

DOI:10.19651/j.cnki.emt.2517832

单目 SLAM 中基于单应性的快速地平线检测方法^{*}

陈晔鑫^{1,2} 张涛^{1,2}

(1. 东南大学仪器科学与工程学院 南京 210096; 2. 东南大学微惯性仪表与先进导航技术教育部重点实验室 南京 210096)

摘要: 在视觉同步定位与建图(SLAM)中,地面信息不仅可以提供重力方向的参考,还能有效辅助障碍物的识别,因此地平面的准确检测对于机器人导航至关重要。针对计算资源受限、缺乏深度信息的单目视觉 SLAM 地平面估计问题,本文提出了一种基于单应性的地面检测方法。首先,通过 RANSAC 方法对初始环境下的匹配特征点对计算单应性矩阵,获取初始地平面和相应的地面点云。随后,基于已获得的地面种子点,在 SLAM 建图过程中结合单应性估计与动态增长策略,逐步扩展地面点云,以实现低成本下对地平面的精确分割。实验结果表明,所提方法在公开数据集和本地测试数据上的分割精度均超过 92.52%,且地平面的角度误差小于 0.13°,归一化平面距离误差小于 0.008,验证了该方法的有效性。同时,所提出的算法仅增加了 4.57% 的计算耗时,能够满足实时运行要求。

关键词: 地平面检测;单应性;单目视觉 SLAM;平面拟合;动态增长

中图分类号: TN965.8; TP391.41 文献标识码: A 国家标准学科分类代码: 510.8040

Fast ground plane detection method based on homography in monocular SLAM

Chen Yexin^{1,2} Zhang Tao^{1,2}

(1. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China; 2. Key Laboratory of Micro-Inertial Instrument and Advanced Navigation Technology, Ministry of Education, Southeast University, Nanjing 210096, China)

Abstract: In visual simultaneous localization and mapping (SLAM), ground information not only provides a reference for gravity direction but also effectively aids in obstacle recognition, making accurate detection of the ground plane crucial for robot navigation. To address the problem of ground plane estimation in monocular visual SLAM with limited computational resources and lacking depth information, this paper proposes a ground detection method based on homography. Initially, the homography matrix is computed using the RANSAC method on matched feature point pairs in the initial environment, obtaining the initial ground plane and corresponding ground point cloud. Subsequently, based on the obtained ground seed points, the homography estimation is combined with a dynamic growth strategy during the SLAM mapping process to gradually expand the ground point cloud, achieving precise segmentation of the ground plane at a low computational cost. Experimental results show that the proposed method achieves segmentation accuracy exceeding 92.52% on public datasets and local test data, with an angular error of less than 0.13° for the ground plane and a normalized plane distance error of less than 0.008, validating the effectiveness of the method. Additionally, the proposed algorithm only increases computational cost by 4.57%, meeting real-time operation requirements.

Keywords: ground detection; homography; monocular visual SLAM; plane fitting; dynamic growth

0 引言

在移动机器人和自动驾驶领域中,环境感知和场景理解是实现精确导航与安全避障的关键。同步定位与建图(simultaneous localization and mapping, SLAM)是机器人

环境感知的一项重要基础性技术。其基于视觉、惯性、激光雷达等传感器,将机器人的运动轨迹与构建的地图进行匹配,从而实现机器人的导航、定位、建图等功能^[1]。地面分割作为场景理解的重要组成部分,需要从视觉输入中识别并分离出地面区域,不仅为机器人提供稳定可靠的重力方

收稿日期:2025-01-06

^{*} 基金项目:广东省基础与应用基础研究基金(2024A1515010269)项目资助

向与参考平面,还能有效辅助二维地图的构建、障碍物识别乃至路径规划。在点云数据处理中,地面点云通常占据较大比例,且通常被视为冗余信息,因此需要对其进行有效识别与去除^[2]。地平面信息可以通过 2D-RGB 图像中的像素分类、3D 点云数据上的地面点分类,或者地平面方程的描述来表示。单目视觉系统由于其成本低廉、安装方便等优点,在环境感知中得到了广泛的应用^[3]。然而,由于单目 SLAM 缺乏直接深度感知能力,导致传统基于深度先验的平面检测方法失效,且生成的视觉点云较为稀疏,因而在进行地面分割时通常面临着额外的挑战。

目前,地面分割算法主要集中在激光雷达领域,且大多基于密集点云与激光扫描模型^[4-7]。文献[5,8]提出通过激光雷达数据生成高程图,从而有效解决地面分割和地形估计问题,在保持高运行时性能的同时,实现对各种场景的良好泛化。随着 SLAM 技术的进步,基于视觉的地面分割的研究重点聚焦于三维点云数据的分类^[9]。Li 等^[10]提出采用曲面法线估计的方法对帧中的点云数据进行处理。然而单目相机通过三角化构建的点云通常较为稀疏,无法形成完整的稠密深度图。在构建局部地图时,所提取的地面点可能分散于不同物体的底部,而非以平面簇的方式存在,使得曲面法线估计算法难以有效应用。

大量研究采用基于随机采样一致性(random sample consensus, RANSAC)的方法从点云数据中提取地平面^[11-13]。具体而言,RANSAC 算法通过迭代随机选择最小点集来拟合最佳平面模型,并有效排除离群点。在平面点占点云总点数中占比较大时,能够取得较为理想的效果。此外,Hough 变换通过将点云数据映射到参数空间,并识别参数空间中的高密度区域,实现了地平面的检测。文献[14-15]提出了三维 Hough 变换在地面检测中的应用,结合 GPU 并行计算加速处理过程,证明了其在特定场景下的有效性。文献[1,3]提出通过构建稠密点云并结合图像分割技术对地面点云进行分割。刁羽峰等^[16]提出了一种基于视觉稠密建图的实时地面分割方法,该方法利用机器人在平面上的移动特性施加平面约束,抵消了 6 自由度 SLAM 中可能出现的翘边现象,并通过结合 RANSAC 算法实现了稳定的地面分割功能。文献[17-18]提出基于获取的深度图像信息提取可通行地图,实现了实时地面分割。Li 等^[19]则通过融合 RGBD 相机与神经网络来提供物体的类别和位置信息,进行实时对象检测和避障路径规划,并提出了潜在的地面区域作为可通行路径。此外,还有研究致力于将单目 RGB 图像与深度学习相结合以进行地面分割。Cakiroglu 等^[20]使用预训练模型从给定的 RGB 图像生成深度图,采用 RANSAC 算法进行三维地平面拟合,并估计物体到地平面的距离。Xiong 等^[21]则提出一种单目无监督方法,从 RGB 视频序列中同时估计自身位姿和地面。然而,视觉实时稠密建图常与深度学习方法通常依赖于昂贵的 GPU 等硬件加速设备,对低端设备的部署不够友好^[16]。

