DOI: 10.19650/j.cnki.cjsi.2413620

基于平面特征的地面机器人雷达-惯性里程计外参标定方法

任家卫,徐晓苏
(东南大学仪器科学与工程学院 南京 210096)

摘 要:准确可靠的传感器外参标定方法是雷达-惯性融合系统实现高精度定位与导航的关键,然而,现有的标定方法大多依赖于惯性传感器三轴激励的获取,当雷达和惯性传感器安装在运动受限的地面机器人上时,现有的标定方法性能下降甚至无法标定。为了解决这一问题,提出了一种基于雷达点云平面特征的地面机器人雷达-惯性里程计外参标定方法。该方法首先利用雷达点云中的平面特征建立残差,通过最小化雷达点到平面的距离迅速将外参收敛至较小的误差范围内。随后,基于八叉树结构,结合雷达点云的空间占用信息,进一步优化外参。最后利用地面分割算法将地面约束纳入标定过程,对平面运动时 Z 轴方向上无法约束的误差进行修正,从而获得完整的六自由度外参。实验结果表明,该方法在两组开源数据集上的标定精度显著优于其他算法,旋转角平均误差分别降低 43.73% 及 36.47%,位移平均误差分别降低了 76.33% 及 41.52%。在实车验证实验中,该方法在平地、崎岖不平的地形、狭窄的通道等各种场景中均成功完成标定,进一步验证了该方法在实际环境中的可靠性与鲁棒性。在定位精度分析实验中,以本研究标定结果为初参的 FAST-LIO2 算法的绝对轨迹均方根误差降低了 6.54% 左右,证明了该方法的实用性和准确性。

关键词: 雷达-惯性里程计;平面约束;地面机器人;标定;传感器融合
中图分类号: TH86 **文献标识码**: A **国家标准学科分类代码**: 420.60

Ground robot LiDAR-inertial odometry calibration based on plane constraint

Ren Jiawei, Xu Xiaosu
(*School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China*)

Abstract: Accurate and reliable sensor extrinsic calibration methods are crucial for high-precision localization and navigation in radar-inertial fusion systems. However, most existing calibration methods rely on the acquisition of triaxial excitation from inertial sensors, and their performance deteriorates or even fails when the radar and inertial sensors are installed on ground robots with restricted movement. To address this issue, a novel calibration method based on planar features in radar point clouds is proposed for radar-inertial odometry on ground robots. The method first constructs residuals using planar features in the radar point clouds and rapidly converges the extrinsic parameters to a smaller error range by minimizing the distance from radar points to the planes. Subsequently, it further optimizes the extrinsic parameters based on the octree structure, incorporating the spatial occupancy information of the radar point clouds. Finally, by integrating ground constraints through a ground segmentation algorithm, the method corrects the errors in the Z-axis direction that cannot be constrained during planar motion, thereby achieving complete 6-DOF (degrees of freedom) extrinsic parameters. Experimental results show that the proposed method significantly outperforms other algorithms in calibration accuracy on two open-source datasets, with average rotational angle errors reduced by 43.73% and 36.47%, and average translational errors reduced by 76.33% and 41.52%, respectively. In real-world vehicle validation experiments, the method successfully achieves calibration in various scenarios, including flat terrain, rugged terrain, and narrow passages, further demonstrating its reliability and robustness in practical environments. In localization accuracy analysis experiments, the absolute trajectory root mean square error of the FAST-LIO2 algorithm, initialized with the calibration results of this paper, is reduced by approximately 6.54%, evaluating the practicality and accuracy of the proposed method.
Keywords: LiDAR-inertial; plane constraint; ground robot; calibration; sensor fusion

收稿日期:2024-12-23 Received Date: 2024-12-23

0 引　　言

机器人通过传感器来实现对周围环境的感知、定位及导航,雷达与惯性测量单元的融合能够为其提供一个既稳健又精确的导航解决方案[1]。为了提高融合系统的有效性,准确的外参至关重要。外参标定指得到多个传感器坐标系之间的变换矩阵,确保来自不同传感器的数据使用同一坐标系衡量,如果外参标定不够准确,融合系统的整体性能将显著下降[2]。

近年来,许多学者对雷达与惯性传感器之间的外参标定进行了研究,也提出了许多外参标定的算法。Gentil 等[3]将雷达与惯性传感器标定表述为因子图优化问题,采用高斯进步回归对雷达与惯性传感器数据进行采样,但是离散因子图中只优化了某些特定时刻的状态,误差较高。Wang 等[4]通过联合优化即时定位与地图构建(simultaneous location and mapping,SLAM)系统中的时间偏移、相机和惯性传感器的状态以及特征点位置来实现标定,但需要相机作为额外的辅助传感器。Lyu 等[5-6]提出基于连续时间批量估计的雷达-惯性测量单元无目标标定方法(targetless calibration of LiDAR-imu system based on continuous-time batch estimation,Li-Calib),使用了基于 β 样条的连续时间轨迹公式来完成标定并且在基于可观测性感知标定方法(observability-aware extrinsic calibration of LiDAR-imu systems,OALi-Calib)中进行了扩展,为了解决退化情况加入了可观测性感知模块,但是该算法仅利用信息矩阵指出了不可观测的方向,未进行校正。Zhu 等[7]提出了鲁棒的实时激光雷达-惯性初始化方法(robust real-time LiDAR-inertial initialization,Li-Init)通过对齐角速度和加速度估计外参,但是需要传感器在所有轴上进行足够的运动才能获取准确的结果。Kim 等[2]提出了一种无目标标定方法(targetless ground robot LiDAR-imu extrinsic calibration method,GRIL-Calib)通过将改进的激光雷达里程计合并到迭代误差状态卡尔曼滤波器中,间接提高标定精度,但是该方法对地面平坦度要求过高,在崎岖地面、台阶或斜坡上运行时,算法的性能可能会显著下降。

除了上述传统优化方法,近年来基于深度学习的标定方法也取得了显著进展。这些方法利用深度学习框架,从图像或点云的像素特征出发完成标定,无需依赖特定特征或地标。文献[8]提出基于几何监督的外参校准方法(geometrically supervised extrinsic calibration using spatial transformer networks,CalibNet)通过最大化图像与点云的几何和光度一致性,使用 3D 空间变换器优化标定。文献[9]提出基于代价体积网络的激光雷达和相机自标定方法(LiDAR and camera self-calibration using cost volume network,LCCNet)借助成本体积层学习图像与点云的相关性完成标定。尽管这些基于深度学习的方法在标定精度上表现出色,但需要引入视觉传感器来辅助雷达与惯性传感器之间的外参标定。这使得它们在标定雷达和惯性传感器外参时的便捷性受到一定限制。

