

# 基于多传感器融合的无人车定位方法

陈旭升,代勇,温承超,秦冠一,周智晨,吴佳欣

(沈阳理工大学 自动化与电气工程学院,沈阳 110159)

**摘要:** 无人车单一传感器同步定位与地图构建(simultaneous localization and mapping, SLAM)算法鲁棒性较差,现有多传感器融合方案则较少考虑车辆运动约束,导致横向定位漂移。为此,提出一种基于ORB-SLAM的视觉-惯性-车轮紧耦合优化方法,将三者约束统一纳入后端的捆集优化(bundle adjustment, BA)。首先给出视觉里程计、惯性测量单元(inertial measurement unit, IMU)和基于阿克曼车辆模型的车轮里程计残差模型,然后建立基于ORB-SLAM的单目视觉-惯性-车轮融合的SLAM系统优化框架。在KAIST数据集和实际校园场景下的实验结果表明,与其他常用SLAM方法相比,本文改进算法有效减少了误差累积,定位与地图构建结果更稳健且精确。

**关键词:** 同步定位与地图构建;无人车;视觉-惯性-车轮定位技术;多传感器融合

中图分类号: TP249

文献标志码: A DOI:10.3969/j.issn.1003-1251.2025.02.006

## Localization Method for Autonomous Vehicles Based on Multi-sensor Fusion

CHEN Xusheng, DAI Yong, WEN Chengchao, QIN Guanyi, ZHOU Zhichen, WU Jiabin

(Shenyang Ligong University, Shenyang 110159, China)

**Abstract:** The robustness of single-sensor simultaneous localization and mapping (SLAM) algorithms for autonomous vehicles is relatively poor, and existing multi-sensor fusion approaches often overlook vehicle motion constraints, leading to lateral localization drift. To address this issue, a tightly-coupled optimization method based on ORB-SLAM is proposed, integrating visual odometry, inertial measurement unit (IMU), and wheel odometry constraints into the back-end bundle adjustment (BA). First, residual models for visual odometry, IMU and wheel odometry based on Ackermann vehicle model are introduced. Then, an optimization framework for a monocular visual-inertial-wheel SLAM system based on ORB-SLAM is established. Experimental results on the KAIST dataset and in real campus scenarios demonstrate that, compared to other common SLAM methods, the proposed algorithm effectively reduces error accumulation, providing more robust and accurate localization and mapping results.

**Key words:** simultaneous localization and mapping; autonomous vehicle; visual-inertial-wheel odometry technology; multi-sensor fusion

同步定位与地图构建(simultaneous localization and mapping, SLAM)<sup>[1]</sup>是一种实时定位技

术,其利用传感器数据估计位置并在未知环境中构建地图,为自动驾驶车辆提供关键的定位与导

航支持。纯视觉 SLAM<sup>[2]</sup>使用相机作为单一传感器,不仅成本低、安装简便,且可捕捉丰富的语义信息,在无人机或低成本自动驾驶车辆中应用较多<sup>[3]</sup>。然而,在光照变化、遮挡和纹理缺乏等复杂环境中,纯视觉 SLAM 易出现特征提取失败,导致系统不稳定或位姿估计错误<sup>[4]</sup>。

为解决上述纯视觉 SLAM 存在的问题,近年来研究人员提出了多种多传感器融合方案<sup>[5]</sup>。文献[6]提出了一种多传感器自适应融合 SLAM 方法,通过采用聚类分割、视觉增强算法处理激光雷达(LiDAR)数据中的低照度图像,以及进行多源数据联合非线性优化,解决了当前方法在复杂环境下存在的退化和精度不足问题,实现了 SLAM 连续可用、精确可靠。文献[7]提出了一种具有运动学约束的视觉-惯性里程计(visual-inertial odometry, VIO),其集成了独立于车轮编码器的速度控制运动模型,并在线校准模型参数以进行状态估计,提高了 VIO 估计的准确性和稳定性。文献[8]提出了一种鲁棒性较好的视觉-深度-惯性-车轮里程计,将 RGB-D 相机、惯性测量单元(inertial measurement unit, IMU)和车轮里程计集成在一个紧密耦合的优化框架中,实现了移动机器人在室内和室外场景中的精确定位。文献[9]提出了一种单目视觉-惯性-车轮里程计,针对低成本 IMU 中大偏差所导致的退化情况,在扩展卡尔曼滤波框架下重新设计了视觉惯性里程计系统模型,可在全球导航卫星系统信号不可用的情况下,实现城市环境中地面车辆的精确定位。

