消失点一致性距离阈值 τ_{vp} 在实验中设定为 10 像素,其余实验配置保持一致,以保证对比结果能够主要反映平行约束模块带来的影响。

本节实验采用绝对轨迹误差(ATE)的均方根误差(RMSE)和最大误差(MAX)作为关键评估指标,以全面、严谨地衡量系统的定位精度。其中,RMSE 反映估计轨迹与真实轨迹之间的平均偏差,体现系统的整体精度;MAX 则表示在最差情况下的最大误差,用以评估系统在复杂环境中的鲁棒性。两项指标相辅相成,共同评估系统在精度与稳定性方面的综合表现。为便于不同序列之间的对比,本节在每组实验结果中统一报告所有序列的平均 RMSE 与 MAX 值,从而更直观地展现整体性能趋势,实验结果见表 2。此外,为增强对比效果,本文设计了柱状图如图 3 和图 4,用于可视化展示不同方法在精度与稳定性方面的差异。进一步地,选取代表性的 MH_01_easy 与 V1_01_easy 序列,绘制二维轨迹对比图,如图 5 所示,以深入分析各方法在轨迹形状与漂移特性上的差异。

表 2 系统整体性能对比

Tab. 2 Comparison of the overall system performance

序列	VINS-MONO		PL-VINS		本文方法(无平行约束)		本文方法(含平行约束)	
	MAX	RMSE	MAX	RMSE	MAX	RMSE	MAX	RMSE
MH_01_easy	0.549 9	0.213 8	0.534 2	0.202 2	0.504 3	0.187 7	**0.481 3**	**0.174 6**
MH_02_easy	0.592 7	0.200 5	0.498 0	0.178 8	0.452 4	0.161 4	**0.434 4**	**0.159 5**
MH_03_medium	0.453 9	0.223 0	0.503 1	**0.214 5**	0.566 1	0.264 9	**0.448 7**	0.217 8
MH_04_difficult	0.484 1	0.339 8	**0.447 0**	**0.299 5**	0.497 9	0.318 1	0.480 4	0.303 9
MH_05_difficult	0.415 0	0.297 1	0.386 7	0.240 8	**0.363 5**	0.222 1	0.396 6	**0.221 8**
V1_01_easy	0.190 5	0.085 3	0.170 0	0.078 3	0.177 2	0.085 4	**0.163 9**	**0.075 5**
V1_02_medium	**0.234 1**	0.091 7	**0.226 5**	0.092 4	0.237 7	0.097 0	0.236 7	0.096 1
V1_03_difficult	0.376 7	0.207 9	**0.320 7**	0.174 8	0.342 7	0.166 0	0.325 3	**0.169 9**
V2_01_easy	0.225 2	0.092 5	0.238 1	0.092 1	0.220 3	0.080 7	**0.218 2**	**0.080 8**
V2_02_medium	0.518 0	0.160 9	0.335 5	**0.122 4**	0.355 0	0.163 0	**0.313 9**	0.140 9
V2_03_difficult	0.510 4	0.220 6	**0.425 1**	0.193 0	0.513 9	0.231 5	0.439 2	**0.184 1**
平均值	0.413 7	0.193 9	0.371 4	0.171 7	0.384 7	0.179 8	**0.358 1**	**0.165 9**

从表 2 的结果来看,本文方法在引入平行约束后取得了最优的整体表现,并且在多个序列均优于其他方法。首先,从全部序列的平均结果来看,本文方法在引入平行约束后表现出最优的综合性能。其平均 MAX 和平均 RMSE 分别达到 0.358 1 m 和 0.165 9 m,均低于其余三种方法。相比 VINS-Mono,平均 MAX 和平均 RMSE 分别下降约 13.4%和 14.4%;相比 PL-VINS,分别下降约 3.6%和 3.4%;相比未引入平行约束的本文方法,分别下降约 6.9%和 7.7%。这表明,引入平行约束后的本文方法不仅能够有效提高系统的整体定位精度,还能够增强轨迹估计的稳定性,使其在不同序列下均具有更好的综合表现。

二维轨迹对比结果进一步验证了上述结论。如图 5 所示,在 MH_01_easy 与 V1_01_easy 两个典型序列中,本文方法对应的估计轨迹在整体形状、转弯段以及局部细节处与真值轨迹保持更高的一致性,其轨迹