综上所述,尽管近年来众多学者在雷达与惯性传感器外参标定领域取得了显著进展,并提出了多种算法,但这些方法仍面临诸多挑战。此外这些算法通常需要两个传感器的三轴激励来激活所有自由度,更适用于集成了惯性元件和雷达传感器的手持设备,因为这种设备可以执行全方位的运动,但是对于运动受限于地面的机器人来说,无法获取充足的激励导致外参校准变得困难[2]。Yan 等[10]提出的多传感器标定工具箱(multi-sensor calibration toolbox for autonomous driving,Open-calib)针对自动驾驶车辆雷达到位姿传感器的标定问题提供了一定解决方案,但 Z 轴方向上的位移误差仍需人工选点后处理,效率较低。

为了解决上述问题,提出了一种基于平面特征的地面机器人雷达-惯性里程计外参标定方法。首先利用滑动窗口思想对多帧雷达点云中的表面特征建立约束,通过最小化雷达点到平面的距离来对雷达和惯性传感器进行外参标定,然后通过建立地面约束,将地平面残差纳入标定的非线性优化中,对地面机器人在平面运动时 Z 轴上无法约束的误差进行修正,使外参在旋转位移六自由度参数上都非常准确。该方法适用于平面机器人,不需要满足三轴激励运动,并且对环境设置要求低,在数据集和实际环境中证明了该方法的鲁棒性和准确性。

1 标定方法原理与框架

地面机器人通过行走 8 字形轨迹收集激光雷达和惯性传感器数据。然后通过数据处理模块获得雷达点云时间戳对应的惯性传感器位姿数据。在获得初步估计外参的情况下,利用位姿数据对雷达点云进行重构,生成世界坐标系下的全局点云图 M。

$$M = \sum \boldsymbol{T}_I^W(\boldsymbol{R}_L^I P_L + \boldsymbol{t}_L^I) \tag{1}$$

式中:M 为世界坐标系下的全局三维点云图;P_L 为雷达坐标系下的点云;$\boldsymbol{t}_L^I$ 为雷达到惯性传感器的三维平移向量;$\boldsymbol{R}_L^I$ 为雷达到惯性传感器的旋转矩阵;$\boldsymbol{T}_I^W$ 为惯性传感器位姿矩阵。优化目标是找到一个从雷达到惯性传感器的变换矩阵,使得生成的全局点云图 M 质量最佳,算法框架如图 1 所示。

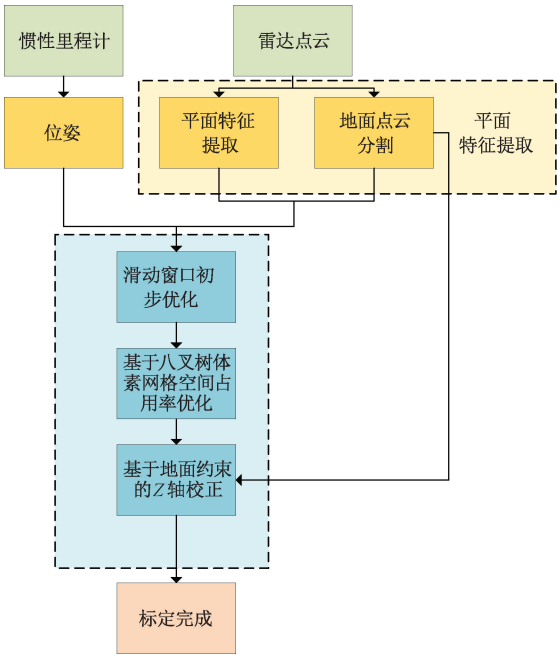

图 1 算法框架流程

Fig. 1 Algorithm framework

该方法包括两个主要阶段:雷达点云预处理和优化。第 1 阶段是雷达点云预处理,主要执行的任务包括:

1) 对雷达点云进行地面分割,提取地面点,同时估计雷达传感器的安装高度以及拟合地面法向量并估计激光雷达与地面坐标系的相对方向。

2) 通过建立自适应体素化网格提取雷达点云中的平面特征,拟合平面的法向量。

第 2 阶段为优化,通过利用第 1 阶段提取的特征来校准外参。在这个阶段,本研究应用了 3 种类型的约束:基于平面特征的初步优化、基于八叉树体素网格空间占用率的优化、基于地面约束的 Z 轴位移校正。具体为:

1) 结合惯性传感器的位姿数据将雷达点云投影到世界坐标系下,进行数据关联,维护一个 n 帧的滑动窗口,联合求解滑动窗口中每一帧与第 1 帧对应平面的点云与法向量的残差。

2) 将三维空间划分为体素网格,优化空间占用率,在校正结果准确的情况下,同一坐标系下全局点云地图所占空间体素最小。空间占用的网格数越少,建图效果越好,对应的外参越准确。

3) 通过直接测量惯性传感器离地高度,将其作为先验,利用地平面约束将外参 $\boldsymbol{T}_L^I$ 中位移分量进行修正。

1.1 激光雷达地面分割

首先,从雷达点云数据中分割地面,获得地面相对于激光雷达的最大旋转矩阵 $\boldsymbol{R}_G^L$。使用快速且鲁棒的激光雷达地面点云分割算法[11](fast and robust ground segmentation solving partial under-segmentation using 3D point cloud,Patchwork++)提取一组地面点 G,该过程如图 2 所示。

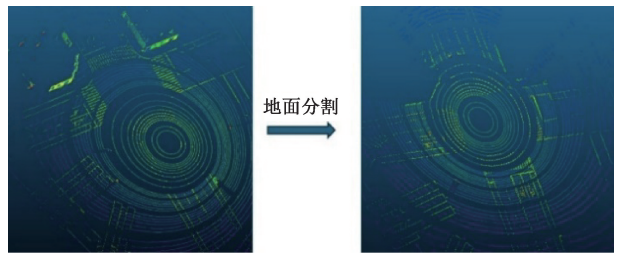

图 2 雷达点云地面分割

Fig. 2 Ground segmentation of LiDAR point cloud

为了将雷达点云 P_L 分为地面点 P_G 以及非地面点 $P_{\bar{G}}$,通过同心圆扇区模型拟合路面几何形态,将点云 P_L 分为多个区域,该过程可表示为:

$$\begin{cases} P_L = P_G \cup P_{\bar{G}} \\ \mathrm{Sec} = \bigcup\limits_{m \in num_z} Z_m \\ Z_m = \{ P_m \mid L_{\min}^m \leqslant \rho_m \leqslant L_{\max}^m \} \end{cases} \tag{2}$$