上述研究为多传感器融合 SLAM 提供了有效的方法,提高了定位和地图构建的精度。现有研究中的融合多将视觉 SLAM 与 IMU 或 LiDAR 传感器紧密结合,紧密耦合滤波解决方案以 MSCKF<sup>[10]</sup>和 ROVINS<sup>[11]</sup>为代表,紧密耦合优化方法以 VINS-Mono<sup>[12]</sup>和 ORB-SLAM3<sup>[13]</sup>等算法为代表。尽管上述方法取得了一定进展,但仍存在如下问题:

1) 复杂的模型构建需要高性能硬件解决系统中的数据同步、对齐和融合;

2) 整个系统受到车辆自身约束,但目前研究中尚未充分考虑这些限制。

为解决上述问题,本文提出一种多传感器 SLAM 系统,该系统将 IMU、车轮速度传感器和视觉信息数据相结合,并引入车辆模型约束。首先推导视觉里程计、IMU 及基于阿克曼车辆模型的车轮里程计残差计算式,并提出一种视觉-惯性

- 车轮捆集优化(bundle adjustment, BA)方法用于位姿优化;然后设计一种面向自动驾驶汽车室外环境的多传感器 SLAM 系统,以期适应长期和大规模的运行环境,满足定位需求。

## 1 残差计算方法

### 1.1 视觉里程计残差

图 1 所示为单目投影误差图。图中: $P$  表示空间点, $P = [x_w, y_w, z_w]^T$ ;  $R$  和  $p$  分别表示不同坐标系间转换的旋转矩阵和平移向量;其余变量说明详见下文。




图 1 单目投影误差图

Fig. 1 Monocular reprojection error diagram

基于刚体运动关系,空间点  $P$  在相机坐标系中第  $j$  时刻图像的测量坐标  $\hat{P}_j^c$  计算如式(1)所示。

$$\hat{P}_j^c = R_c^c(R_{w_j}^b(R_{b_i}^w(R_c^c \frac{1}{\lambda_p} \bar{P}_i^c + p_c^b) + p_{b_i}^w + p_{w_j}^b) + p_c^b) \quad (1)$$

式中: $R_c^c$  和  $p_c^c$  分别表示从 IMU 坐标系转换到相机坐标系的旋转矩阵和平移向量; $R_c^b$  和  $p_c^b$  分别表示从相机坐标系转换到 IMU 坐标系的旋转矩阵和平移向量; $R_{w_j}^b$  和  $p_{w_j}^b$  分别表示第  $j$  时刻图像由世界坐标系转换到 IMU 坐标系的旋转矩阵和平移向量; $R_{b_i}^w$  和  $p_{b_i}^w$  分别表示第  $i$  时刻图像由 IMU 坐标系转换到世界坐标系的旋转矩阵和平移向量; $\bar{P}_i^c$  表示在归一化图像平面上第  $i$  时刻图像的观测值; $\lambda_p$  表示空间点  $P$  的逆深度。则空间点  $P$  在第  $j$  时刻图像的归一化平面坐标  $\hat{P}_j^c$  为

$$\hat{P}_j^c = \frac{\hat{P}_j^c}{[\hat{P}_j^c]_s} \quad (2)$$

式中 $[\hat{P}_j^c]_s$  表示空间点  $P$  在第  $j$  时刻图像中的深度。

视觉里程计的约束残差  $\gamma_{\text{camera}}(\hat{z}_{c,k}^{c,k+1}, \mathcal{X})$  计算式为

$$\gamma_{\text{camera}}(\hat{z}_{c,k}^{c,k+1}, \mathcal{X}) = [\hat{P}_k^c - \bar{P}_k^c] \quad (3)$$

式中:角标  $k$  表示任一  $k$  时刻; $\hat{z}_{b,k}^{b,k+1}$  为相机坐标系下  $k$  到  $k+1$  时刻的观测变量; $\chi$  为状态变量。

