

室外环境下基于点线特征的视觉-惯性里程计和全球卫星导航系统定位算法

何璇, 潘树国*, 谭涌, 高旺, 章辉

东南大学仪器科学与工程学院, 江苏 南京 210096

摘要 为了解决视觉-惯性里程计(VIO)在室外复杂环境中图像特征信息不足和累计误差的问题,设计提出了一种基于点线特征的单目VIO和全球卫星导航系统(VIO-GNSS)定位算法。首先,提出了一种基于几何约束的最小化策略对提取的线特征进行前后帧间约束匹配,改进了基于点线特征的单目VIO算法;在此基础上,建立了改进的VIO-GNSS松耦合定位模型,利用GNSS全局观测值对VIO位姿估计的累计误差进行校正和抑制。在KIITI数据集和实测数据集中进行了实验验证,结果表明,与几种同类算法相比,提出算法在GNSS信号良好/间断/拒止的大型室外复杂环境中均可保持良好的精度和鲁棒性,且满足驾驶定位的实时性要求。

关键词 机器视觉; 运动估计和光流; 点线特征; 视觉-惯性里程计; 卡尔曼滤波; 多传感器定位

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP202259.1815002

Visual-Inertial Odometry and Global Navigation Satellite System Location Algorithm Based on Point-Line Feature in Outdoor Scenes

He Xuan, Pan Shuguo*, Tan Yong, Gao Wang, Zhang Hui

School of Instrument Science and Engineering, Southeast University, Nanjing 210096, Jiangsu, China

Abstract To address the problem of insufficient image feature information and the accumulated error of visual-inertial odometry (VIO) in an outdoor complex environment, this paper proposes a VIO and global navigation satellite system (GNSS) algorithm based on a combination of point and line features. First, the paper designs a minimization strategy using geometric constraints, which performs constraint matching between the front and back frames on the extracted line features. In addition, an improved VIO-GNSS loose coupling model is built, in which the accumulated error in VIO pose estimation is suppressed using the global observation value of the GNSS. The experimental results in the KIITI data set and measured data set show that the proposed algorithm can maintain good accuracy and robustness compared with several similar algorithms in large outdoor complex environments with good/rejected/interrupted GNSS signals and meet the real-time requirements of driving positioning.

Key words machine vision; motion estimation and optical flow; point and line features; visual-inertial odometry; Kalman filter; multisensor positioning

1 引言

精准的行车定位是自动驾驶的关键技术之一。无人车行车定位技术可分为全局定位与局部定位两种。全局定位主要指利用全球卫星导航系统(GNSS)进行定位导航。局部定位主要由激光雷达、视觉里程计

(VO)和惯性测量单元(IMU)^[1]等传感器对载体所处的三维环境进行定量感知,估计载体的位姿信息。由于激光雷达造价较高,业界更倾向于选用造价低且可捕获环境纹理信息的VO与IMU紧耦合的定位方案,即视觉-惯性里程计(VIO)进行局部定位。

现有的VIO算法主要依赖点特征完成特征提取

收稿日期: 2021-06-16; 修回日期: 2021-07-08; 录用日期: 2021-07-20

基金项目: 国家自然科学基金(41774027, 41904022)、东南大学至善青年学者资助计划(2242021R41134)、教育部-中国移动科研基金(MCM20200J01)

通信作者: *psg@seu.edu.cn

与跟踪,特征点的质量与数量严格影响算法正常初始化和逐帧位姿估计。然而,点特征对环境纹理要求较高,采用特征匹配法的 VIO^[2-5]在隧道等弱纹理环境中难以实时提取有效特征点,且误匹配率极高;基于直接法的 VIO^[6-9]虽在实时性和特征点提取数量方面有所改善,但在复杂环境下的特征提取情况仍不理想。因此,需引入受弱纹理环境影响较小,且在环境中数量更为丰富的线特征对图像帧增加额外的特征约束。目前,基于点线特征结合的研究的主要代表有:PL-VIO^[10]、PLS-VIO^[11]、PL-VINS^[12]等。以 PL-VINS 为例,采用迭代更新普吕克坐标四参数优化误差向量,较仅使用点特征的方法的精度有所改善。但是,由于 VIO 位姿估计结果处于局部坐标系的固有缺陷,在大型复杂环境中的累计误差和连续转弯后的数据漂移情况仍较为显著。

鉴于以上问题,可引入 GNSS 提供的基于地球坐标系的全局定位信息对 VIO 累计误差进行校正。而 VIO 能在隧道等 GNSS 拒止区域和城市中心 GNSS 多径效应区域提供连续定位信息,并可以有效弥补 GNSS 信号更新频率低的缺陷^[13]。但现有的相关工作中仍存在一些局限性,比如,实际应用中车辆需穿越城市峡谷和隧道等复杂环境,与现有工作^[14-16]中使用全程良好的 GNSS 信号的假设不同,间断性的 GNSS 信号更接近实际情况。针对这种情况,文献^[17-18]中使用的基于贝叶斯网络的因子图是较为常用的方法,但会丢弃