一些研究将单应性应用于地面检测问题^[12,22-24]。Zhou 等^[22]基于射影几何提出了基于单应性的地面检测方法,将问题转化为估计序列中两帧之间的单应性矩阵。晏小彬等^[24]融合视觉传感器与激光雷达,使用单应性估计初始运动位姿,辅助激光雷达在运动过程中进行点云校正。此类算法在较低计算成本条件下实现了单目视觉下的地面检测。

总体而言,现有的主流单目 SLAM 系统应用于小型室内机器人时,由于平台特性的限制而存在诸多局限;或由于地图稠密而无法实时运行;或是在稀疏点云条件下缺乏地面结构特征;而基于深度学习的方法又对硬件要求较高,难以运行在资源受限的平台中。在当前研究中,缺乏单目视觉下快速稳健的地面检测方法。鉴于大量环境下的地面结构特征明显,本研究基于地面可近似为平面的基本前提,提出了一种结合单应性估计与动态增长的地面分割方法。该方法利用单应性检测揭示图像中地面点的几何关系,并基于种子点集在建图过程中持续进行动态的地面区域分割,有效处理噪声问题。本文将首先介绍所使用的算法框架及总体流程,随后描述利用单应性初始识别图像中的地面特征点过程,阐述单应性估计与单应性分解的具体原理;然后介绍建图过程中将地面点扩展为连续区域的动态增长与闲时检测策略。最后,通过实验验证所提出的地面分割算法,评估其分割的准确性和鲁棒性,验证该单目 SLAM 系统的分割性能。

1 算法框架

针对单目视觉系统中对于准确且鲁棒的地面检测需求,本文提出了一种利用角点检测的稀疏特征集同时进行运动估计与地面检测的方法。该方法能够在计算资源有限的情况下,提供准确且实时的位姿信息与地面分割结果。本文提出的地面分割算法在单目 SLAM 框架 ORB-SLAM2 算法的基础上进行改进,通过优化特征点处理并引入单应性检测与动态增长策略,在单目初始化与连续运行中实现了高效可靠的地面点云分割。其整体算法框架如图 1 所示,算法共由 3 个线程组成:跟踪线程、局部建图线程和回环检测线程,虚线部分内为本文新增的模块。跟踪线程包括特征点的提取和匹配、地图初始化以及局部地图跟踪,确保系统能够实时更新位姿信息,并筛选出具有代表性的关键帧;局部建图线程用于优化前端估计的位姿、更新地图点并进行地面点的判别;闭环检测线程则负责闭环检测和矫正任务,对地图进行相应的调整以消除累计误差。

地面提取过程可通过地图初始化和更新地图点两个入口启动,负责提取地面点并计算地面向量。在地图初始化阶段,算法通过计算单应性矩阵并对其分解,确定地平面的位置以及初始地面点。在持续运行过程中,每当有新关键帧加入时,系统会进行局部建图并更新地图点,在判断地面点的过程中,系统利用已计算的地面向量来提取地平面,并

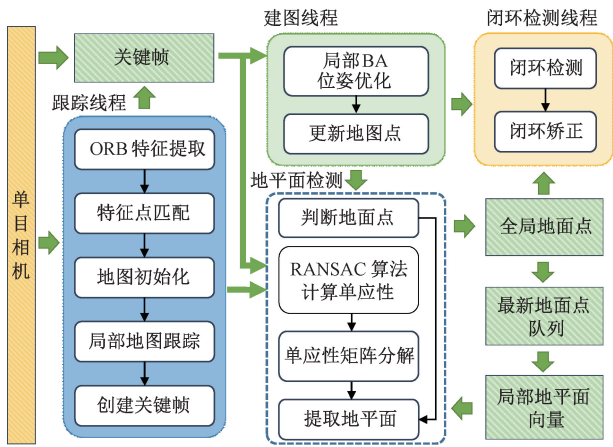


图 1 算法框架

Fig.1 Algorithm framework

将其作为地图的一部分进行存储。为进一步提高地面点云分割的精度,在系统计算资源允许的情况下,算法会再次利用单应性来审查先前过程中的可能遗漏的地面点,以确保分割结果的准确性。

其地面分割部分算法的流程如图 2 所示。该算法主要在框架中的跟踪线程与局部建图线程中进行处理。具体而言,在跟踪线程中,增加了地面与地面点的初始化过程,使用 RANSAC 算法估计地面匹配点的单应性矩阵,并通过地对单应性矩阵的分解,获取地面参数与初始位姿。在局部建图线程中,生成新地图点之后,根据点面距离阈值筛选出地面点,并将其添加至地面点集。随后,利用地面点集拟合出新的地平面参数。当当前关键帧对应的共视帧具有足够的共视地面点时,进行额外的单应性匹配,以提取可能遗漏的地面点。

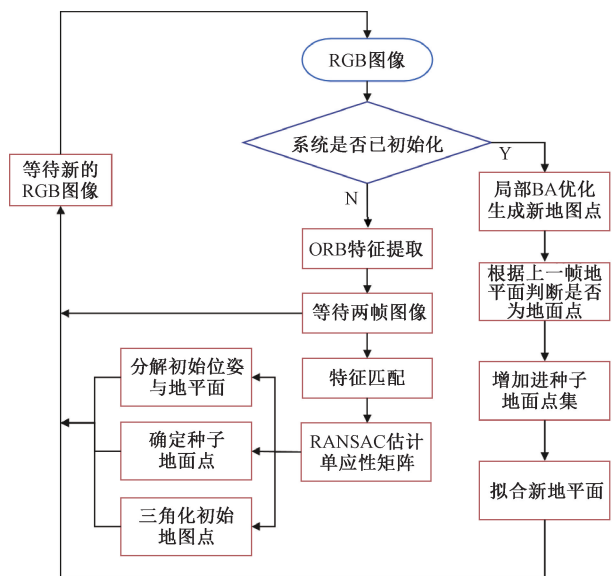


图 2 算法流程

Fig.2 Algorithm flow

2 地平面与地面点初始化

2.1 地面向量描述

在三维直角坐标系中,地平面一般可表示为:

$$\mathbf{n}^T \mathbf{p}_g + d = 0 \quad (1)$$

式中: \mathbf{n} 表示地面的单位法向量, \mathbf{p}_g 表示地平面上任意一点的三维坐标, d 则为原点到该平面的距离。考虑到平面在空间的自由度为 3,其中 \mathbf{n} 仅占据两个自由度,为了便于后续拟合运算,将地平面参数化为:

$$\mathbf{n}_g = [a \ b \ c]^T = \frac{\mathbf{n}}{d} \quad (2)$$

即式 (1) 转化为:

$$\mathbf{n}_g^T \mathbf{p}_g + 1 = 0 \quad (3)$$

该方法虽不能表示经过坐标原点的平面,但在实际应用中,由于坐标原点通常代表地图初始化时的相机位姿,不可能位于地面区域,因此将地平面参数进行上述表示是合理的。

2.2 基于 RANSAC 的单应性矩阵估计

在进行连续的地面分割之前,必须完成地平面参数与地面点的初始化。单目视觉 SLAM 系统的初始化系统较为复杂,它依赖于两帧图像间的匹配来计算初始相机姿态,并通过三角测量构建出初始地图点。在单目初始化过程中,当获得两帧 RGB 图像并成功匹配特征点后,可利用这些信息进行地面检测。采用 RANSAC 算法提取出图像中具有最多匹配点对的单应性矩阵。

根据单目针孔成像模型,同一平面上的点于不同视角中共享相同的单应变换。即对于两幅图像 I_1, I_2 中一组已匹配的特征点 $\{x_i \leftrightarrow x_i' \mid x_i \in I_1, x_i' \in I_2\}$,若所有的点共面,则存在一个单应矩阵 \mathbf{H} ,使得这些点满足齐次方程:

$$\mathbf{x}_i' = \mathbf{H} \mathbf{x}_i \quad (4)$$

其中, \mathbf{x} 表示齐次图像坐标 $(u_x, u_y, 1)^T$, \mathbf{H} 是 3×3 的单应矩阵。由于隐含了比例因子,故具有 8 个自由度。由于每组匹配点对提供两项独立的约束,至少需要 4 对非退化的匹配点来确定单应矩阵 \mathbf{H} ;在实践中通常使用更多的点对以最小二乘法求解,从而提高估计精度^[22]。

鉴于不同的平面具有不同的单应性,理论上,只要找到包含至少 4 个地面点的单应,则该单应就对应于地平面。可以根据式 (4),使用一种通过将检测到的特征点分组为共享单应性的共面集合的方法来检测地平面。计算出 \mathbf{H} 之后,可以用来验证场景中的其他点是否属于同一平面。假设地平面包含最多的特征点,那么可以通过搜索在两个视图中占多数特征点的主导单应性来检测它。然后利用该单应性判断该平面上是否存在其他特征点,从而实现地平面的检测。

在实际应用中,系统的硬件配置,尤其是相机相对于地平面的视角,显著影响了图像中哪些区域更可能是地面。因此基于相机的配置习惯,在初始化阶段,策略性地选取图

像下半部分作为兴趣区域,保留此区域内的匹配点对以用于后续的单应性检测。

本文提出的方法采用经典的 RANSAC 算法迭代估计单应性矩阵,以检测给定对应关系中的主导单应性。在每次迭代中随机选择兴趣区域中的 4 对匹配点形成组,来初始化单应性矩阵 \mathbf{H} ,然后评估该矩阵与其余点对的一致性。若该矩阵与剩余点对之间的距离低于设定阈值,则将这些点对视为内点加入候选集合,并据此计算该次迭代得分。由于仅由 4 个点确定 \mathbf{H} ,容易导致单应性的过拟合并可能收敛至局部最优解。因此完成迭代后,最后选取得分最高的组别,并根据该组别的所有点对重新计算单应性矩阵,作为最终的估计结果。其流程如算法 1 所示。

算法 1 基于 RANSAC 的主导单应性检测算法

输入: N 对匹配点对 $m = \{\mathbf{x}_1, \mathbf{x}_2\}$, 随机迭代次数 k

输出: 主导单应性矩阵 \mathbf{H} , 地平面内点集合 G_p

Initialize:

- 1: for $i=1, 2, \dots, k$ do
- 2: 随机选取 4 个匹配点对, 记为 $m_{i1}, m_{i2}, m_{i3}, m_{i4}$,
- 3: $G_i \leftarrow \{m_{i1}, m_{i2}, m_{i3}, m_{i4}\}$ 为初始包含一组随机 4 个匹配点对的集合

4: **end for**

CalculateScores:

- 5: for $i=1, 2, \dots, k$ do
- 6: $\mathbf{H}_i \leftarrow$ 根据 G_i 集合的约束计算其单应性矩阵
- 7: 根据卡方检验, 测试其余点对是否满足该单应性
- 8: for $m_j \notin G_i$ do
- 9: if $i=1, 2, \dots, k$ then
- 10: $G_j \leftarrow G_j \cup \{\mathbf{x}_i\}$ 将点对加入到该集合中
- 11: **endif**
- 12: **endfor**
- 13: $S_i \leftarrow \text{INLIERS}(\mathbf{H}_i, G_i)$ 计算第 i 组中得分
- 14: **endfor**

FindBestHomography:

- 15: $p \leftarrow \text{argmax}_{i \in \{1, \dots, k\}} S_i$ 获取 k 组中得分 S 最高的组别
- 16: $\mathbf{H} \leftarrow$ 根据集合中所有点对重新计算第 p 组中的单应性矩阵 \mathbf{H}_p

2.3 单应性分解

在算法 1 获取了单应性矩阵后,接下来需要从单应性矩阵 \mathbf{H} 中恢复出两帧图像之中的平面信息,为此采用 Faugeras 的 SVD-based 方法进行分解,以确定场景中的其他点是否位于同一平面。

在单目初始化过程中,设定第一帧相机位姿 \mathbf{T}_0 为单位矩阵,而第二帧相机位姿表示为 $\mathbf{T}' = [\mathbf{R} | \mathbf{t}]$,其中 \mathbf{R} , \mathbf{t} 分别代表相对于第一帧相机坐标系中的旋转矩阵与平移向

量。在第一帧图像坐标系中,结合式(1)的约束,可以推导出:

$$\mathbf{H} = \mathbf{R} - \frac{\mathbf{t}\mathbf{t}^T}{d} \quad (5)$$

将其进行 SVD 分解为:

$$\mathbf{H} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T \quad (6)$$

并设 $\mathbf{\Sigma} = \text{diag}\{\sigma_1, \sigma_2, \sigma_3\}$, 其中 $\sigma_1 > \sigma_2 > \sigma_3$, 接下来令:

$$\begin{cases} s = \det\mathbf{U}\det\mathbf{V} \\ \mathbf{n}' = \mathbf{V}^T \mathbf{n} \\ d' = sd \end{cases} \quad (7)$$