式中:Sec 为同心圆扇区;Z_m 表示扇区的第 m 个区域;num_z 为区域的个数;P_m 为 Z_m 区域内的点云集合;$\rho_m = \sqrt{x_m^{\,2} + y_m^{\,2}}$,为 P_m 中的点云半径;$L_{\min}^m$ 和 $L_{\max}^m$ 表示最小和最大半径边界;最终的地面点 P_G 可以由式(3)得到。

$$\begin{cases} (\hat{P}_G)_n = \{ P_n \mid H(P_n) \leqslant \alpha \} \\ f(\chi_n) = \phi_n \cdot \psi_n \cdot \varphi_n \\ P_G = \bigcup\limits_{n \in num_c} [f(\chi_n) \geqslant 0.5] (\hat{P}_G)_n \end{cases} \tag{3}$$

式中:$(\hat{P}_G)_n$ 为估计地面点;$H(P_n)$ 为点云 P_n 的平均高度值;α 为设定的高度阈值;$f(\chi_n)$ 为地面点系数;ϕ 为设置的角度阈值,其值为 0 或 1;ψ 为高度差误差置信度,解决垂直度相同而高度不同平面的问题,该变量的取值介于 0 和 1 之间;φ 为坡度阈值,增加斜坡平面的判断,该变量的取值介于 0 和 1 之间;$[\cdot]$ 为判断,如果满足条件返回 1,否则返回 0。然后,将主成分分析应用于地面点 G 的协方差矩阵 $\boldsymbol{A}_G$,得到接地平面的法向量 $\boldsymbol{n}_L = \overrightarrow{(a_L, b_L, c_L)}$,同时定义一个关于地面坐标系 $\{\boldsymbol{G}\}$ 的法向量 $\boldsymbol{n}_G = \overrightarrow{(0,0,1)}$。从两个法向量 $\boldsymbol{n}_L$ 和 $\boldsymbol{n}_G$ 得到从 $\{\boldsymbol{G}\}$ 到雷达坐标系 $\{\boldsymbol{L}\}$ 的旋转矩阵 $\boldsymbol{R}_G^L$,即:

$$\boldsymbol{R}_G^L = \exp(\{\phi_{gl} \boldsymbol{n}_{gl}\}_\times) \tag{4}$$

式中:$\phi_{gl} = \arccos(\boldsymbol{n}_G^{\mathrm{T}} \cdot \boldsymbol{n}_L)$;$\boldsymbol{n}_{gl} = n_g \times n_l$;$(\cdot)_\times$ 表示反对称矩阵。

1.2　基于地面约束的 Z 轴校正

对于运动受限于地面的机器人来说,不能进行垂直方向运动,无法获取充足的激励,因此在雷达与惯性传感器的外参标定上所得到的结果在 Z 轴方向上很可能存在误差[12]。为了解决这个问题,本研究提出基于地面约束的 Z 轴校正。具体来说,通过直接测量惯性传感器离地高度向量 $\boldsymbol{d}_I$ 并将其用作先验,利用平面机器人中 $\boldsymbol{t}_L^I$ 的 Z 轴分量无法约束的事实,对雷达与惯性里程计之间的外参 $\boldsymbol{R}_L^I$ 与 $\boldsymbol{t}_L^I$ 建立约束,如图 3 所示。

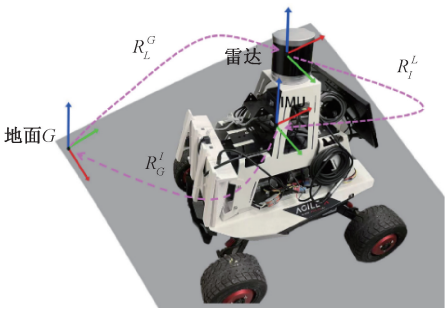

图 3　各坐标系转换关系

Fig. 3　Transformation relationships between various coordinate systems

通过从 1.1 节中基于激光雷达地面分割得到雷达高度向量 $\boldsymbol{d}_L$,位姿的旋转矩阵 $\boldsymbol{R}_I^G$,建立约束条件为:

$$\begin{cases}(\boldsymbol{R}_I^G\boldsymbol{R}_L^I\boldsymbol{R}_G^L)=1\\ \boldsymbol{e}_3^{\mathrm{T}}(\boldsymbol{R}_I^L\boldsymbol{R}_G^I\boldsymbol{d}_I-\boldsymbol{d}_L)=\boldsymbol{e}_3^{\mathrm{T}}\boldsymbol{t}_L^I\end{cases}\tag{5}$$

式中:$\boldsymbol{e}_3=\overrightarrow{(0,0,1)}$。通过将地面约束纳入标定过程,进一步优化外参误差到更小的值。

1.3　雷达点云平面特征提取

为了提取点云中面特征,遍历每一环雷达点云,记录每个点与前后 10 个点的距离 dis_{P_L},若距离不超过设定阈值 μ,则加入面点集合 P_{plane},否则加入角点集合 P_{cornor}。

$$\begin{cases}P_{plane}=\sum(P_L\mid dis_{P_L}\leqslant\mu)\\ P_{cornor}=\sum(P_L\mid dis_{P_L}>\mu)\end{cases}\tag{6}$$

为了得到不同帧点云对应同一平面的点集,需寻找雷达帧间的特征点对应,对雷达点云图进行体素化操作[12],将点云图分割成一个个预设体积的体素,记录这个点云来自第几帧,并记录对应的位姿,对每个体素计算体素内所有点的协方差矩阵 $\boldsymbol{A}$。

$$\begin{cases}\bar{p}=\dfrac{1}{N}\sum\limits_{i=1}^{N}p_i\\ \boldsymbol{A}=\dfrac{1}{N}\sum\limits_{i=1}^{N}(p_i-\bar{p})(p_i-\bar{p})^{\mathrm{T}}\\ \eta_k=\lambda_k(\boldsymbol{A})\end{cases}\tag{7}$$

式中:N 代表体素内的点数量;$\bar{p}$ 代表该面中心点;$\lambda_k(\boldsymbol{A})$ 表示矩阵 $\boldsymbol{A}$ 的第 k 个特征值,$\boldsymbol{A}$ 的最小特征值对应的特征向量就是平面的法向量。