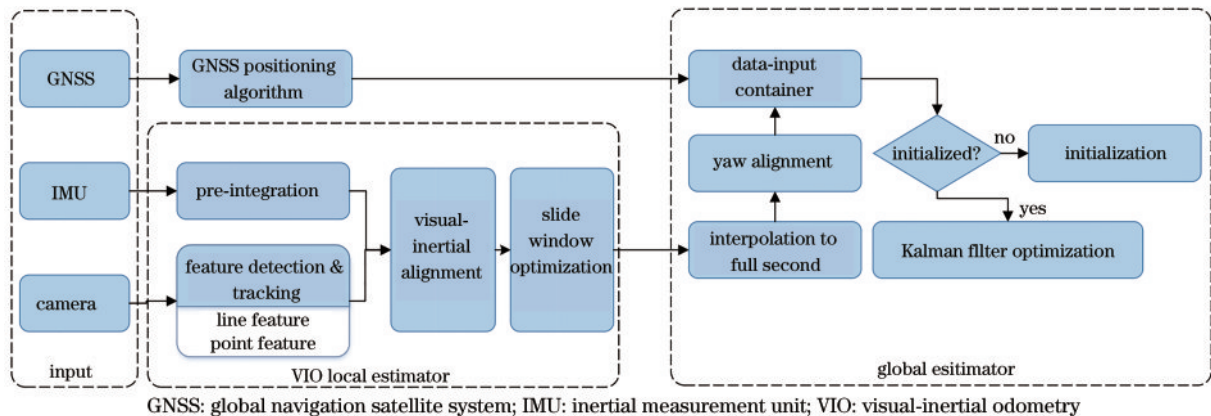
所有测量异常值,从而降低系统的可用性,且利用滑窗多次迭代趋近最优解的方式会降低计算效率,与车辆在复杂大型场景中长时间定位的实时性需求相悖。

在以上研究的基础上,本文提出了一种基于点线特征结合的单目 VIO-GNSS 多传感器定位算法,以提升在城市峡谷、隧道等复杂大型场景中定位的精度和鲁棒性。主要创新点为:1) 设计了一种基于点线特征的直接法 VIO 框架,提出一种基于几何约束的最小化策略,对提取到的线特征进行前后帧间约束匹配,改善弱纹理环境内视觉特征追踪的稳健性;2) 搭建了一个 GNSS 与 VIO 的松耦合模型,利用滤波的方法使用 GNSS 全局定位结果对 VIO 定位结果进行优化,并通过 KITTI 和实测数据集证明其在 GNSS 信号全程良好/拒止/间断环境内均具有较高的定位精度和鲁棒性。

2 基于点线特征的 VIO-GNSS 定位算法

2.1 算法框架

所提出的算法总体框架如图 1 所示。该系统包含两个松耦合模块,即 VIO 局部位姿估计模块和全局位姿估计模块。图像帧和 6 轴 IMU (3 轴加速度计和 3 轴陀螺仪) 作为局部观测值输入,用以完成 VIO 局部位姿估计。经伪距单点定位 (SPP) 算法求解后获得的 GNSS 定位结果作为全局观测值输入,用以与 VIO 位姿解算结果进行全局位姿优化估计。



GNSS: global navigation satellite system; IMU: inertial measurement unit; VIO: visual-inertial odometry

图 1 提出算法总体框架

Fig. 1 General framework of proposed algorithm

VIO 局部位姿估计模块以 VINS-Mono 为基础进行搭建,用以实现 VO 和 IMU 的紧耦合位姿估计。本文在 VO 的特征提取与跟踪模块增加经几何约束后的线特征以增强图像特征约束,与点特征共同作为视觉特征信息。视觉特征信息与 IMU 预积分结果进行时间对齐后,共同输入至非线性优化的滑动窗口内,以获得最大后验估计,得出 VIO 局部位姿估计结果。

全局位姿估计模块通过将 GNSS 和 VIO 位姿估计结果输入至卡尔曼滤波器内,用以实现 VIO 和 GNSS 的松耦合位姿估计。在输入滤波器前,需对 VIO 估计值进行以下预处理:1) 由于 GNSS 更新频率

低,定位结果为整秒输出,需对频率较高的 VIO 估计值的时间通过线性插值至整秒,以实现 GNSS 与 VIO 估计值的时间对准;2) 以 GNSS 测量值为参考,对 VIO 估计值进行高程对齐,进一步对准全局位置和局部位姿。此后,通过卡尔曼滤波处理局部姿态和全局位置,实现局部精确和全局无漂移的连续位姿估计。

2.2 线特征的提取与约束匹配

常用的线特征提取算法有:Hough^[19]、LSWMS^[20]、EDLine^[21]及 LSD 等。这些算法在本实验数据集实测道路中的特征提取结果及耗时如图 2 所示。




图 2 实测环境内各算法的线特征提取结果及耗时。(a) Hough算法(118.045 ms);(b) LSD算法(62.7 ms);
(c) LSWMS算法(40 ms);(d) EDLine算法(18.2 ms)

Fig. 2 Line feature extraction results and time consumption of each algorithm in measured environment. (a) Hough algorithm (118.045 ms); (b) LSD algorithm (62.7 ms); (c) LSWMS algorithm (40 ms); (d) EDLine algorithm (18.2 ms)

权衡精度、实时性和有无调参需求等因素,本文选用 LSD 算法进行线特征提取,并使用 LBD 描述子用于特征匹配。给定世界坐标系中提取的一条线 $l_w = [n_w^T, v_w^T]^T \in \mathbb{R}^6$, 其中 $n_w, v_w \in \mathbb{R}^3$ 为 l_w 的法向量和方向向量。记从世界坐标系到相机坐标系的变换矩阵为 $T_w^c = [R_w^c, t_w^c]$, 分别用 R_w^c, t_w^c 表示旋转和平移量, 则 l_w 在相机坐标系内的普吕克坐标为

$$l_c = \begin{bmatrix} n_c \\ v_c \end{bmatrix} = T_w^c l_w = \begin{bmatrix} R_w^c & [t_w^c]_{\times} R_w^c \\ 0 & R_w^c \end{bmatrix} \begin{bmatrix} n_w \\ v_w \end{bmatrix} \in \mathbb{R}^6, \quad (1)$$