颜色更为突出且与真值轨迹的重合程度更高，表明该方法具有更好的效果。

需要指出的是，本文方法在不引入平行约束时，虽然平均 RMSE 优于 VINS-Mono，但平均 MAX 反而高于 VINS-Mono，且平均 RMSE 和平均 MAX 均高于 PL-VINS。这表明，仅采用短线段剔除和过长线段截断策略，虽然能够在一定程度上提高线段质量并降低前端处理开销，在部分场景下也能够取得一定效果，但对于较为复杂的场景，仍难以有效抑制部分图像帧中的较大观测偏差，从而导致后端优化稳定性不足，轨迹误差波动较为明显。相比之下，在后端进一步引入平行约束后，系统性能得到了明显改善，在 EuRoC 数据集的大部分序列上均取得了更优结果，说明本文前端线段筛选策略与后端平行约束之间具有较好的协同作用。

综合实验结果可以看出，本文方法在 EuRoC 典型低纹理结构化场景中取得了较好的定位性能，说明了前端线段筛选与后端结构约束的结合能够有效提升定位精度与稳定性。与此同时，轨迹对比结果也表明，本文方法与真实轨迹具有更高一致性，验证了所提方法以及所构建系统的有效性。

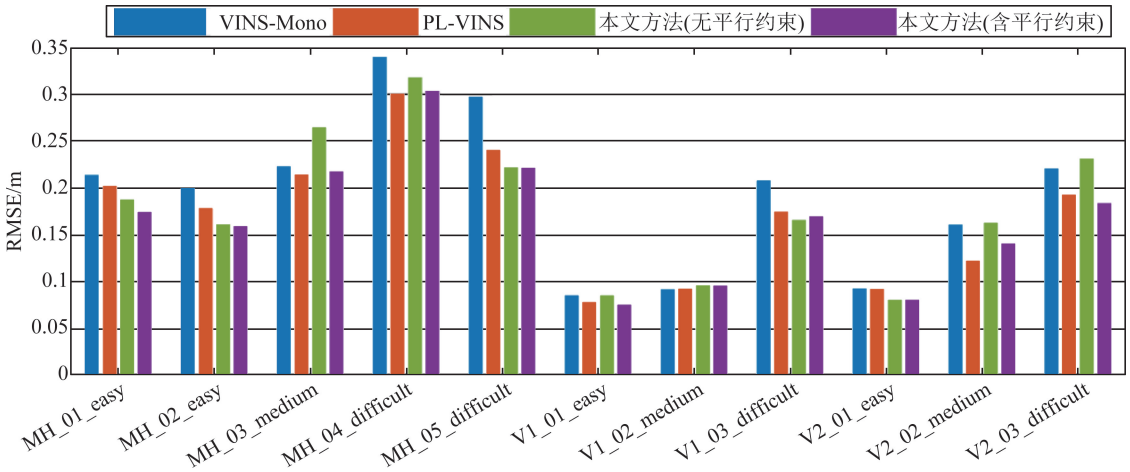


图 3　不同方法在各序列上的 RMSE 对比图

Fig. 3　Comparison of RMSE across different methods on various sequences

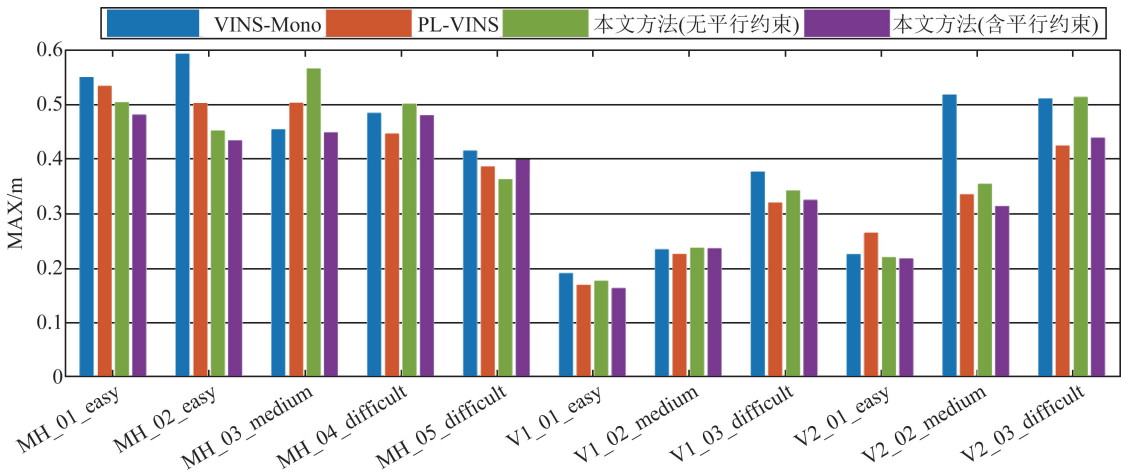


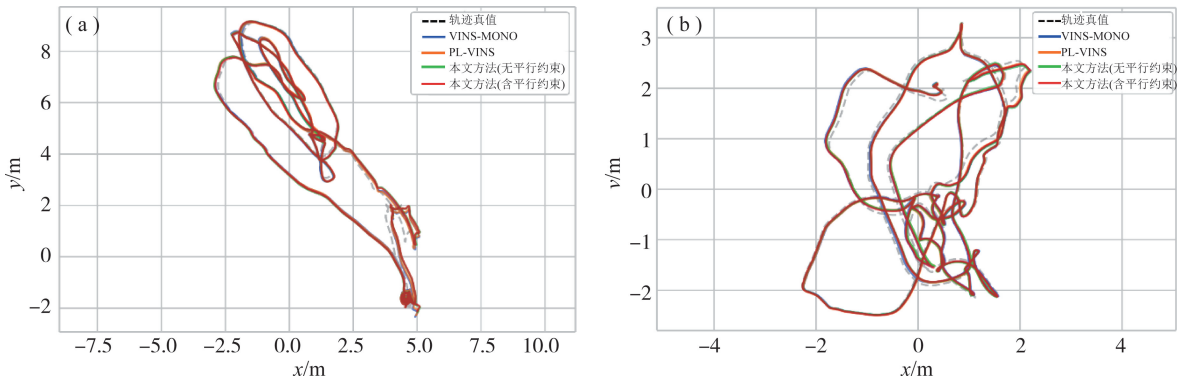
图 4　不同方法在各序列上的 MAX 对比图

Fig. 4　Comparison of MAX across different methods on various sequences

3　结论

为提升点线 VIO 在低纹理、结构化场景下的定位精度，本文提出了一种结合线段截断与平行约束的点线视觉惯性里程计方法。针对 LSD 算法提取线段长度差异大、分布不均的问题，本文通过剔除过短线段并对过长线段进行适度截断，生成长度适中的子线段，从而提高线段处理效率与可跟踪性。在此基础上，利用截断子线段方向一致的特性，在曼哈顿世界假设下估计场景主方向，并在后端优化中引入平行约束以增强姿

态估计的方向稳定性。实验结果表明,所提出的线段截断策略能够提升点线 VIO 的匹配稳定性,而结合平行约束后,在多数结构化场景序列中进一步降低了轨迹误差并增强了系统鲁棒性。需要指出的是,本文方法依赖曼哈顿世界假设,在非结构化或自然场景中,主方向估计的显著性与稳定性往往不足,此时平行约束带来的增益会减弱,甚至可能引入不准确的方向约束,从而影响优化效果。未来工作将重点提升结构线段的提取与维护质量,并引入主方向置信度评估与自适应约束策略,同时探索更通用的平行约束建模方法,以增强该方法在非曼哈顿环境下的适用性与稳定性。



注:(a) MH_01_easy 序列二维轨迹对比;(b) V1_01_easy 序列二维轨迹对比。

图 5 二维轨迹对比图