1.4　滑动窗口联合求解

首先数据处理模块获得雷达点云时间戳对应的惯性传感器位姿数据,通过杆臂测量得到初始外参 $\boldsymbol{T}_L^I$,结合位姿信息,维护一个 n 帧的滑动窗口,如图 4 所示。

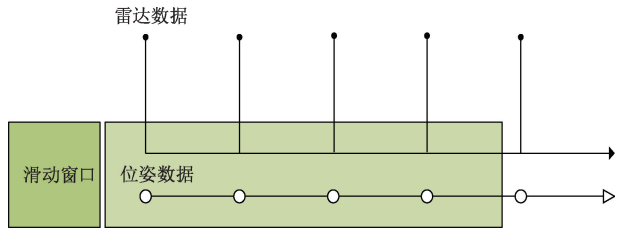

图 4　滑动窗口优化

Fig. 4　Sliding window optimization

滑动窗口中位姿矩阵为 $\boldsymbol{T}_1^W\boldsymbol{T}_2^W\cdots\boldsymbol{T}_n^W$,面特征 P_{plane}、平面法向量 $\boldsymbol{n}^i$、平面中心点 $\bar{p}_i$,将雷达点云投影到世界坐标系中,即:

$$P_i^W=(\boldsymbol{T}_I^W)_i\boldsymbol{T}_L^IP_i^L\tag{8}$$

式中:P_i^L 表示雷达坐标系中的第 i 帧点云;$\boldsymbol{T}_L^I$ 为雷达到惯性里程计初始外参矩阵;$\boldsymbol{T}_I^W$ 为第 i 帧的位姿数据;P_i^W 表示世界坐标系中的第 i 帧点云。数据关联则通过点云图体素化来将第 n 帧与第 1 帧所对应平面的点云建立损失函数,从雷达到姿态传感器的变换矩阵 $\boldsymbol{T}_L^I$ 可抽象为最小二乘优化问题。

$$\begin{cases}\boldsymbol{T}_L^I=\operatorname{argmin}\left(\sum\limits_{i=k}^{n}\|\xi_k\|^2\right)\\ \xi_k=\sum\limits_{n=1}^{N}\boldsymbol{n}^{\mathrm{T}}(P_{plane}^n-P_{plane}^1)\end{cases}\tag{9}$$

式中:ξ_k 为第 k 帧平面上的点到平面的残差;P_{plane}^n 为第 n 个平面上的平面点;$\boldsymbol{n}^{\mathrm{T}}$ 指第 1 帧平面的法向量;N 指第 k 帧一共提取到平面的数量[13]。通过解这个最小二乘问题,可以得到初步优化的外参解。

1.5　基于八叉树体素网格空间占用率优化

为了进一步优化由滑动窗口联合求解得到的外参 $\boldsymbol{T}_{L(refine)}^I$,将三维空间细分为体素网格,并对雷达采集的点云数据进行降采样处理,提升标定效率。通过不断优化空间占用率,可以进一步改善外参的精度[14]。具体而言,当空间占用的网格数量减少时,所构建的全局点云地图质量将提升,同时对应的外参也将更加精确,该过程如图 5 所示。

基于平面特征优化已将外参标定精确至较低误差水平,基于八叉树体素网格空间占用率的优化策略能在极小的参数调整范围内进一步微调外参。这种精细化的优化过程确保了校准速度的高效性,实现了快速而准确的外参校准。本研究利用惯性传感器数据及优化后外参

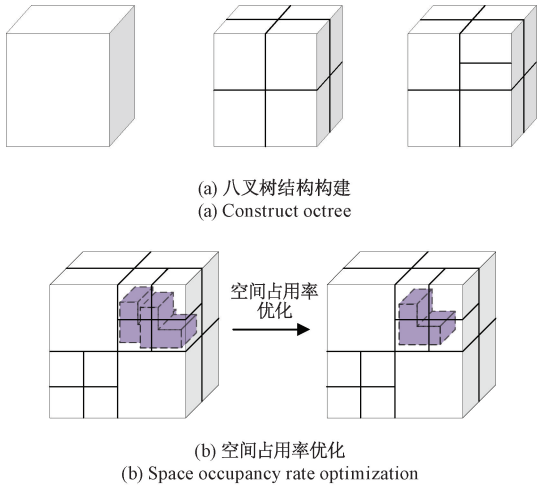

(a) 八叉树结构构建
(a) Construct octree

(b) 空间占用率优化
(b) Space occupancy rate optimization

图 5 八叉树体素网格空间占用率优化

Fig. 5 Octree voxel grid space occupancy optimization

$\boldsymbol{T}^{I}_{L(refine)}$ 对雷达点云进行重构,生成世界坐标系下的全局点云 M_{refine},因此优化目标变为:

$$\begin{cases} \boldsymbol{T}^{I}_{L} = \text{argmin}\{occpancy(M_{refine})\} \\ M_{refine} = \sum \boldsymbol{T}^{W}_{I}\boldsymbol{T}^{I}_{L(refine)}P_{L} \end{cases} \tag{10}$$

式中:$occpancy(\cdot)$ 表示空间占用率;P_L 为雷达坐标系下点云。通过解这个优化问题,找到一个最优的外参 $\boldsymbol{T}^{I}_{L}$,使全局点云图占据最少的网格数。

2 验证

验证实验共分两部分:首先利用开源数据集完成仿真实验,主要验证该方法在外参标定方面的性能。选取上海人工智能实验室的公开数据集(AI-Lab dataset, AI-Lab)以及上海交通大学的多源多场景数据集[15](a multi-sensor and multi-scenario dataset, M2DGR)数据集的共 3 个序列来验证算法。其中 AI-Lab 数据集为室外空旷平面场景,而 M2DGR 数据集的两个序列采集于开放环境,场景中存在部分动态障碍物(如行人和车辆),增加了实验的复杂性。通过在不同场景下的标定实验,定量分析了外参平移部分与旋转部分的平均绝对误差。为了说明本研究算法的有效性,在各数据集序列上与其他最近开源的雷达-惯性传感器标定方法 Open-calib[10]、Li_init[7] 以及 LI-Calib[5] 进行了比较,各算法对比如表 1 所示。

然后完成样机验证实验,由于无法获取真实世界中雷达和惯性测量单元之间的外参真值[6-7],因此主要验证了以本研究标定结果合成的全局雷达点云场景一致性,此外,通过校准后的外参来检验紧耦合雷达-惯性里程计的性能间接验证本研究方法的有效性[16]。