由式(1)可以得到将 l_c 投影到像平面的投影线方程为

$$\bar{l} = [l_1, l_2, l_3]^T = K n_c, \quad (2)$$

式中, K 为线投影矩。

考虑到车辆行驶中的以下几种情况: 1) 微小角度偏移; 2) 沿 n_w 方向的微小偏移; 3) 沿 v_w 方向的微小偏移, 本文提出了一种基于几何约束的最小化策略, 对提取到的线特征进行前后帧间约束匹配, 以提升行车时捕获的图像信息中线特征的匹配精度和数量(图 3)。




图 3 连续两帧间同一线特征可能的变化情况。(a) 存在微小夹角; (b) 存在微小距离

Fig. 3 Possible changes in same line feature between two consecutive frames. (a) Existence of slight angles; (b) existence of slight distances

通过上述约束, 可将线特征匹配与跟踪记为一个稀疏的最小化问题。设 $e_{ij} = [\theta_{ij}, d_{ij}, \mu_{ij}, \rho_{ij}]^T, t = [0, 0, 1, 1]^T$, 构建线性约束方程 $A_i = [e_{i0}, \dots, e_{ij}, e_{in}]$ 。引入匹配向量 m_i :

$$m_i = [m_{i0}, \dots, m_{ij}, \dots, m_{in}]^T = \begin{cases} 1 & l_i \text{ matches } l_j \\ 0 & l_i \text{ does not match } l_j \end{cases}, \quad (4)$$

若 $\sum m_m = 1$, 则满足线性约束 $A_i m_i = t$, 则基于几何约

束的最小化问题可表示为

假设 $L_1 = \{l_i = (s_i, e_i) | i \in 1, \dots, m\}, L_2 = \{l_j = (s_j, e_j) | j \in 1, \dots, n\}$ 分别为连续两帧提取的线特征集, 则可通过匹配产生线特征对子集 $M_{12} = \{(l_i, l_j) | l_i \in L_1, l_j \in L_2\}$ 。 M_{12} 中的元素需满足以下几何约束:

$$\begin{cases} \theta_{ij} = \arctan\left(\frac{\|v_i \times v_j\|}{v_i} \times v_j\right) = 0 \\ d_{ij} = \left\| \frac{\bar{l}_i^T \cdot (s_j + e_j)}{2\sqrt{l_i^2 + l_j^2}} \right\|_2 = 0 \\ \mu_{ij} = \frac{\min\{L_i, L_j\}}{\max\{L_i, L_j\}} = 1 \\ \rho_{ij} = \frac{L_i \cos \theta_{ij}}{L_j} = 1 \end{cases}, \quad (3)$$

式中: θ_{ij} 为 l_i 和 l_j 的方向向量夹角; d_{ij} 为 l_j 中点到 l_i 的距离; L_x 为 l_x 在像平面中的长度; μ_{ij} 和 ρ_{ij} 分别为两线特征间的长度比例和投影比例。

束的最小化问题可表示为

$$\|A_i m_i = t\|_2 < \sigma, \min \|m_i\|_1, \quad (5)$$

式中, $\sigma > 0$ 为约束的最大公差。

2.3 VIO 局部位姿优化模型

VO 的特征提取与跟踪模块增加经几何约束后的线特征以增强图像特征约束, 与点特征共同作为视觉特征信息。视觉特征信息与 IMU 预积分结果共同输

入至非线性优化的滑动窗口内,以获得最大后验估计,得出 VIO 局部位姿估计结果。

首先构建 VIO 局部位姿估计模块在世界坐标系中的全局状态向量:

$$\mathbf{X} = [x_i, x_{i+1}, \dots, x_{i+f}, \lambda_i, \lambda_{i+1}, \dots, \lambda_{i+p}, o_i, o_{i+1}, \dots, o_{i+l}],$$

$$\mathbf{x}_n = [p_n^w, q_n^w, v_n^w, b_{an}, b_{gn}], n \in [i, i+f], \quad (6)$$

式中: \mathbf{x}_n 包括第 n 个 IMU 提供的载体位置 p_n^w 、方向 q_n^w 、速度 v_n^w 、加速度偏置 b_{an} 和陀螺仪偏置 b_{gn} ; f, p 和 l 分别表示滑窗内图像帧、点特征和线特征的总数; λ_{i+m} 表示第 m 个特征点与初始特征点之间的逆深度; o_{i+w} 为第 w 条特征线在世界坐标系中的正交表示。

根据式(6),可以通过最小化所有测量残差的代价函数以获得最大后验估计,从而优化滑动窗口内的所有状态向量,滑动窗口内的非线性优化方程为

$$\left\{ \begin{array}{l} \min_{\mathbf{X}} \left\{ \rho(\|r - \mathcal{H}\mathbf{X}\|^2) + \sum_{k \in B} \rho(\|r_b(\hat{z}_{k+1}^k, \mathbf{X})\|_{p_i}^2) + \right. \\ \left. \sum_{(i,j) \in F} \rho(\|r_f(\hat{z}_i^j, \mathbf{X})\|_{p_c}^2) + \sum_{(i,j) \in L} \rho(\|r_l(\hat{z}_i^j, \mathbf{X})\|_{p_c}^2) \right\}, \\ \rho(s) = \begin{cases} s & s \leq 1 \\ 2\sqrt{s} - 1 & s > 1 \end{cases} \end{array} \right. \quad (7)$$