其中,设 $\mathbf{n}' = [n'_x, n'_y, n'_z]^T$, 在奇异值各不相同的情况下可解得:

$$\begin{cases} n'_x = \pm \sqrt{\frac{\sigma_1^2 - \sigma_2^2}{\sigma_1^2 - \sigma_3^2}} \\ n'_y = 0 \\ n'_z = \pm \sqrt{\frac{\sigma_2^2 - \sigma_3^2}{\sigma_1^2 - \sigma_3^2}} \\ d' = \pm \sigma_2 \end{cases} \quad (8)$$

故而存在 8 个可能的解组合。

在多视图几何重建中,基于两幅独立投影图像中的共面点集,通常可以重建这些点相对于两个投影中心的三维坐标。然而文献[25]指出,在连接两个投影中心的直线与该平面不垂直,并且所有可见点更接近于其中一个投影中心的情况下,重建过程可能会遭受二义性问题。这种二义性可能产生误导性的解释,错误地反映相机的姿态以及平面法线的方向。

为了解决该二重歧义,本方法在求出所有可能的 8 个候选解之后,对每一个候选解进行分析,验证重构的三维点是否位于两个相机前方,并统计具有较小重投影误差的点的数量。随后取统计点数最多的的两个解作为有效解,根据式(7)计算其在世界坐标系下的平面参数 n 。鉴于先前讨论的相机配置惯例,地面区域位于图像下半部分时,地面法向量应朝向图像上方,即判断当 $n_y < 0$ 时,避免采用该解以防止地图初始化过程的失败。

3 地面的连续分割

当单目 SLAM 系统进行初始化之后,建图线程随即开始运行。随着单目相机在场景中移动以进行区域探索时,建图线程将不断生成新的点云数据,构建三维空间中的特征信息。为确保地图的准确性和实时性,此时需要对地面进行连续的分割与更新。本文提出了一种在单目视觉环境下的连续地面分割方法,该方法依托于局部地图的动态更新机制以及基于单应性检验的漏检识别技术。系统会在每个关键帧中,对局部地图点进行分割与更新,从而实现高效的地面分割。本系统在建图过程中对地面连续分割的结构与流程如图 3 所示,清晰展示了其工作原理与步骤。

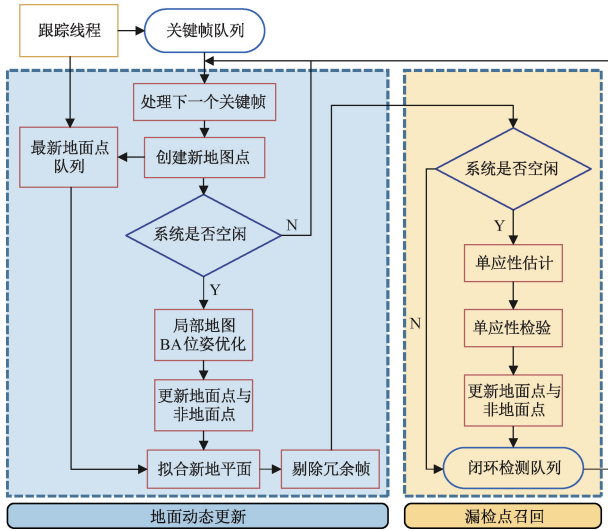


图 3 地面连续分割的工作流程

Fig. 3 Workflow of continuous ground segmentation

3.1 动态分类与更新

虽然 RANSAC 鲁棒估计算法可被用来从给定的匹配点对中搜索主导单应性,但其基于随机采样的特性导致了较差和不可预测的速度性能,限制了其实时应用^[22]。为了克服该问题,该算法通过维持一个容量为 N 的滑动窗口队列来管理观测到的最新地面点:每当新一帧图像被处理时,该帧对应的地面点将被添加至队列中;若此时队列大小超过预设容量 N ,则移除最早加入的地面点以确保队列规模不超过 N 。具体算法步骤如下:

- 1) 在局部建图线程等待当前关键帧,在新关键帧中创建新的三维点,并将其中的地面点加入地面点队列;
- 2) 利用当前关键帧及其共视关键帧进行局部 BA 优化,从而校正关键帧与三维地图点位置信息,更新局部地图;
- 3) 根据当前地面参数的估计值,通过三维点到地面的距离进行判断,对所有共视关键帧的地图点分类,并把原先非地面点更新为地面点的点加入地面点队列;
- 4) 根据跟踪线程最新观测到的地面点与建图线程中动态分类获得的地面点集合,根据式(9)求取地平面的最小二乘解,从而更新当前的地平面参数;
- 5) 剔除冗余的历史关键帧,释放当前关键帧,并根据关键帧是否处理完毕来执行漏检点召回或继续处理下一帧的建图过程。

简而言之,它根据前一帧的地面参数,通过当前帧更新的点云,计算出共视图中每个地图点到当前估计的地平面的距离 d :

$$d = \frac{|\mathbf{n}_g^T \mathbf{p} + 1|}{\|\mathbf{n}_g\|} \quad (9)$$

并根据所设定的距离阈值 ϵ ,将距离小于该阈值的点分类为地面点,而将距离大于该阈值的点分类为非地面点。

然后根据所有共视图中的地面点求出地平面的最小二乘解,从而计算出当前帧的地面参数。

将所有的 3D 点进行平面拟合可能会导致计算复杂度较高,通过该方法,能够实时地在每个关键帧根据当前地图信息来更新地面参数,并对地图点进行准确的分类。相比于使用全局点进行平面拟合的方法,该方法仅使用大小为 N 的最近地面点队列中的点进行更新,从而大大减少了计算量。

3.2 基于单应性的地面点检测

在进行地平面与地面点的动态更新时,不可避免地会出现少检、漏检的情况。因此,本文提出了一种基于单应性的闲时检测的方法,当系统空闲时,通过单应性估计来获取更多的地面点,从而减少误判。

根据图 3 所示,每当新的关键帧传入建图线程时,将会进行地图点的更新。当满足前文所述的特定的阈值条件时,将其加入到地图中。除此之外,当系统已满足实时运行、具有充分的计算资源时,将会在系统闲时与其共视特征点最多的共视关键帧 I_m 使用地面特征点计算其单应性矩阵 \mathbf{H}_{cm} 。两个关键帧的单应性过程如 2.2 节中所述。