表 1 算法对比

Table 1 Comparison of algorithms

算法	适用范围	是否需要全轴激励	无 Z 轴激励时 Z 轴标定能力	可拓展性
Open-calib	自动驾驶汽车	否	否	不能拓展
Li_init	多种机器人	是	否	不能拓展
LI-Calib	多种机器人	是	否	不能拓展
本研究方法	多种机器人	否	是	支持雷达与其他位姿传感器

使用绝对误差评价平移向量,分别记录了平移向量在 X、Y、Z 这 3 个方向上的绝对误差;并将外参旋转矩阵转换为欧拉角,计算横滚角(roll angle, Roll)、俯仰角(pitch angle, Pitch)和偏航角(yaw angle, Yaw)的角度的误差[8]。平移向量的绝对误差[17]表示为:

$$E_T = |\boldsymbol{t}_{pred} - \boldsymbol{t}_{rel}| \tag{11}$$

式中:$|\cdot|$表示向量的二范数;$\boldsymbol{t}_{pred}$ 代表平移向量分量的预测值;$\boldsymbol{t}_{rel}$ 代表平移向量分量真值。此外,本研究所使用的评价指标为平均绝对误差(mean absolute error, MAE),在 t 时刻的 MAE 是估计值 $\tilde{p}$ 与真值之间 p_{rel} 的误差,计算公式为:

$$r_{MAE} = \frac{1}{n}\sum_{i=1}^{n}|\tilde{p} - p_{rel}| \tag{12}$$

通过分析平均绝对误差,能够量化标定结果在平移和旋转方向上的误差大小,从而全面评估其性能。

2.1 AI-Lab 数据集标定实验

本研究使用 AI-Lab 开源标定数据集评估算法,此数据集由禾赛 Pandar64 激光雷达负责采集,而姿态信息则由安装于车辆后轴上的 Novatel PwrPak7 传感器提供,在数据采集过程中,车辆在路口连续行驶 8 字形轨迹,以此方式收集激光雷达与姿态传感器的同步序列数据,具体的标定场景如图 6 所示。

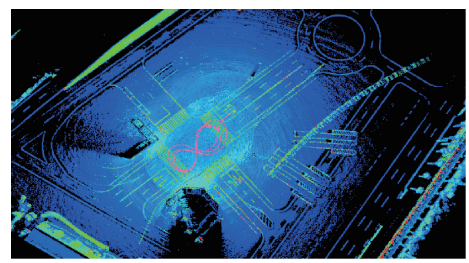

图 6 标定数据集场景

Fig. 6 Calibration dataset scenarios

对于初始参数设置,在数据集提供的外参真值基础上,人为地对 Roll、Yaw、Pitch 角度分别添加 10°的偏置,

对位移参数各添加 0.3 m 的偏移,以此作为验证算法性能的初参。为了获得稳定的评估结果,记录了 10 组标定实验的数据,并计算了这些数据的平均值。为了证明该算法的有效性,分别计算平移 t_x、t_y、t_z 和旋转 Roll、Yaw、Pitch 的 *MAE*。

实验结果表明,当对外参的单轴旋转添加 10°的偏置时,本研究算法能够在不到 10 s 的时间内迅速将旋转误差收敛至 0.5°以内,平移误差能在 0.3 m 的基础上收敛到 0.02 m 以内。标定效果对比如图 7 所示,这一收敛过程如图 8 所示。

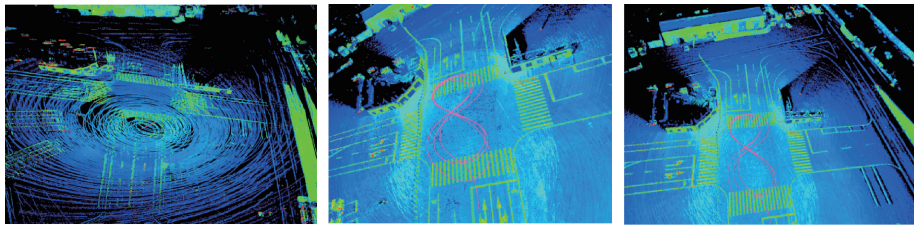

(a) 加偏后全局点云
(a) Global point cloud after adding bias

(b) 真值
(b) GT

(c) 本研究方法
(c) The proposed method

图 7　外参标定效果

Fig. 7　Extrinsic parameter calibration results

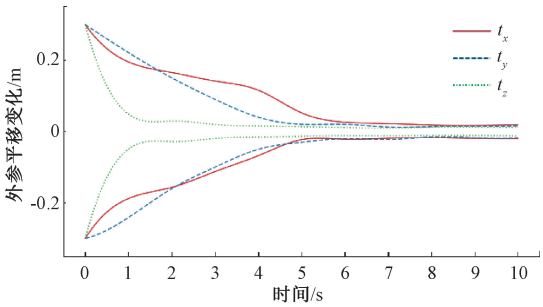

(a) 平移误差收敛曲线
(a) Convergence curve of translational error

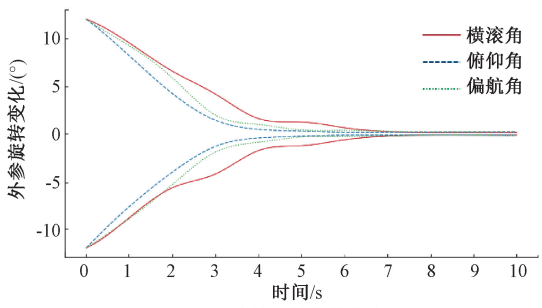

(b) 旋转误差收敛曲线
(b) Rotation error convergence curve

图 8　外参加偏优化结果

Fig. 8　Extrinsic parameter calibration results

为了验证本研究算法的全局优化性能,设置了与其他先进标定算法的对比实验,对于初始外参设置,在数据集真值基础上人为地对 Roll、Yaw、Pitch 角度各加 10°的偏置,同时对位移参数各加 0.2 m 的偏移。

为了获得稳定的评估结果,记录了 10 组标定实验的数据,并计算了平均绝对误差,结果如表 2 所示,从表 2 中可以得到,该算法相较于其他算法旋转角平均误差降低 43.73%,位移平均误差降低了 76.33%。