式中: ρ 为 Huber 损失函数; B 表示滑窗内所有 IMU 积分测量值; F 和 L 表示图像帧中提取的所有点特征和线特征; p_i 和 p_c 分别为 IMU 和视觉信息的协方差矩阵; $\{r, \mathcal{H}\}$ 为边缘化后的先验信息; $r_b(\hat{z}_{k+1}^k, \mathbf{X})$ 为 IMU 残差; $r_f(\hat{z}_i^j, \mathbf{X})$ 为视觉特征点在相机坐标系中的重投影误差,详见文献[6]; $r_l(\hat{z}_i^j, \mathbf{X})$ 为新增线特征在相机坐标系中的重投影误差:

$$r_l(\hat{z}_i^j, \mathbf{X}) = \begin{bmatrix} d(s_i^j, l_i^j) \\ d(e_i^j, l_i^j) \end{bmatrix}. \quad (8)$$

可根据式(2)得

$$d(s_i^j, l_i^j) = \frac{s_i^{jT} \bar{l}_i^j}{\sqrt{l_{i1}^2 + l_{i2}^2}} \in \mathbb{R}^1,$$

$$d(e_i^j, l_i^j) = \frac{e_i^{jT} \bar{l}_i^j}{\sqrt{l_{i1}^2 + l_{i2}^2}} \in \mathbb{R}^1, \quad (9)$$

其相应优化变量的雅可比矩阵可通过链式法则[3]求解。

2.4 全局位姿估计初始化

如前所述, VIO 局部位姿估计值在局部坐标系中,当前帧位姿估计值以前一帧位姿估计值为基础进行求解,从而引起累计误差。因此,须将其转换为全局地心地固(ECEF)坐标系。如图4所示,本系统涉及的全局坐标系 $\{E\}$ 为 ECEF 坐标系,局部坐标系 $\{V\}$ 中包含相




图4 提出系统涉及的坐标系示意图

Fig. 4 Schematic diagram of coordinate frame involved in proposed system

机坐标系 $\{C\}$ 、IMU 局部坐标系 $\{I\}$ 和 GNSS 接收机局部坐标系 $\{G\}$ 。

给定滑窗内单目 VIO 其在相机坐标系 $\{C\}$ 中的一组位姿估计值: $\{{}^V p_{C_i}, \dots, {}^V p_{C_j}\}$, 可利用杆臂补偿公式(10)将其转换到 GNSS 接收机局部坐标系 $\{G\}$ 中:

$${}^V p_{G_n} = {}^V p_{C_n} + {}^V R_{C_i} P_{C_i}^G, n \in [i, j], \quad (10)$$

式中: ${}^V p_{G_n}$ 为 ECEF 坐标系中的 VIO 观测值; ${}^V R_{C_i}$ 为 VIO 在局部坐标系中的旋转矩阵; $P_{C_i}^G$ 为 GNSS 接收机局部坐标系 $\{G\}$ 到相机坐标系 $\{C\}$ 的外参矩阵。设 ECEF 坐标系中的一组 GNSS 观测值 $\{{}^E p_{G_i}, \dots, {}^E p_{G_j}\}$, 定义局部坐标系到 ECEF 坐标系的转换参数为 S, R, t , 则可构建以下最小二乘问题进行求解:

$$\min_{S, R, t} \frac{1}{2} \sum_{n=1}^j \left\| {}^E p_{G_n} - (SR {}^V p_{G_n} + t) \right\|_2^2. \quad (11)$$

每次全局位姿估计滤波器更新后,获得的最优位姿估计值将被用于更新下一时刻的 VIO-ECEF 坐标系转换参数。

2.5 全局位姿估计滤波模型

得到 ECEF 坐标系内的 VIO 观测值后,需将其与 GNSS 观测值共同输入卡尔曼滤波器内,以实现 VIO 和 GNSS 的松耦合位姿估计,传播和测量更新过程中的误差状态向量为

$$\tilde{\mathbf{x}} = [\tilde{P}_x \ \tilde{P}_y \ \tilde{P}_z \ \tilde{V}_x \ \tilde{V}_y \ \tilde{V}_z]^T, \quad (12)$$

式中: $\tilde{P}_x, \tilde{P}_y, \tilde{P}_z$ 表示 x, y, z 方向的位置误差量; $\tilde{V}_x, \tilde{V}_y, \tilde{V}_z$ 表示 x, y, z 方向的速度误差量,其值为 $\tilde{V}(t) = \tilde{\dot{P}}(t)$ 。根据运动学公式,可推导出误差状态传递模型为

$$\dot{\tilde{\mathbf{x}}}(t) = \begin{bmatrix} 0_{3 \times 3} & I_{3 \times 3} \\ 0_{3 \times 3} & 0_{3 \times 3} \end{bmatrix} \tilde{\mathbf{x}}(t) + \begin{bmatrix} I_{3 \times 3} & 0_{3 \times 3} \\ 0_{3 \times 3} & I_{3 \times 3} \end{bmatrix} \omega(t) = \mathbf{F}(t) \tilde{\mathbf{x}}(t) + \mathbf{G}(t) \omega(t), \quad (13)$$

式中, $\omega(t)$ 为系统噪声。

设前后帧间时间间隔为 Δt , 可得离散化后的系统状态矩阵:

$$\phi_{k,k-1} = \mathbf{I} + F(t)\Delta t = \begin{bmatrix} 1 & & & \Delta t \\ & 1 & & \Delta t \\ & & 1 & \Delta t \\ & & & 1 \end{bmatrix}, (14)$$