## 1.2 IMU 残差

随着姿态更新,IMU 测量值将重新传递并进行积分计算。为避免冗余计算,进行 IMU 预积分操作,将要优化的变量进行分离。假设 IMU 偏差已知,将 IMU 模型应用于任一  $k$  时刻,空间点  $P$  从世界坐标系转换为 IMU 坐标系,相关表达式如式(4)~(6)所示。

$$\mathbf{R}_{w k}^b \mathbf{P}_{w k+1} = \mathbf{R}_{w k}^b (\mathbf{P}_{w k} + \mathbf{V}_{w k} \cdot \Delta t - \frac{1}{2} \mathbf{g}_w \cdot \Delta t^2) + \boldsymbol{\alpha}_{b,k}^{b,k+1} \quad (4)$$

$$\mathbf{R}_{w k}^b \mathbf{V}_{w k+1} = \mathbf{R}_{w k}^b (\mathbf{V}_{w k} - \mathbf{g}_w \cdot \Delta t) + \boldsymbol{\beta}_{b,k}^{b,k+1} \quad (5)$$

$$\mathbf{q}_{w k}^b \otimes \mathbf{q}_{w k+1}^b = \boldsymbol{\gamma}_{b,k}^{b,k+1} \quad (6)$$

其中

$$\boldsymbol{\alpha}_{b,k}^{b,k+1} = \iint_{t \in [k,k+1]} [\mathbf{R}_{b,t}^{b,k} (\hat{\mathbf{a}}_{b,t} - \mathbf{b}_{a,t} - \mathbf{n}_a)] dt^2 \quad (7)$$

$$\boldsymbol{\beta}_{b,k}^{b,k+1} = \int_{t \in [k,k+1]} [\mathbf{R}_{b,t}^{b,k} (\hat{\mathbf{a}}_{b,t} - \mathbf{b}_{a,t} - \mathbf{n}_a)] dt \quad (8)$$

$$\boldsymbol{\gamma}_{b,k}^{b,k+1} = \frac{1}{2} \int_{t \in [k,k+1]} [\Omega(\hat{\boldsymbol{\omega}}_{b,t} - \mathbf{b}_{\omega,t} - \mathbf{n}_{\omega}) \cdot \boldsymbol{\gamma}_{b,t}^{b,k}] dt \quad (9)$$

式中: $\mathbf{P}_{w k}$  和  $\mathbf{V}_{w k}$  分别为  $k$  时刻世界坐标系下的位姿向量和速度向量; $\Delta t$  为  $k$  时刻与  $k+1$  时刻的时间间隔; $\mathbf{g}_w$  表示世界坐标系中的重力加速度; $\mathbf{q}_{w k}^b$  为  $k$  时刻世界坐标系转换到 IMU 坐标系的旋转矩阵四元数表示形式; $\otimes$  表示四元数间的乘法运算; $\mathbf{R}_{b,t}^{b,k}$  为 IMU 坐标系下  $t$  到  $k$  时刻的旋转矩阵; $\hat{\mathbf{a}}_{b,t}$  和  $\mathbf{b}_{a,t}$  表示 IMU 坐标系中  $t$  时刻加速度的估计值和偏差; $\hat{\boldsymbol{\omega}}_{b,t}$  和  $\mathbf{b}_{\omega,t}$  表示 IMU 坐标系中  $t$  时刻角速度的估计值和偏差; $\mathbf{n}_a$  和  $\mathbf{n}_{\omega}$  代表高斯白噪声; $\boldsymbol{\gamma}_{b,t}^{b,k}$  为单位四元数; $\Omega$  为矩阵函数, $\Omega(\mathbf{w}) =$

$$\begin{bmatrix} -\mathbf{w}^\wedge & \mathbf{w} \\ -\mathbf{w}^\top & \mathbf{0} \end{bmatrix}, \text{其中 } \mathbf{w} \text{ 表示函数的自变量。}$$

因此,IMU 的约束残差  $\boldsymbol{\gamma}_{\text{imu}}(\hat{z}_{b,k}^{b,k+1}, \chi)$  计算式为

$$\boldsymbol{\gamma}_{\text{imu}}(\hat{z}_{b,k}^{b,k+1}, \chi) = \begin{bmatrix} \Delta \boldsymbol{\alpha}_{b,k}^{b,k+1} \\ \Delta \boldsymbol{\beta}_{b,k}^{b,k+1} \\ \Delta \boldsymbol{\theta}_{b,k}^{b,k+1} \\ \Delta \mathbf{b}_a \\ \Delta \mathbf{b}_\omega \end{bmatrix} =$$

$$\begin{bmatrix} \mathbf{R}_{w k}^b (\mathbf{P}_{w k+1} - \mathbf{P}_{w k} - \mathbf{V}_{w k} \cdot \Delta t + \frac{1}{2} \mathbf{g}_w \cdot \Delta t^2) - \boldsymbol{\alpha}_{b,k}^{b,k+1} \\ \mathbf{R}_{w k}^b (\mathbf{V}_{w k+1} - \mathbf{V}_{w k} + \mathbf{g}_w \cdot \Delta t) - \boldsymbol{\beta}_{b,k}^{b,k+1} \\ 2[\mathbf{q}_{w k}^b \otimes \mathbf{q}_{w k+1}^b \otimes \boldsymbol{\gamma}_{b,k}^{b,k+1}] \\ \mathbf{b}_{a,k+1} - \mathbf{b}_{a,k} \\ \mathbf{b}_{\omega,k+1} - \mathbf{b}_{\omega,k} \end{bmatrix} \quad (10)$$