2.2　M2DGR 数据集标定实验

M2DGR[15] 数据集是由上海交通大学针对地面机器人导航采集的数据集,该数据集提供了各传感器之间的标定参数。根据实验需求,选择了 M2DGR 数据集中的 2 个序列(gate_01、street_08)为测试场景,在这些序列中机器人为地面运动,并且存在车辆、行人等动态障碍物,能较好地验证本研究算法的精度以及在复杂环境下的标定性能。对于初始参数,利用欧拉角转换将初始旋转参数加偏 10°,初始位移参数偏离真值 0.2 m。为了获得稳定的评估结果,每个序列记录 10 组标定实验数据,并计算两组序列的平均误差,结果如表 3 所示。本研究算法相较于其他算法旋转角平均误差降低 36.47%,位移平均误差降低了 41.52%。整体误差较大的原因是该数据集

表 2　AI-Lab 外参标定误差

Table 2　AI-Lab extrinsic parameter calibration errors

AI-Lab	旋转/(°)			位移/m		
	横滚角	俯仰角	偏航角	t_x	t_y	t_z
Open-calib	0.425 132 3	0.303 124 3	0.610 592 2	0.040 237 4	0.031 452 8	0.200 000 0
Li-Init	0.723 847 8	0.712 575 4	0.904 123 3	0.087 937 3	0.071 773 1	0.112 145 4
LI-Calib	0.558 289 4	0.628 520 7	0.958 292 0	0.094 840 1	0.062 317 8	0.146 048 1
本研究算法	0.271 082 4	0.292 812 9	0.404 123 3	0.028 211 4	0.020 946 1	0.017 491 2

表 3 M2DGR 外参标定误差

Table 3 M2DGR extrinsic parameter calibration errors

M2DGR	旋转/(°)			位移/m		
	横滚角	俯仰角	偏航角	t_x	t_y	t_z
Open-calib	0.513 495 0	0.445 139 5	0.913 650 9	0.108 036 2	0.099 067 9	0.200 000 0
Li-Init	0.850 578 9	0.519 572 6	1.004 951 3	0.098 312 7	0.111 531 3	0.092 145 9
LI-Calib	0.691 732 9	0.274 039 1	0.672 910 1	0.041 259 2	0.122 947 2	0.164 054 7
本研究算法	0.368 368 5	0.151 961 6	0.697 175 1	0.068 713 5	0.076 098 1	0.054 233 6

场景均在较为空旷处采集,场景中建筑物较为分散,可提取的平面特征较少,并且存在部分运动物体,对标定产生了一定干扰。

2.3 实测实验

由于无法获取真实世界中雷达和惯性测量单元之间的外参真值,为了验证该方法的有效性,设计了地面机器人外参标定实验。主要验证了以该研究标定结果合成的全局雷达点云场景一致性,此外,通过校准后的外参来检查紧耦合雷达-惯性里程计的性能间接验证该方法的有效性。实验平台基于松灵 SCOUT MINI 底盘构建,并集成了包括 CH110 惯性测量单元、RS-Helios-16P 激光雷达等在内的多种高精度传感器。该平台采用 8 核-32G ARMv8.2 处理器作为移动机器人的计算核心,以确保强大的数据处理能力,实验设备的配置如图 9 所示。

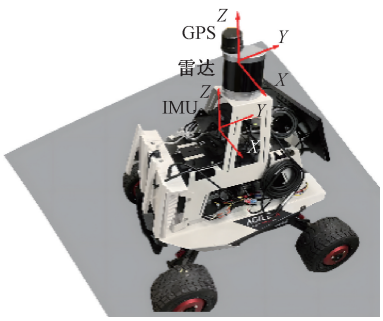

图 9 实验设备

Fig. 9 Experimental equipmen

1) 标定实验

为了验证所提算法的有效性,选择在校园内的多个场景中设计实验,包括平地、走廊、非平坦路面,具体场景如图 10 所示。

机器人以一定的速度在按照预设的 8 字形路径进行数据采集。为了确保位姿数据的准确性,将惯性传感器与其他传感器数据通过进行融合处理。随后,基于采集到的数据和实际场景进行了标定工作。通过这一实验设计,旨在全面而深入地评估所提方法在平面运动机器人

(a) 平地 (b) 走廊 (c) 斜坡

(a) Flatground (b) Corridor (c) Ramp

图 10 实验场景

Fig. 10 Experimental scenarios

在各种场景中的应用效果,以进一步证实其在实际操作环境中的可靠性、精确度与鲁棒性。

在实验中,首先根据传感器的实际安装位置以及全局点云图的初步拼接效果,对初始参数进行了估计,为了模拟实际应用中可能出现的误差情况[18],在此初参基础上利用欧拉角转换将初始旋转参数加偏 10°,初始位移参数偏离预估值 0.2 m。标定前后全局点云可视化结果如图 11 所示。可见标定后点云图中物体轮廓更清楚无杂影,物体高度比例与实际更相符,全局一致性更好。

2) 标定结果验证实验

为了定量分析本研究算法标定的精度,将该算法标定得到的参数与 Li_init 所得外参分别作为紧耦合雷达-惯性融合系统[1](fast direct LiDAR-inertial odometry, FAST-LIO2)的初始参数,进行定位精度分析。为了获取高精度的地面真值,采用了锚点法,并借助激光投线仪和激光测距仪这两种专业工具,设备如图 12 所示。

首先,设定激光投线仪的中心红点为坐标原点,利用其垂直射出的两条光线分别作为 X 和 Y 轴,从而构建一个精确的二维坐标系。接着,将激光测距仪放置在激光投线仪的位置,并向指定方向射出光线。为了确保测量的准确性,在合适的位置放置遮挡物,并使用激光测距仪测量出遮挡物与投线仪之间的精确距离。随后,用油笔在地面上做好距离标记,以便后续记录和参考。依次测量并记录实验场景内各个关键点的位置信息,直至完成整个场景的测量工作。这样,就得到了一系列精确的锚点坐标。

(a) 真实场景
(a) GT

(b) 标定前场景
(b) Before calibration

(c) 本研究算法
(c) The proposed method

图 11　标定前后全局点云效果

Fig. 11　Comparison before and after calibration

(a) 激光投线仪
(a) Laser line projector

(b) 激光测距仪
(b) Laser rangefinder

图 12　锚点法工具

Fig. 12　Anchor point method tool

为了更精确地分析定位精度,引入绝对轨迹误差(absolute trajectory error, ATE)作为评估定位准确性的关键指标[19]。ATE 的计算过程是将地面真实轨迹与 FAST-LIO2 算法估计的轨迹根据时间戳进行精确对齐,随后逐对计算两者位姿之间的偏差,并将这些偏差以直观的图表形式呈现出来,以便进行详尽的分析。