下一步,构建系统的量测模型如下:

$$\mathbf{Z}_k = \mathbf{H}_k x_k + V_k, \quad \mathbf{Z} = \begin{bmatrix} P_x - \hat{P}_x \\ P_y - \hat{P}_y \\ P_z - \hat{P}_z \\ V_x - \hat{V}_x \\ V_y - \hat{V}_y \\ V_z - \hat{V}_z \end{bmatrix}, \quad \mathbf{H}_k = \mathbf{I}_{6 \times 6} \quad (15)$$

系统测量值 \mathbf{Z} 设为 GNSS 测量值 P 、 V 和 VIO 估计值 \hat{P} 、 \hat{V} 在 ECEF 坐标系中的差值; \mathbf{H}_k 为观测矩阵; V_k 为观测噪声。由此可以根据上述误差状态传递模型和量测模型构建卡尔曼滤波模型,实现连续且实时的位姿估计。

3 实验验证与结果分析

为验证经几何约束后的线特征对单目 VIO 的积极作用和 VIO-GNSS 融合算法在复杂环境中的优良性能,本文实验分别在 KITTI raw 数据集^[9]和实测数据集中进行,其中, KITTI raw 数据集实验用以评估 GNSS 全程信号良好环境中算法的位姿估计结果;实测数据集实验分为两个部分,通过隧道/城市道路及测

试场实测数据集实验分别验证 GNSS 拒止/间断环境中算法的定位性能,并与已有的几种常用算法: Vins_Mono^[6]、PL-VIO^[10]和 Vins_Fusion^[14]进行对比评估,从而对本文提出算法在不同行车环境中的定位性能进行全面验证。实测数据采集使用的车载硬件平台如图 5 所示。




图 5 实测数据采集平台

Fig. 5 Platform for actual measurement data acquisition

实验在 64 位的 Ubuntu16.04 操作系统的 PC 端运行,处理器为 Intel Core i7-8700,内存为 16 GB。

3.1 基于几何约束的线特征匹配结果

相较于利用传统的 LSD 算法,本文提出算法利用几何约束构建最小化方程,弥补了 LSD 算法因端点标记唯一性使长线段被切割,导致前后帧间匹配精度较差的不足。在线特征匹配数量阈值均设为 100 的基础上,分别利用 LSD 算法和提出算法在 KITTI 数据集、隧道实测数据集、城市道路和测试场道路实测数据集内进行线特征提取与匹配,二者的线特征匹配结果如图 6 所示。由图 6 可知,在多种复杂环境中,提出算法的前后帧间线特征匹配精度和特征数均高于 LSD 算法。



图 6 传统 LSD 算法和提出算法线特征匹配结果。(a) LSD 算法; (b) 提出算法

Fig. 6 Line feature matching results of traditional LSD algorithm and proposed algorithm. (a) LSD algorithm; (b) proposed algorithm

3.2 KITTI 公共数据集定位结果与分析

本节采用 KITTI raw 数据集验证 GNSS 信号全程良好环境中各算法的定位精度。KITTI 数据集包括市区、村镇及高速公路等多种室外复杂环境,使用车载平台对双目图像 (Point Grey Flea2 相机采集, 1382 pixel × 512 pixel 单色, 10 frame/s)、IMU 和 GNSS 观测值进行采集。本文仅采用其单目图像信息

进行实验,并通过绝对轨迹误差 (APE) 指标对定位结果进行量化评估。

由图 7、图 8 可以看出,传统的基于点特征直接法的 VIO (Vins_Mono) 算法在室外复杂环境中由于动态环境影响,特征跟踪精度较低,且受累计误差影响较大。在 09_30_0027 数据集中, Vins_Mono 在初始的连续转弯的开阔环境路段已产生大范围数据漂移,后半

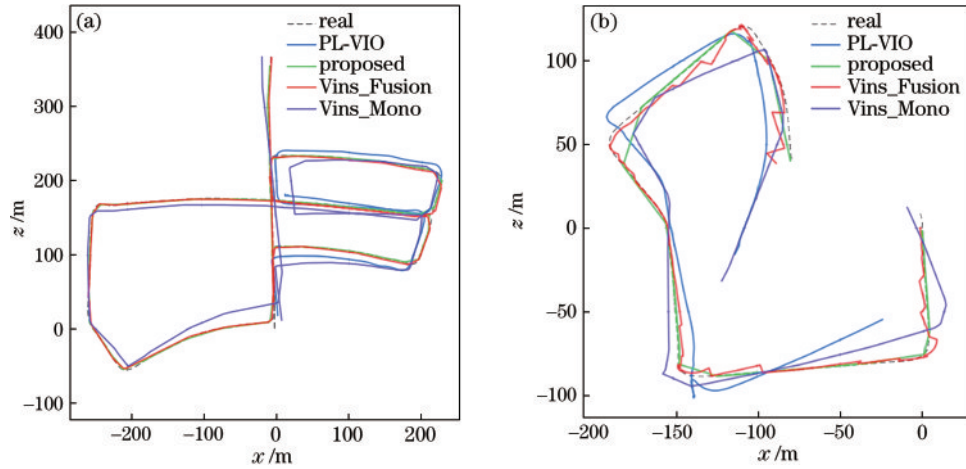


图 7 KITTI数据集实验轨迹拟合图。(a) 09_30_0018数据集;(b) 09_30_0027数据集

Fig. 7 Trajectory fitting curves of KITTI data set experiments. (a) 09_30_0018 data set; (b) 09_30_0027 data set