式中: $\hat{z}_{b,k}^{b,k+1}$  为 IMU 坐标系下  $k$  到  $k+1$  时刻的观测变量; $\Delta \boldsymbol{\alpha}_{b,k}^{b,k+1}$  为位姿残差; $\Delta \boldsymbol{\beta}_{b,k}^{b,k+1}$  为速度残差; $\Delta \boldsymbol{\theta}_{b,k}^{b,k+1}$  为旋转残差; $\Delta \mathbf{b}_a$  为加速度残差; $\Delta \mathbf{b}_\omega$  为角速度残差。

## 1.3 车轮里程计残差

采用阿克曼模型<sup>[14]</sup>描述车辆转向运动,如图2所示。




图2 车辆运动学模型

Fig. 2 Vehicle kinematics model

根据控制输入  $\mathbf{u} = [V, \omega]^\top$ , 可得到车辆的运动学方程为

$$\begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{\theta} \end{bmatrix} = \begin{bmatrix} \cos \theta \\ \sin \theta \\ 0 \end{bmatrix} \cdot V + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \cdot \omega \quad (11)$$

式中: $\dot{x}$  表示横向车辆速度; $\dot{y}$  表示纵向车辆速度; $\dot{\theta}$  表示车辆角速度; $\theta$  表示偏航角; $V$  表示车辆的瞬心速度; $\omega$  表示横摆角速度。记  $k$  时刻车辆坐标系下的位姿为  $\mathbf{P}_{v,k} = [x_k, y_k, \theta_k]^\top$ , 则车辆在  $k+1$  时刻的位姿  $\mathbf{P}_{v,k+1}$  推算为

$$\mathbf{P}_{v,k+1} = \mathbf{P}_{v,k} + \int_{t \in [k,k+1]} \dot{\mathbf{P}}_{v,t} dt \quad (12)$$

式中  $\dot{\mathbf{P}}_{v,t} = [\dot{x}_k, \dot{y}_k, \dot{\theta}_k]^\top$ 。

将  $\mathbf{P}_{v,k+1}$  从车辆坐标系转换到世界坐标系,

可得到  $k + 1$  时刻世界坐标系中的测量平移向量  $\mathbf{p}_{v,k+1}^w$  为

$$\mathbf{p}_{v,k+1}^w = \mathbf{p}_{v,k}^w + \mathbf{R}_{b,k}^w (\mathbf{R}_{v,k}^b \int_{t \in [k,k+1]} \dot{\mathbf{p}}_{v,t} dt + \mathbf{p}_{v,k}^b) + \mathbf{p}_{b,k}^w \quad (13)$$

式中  $\mathbf{R}_{v,k}^b$  和  $\mathbf{p}_{v,k}^b$  分别为  $k$  时刻车辆坐标系转换到 IMU 坐标系的旋转矩阵和平移向量。

系统的状态平移向量  $\mathbf{p}_{v,k+1}^w$  可表示为

$$\mathbf{p}_{v,k+1}^w = \mathbf{R}_{v,k}^v \mathbf{p}_{v,k}^w - \mathbf{p}_{v,k}^b \quad (14)$$

因此,车轮里程计的平移约束残差  $\gamma_{v,k+1}^p$  为

$$\gamma_{v,k+1}^p = \mathbf{p}_{v,k+1}^w - \mathbf{p}_{v,k+1}^w \quad (15)$$

通过罗德里格斯公式<sup>[15]</sup>可将  $k$  到  $k + 1$  时刻的偏航角转换为相应的旋转矩阵  $\mathbf{R}_{v,k}^{v,k+1}$ , 表达式为

$$\mathbf{R}_{v,k}^{v,k+1} = \mathbf{I}_{3 \times 3} + (\sin \|\theta_{v,k}^{v,k+1}\|) \mathbf{n}_v^\wedge + (1 - \cos \|\theta_{v,k}^{v,k+1}\|) \mathbf{n}_v \mathbf{n}_v^T \quad (16)$$