当完成了单应性的计算后,用单应性矩阵计算当前关键帧 I_c 与共视关键帧 I_m 的非地面特征点的单应性投影误差:

$$e_H = \|\mathbf{H}_{cm} \mathbf{x}_m - \mathbf{x}_c\|_2 \quad (10)$$

若特征点的投影误差通过自由度为 2 的卡方检验,则该点为更新过程中的检漏点,其特征点对应的三维地图点需要重新标记为地面点。如图 4 所示,在动态更新的过程中,不进行单应性检验的情况下,地面区域存在一些漏检点;进行检验后,地面区域的漏检点被重新正确识别为地面点。




图 4 通过单应性检验获取更多地面点

Fig. 4 Obtaining more ground points through homography inspection

4 实验和评估

为了全面验证本文提出的地面分割方法的有效性,本文设计了一系列实验,涵盖了多种环境条件和数据集。实验部分包括算法测试和性能测试两个主要部分。算法测试旨在通过不同场景下的实验数据,展示本文方法在地面分割方面的定性表现。性能测试则通过定量分析,评估算法的分割准确度与计算速度,根据分割性能来权衡设定的参数。在评估过程中,将准确性的评估分为两个维度:地平面

的精度和地面点的准确度,全面地评估算法在不同场景下的表现,并与其他地面分割方法进行了性能对比,以验证其在实际应用中的可行性。实验将人工分割结果作为真值,对算法分割结果进行定量评估。

4.1 算法测试


为验证本文提出的地面分割方法在不同环境下的有效性和全面性,实验数据覆盖了经典开源评估数据集包括 TUM 数据集与 KITTI 数据集,以及多个场景下的自采数据。自采数据在室内外多种环境下进行,所有环境均具有充足的光照且保持地面的平整。采集设备包括手持豪威 OV64B 传感器和安装在移动机器人上的 ZED2 相机,二者均以 640×480 分辨率采集单目图像数据。其中,安装在机器人上的相机保持固定高度拍摄,而手持相机的高度则根据操作者的变化而不固定。数据处理所使用的计算环境为配备 AMD R5 5600 处理器和 16 GB 内存的计算平台,搭载 Ubuntu 18.04 系统。在相同计算环境中,将本文算法与原版 ORB-SLAM2 算法的运行结果进行对比。通过开源数据及自采数据的多维度测试,评估了算法在不同场景下的分割性能。

1) 室外场景

本场景为图书馆前所采集的一片室外空地,其环境与相机的运动轨迹如图 5 所示,在该室外区域环境下,本文方法得到的地面点的分割结果与环境点云如图 5(a)、(b)所示。



(a) 图像的地面特征与非地面特征
(a) Ground features and non-ground features of image



(b) 环境点云中的地面点与非地面点
(b) Ground points and non-ground points in the environment


图 5 室外环境实验结果

Fig. 5 Experimental results of outdoor environment


2) 办公室场景

在办公室环境下,通过本文方法得到的地面点的分割

结果与环境点云如图 6 所示。由图 6(a)可知,实验室的地面上存在明显的纹理,特征较为明显。因此产生的地面点云较为密集,占据了点云的大部分,从侧面观察点云,图 6(b)中的地面点云较为平整,且覆盖了场景的全部区域,分割较为准确。



(a) 图像的地面与非地面特征点
(a) Ground and non-ground feature points of image



(b) 环境点云中的地面点与非地面点
(b) Ground points and non-ground points in the environment

图 6 办公室环境实验结果

Fig. 6 Experimental results of office environment

3) 图书馆场景


在图书馆中穿越自习室与大厅区域,通过本文方法获得相机的运动轨迹与地面稀疏点云如图 7 所示。

在轨迹前半段,场景区域结构化明显,具有丰富的地面特征,因此构建出了大量地面点云;而在走廊、大厅区域中,由于地面为瓷砖,地面上的纹理更为稀少,且瓷砖在地面上存在严重的倒影现象,导致初始化困难。同时由于地面区域边界比较明晰,所以地面点云大都集中在走廊与墙角的边缘处。本文方法得到的地面模型能够基本准确地反映地面可通行区域的覆盖范围,但由于倒影现象的影响,易在地面下方产生虚假点云。该实验环境对于地平面的初始化与跟踪具有一定的挑战。图 7(a) 中的倒影特征与图 7(b) 中地面点下方的点云反映了实验过程中因倒影现象造成的干扰。


4) 地下车库场景

为了验证本文方法在更大场景下的有效性,在长约 100 m 的地下车库这一更复杂的环境下进行了实验。

在地下车库环境中,本文方法得到的地面分割结果与环境点云如图 8 所示。该地下车库光线较暗、地面纹理较少、存在多种障碍物(如车辆、柱子等)与坑槽,这些因素对地面分割算法提出了更高的挑战。图 8(a) 展示了地下车



(a) 图像地面区域存在许多非地面特征点
(a) Many non ground feature points in the ground area



(b) 环境点云中的地面分割结果
(b) Ground segmentation results in environmental point clouds


图 7 图书馆环境实验结果

Fig. 7 Experimental results of library environment

库的图像,其中地面特征点较为稀疏。图 8(b) 展示了相机运动轨迹与分割后的环境点云,可直观地观察到地面分割的效果。



(a) 图像中地面纹理较少
(a) Few ground textures in the image



(b) 环境点云中的地面分割结果
(b) Ground segmentation results in environmental point clouds

图 8 地下车库环境实验结果


Fig. 8 Experimental results of underground garage

5) KITTI 数据集实验

为验证本算法在较大范围环境下的分割性能,在 KITTI 数据集的 KITTI_01、KITTI_02 序列中进行实验,该场景为城市中的道路环境,实验分割结果如图 9 所示。在城市道路的大范围、大尺度场景下,单目估计导致远处三维点的位置误差较大,可能使部分地面点未被识别为地面。此外,此场景下的光照较为均匀,但道路中的地面纹理较少,仅在道路标线、路沿与墙角处存在较为稀疏的地面特征点,因此分割出的地面点较少。尽管地面特征占比较小,本文方法依旧获得了比较准确的地面分割结果。



(a) KITTI_01



(b) KITTI_02

图 9 KITTI 数据集实验结果

Fig. 9 Experimental results of KITTI dataset

6) 实验效果

上文的实验结果清晰地展示了 ORB-SLAM2 在单目视觉条件下生成的稀疏点云,其中地面点占据了显著的比例。原始的 ORB-SLAM2 算法仅关注点云的相对位置信息,而未能识别和利用地平面的特性,对场景的描述效果很弱,导致了算法无法进行地面分割、构建平面地图、识别特定目标,从而无法指导视觉系统的导航。本文提出的方法不仅成功地补充了地平面的位置信息,还对点云进行了分类,有效地覆盖了单目相机视野内的地面区域。此改进显著提升了算法的实用性,为视觉导航系统提供了更丰富的可能性。