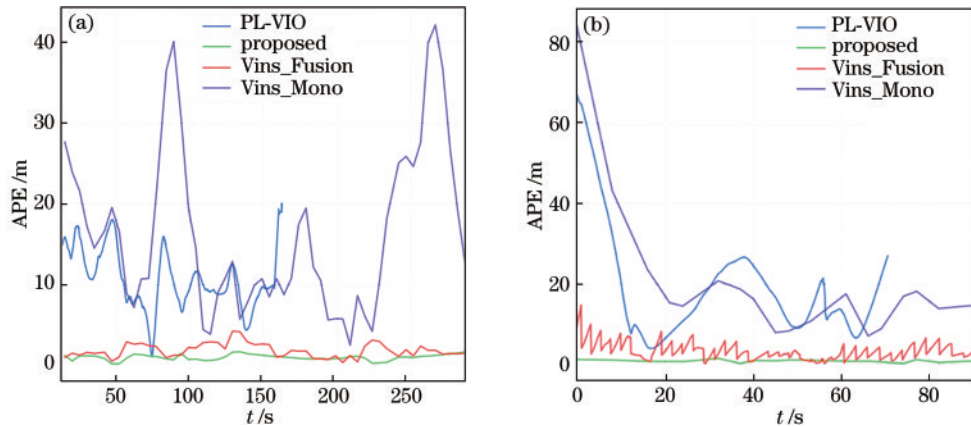


图 8 KITTI数据集实验绝对轨迹均方根误差(APE_RMSE)对比图。(a) 09_30_0018数据集;(b) 09_30_0027数据集

Fig. 8 APE root mean square error (APE_RMSE) comparison curves of KITTI data set experiments. (a) 09_30_0018 data set; (b) 09_30_0027 data set

程算法无法正常运行,基于点线特征的PL-VIO算法也同样失效。采用GNSS观测值辅助VIO定位的Vins_Fusion算法和提出算法由于GNSS全局观测值对局部位姿累计误差的抑制作用和不受连续转弯路段影响,APE曲线均保持在较低的数值范围内,且波动较为平缓,在定位精度和鲁棒性方面均优于纯VIO算法。进一步地,由表1可知,得益于基于点线特征结合的前端和卡尔曼滤波的后端的双重作用,提出算法较Vins_Fusion的绝对轨迹精度提升效果显著,在GNSS全程信号良好环境中展现出良好的定位性能。

表 1 各算法在KITTI数据集内APE_RMSE对比
Table. 1 Comparison of APE_RMSE of each algorithm in

Sequence	KITTI data set			Proposed
	Vins_Mono	PL-VIO	Vins_Fusion	
09_30_0018	20.46	11.18	5.37	1.03
09_30_0027	26.41	23.32	3.66	0.74
09_30_0033	22.86	20.39	7.25	2.54
09_30_0034	15.31	26.78	4.62	0.68

3.3 隧道实测数据及定位结果与分析

本节采用隧道实测数据集验证GNSS信号拒止环境中各算法的定位精度。由于行车途径的GNSS拒止环境实为动态大场景环境,且实际光照条件较为复杂,与传统室内静态环境不同。因此,未选用常用的室内静态公共数据集中的实验结果进行分析。实验真值由GNSS/INS/轮速计和高精度车道地图融合定位系统提供。部分数据集定位结果的APE曲线如图9所示。

由图9可以看出,在GNSS拒止仅依靠VIO进行局部位姿估计的环境中,各算法存在同源性。虽然各算法的APE波动趋势大致相同,但可以看出通过引入线特征对图像帧增加额外的特征约束对VIO的定位误差有一定改善作用。由表2可知,Tunnel 2数据集实验中,基于点线特征的VIO较基于点特征的VIO的精度提升约为28.41%~50.93%之间,其主要原因在于隧道内图像纹理匮乏,难以跟踪到足够数量的有效特征点。进一步地,在基于点线特征的VIO算法的纵向对比中,提出算法较PL-VIO的精度提升




图 9 隧道实测数据集实验 APE_RMSE 对比曲线图。(a) Tunnel 1 数据集; (b) Tunnel 2 数据集
Fig. 9 APE_RMSE comparison curves of tunnel data set experiments. (a) Tunnel 1 data set; (b) Tunnel 2 data set

表 2 各算法在隧道实测数据集内 APE_RMSE 对比
Table. 2 Comparison of APE_RMSE of each algorithm in tunnel data set unit: m

Sequence	Vins_Mono	PL-VIO	Vins_Fusion	Proposed
Tunnel 1	86.24	65.62	73.66	60.94
Tunnel 2	70.19	46.26	64.62	34.44
Tunnel 3	165.53	96.06	144.32	70.56

约为 7.13%~26.54% 之间,由于隧道内光照条件复杂导致车道线特征信息模糊,PL-VIO 采用的 LSD 算法易将长车道线特征分割后的多条线特征误判为无效匹配,而提出算法利用几何约束策略有效提取足够的车道线边缘信息,提升了 VIO 特征提取与跟踪的有效

性。综上所述,虽然本实验中 4 种仅利用 VIO 进行局部位姿估计的定位结果均未能满足实际定位需求,但相对于其他 4 种算法,提出算法的定位精度仍有一定提升。因此,对于行车途径的动态大场景室内环境,后续可考虑采用多传感器融合(如激光雷达等)对纯 VIO 定位结果进行校正,以满足实际行车定位需求。

3.4 城市道路实测数据及定位结果与分析

本节采用城市道路实测数据集验证间断性 GNSS 信号环境中各算法的定位精度。数据采集地点为北京顺沙路测试场和东南大学九龙湖校区外围道路,实验真值由实时动态(RTK)载波相位差分定位结果提供。数据集定位结果的轨迹拟合图和 APE 曲线如图 10~11 所示。