式中:  $\mathbf{I}_{3 \times 3}$  为三阶单位矩阵;  $\theta_{v,k}^{v,k+1}$  为  $k$  到  $k + 1$  时刻的偏航角;  $\mathbf{n}_v$  表示车辆在相邻测量时间步所处平面的法向量, 可通过对应于第  $k - 2$ 、 $k - 1$  和  $k$  时刻的平移向量求得。

将获得的旋转矩阵  $\mathbf{R}_{v,k}^{v,k+1}$  转换为世界坐标系下的四元数, 可得到  $k + 1$  时刻世界坐标系中测量旋转矩阵  $\mathbf{q}_{v,k+1}^w$  为

$$\mathbf{q}_{v,k+1}^w = \mathbf{q}_{v,k}^w \otimes \mathbf{q}_{v,k}^{v,k+1} \quad (17)$$

式中  $\mathbf{q}_{v,k}^{v,k+1}$  为车辆坐标系下  $k$  到  $k + 1$  时刻的旋转矩阵。

系统的状态旋转矩阵  $\mathbf{q}_{v,k+1}^w$  可表示为

$$\mathbf{q}_{v,k+1}^w = \mathbf{q}_{b,k+1}^w \otimes \mathbf{q}_{v,k+1}^b \quad (18)$$

式中:  $\mathbf{q}_{v,k+1}^b$  为车辆坐标系转换到 IMU 坐标系的旋转矩阵;  $\mathbf{q}_{b,k+1}^w$  为 IMU 坐标系转换到世界坐标系的旋转矩阵。

因此, 车轮里程计的旋转约束残差  $\gamma_{v,k+1}^d$  为

$$\gamma_{v,k+1}^d = 2[\mathbf{q}_{w,k+1}^v \otimes \mathbf{q}_{v,k+1}^w] \quad (19)$$

综上, 车轮里程计的约束残差  $\gamma_{\text{wheel}}(\hat{\mathbf{z}}_{v,k}^{v,k+1}, \boldsymbol{\chi})$  为

$$\gamma_{\text{wheel}}(\hat{\mathbf{z}}_{v,k}^{v,k+1}, \boldsymbol{\chi}) = \begin{bmatrix} \mathbf{p}_{v,k+1}^w - \mathbf{p}_{v,k+1}^w \\ 2[\mathbf{q}_{w,k+1}^v \otimes \mathbf{q}_{v,k+1}^w] \end{bmatrix} \quad (20)$$

式中  $\hat{\mathbf{z}}_{v,k}^{v,k+1}$  为车辆坐标系下  $k$  到  $k + 1$  时刻的观测变量。

## 2 视觉 - 惯性 - 车轮约束的 BA 优化方案

本文提出一种专用于自动驾驶设计的基于 ORB-SLAM 的视觉 - 惯性 - 车轮 SLAM 系统。将传统的 BA 优化替换为基于车辆模型的紧耦合视觉惯性约束的 BA 优化, 其完整的系统框架如图 3 所示, 包括跟踪、局部地图构建、闭环检测和地图融合等四个关键模块。

基于 BA 的视觉惯性里程计和轮式里程计的位姿估计优化方案如下:

- 1) 由摄像头等传感器收集图像数据, 提取特征点并执行 SLAM, 估计车辆的姿态;
- 2) IMU 集成了加速度计和陀螺仪等传感器, 提供车辆的线性加速度和角速度信息, 其可在短时间内提供高频率的姿态变化;
- 3) 车轮里程计通过监测车辆车轮的旋转估计车辆的运动, 包括行驶距离和方向变化;
- 4) BA 的非线性优化技术通过最小化视觉、IMU 和车轮里程计观测值和测量值之间的误差, 获得更准确的姿态估计, 实现在运动过程中调整车辆的姿态。