4.2 性能测试

本实验将从 9 个图像序列中生成的点云进行人工标注分类作为真值,计算其分割精度与运算速度。其中包含 KITTI 与 TUM RGBD 数据集下的 4 个场景,与自录数据集下的室外、走廊、办公室、书库、地下车库场景。

1) 点云分割精度

为定量评估本文算法的分割效果,采用 Lee 等^[26]提出的精确率 (precision, P)、召回率 (recall, R) 和 F_1 分数 3 个评价指标来分析^[2]:

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (11)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (12)$$

$$F_1 = \frac{2N_{TP}}{2N_{TP} + N_{FP} + N_{FN}} \quad (13)$$

式中: N_{TP} 表示地面点被正确标记的数量; N_{FP} 表示非地面点被错误地标记为地面点的数量; N_{FN} 表示地面点被错误地标记为非地面点的数量。 P 值越大, 表明从分割结果中误分割的比例越少、正确识别为地面点的准确性越好; R 值越大, 表明数据集中真实的地面点云被正确分割的比例越多, 找到所有正确地面点的能力越好; F_1 分数是精确率和召回率的调和平均值, 它综合考虑了精确率和召回率, 是一个平衡两者之间关系的指标。

首先考察地面阈值对所提出指标的影响。图 10 显示了地面分割精度随地面阈值 ϵ 的变化曲线。分析该变化趋势可知, 由于 ϵ 的增大使得更多地面点被识别, 导致了召回率的提升。然而较高的 ϵ 值可能导致一些原本不属于地面的邻近点被错误分类为地面点, 从而引发精确率的下降。在多数情况下, F_1 分数在 0.03~0.06 之间逐渐增加, 而在 0.06~0.10 之间逐渐减小。因此, 将地面阈值设为 0.06 可在整个实验中产生最合理的地面分割性能。




图 10 分割性能随地面阈值的变化曲线

Fig. 10 The variation curve of segmentation performance with ground threshold

根据所设置的地面阈值, 实验计算出了本文所提出的方法在不同环境下的分割精度, 并将结果进行了展示, 如表 1 所示。

本研究通过在 9 个不同场景下对点云数据进行地面分割的实验, 验证了所提出方法的有效性。实验结果表明, 所提出的方法在所有数据集上均展现出了较高的分割精度。其中, 分割精确率 (P 值) 在所有场景中均超过了 0.95, 而 F_1 指标也均超过了 0.92。表 1 中的数据表明, 本文所提出的单目视觉下的点云地面分割方法在处理不同场景的点云数据时, 均能保持较高的精确率和召回率。

具体而言, 由于小型简单场景中的序列长度较短同时地面较为平整, 在 freiburg2_pioneer_slam2 与 ours_office 场景下, F_1 指标达到了 98% 以上, 显示出了极高的分割性能。这主要是因为这些场景中的地面特征较为均匀, 减少

表 1 不同场景下地面分割的精度
Table 1 Accuracy of ground segmentation in different scenarios

数据集	P	R	F_1
KITTI_01	0.966 2	0.980 2	0.973 1
KITTI_02	0.959 3	0.976 6	0.967 9
freiburg1_floor	0.981 3	0.964 0	0.972 6
freiburg2_pioneer_slam2	0.979 2	0.996 5	0.987 8
ours_square	0.963 0	0.890 4	0.925 2
ours_library	0.977 2	0.908 5	0.941 6
ours_office	0.979 9	0.982 8	0.981 4
ours_stackroom	0.950 2	0.944 5	0.945 7
ours_carpark	0.965 9	0.973 7	0.969 8

了算法的误判。同时在 KITTI 数据集和地下车库和较大尺度的场景下, 得益于连续分割策略中对地面的动态更新, 即使在相机运动较长距离后也能达到 96% 以上的 F_1 分数。这表明在较为规则的大小场景中, 所提出的方法均能够有效地进行地面分割, 且具有很高的准确性。

但在室外 ours_square 场景中, 由于不够平整的地面和地面与部分草丛之间模糊的边界增加了误判的可能性。导致该场景下召回率相对较低 (0.890 4)。这可能意味着在室外场景中, 地面与非地面点的区分具有更高的难度, 更易因为地面边界与形状的不规则影响分割算法的性能。

而在 ours_library 场景的实验中, 倒影现象对地面分割算法的性能构成了一定挑战。由于倒影现象在地面下产生的虚假倒影点, 图像中的地面特征点数量少于其他场景, 因而部分非地面点被错误地分类为地面点, 其召回率取得较低的水平 (0.908 5)。这表明倒影现象对于地面分割算法的性能具有负面影响, 可能会导致算法造成一定的漏检错检, 从而降低了分割的准确性。此外, 倒影还可能对地面点云的不连续性, 进一步影响地平面的初始化和跟踪。

尽管在不同数据集下的场景复杂度存在差异, 但所提出的方法仍能保持稳定的性能。这表明方法具有一定的泛化能力, 能够适应不同环境条件下的地面分割任务。

为了进一步评估本文算法的性能, 将本文算法与 Patchwork^[26]、R-GPF^[27]、文献[28]和文献[17]所提出的地平面提取算法在 KITTI 与 TUM 数据集进行了对比测试。其中 Patchwork 与 R-GPF 为基于激光雷达的地面分割方法, 使用直立度平整度等参数进行地面的估计, 而文献[28]的 Enhanced RANSAC 方法与文献[17]为基于深度相机的点云分割方案。其中对于 Patchwork, 设置直立度 $\theta\tau = 45^\circ$, $\{N_{\theta,1}, N_{\theta,2}, N_{\theta,3}, N_{\theta,4}\} = \{16, 32, 54, 32\}$, $L_{\min} = 2.7 \text{ m}$, $L_{\max} = 80.0 \text{ m}$; 对于 R-GPF, 设置 $N_{\text{seed}} = 20$, $z_{\text{seed}} = 0.5$, $M_d = 0.15$, $M_h = -1.1$ 。 z_{seed} 和 M_d 越小, 标准越保守。最后, 对于 Enhanced RANSAC, 使用 4 cm 的 K 邻域半径搜索, 并使用 2 cm 的距离阈值来拟合平面模型。

其余情况均使用默认的参数设置。对比结果如表 2 所示。

表 2 本文提出的方法与其他地面分割方法的性能对比
Table 2 Performance comparison of the proposed method with other ground segmentation methods

方法	传感器	P ↑	R ↑	F ₁ ↑
本文方法	单目相机	0.974 5	0.956 0	0.965 2
Patchwork ^[26]	激光雷达	0.918 8	0.928 4	0.924 0
R-GPF ^[27]	激光雷达	0.746 8	0.981 5	0.845 2
Enhanced RANSAC ^[28]	深度相机	0.988 5	0.940 5	0.963 9
文献[17]	深度相机	0.934 0	0.621 3	0.746 2