假设 FAST-LIO2 估计出的位姿矩阵为 $\boldsymbol{P}_i \in SE(3)$, $i=1,\cdots,n$,真实位姿矩阵为 $\boldsymbol{Q}_i \in SE(3), i=1,\cdots,n$, Δt 为时间间隔,$\boldsymbol{S} \in Sim(3)$ 是估计的位姿坐标系和真实的轨迹坐标系之间的相似变换矩阵,定义第 i 帧的 ATE 为[20]:

$$\boldsymbol{F}_i = \boldsymbol{Q}_i^{-1}\boldsymbol{S}\boldsymbol{P}_i \tag{13}$$

则在得到实验中的 m 个 ATE 后,可求出其均方根误差(root mean squared error,RMSE)。

$$RMSE(F_{i:n},\Delta t) = \sqrt{\left(\frac{1}{m}\sum_{i=1}^{m} \| trans(F_i) \|^2\right)} \tag{14}$$

式中:$trans(F_i)$ 是取其平移部分。

在实验过程中,利用遥控设备精准地操控机器人沿着预设的锚点进行移动,确保其行走的总距离为 62.393 m。实验所得到的轨迹图如图 13 所示。

该图直观地展示了不同算法标定结果下的机器人行走轨迹。其中虚线表示锚点法绘制的轨迹真值。实线代表以本研究算法标定结果为初始参数的 FAST-LIO2 里程计所输出的轨迹,而点划线则展示了以 Li_init 标定结果

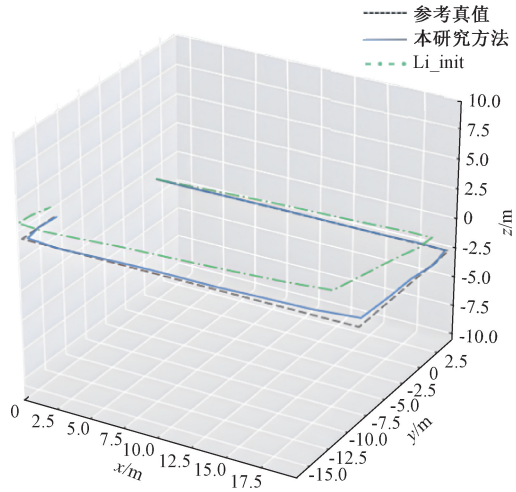

图 13 实验轨迹

Fig. 13 Experimental trajectory diagram

为初始参数的 FAST-LIO2 里程计所输出的轨迹。

从轨迹分析,以 Li_init 标定结果为参数的轨迹图,在终点位置与真值相比偏差较大,并且在 Z 轴方向上出现了显著的偏移。这种偏差可能源于 Li_init 算法在平面运动标定过程中的局限性,未能完成 Z 轴校正。相比之下,以本研究算法标定结果为初始参数的轨迹图与真值更为接近,不仅在整体走势上保持一致,而且在终点位置也仅有微小的偏差。此外,该轨迹图在 Z 轴方向上未出现明显的起伏或偏移,表明本研究算法在标定过程中具有较高的准确性和稳定性。

各算法标定后绝对轨迹误差图如图 14 所示。图中左侧呈现了不同算法的精度表现,右侧柱状图呈现了轨迹对应的误差分布情况。从绝对轨迹误差图可以看出,该算法在的误差最大值小于对比算法,最小值接近。

为具体分析定位精度,给出上述算法的绝对轨迹误差值,并定义提升率公式为:

$$improvement = \frac{other - our}{other} \times 100\% \tag{15}$$

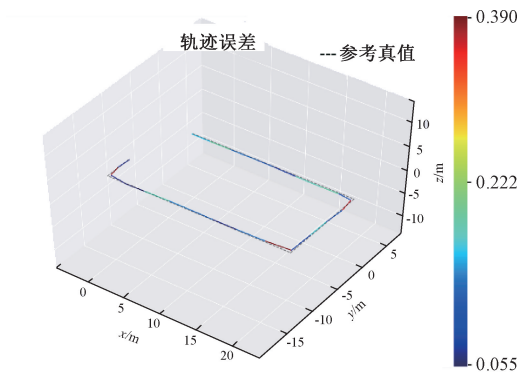

(a) Li_init标定算法

(a) The result of Li_init

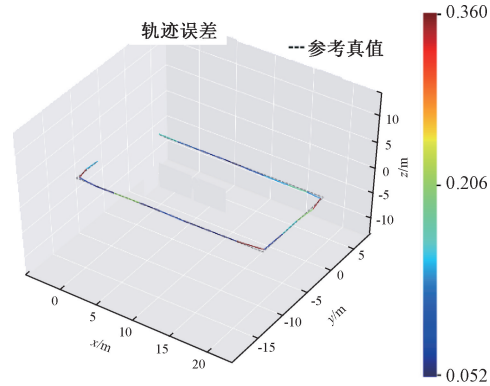

(b) 本研究算法

(b) The proposed method

图 14 绝对轨迹误差结果

Fig. 14 Absolute trajectory error results

式中:*other* 为其他算法的运行结果;*our* 为本研究算法的运行结果。各算法的绝对轨迹误差对比如表 4 所示。

表 4 算法绝对轨迹误差对比

Table 4 Comparison of absolute trajectory errors among algorithms (m)

对比项	本研究方法	Li_init
均方根误差	0.173 718	0.185 077
平均值	0.144 865	0.158 856
中位数	0.118 179	0.132 357

通过对比可以得到,以本研究标定结果为初参绝对轨迹均方根误差为 0.173 718 m,相较于 Li_init 提升了 6.538 7%,且轨迹与真值更吻合。

实验结果表明,本研究算法在平面运动机器人的标定中有着更高的精度,对平面运动机器人雷达-惯性融合系统的精度提升更大,证明了本研究算法的实用性和有效性。

3 结 论

本研究设计的基于平面特征的地面机器人雷达-惯性里程计外参标定方法,通过构建雷达点云平面与惯性里程计数据的残差,结合滑动窗口优化策略,能在较短时间内实现外参的高精度收敛。此外,该方法采用的基于地面约束的 Z 轴标定技术,有效提升了传感器坐标系间位移的校正精度,确保了六自由度参数的高准确性。在两组开源数据集标定实验中,本研究方法相较于其他算法在精度上提升显著,旋转角平均误差分别降低 43.73% 及 36.47%,位移平均误差分别降低了 76.33% 及 41.52%。里程计精度验证实验表明,以本研究算法为初

始参数的雷达惯性融合系统,其轨迹精度显著提升,绝对轨迹均方根误差降低了 6.54%,验证了该算法的有效性和实用性。

参考文献

[1] XU W, CAI Y X, HE D J, et al. FAST-LIO2: Fastdirect LiDAR-inertial odometry[J]. IEEE Transactions on Robotics, 2022, 38(4):2053-2073.