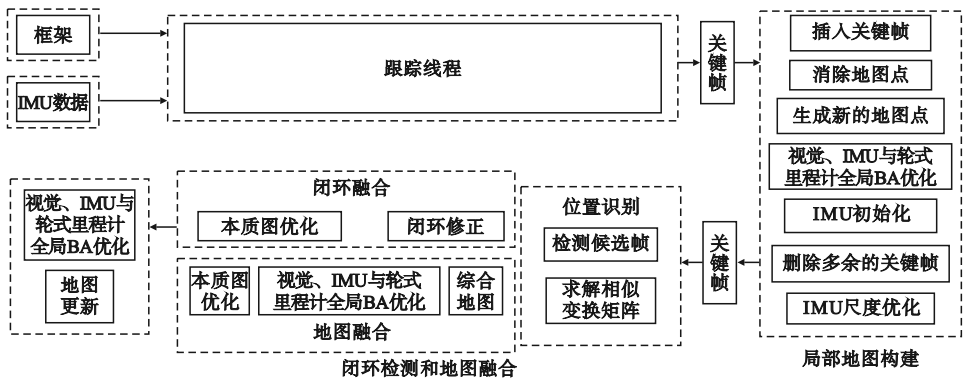


图 3 系统框架

Fig. 3 System framework

本文系统采用 VINS-Mono 系统<sup>[12]</sup>的解决方案, 实现视觉估计和 IMU 预积分之间的空间对

齐: 1) 估计陀螺仪零偏, 并同时使用求解的零偏进行预积分; 2) 求解各帧的速度、重力向量和尺度信

息,随后进行校正。

相机、IMU 和轮式里程计可能由于硬件使用时间戳不同及采样率为非整数倍而产生异步采样数据,本文通过外参标定求出延迟和插值的方法进行时间对齐。

状态变量  $\chi$  表示为

$$\chi = [X_0, X_1, \dots, X_N, X_c^b, X_v^b, \lambda_0, \lambda_1, \dots, \lambda_M] \quad (21)$$

式中:  $X_c^b = [p_c^b, q_c^b]$ ,  $X_v^b = [p_v^b, q_v^b]$ , 分别表示相机坐标系和车辆坐标系相对于 IMU 坐标系的外参矩阵,其中  $p_c^b$ 、 $q_c^b$  分别为相机坐标系转换到 IMU 坐标系的平移向量和旋转矩阵,  $p_v^b$ 、 $q_v^b$  分别为车辆坐标系转换到 IMU 坐标系的平移向量和旋转矩阵;  $X_n$  ( $n=1, 2, \dots, N$ ) 表示 IMU 坐标系转换到世界坐标系的平移向量、速度向量、旋转矩阵、加速度计偏置和陀螺仪偏置等构成的矩阵,  $N$  表示要

优化的关键帧数量;  $\lambda_m$  ( $m=1, 2, \dots, M$ ) 表示第  $m$  个特征第一次观测的逆深度,  $M$  表示要优化的特征数量。

通过最小化测量值的马氏距离平方和,构建最小二乘问题的目标函数为

$$\min [ \sum \gamma_{\text{camera}}(\hat{z}_{c,k}^{c,k+1}, \chi) + \sum \gamma_{\text{imu}}(\hat{z}_{b,k}^{b,k+1}, \chi) + \sum \gamma_{\text{wheel}}(\hat{z}_{v,k}^{v,k+1}, \chi) ] \quad (22)$$

采用 Ceres 库解决上述最小二乘问题,该库提供有效的数值优化工具,用于解决复杂的非线性最小二乘问题。通过优化更新所有状态变量,同时调整地图中的车辆姿态和地图点位置。BA 优化过程如图 4 所示,当当前帧和共视帧被添加为局部关键帧时进行局部 BA;当闭环检测结束时进行全局 BA。

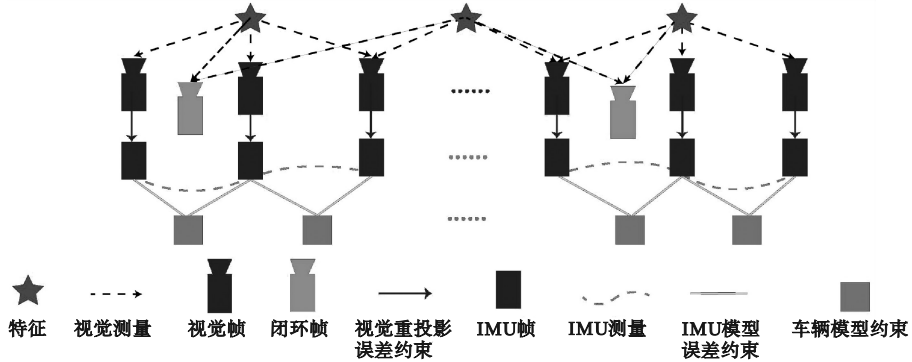


图 4 BA 优化示意图

Fig. 4 Diagram of BA optimization

### 3 实验分析

实验在搭载 Ubuntu 20.04 操作系统的嵌入式微处理器 NVIDIA RTX A500 上进行,该处理器配备 GA107S 处理器和 4 GB 的 GDDR6 内存。选择 C++11 为编程语言,并使用 GCCv4.8 编译器进行编译。硬件系统框架如图 5 所示。