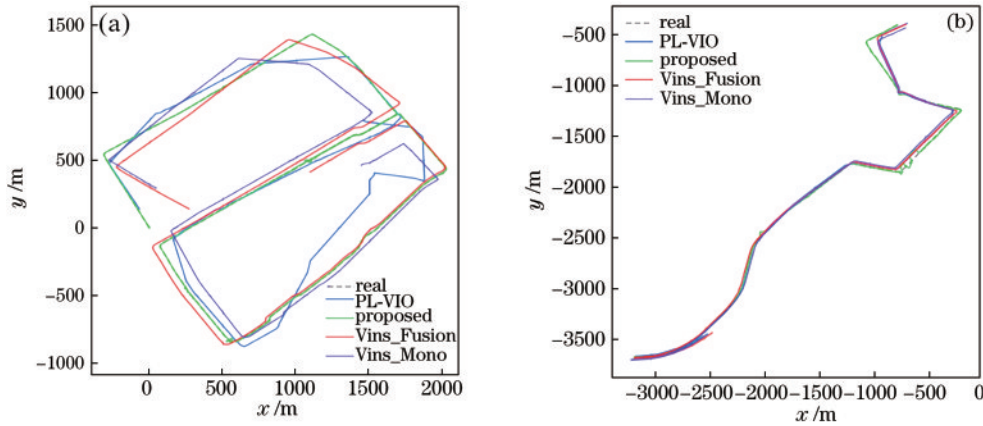


图 10 城市道路实测数据集实验轨迹拟合图。(a) 城市道路数据集; (b) 测试场道路数据集
Fig. 10 Trajectory fitting curves of urban road data set experiment. (a) Urban road data set; (b) road of test field data set

根据文献[18]中提出的实际环境中 GNSS 信号拒止占比,本实验将部分经 SPP 解算后得到的 GNSS 观测值随机剔除,城市道路数据集无 GNSS 信号区域为 (850 s, 900 s), (1300 s, 1350 s), (2000 s, 2050 s), 测试场数据集无 GNSS 信号区域为 (200 s, 240 s), (400 s, 440 s), (660 s, 700 s)。结合图 10、图 11 可知,GNSS 观测值对 VIO 累计误差起到较好的抑制作用,在 GNSS 信号间断时间段,算法也可为纯 VIO 位姿估计

提供精度较高的初始值,有效约束了累计漂移。由表 3 可知,黄昏时采集的城市道路数据集因有效视觉信息匮乏导致 APE_RMSE 较大,而 GNSS 信号不受环境光照条件影响,辅助 VIO 进行连续定位的精度提升显著。测试场路段在 (180 s, 290 s) 路段为连续环形转弯路段,由于转弯时提取的有效特征点数量不足, VIO 跟踪丢失情况较为显著,但 GNSS 信号恢复后对更新的位姿估计值进行了全局坐标系中的校准,抑制




图 11 城市道路实测数据集实验 APE_RMSE 对比图。(a) 城市道路数据集;(b) 测试场道路数据集

Fig. 11 APE_RMSE comparison curves of urban road data set experiment. (a) Urban road data set; (b) road of test field data set

表 3 各算法在城市道路实测数据集内定位性能对比

Table 3 Positioning performance comparison of APE_RMSE of each algorithm in urban road data set

	Urban road		Road of test field	
	APE_RMSE /m	Completeness /%	APE_RMSE /m	Completeness /%
SPP	—	92.86	—	84.00
Vins_Mono	206.73	100.00	98.19	100.00
PL-VIO	151.42	100.00	82.58	100.00
Vins_Fusion	99.90	100.00	63.09	100.00
Proposed	3.10	100.00	14.72	100.00

了纯 VIO 定位在(250 s, 300 s)内的下一个 APE 峰值产生。与同样利用 GNSS 信号辅助 VIO 的 Vins_Fusion 相比,提出算法的抑制作用更为显著,全程 APE_RMSE 约为 14.72 m。

3.5 实时性分析

为验证提出算法与其他基于点线特征的 VIO 算法的实时性差异,本节选取城市道路数据集实验中 PL-VIO 和提出算法涉及点线特征的几个环节的耗时进行对比,对比结果如表 4 所示。可以看出提出算法的线特征匹配与跟踪环节运行时间少于 PL-VIO,约为 27.219 ms,而 PL-VIO 耗时约为 31.376 ms。此外,其线特征剔除和边缘化环节耗时虽在整体算法流程中占比较低,但也均略低于 PL-VIO。究其原因为由于基于几何约束策略的线特征匹配对行车捕获的图像信息前后帧间的线特征匹配精度有一定提升,误判为无效的线特征数量降低。虽较仅使用点特征的 VIO 算

法耗时成本增加,但与同类基于点线特征的算法相比,仍具有较好的实时性。

4 结 论

针对传统 VIO 在室外复杂环境因弱纹理环境导致的提取有效特征数目不足的问题,设计了一种基于点线特征结合的 VIO 算法,并提出一种基于几何约束的最小化策略,对提取到的线特征进行前后帧间约束匹配,从而提升车辆行驶时捕获的图像信息中线特征的匹配精度和数量,降低线特征误匹配率。该算法提升了 VIO 算法在室外复杂环境中定位稳健性和连续定位能力。此外,搭建了一个 VIO/GNSS 松耦合模型,利用 GNSS 全局观测值对大型室外场景中 VIO 姿态估计的累计误差进行抑制,对 VIO 在复杂场景中的鲁棒性和实时定位精度起到一定积极作用。