根据表 2 的实验结果,本文方法的分割精度高于 Patchwork、R-GPF,以及基于深度相机的方法。与稠密点云相比,单目视觉构建的地面点云更为稀疏,不具有较强的结构特征;但视觉特征点的匹配与单应性检测可以为地平面的估计提供更强的约束作用。上述分析表明,本文算法能够有效利用单目相机的单应性估计分割 SLAM 过程的地面点云,具有较高的精度。

2) 地平面精度

为了定量衡量地平面的精度,本文将基于标注地面点真值拟合得到的地平面视为地平面真值,并采用以下指标进行评估:

(1) 欧几里得距离(L2 范数):通过计算得出的地面向量与真实地面向量之间的欧几里得距离,来衡量两者在空间上的偏差。

$$D_{L2} = \| \mathbf{n}_{\text{est}} - \mathbf{n}_{\text{true}} \|_2 \quad (14)$$

(2) 角度误差:通过计算得出的法向量与真实法向量之间的夹角差异,以角度为单位来表示。该误差越小,意味着测得的地平面向量与真实情况的夹角偏差越小,法向量的准确性越高。

$$e_{\theta} = \arccos\left(\frac{\mathbf{n}_{\text{est}} \cdot \mathbf{n}_{\text{true}}}{\|\mathbf{n}_{\text{est}}\| \|\mathbf{n}_{\text{true}}\|}\right) \quad (15)$$

(3) 平面距离误差:通过比较原点(相机的初始位置)到计算出的地平面之间的距离 d_{est} 与原点在真实地平面上的

高度 d_{true} ,可以得到它们之间的平面距离误差。但由于单目尺度的不确定性,本文将初始帧到地面的距离 d_{est} 作为基准,得到尺度归一化情况下的平面距离误差,从而来评估地平线方程的截距精度。

$$e_d = \frac{d_{\text{est}} - d_{\text{true}}}{d_{\text{est}}} \quad (16)$$

应用本文所提出的方法,计算以上 3 项指标在不同环境下的结果,所得到的数据如表 3 所示。

表 3 不同场景下的误差指标

Table 3 Error indicators under different scenarios

数据集	D _{L2}	e _θ /(°)	e _d
KITTI_01	0.005 6	0.064 4	0.004 2
KITTI_02	0.005 3	0.093 9	-0.002 6
freiburg1_floor	0.002 5	0.080 3	-0.000 8
freiburg2_pioneer_slam2	0.029 5	0.113 3	0.007 4
ours_square	0.003 3	0.030 5	-0.002 5
ours_library	0.004 1	0.056 7	-0.002 0
ours_office	0.003 1	0.040 4	-0.001 4
ours_stackroom	0.010 5	0.120 2	-0.002 5
ours_carpark	0.009 7	0.044 6	0.006 0

根据表中的数据,实验得到的地面的角度误差均小于 0.13°,尺度归一化的平面距离误差均小于 0.008。表明本方法能够进行较高精度的地平面估计。

3) 运算速度

随着系统运行时间的增长,累积的点云数据量逐渐增加,导致运算时间随之变化。本文方法的运算时间随时间变化的曲线如图 11 所示。在初始化阶段,算法执行基于 RANSAC 的单应性矩阵估计与单应性分解,这一过程具有相对较高的耗时。一旦初始化完成并进入地面连续分割阶段,由于初期点云数据量较小,运算时间保持在较低水平,以避免对定位与建图资源的占用。随着更多数据的积累,尽管点云规模不断增大,本方法有效控制了运算时间的增长,表现出良好的时间复杂度。




图 11 运算时间随帧数变化的曲线

Fig. 11 Curve of operation time varying with frame number

在实际的运行中,本文方法与 ORB-SLAM 算法平均每一帧各阶段的运算时间如表 4 所示。从表 4 数据可以看出,相比较于 ORB-SLAM2,本文方法中的 SLAM 过程的运算时间基本不变。增加的运算时间大部分集中于单应性矩阵的分解,但该操作仅在单目 SLAM 系统初始化时进行,因此不影响系统运行时的性能。同时由于本方法添加的所有计算均在局部建图线程触发关键帧时执行,因此实际分摊到每一帧的额外计算时间非常短。

表 4 各模块平均运算时间

Table 4 Average operation time of each module

模块	运算时间/ms	
	本文方法	ORB-SLAM2
SLAM 过程	19.503	19.512
单应性矩阵估计	3.753	—
单应性分解	3.953	—
地面点更新	1.263	—
平均单帧耗时	20.405	19.512

经过实验测试,本文方法能够达到 30 fps 的平均运行速度,达到实时运行。本文方法的每帧平均耗时为 20.405 ms,相较于 ORB-SLAM2 的平均单帧耗时提升了 4.57%,变化不明显,验证本文方法能达到较快的运算速度,能够满足预期的应用要求。

5 结 论

本文针对单目视觉 SLAM 中地面信息缺失的问题,提出了一种基于单应性和动态增长的地面检测方法。该方法基于地面为平面这一假设,并结合相机硬件配置的特点,在 ORB-SLAM2 框架的基础上进行了扩展,引入了地面分割功能。算法分析与实验结果表明:

该方法能够有效利用单目相机估计相对运动,同时捕捉地面区域图像的纹理信息,通过共面点的单应性估计与连续分割策略,对三维点云进行地面与非地面的分类。

在公开数据集的仿真实验中,算法能达到 96.79% 以上的分割精度,同时在本地测试数据上,算法能达到 92.52% 以上的精度,并通过与其他地面分割方法的对比验证了所提出方法的有效性。

该算法获得了地平面方程,计算后表明其法向量能够达到 0.13° 以内的角度误差与 0.008 以内的尺度归一化平面距离误差。使用不同数据的实验表明,所提出的算法在硬件成本和计算成本上均有显著的优势,能够达到实时运行,具有实际部署的前景。

本文算法目前只实现了地面的检测工作,如何利用地面信息参与进定位与建图工作,将地面约束加入局部优化与全局优化过程中、为上层应用提供更丰富的辅助信息,是下一步工作的重点研究方向。