Fig. 5 Comparison of 2D trajectory

参 考 文 献

[1] Alsadik B, Karam S. The simultaneous localization and mapping (SLAM): an overview[J]. Journal of Applied Science and Technology Trends, 2021, 2(4), 120-131.

[2] Arafat M Y, Alam M M, Moh S. Vision-based navigation techniques for unmanned aerial vehicles: review and challenges[J]. Drones, 2023, 7(2): 89.

[3] Huang G. Visual-inertial navigation: a concise review[C]//Proceedings of International Conference on Robotics and Automation IEEE, 2019: 9572-9582.

[4] Jiang J Q, Yuan J, Zhang X T, et al. DVIO: an optimization-based tightly coupled direct visual-inertial odometry[J]. IEEE Transactions on Industrial Electronics, 2021, 68(11): 11212-11222.

[5] Von Stumberg L, Cremers D. DM-VIO: delayed marginalization visual-inertial odometry[J]. IEEE Robotics and Automation Letters, 2022, 7(2): 1408-1415.

[6] Yang W Z, Zhuang Y, Luo D T, et al. VI-HSO: hybrid sparse monocular visual-inertial odometry[J]. IEEE Robotics and Automation Letters, 2023, 8(10): 6283-6290.

[7] Jiang H, Shang Y L, Xue S, et al. UMPL- VINS: generalized SLAM for multi-scene metaverse applications[J]. 2024,224:242-253.

[8] Xu L, Yin H S, Shi T, et al. EPLF-VINS: real -time monocular visual-inertial SLAM with efficient point-line flow features[J]. IEEE Robotics and Automation Letters, 2022, 8(2): 752-759.