实验结果表明,在 GNSS 信号全程良好/拒止/间断的室外复杂环境中,与几种同类算法相比,提出算法在特征提取数量、定位精度、连续性和鲁棒性方面均具有较大优势。实时性方面,虽然相较于仅使用点特征的 VIO 算法的耗时增加,但与同类基于点线特征的算法相比,时间效率略有提升,仍然可以满足大型室外环境中行车定位的实时性需求。

参 考 文 献

[1] Gong Z, Liu P L, Wen F, et al. Graph-based adaptive fusion of GNSS and VIO under intermittent GNSS-

表 4 提出算法与 PL-VIO 算法实时性比较

Table. 4 Comparison of real-time performance of proposed algorithm with PL-VIO algorithm

Operation	PL-VIO / ms	Proposed / ms
Point feature extraction and tracking	7.860	6.011
Line feature extraction and tracking	31.376	27.219
Line feature elimination	0.027	0.009
Marginalization	1.326	1.192

- degraded environment[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 20192183.
- [2] 钱琦, 白庭铭, 闭云峰, 等. 基于点线特征的单目同步定位与建图初始化方法[J]. *光学学报*, 2021, 41(12): 1215002.
- Qian Q, Bai T M, Bi Y F, et al. Monocular simultaneous localization and mapping initialization method based on point and line features[J]. *Acta Optica Sinica*, 2021, 41(12): 1215002.
- [3] Mur-Artal R, Tardós J D. ORB-SLAM2: an open-source SLAM system for monocular, stereo, and RGB-D cameras[J]. *IEEE Transactions on Robotics*, 2017, 33(5): 1255-1262.
- [4] Zheng F, Tsai G, Zhang Z, et al. Trifo-VIO: robust and efficient stereo visual inertial odometry using points and lines[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 1-5, 2018, Madrid, Spain. New York: IEEE Press, 2018: 3686-3693.
- [5] Klein G, Murray D. Parallel tracking and mapping for small AR workspaces[C]//2007 6th IEEE and ACM International Symposium on Mixed and Augmented Reality, November 13-16, 2007, Nara, Japan. New York: IEEE Press, 2007: 225-234.
- [6] 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.
- [7] von Stumberg L, Usenko V, Cremers D. Direct sparse visual-inertial odometry using dynamic marginalization [C]//2018 IEEE International Conference on Robotics and Automation, May 21-25, 2018, Brisbane, QLD, Australia. New York: IEEE Press, 2018: 2510-2517.
- [8] Engel J, Schöps T, Cremers D. LSD-SLAM: large-scale direct monocular SLAM[M]//Fleet D, Pajdla T, Schiele B, et al. *Computer vision-ECCV 2014. Lecture notes in computer science*. Cham: Springer, 2014, 8690: 834-849.
- [9] 李涛, 关棒磊, 张家铭, 等. 基于点线特征结合的单目相对位姿测量方法[J]. *激光与光电子学进展*, 2020, 57(8): 081102.
- Li T, Guan B L, Zhang J M, et al. Relative pose measurement method for monocular cameras by combining the point and line features[J]. *Laser & Optoelectronics Progress*, 2020, 57(8): 081102.
- [10] 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.
- [11] Wen H Y, Tian J D, Li D. PLS-VIO: stereo vision-inertial odometry based on point and line features[C]//2020 International Conference on High Performance Big Data and Intelligent Systems (HPBD&IS), May 23, 2020, Shenzhen, China. New York: IEEE Press, 2020: 19732742.
- [12] Fu Q, Wang J L, Yu H S, et al. PL-VINS: real-time monocular visual-inertial SLAM with point and line[EB/OL]. (2020-09-16)[2021-03-02]. <https://arxiv.org/abs/2009.07462>.
- [13] 卢俊鑫, 方志军, 陈婕妤, 等. 点线特征结合的 RGB-D 视觉里程计[J]. *光学学报*, 2021, 41(4): 0415001.
- Lu J X, Fang Z J, Chen J Y, et al. RGB-D visual odometry combined with points and lines[J]. *Acta Optica Sinica*, 2021, 41(4): 0415001.
- [14] Boucher C, Noyer J C. A hybrid particle approach for GNSS applications with partial GPS outages[J]. *IEEE Transactions on Instrumentation and Measurement*, 2010, 59(3): 498-505.
- [15] Vu A, Ramanandan A, Chen A N, et al. Real-time computer vision/DGPS-aided inertial navigation system for lane-level vehicle navigation[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2012, 13(2): 899-913.
- [16] Sünderhau N, Protzel P. Towards robust graphical models for GNSS-based localization in urban environments [C]//International Multi-Conference on Systems, Signals & Devices, March 20-23, 2012, Chemnitz, Germany. New York: IEEE Press, 2012: 12726756.
- [17] Cao S Z, Lu X Y, Shen S J. GVINS: tightly coupled GNSS-visual-inertial fusion for smooth and consistent state estimation[J]. *IEEE Transactions on Robotics*, 2022, 2: 1-18.
- [18] Fernandes L A F, Oliveira M M. Real-time line detection through an improved Hough transform voting scheme[J]. *Pattern Recognition*, 2008, 41(1): 299-314.
- [19] Nieto M, Cuevas C, Salgado L, et al. Line segment detection using weighted mean shift procedures on a 2D slice sampling strategy[J]. *Pattern Analysis and Applications*, 2011, 14(2): 149-163.
- [20] Akinlar C, Topal C. EDLines: a real-time line segment detector with a false detection control[J]. *Pattern Recognition Letters*, 2011, 32(13): 1633-1642.
- [21] Geiger A, Lenz P, Stiller C, et al. Vision meets robotics: the KITTI dataset[J]. *The International Journal of Robotics Research*, 2013, 32(11): 1231-1237.