[2] KIM T Y, PAK G, KIM E. GRIL-calib: Targetless ground robot IMU-LiDAR extrinsic calibration method using ground plane motion constraints[J]. IEEE Robotics and Automation Letters, 2024, 9(6): 5409-5416.

[3] GENTIL C, VIDAL-CALLEJA T, HUANG S. 3D LiDAR-IMU calibration based on upsampled preintegrated measurements for motion distortion correction[C]. 2018 IEEE International Conference on Robotics and Automation (ICRA), 2018:2149-2155.

[4] WANG Y, MA H W. Online spatial and temporal initialization for a monocular visual-inertial-LiDAR system[J]. IEEE Sensors Journal, 2022, 22(2):1609-1620.

[5] LYU J J, XU J H, HU K W, et al. Targetless calibration of LiDAR-IMU system based on continuous-time batch estimation[C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2020:9968-9975.

[6] LYU J J, ZUO X X, HU K W, et al. Observability-aware intrinsic and extrinsic calibration of LiDAR-IMU systems[J]. IEEE Transactions on Robotics, 2022, 38(6):3734-3753.

[7] ZHU F CH, REN Y F, ZHANG F. Robust real-time LiDAR-inertial initialization[C]. 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2022:2632-2639.

[8] IYER G, RAM R K, MURTHY J K, et al. CalibNet: Geometrically supervised extrinsic calibration using 3D spatial transformer networks (conference paper)[C]. 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2018:1110-1117.

[9] LYU X D, WANG B Y, DOU Z W, et al. LCCNet: LiDAR and camera self-calibration using cost volume network[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2021:2888-2895.

[10] YAN G H, LIU ZH CH, WANG CH J, et al. OpenCalib: A multi-sensor calibration toolbox for autonomous driving[J]. Software Impacts, 2022, 14: 100393.

[11] LEE S, LIM H, MYUNG H. Patchwork++: Fast and robust ground segmentation solving partial under-segmentation using 3D point cloud[C]. 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2022:8618-8625.

[12] LIU ZH, ZHANG F. BALM: Bundle adjustment for Lidar mapping[J]. IEEE Robotics and Automation Letters, 2021, 6(2):3184-3191.

[13] 付瑶. 激光雷达、IMU 联合标定及实时点云建图方法研究[D]. 北京: 北京建筑大学, 2023.
FU Y. Research on LiDAR and IMU joint calibration and real-time point cloud mapping[D]. Beijing: Beijing University of Civil Architecture, 2023.

[14] 朱东福. 基于多传感器融合的地面机器人状态估计研究[D]. 武汉:华中科技大学, 2020.
ZHU D F. Research on state estimation of ground robot based on multi-sensor fusion[D]. Wuhan: Huazhong University of Science and Technology, 2020.

[15] YIN J, LI ANG, LI T, et al. M2DGR: A multi-sensor and multi-scenario SLAM dataset for ground robots[J]. IEEE Robotics and Automation Letters, 2022, 7(2): 2266-2273.

[16] 张福斌,王凯,廖伟飞, 等. 激光雷达/MEMS IMU/里程计紧组合导航算法[J]. 仪器仪表学报, 2023, 43(7):139-148.
ZHANG F B, WANG K, LIAO W F, et al. A tightly coupled navigation algorithm for LiDAR/MEMS IMU/odometer[J]. Chinese Journal of Scientific Instrument, 2023,43(7):139-148.

[17] 彭梦,邬书跃,陈龙, 等. 一种鲁棒的 2D 激光雷达和摄像机最小解标定方法[J]. 电子测量与仪器学报, 2023,37(8):146-154.
PENG M, WU SH Y, CHEN L, et al. A robust minimal solution calibration method for 2D LiDAR and camera[J]. Journal of Electronic Measurement and Instru-mentation, 2023,37(8):146-154.

[18] 黄平,胡超,张宁, 等. 车载 LiDAR-IMU 外参联合标定算法[J]. 仪器仪表学报,2022,43(10):128-135.
HUANG P, HU CH, ZHANG N, et al. Joint extrinsic

calibration algorithm for LiDAR-IMU [J]. Chinese Journal of Scientific Instrument, 2022, 43(10): 128-135.

[19] 诸葛晶昌,高宏,罗其俊, 等. 激光雷达 IMU 紧耦合 SLAM 算法研究[J]. 仪器仪表学报,2024,45(11): 243-251.
ZHUGE J CH, GAO H, LUO Q J, et al. Research on tightly coupled LiDAR-IMU SLAM algorithm [J]. Chinese Journal of Scientific Instrument, 2024, 45(11): 243-251.

[20] 王晨旭. SLAM 系统关键技术研究[D]. 北京:北京邮电大学,2021.
WANG CH X. Research on key technologies of SLAM systems[D]. Beijing: Beijing University of Posts and Telecommunications, 2021.

作者简介

任家卫,2020 年于太原理工大学获得学士学位,现为东南大学硕士研究生,主要研究方向为视觉感知与定位。
E-mail:949505932@qq.com

Ren Jiawei received his B. Sc. degree from Taiyuan University of Technology in 2020. He is currently a master student at Southeast University. His main research interests include visual perception and localization.

徐晓苏(通信作者),1982 年于东南大学获得学士学位,1985 年于东南大学获得硕士学位,1991 年于东南大学获得博士学位。现为东南大学仪器科学与工程学院教授,主要研究方向为惯性导航、组合导航、卫星导航、视觉导航、智能滤波技术。
E-mail:xxs@seu.edu.cn

Xu Xiaosu(Corresponding author) received his B. Sc. degree from Southeast University in 1982, received his M. Sc. degree from Southeast University in 1985, and received his Ph. D. degree from Southeast University in 1991. He is currently a professor with the School of Instrument Science and Engineering at Southeast University. His main research interests include inertial navigation, integrated navigation, satellite navigation, visual navigation, and intelligent filtering technologies.