[9] Gromrone Von Gioi R, Jakubowicz J, Morel J M, et al. LSD: a line segment detector[J]. Image Processing on Line, 2012, 2: 35-55.

[10] 魏光睿, 高强, 吉月辉, 等. 基于点线特征的视觉同时定位与地图构建综述[J]. 天津理工大学学报, 2024, 40(2): 63-69.

[11] Zhao Z Z, Song T, Xing B, et al. PLi-VINS: visual-inertial SLAM based on point-line feature fusion in indoor environment[J]. Sensors, 2022, 22(14): 5457.

[12] Sun M, Hu C. A monocular visual inertial SLAM algorithm with point-line feature fusion[J]. International Journal of Frontiers in Engineering Technology, 2023, 5(2):39-45.

[13] Coughlan J M, Yuille A L. Manhattan world: compass direction from a single image by Bayesian inference[C]//Proceedings of the Seventh IEEE International Conference on Computer Vision, 2002:941-947.

[14] Zou D P, Wu Y X, Pei L, et al. StructVIO: visual-inertial odometry with structural regularity of man-made environments[J]. IEEE Transactions on Robotics, 2019, 35(4): 999-1013.

[15] Company-Corcoles J P, Garcia-Fidalgo E, Ortiz A. MSC-VO: exploiting Manhattan and structural constraints for visual odometry[J]. IEEE Robotics and Automation Letters, 2022, 7(2): 2803-10.

[16] Xu B, Wang P, He Y J, et al. Leveraging structural information to improve point line visual-inertial odometry[J]. IEEE Robotics and Automation Letters, 2022, 7(2): 3483-90.

[17] 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): 1004-20.

[18] Shi J. Good features to track[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 1994, 593-600.

[19] Tomasi C. Detection and tracking of point features[J]. Technical Report, 1991, 91(21): 9795-9802.

[20] Zhang L L, Koch R. An efficient and robust line segment matching approach based on LBD descriptor and pairwise geometric consistency [J]. Journal of Visual Communication and Image Representation, 2013, 24(7): 794-805.

[21] 张彧，檀祖冰，曹东璞，等. 基于视觉和惯性测量单元的里程计关键技术研究综述[J]. 机械工程学报，2024，60(10)：3-21.

[22] 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.

[23] Si H Q, Yu H, Chen K Y, et al. Point-line visual-inertial odometry with optimized line feature processing[J]. IEEE Transactions on Instrumentation and Measurement, 2024:73:1-13.

[24] 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.

[25] Lu X H, Yaoy J, Li H A, et al. 2-line exhaustive searching for real-time vanishing point estimation in Manhattan world[C]//Proceedings of IEEE Winter Conference on Applications of Computer Vision, 2017:345-353.

[26] 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.

[27] Bustos A P, Chin T J, Eriksson A, et al. Visual SLAM: why bundle adjust? [C]//Proceedings of International Conference on Robotics and Automation IEEE, 2019:2385-2391.

[28] Schubert D, Goll T, Demmel N, et al. The TUM VI benchmark for evaluating visual-inertial odometry[C]//Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems, 2019:1680-1687.

[29] Grupp M. Evo: Python package for the evaluation of odometry and slam [Z], 2017.

[30] Fu Q, Wang J L, Yu H, et al. PL-VINS: real-time monocular visual-inertial SLAM with point and line features[EB/OL]. arXiv preprint arXiv:200907462, 2020.

（责任编辑：刘庆松）

（上接第 832 页）

[26] Gu A, Johnson I, Goel K, et al. Combining recurrent, convolutional, and continuous-time models with linear state space layers[C]. Proceedings of Neural Information Processing Systems, Virtual, 2021, 34: 572—585.

[27] Smith J T H, Warrington A, Linderman S W. Simplified state space layers for sequence modeling [EB/OL]. arXiv preprint arXiv:2208.04933, 2022.

[28] Gu A, Goel K, Ré C. Efficiently modeling long sequences with structured state spaces [EB/OL]. arXiv preprint arXiv:2111.00396, 2021.

[29] Gu A, Dao T. Mamba: linear-time sequence modeling with selective state spaces [EB/OL]. arXiv preprint arXiv:2312.00752, 2023.

[30] Fang S, Li K Y, Li Z. Changer: feature interaction is what you need for change detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-11.

[31] Sun B, Gao Y X, et al. Analysis of quality objective assessment metrics for visible and infrared image fusion[J]. Journal of Image and Graphics, 2023,28(1):144-155.

（责任编辑：刘庆松）