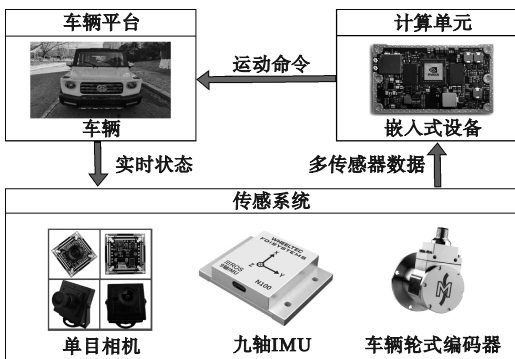


图 5 硬件系统框架

Fig. 5 Framework of the hardware system

### 3.1 数据集实验

本文对 KAIST 数据集中的城市序列 32 进行轨迹估计的比较分析,分别采用 ORB-SLAM3、VINS-Mono、VIWO<sup>[9]</sup> 和本文提出系统获得定位轨迹,比较结果如图 6 所示。

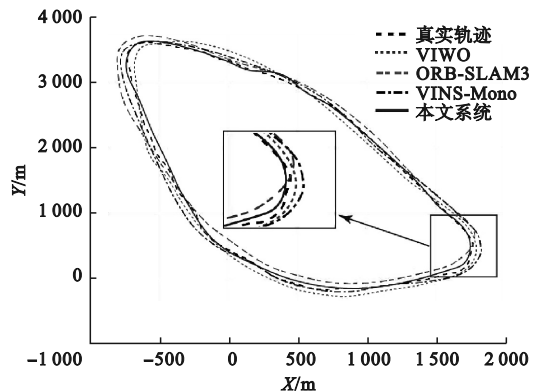



图 6 不同系统下 KAIST 序列 32 的定位轨迹比较

Fig. 6 Comparison of localization trajectory of KAIST sequence 32 in different systems


由图 6 可明显看出:本文系统估计的轨迹与地面真实轨迹高度一致,特别是尖锐转弯部分;VINS-Mono 和 VIWO 估计的轨迹与地面真实轨迹相对接近;ORB-SLAM3 估计的轨迹与真实轨迹偏差较大。

采用本文提出的系统进行轨迹估计,KAIST 数据集中序列 32 的绝对定位误差 (APE) 和绝对轨迹误差 (ATE) 分析结果如图 7 所示。图中:RMSE 表示均方根误差;Median 表示中值误差;Mean 表示均值误差;Std-dev 表示标准差误差。由图 7 可见:RMSE (APE) 约为 0.112,表明本文系统在提供准确、一致和可靠的绝对位置信息方面表现较优;RMSE (ATE) 约为 0.124,表明本文系统在轨迹估计方面具有很高的准确性。

为进一步证实本文系统的可靠性和准确性,对 KAIST 数据集中城市场景序列 20~30 进行深入定量分析,通过估计轨迹与相应地面真实轨迹之间的偏差程度,评估不同系统的性能,结果如表 1 所示。由表 1 可见,本文系统的 APE 和 ATE 值



(a) ATE分析



(b) APE分析

图 7 KAIST 序列 32 的 ATE 和 APE 分析

Fig. 7 ATE and APE analysis of KAIST sequence 32

均较低,约在 0.10 左右,相比于其他系统减小约 20%,说明本文系统稳定性和精确性均较好,可在复杂的城市环境中保持准确定位能力。

表 1 KAIST 城市场景序列 20~30 下不同系统的 APE 和 ATE 性能比较

Table 1 APE and ATE performances comparison for different systems of KAIST City scene sequence 20 to 30

序列号	ORB-SLAM3		VINS-Mono		VIWO		本文系统	
	APE	ATE	APE	ATE	APE	ATE	APE	ATE
20	0.647	0.768	0.195	0.154	0.142	0.136	0.102	0.104
21	0.458	0.484	0.139	0.125	0.120	0.121	0.103	0.102
22	0.341	0.348	0.215	0.148	0.128	0.132	0.128	0.107
23	0.554	0.484	0.139	0.114	0.210	0.195	0.119	0.096
24	0.469	0.443	0.248	0.214	0.167	0.142	0.132	0.095
25	0.484	0.347	0.428	0.317	0.151	0.163	0.128	0.096
26	0.698	0.547	0.335	0.248	0.144	0.146	0.098	0.068
27	0.735	0.687	0.287	0.214	0.157	0.149	0.103	0.089
28	0.471	0.414	0.115	0.105	0.142	0.138	0.100	0.091
29	0.357	0.358	0.224	0.168	0.128	0.136	0.093	0.054
30	0.478	0.424	0.147	0.141	0.154	0.140	0.102	0.073

### 3.2 真实校园环境实验

为确保实验的可行性和可靠性,使用一系列高性能低成本的传感器设备,包括上海宏世康新材料科技有限公司的单目相机、WHEELTEC 公司的九轴 IMU (兼容 ROS)、广州中海达的 RTK 和 IMU 集成导航系统 iNAVS, Michigan Scientific 公司的高分辨率轮编码器。为保证实验数据的准确

性,使用 iNAVS 提供的数值作为后续实验的地面真实值,传感器设备安装在宏博车辆上。

真实校园环境下不同系统生成的轨迹如图 8 所示。可以看出,与其他同类系统相比,本文系统估计的轨迹与 RTK 生成的真实轨迹更接近,且高度吻合,进一步证实本文系统在校园环境能够准确估计运动轨迹。




图8 真实校园环境不同系统的定位轨迹比较

Fig. 8 Comparison of localization trajectories of different systems in real campus environment

为进一步量化校园环境中估计轨迹的误差,采用本文系统进行10次实验,并取各实验数据的算术平均值,结果如图9和表2所示。可见,本文提出的SLAM系统始终表现出较低的APE和

表2 真实校园环境下不同系统的APE和ATE性能比较


Table 2 Performances comparison of APE and ATE for different systems in a real campus environment

误差类型	ORB-SLAM3		VINS-Mono		VIWO		本文系统	
	APE	ATE	APE	ATE	APE	ATE	APE	ATE
RMSE	1.320	1.212	1.147	1.068	0.235	0.254	0.116	0.094
Mean	1.412	1.352	1.258	1.084	0.239	0.225	0.093	0.090
Median	1.458	1.341	1.241	1.148	0.225	0.218	0.084	0.071
Std-dev	1.512	1.125	1.354	1.284	0.239	0.214	0.079	0.076


## 4 结论

提出了一种基于视觉-惯性-车轮融合的ORB-SLAM系统,该系统在KAIST数据集和真实校园环境下均展现了较好的定位性能,与纯视觉的ORB-SLAM2相比,该系统表现出更高的鲁棒性,在定位精度方面,其优于传统的视觉惯性SLAM系统(如ORB-SLAM3、VIWO和VINS-Mono)。本文通过紧密耦合的滤波和优化技术,实现了多传感器数据的有效融合,显著抑制了定位误差的累积,且在无需高性能处理器的情况下实现了高精度的定位与地图构建,具有较高的实用性。随着对精确可靠的自动驾驶定位技术要求不断提高,本文提出的系统在自动驾驶导航方面具有较大的应用潜力。

ATE值,表明其具有更高的定位精度。



(a) ATE分析



(b) APE分析

图9 真实校园环境下的ATE和APE分析  
Fig. 9 ATE and APE analysis in real campus environment

## 参考文献(References):

- [1] 杨娜,程磊. 基于高效回环检测的大场景下的SLAM算法[J]. 沈阳理工大学学报,2024,43(2):45-51.  
YANG N, CHENG L. SLAM algorithm in large scenes based on efficient loop detection[J]. Journal of Shenyang Ligong University, 2024, 43(2): 45-51. (in Chinese)
- [2] 高宏伟,于斌,武炎明. 视觉SLAM的空地协同导航方法研究[J]. 沈阳理工大学学报,2022,41(1):7-13.  
GAO H W, YU B, WU Y M. Research on air-ground cooperative navigation based on VSLAM[J]. Journal of Shenyang Ligong University, 2022, 41(1): 7-13. (in Chinese)
- [3] 王朋,郝伟龙,倪翠,等. 视觉SLAM方法综述[J]. 北京航空航天大学学报,2024,50(2):359-367.  
WANG P, HAO W L, NI C, et al. An overview of visual SLAM methods[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50(2): 359-367. (in Chinese)
- [4] 蔡英凤,陆子恒,李祎承,等. 基于多传感器融合的紧耦合SLAM系统[J]. 汽车工程,2022,44(3):350-361.  
CAI Y F, LU Z H, LI Y C, et al. Tightly coupled SLAM system based on multi-sensor fusion[J]. Automotive Engineering, 2022, 44(3): 350-361. (in Chinese)

(下转第47页)