参考文献

- [1] 张林. 室内动态环境地图构建方法研究[D]. 成都: 四川大学, 2022.
ZHANG L. Research on the construction method of indoor dynamic environment map [D]. Chengdu: Xihua University, 2022.
- [2] 张佩翔, 王奇, 高仁璟, 等. 局部阈值自适应的地面点云分割[J]. 光学精密工程, 2023, 31(17): 2564-2572.
ZHANG P X, WANG Q, GAO R J, et al. Ground point cloud segmentation based on local threshold adaptive method [J]. Optics and Precision Engineering, 2023, 31(17): 2564-2572.
- [3] 张釜恺, 芮挺, 何雷, 等. 一种低成本的机器人室内可通行区域建模方法[J]. 北京航空航天大学学报, 2019, 45(12): 2470-2478.
ZHANG F K, RUI T, HE L, et al. A low-cost indoor passable area modeling method for robots[J]. Journal of Beijing University of Aeronautics and Astronautics, 2019, 45(12): 2470-2478.
- [4] GUO D, YANG G, QI B, et al. A fast ground segmentation method of LiDAR point cloud from coarse-to-fine [J]. IEEE Sensors Journal, 2023, 23(2): 1357-1367.
- [5] STEINKE N, GOEHRING D, ROJAS R. GroundGrid: LiDAR point cloud ground segmentation and terrain estimation [J]. IEEE Robotics and Automation Letters, 2024, 9(1): 420-426.
- [6] SKUDDIS D, KOEBERLE J, HAALA N. LiDAR ground segmentation and modeling for mobile robots in unstructured terrain [C]. 2022 8th International Conference on Automation, Robotics and Applications (ICARA 2022). New York: IEEE, 2022: 57-61.
- [7] LENG ZH X, LI SH, LI X, et al. An improved fast ground segmentation algorithm for 3D point cloud[C]. 32nd 2020 Chinese Control And Decision Conference (CCDC 2020). New York: IEEE, 2020: 5016-5020.
- [8] 张权. 基于障碍物识别的轮腿式移动机器人自主越障研究[D]. 哈尔滨: 哈尔滨工业大学, 2021.
ZHANG Q. Research on autonomous obstacle negotiation of wheel-legged mobile robot based on obstacle detection [D]. Harbin: Harbin Institute of Technology, 2021.
- [9] 贾继阳, 黄振峰, 梁巍. 基于凹包算法的点云地面分割方法[J]. 电子测量技术, 2023, 46(15): 67-72.
JIA J Y, HUANG ZH F, LIANG W. Method of point cloud ground segmentation based on concave hull [J]. Electronic Measurement Technology, 2023, 46(15): 67-72.

- [10] LI B R, QIAN X L. Real-time detection of travelable path based on image point cloud[C]. 2019 Chinese Control Conference(CCC), 2019: 4608-4612.
- [11] JIN X, YANG H, LIAO X, et al. A robust Gaussian process-based LiDAR ground segmentation algorithm for autonomous driving[J]. *Machines*, 2022, 10(7): 507.
- [12] ZHANG C, CZARNUCH S. Perspective independent ground plane estimation by 2D and 3D data analysis[J]. *IEEE Access*, 2020, 8: 82024-82034.
- [13] 杨少舟, 龙东平, 陈继尧, 等. 基于 M 估计算法的三维点云平面拟合方法研究[J]. *电子测量技术*, 2024, 47(5): 70-76.
- YANG SH ZH, LONG D P, CHEN J Y, et al. Research on three-dimensional point cloud plane fitting method based on M-estimation algorithm [J]. *Electronic Measurement Technology*, 2024, 47(5): 70-76.
- [14] TIAN Y, SONG W, CHEN L, et al. Fast planar detection system using a GPU-based 3D Hough Transform for LiDAR point clouds [J]. *Applied Sciences*, 2020, 10(5): 1744.
- [15] SONG W, ZHANG L F, TIAN Y F, et al. 3D hough transform algorithm for ground surface extraction from LiDAR point clouds [C]. 2019 International Conference on Internet of Things(iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data(SmartData). New York: IEEE, 2019: 916-921.
- [16] 刁羽峰. 面向实时应用的视觉定位与稠密建图研究[D]. 重庆: 重庆大学, 2022.
- DIAO Y F. Research on visual localization and dense mapping for real-time applications[D]. Chongqing: Chongqing University, 2022.
- [17] 江岑倩. 基于 ToF 的野外地面分割方法研究及在仿真平台的应用[D]. 北京: 北京工业大学, 2020.
- JIANG C Q. Research on field ground segmentation method based on ToF and application in simulation platform [D]. Beijing: Beijing University of Technology, 2020.
- [18] KIM T, LIM S, SHIN G, et al. An open-source low-cost mobile robot system with an RGB-D camera and efficient real-time navigation algorithm [J]. *IEEE Access*, 2022, 10: 127871-127881.
- [19] LI Z, SONG F, CLARK B C, et al. A wearable device for indoor imminent danger detection and avoidance with region-based ground segmentation[J]. *IEEE Access*, 2020, 8: 184808-184821.
- [20] CAKIROGLU O, WIESER V, ZELLINGER W, et al. Detection of the 3D ground plane from 2D images for distance measurement to the ground[C]. *Database and Expert Systems Applications, DEXA 2022 Workshops*, 2022: 44-54.
- [21] XIONG L, WEN Y, HUANG Y, et al. Joint unsupervised learning of depth, pose, ground normal vector and ground segmentation by a monocular camera sensor[J]. *Sensors*, 2020, 20(13): 3737.
- [22] ZHOU J, LI B X. Homography-based ground detection for a mobile robot platform using a single camera[C]. 2006 IEEE International Conference on Robotics and Automation, USA: IEEE, 2006: 4100-4105.
- [23] ARROSPIDE J, SALGADO L, NIETO M, et al. Homography-based ground plane detection using a single on-board camera[J]. *IET Intelligent Transport Systems*, 2010, 4(2): 149-160.
- [24] 晏小彬, 彭道刚, 威尔江. 基于地平面的单目视觉辅助激光雷达 SLAM 研究[J]. *光学学报*, 2020, 40(24): 173-183.
- YAN X B, PENG D G, QI ER J. Research on ground-plane-based monocular aided LiDAR SLAM[J]. *Acta Optica Sinica*, 2020, 40(24): 173-183.
- [25] BUTT M M, ZHANG H, QIU X, et al. Monocular SLAM initialization using epipolar and homography model [C]. 2020 5th International Conference on Control and Robotics Engineering (ICCRE), 2020: 177-182.
- [26] LEE S, LIM H, MYUNG H. Patchwork plus plus: Fast and robust ground segmentation solving partial under-segmentation using 3D point cloud [C]. 2022 IEEE/RSJ International Conference on Intelligent Robots And Systems (IROS). New York: IEEE, 2022: 13276-13283.
- [27] LIM H, HWANG S, MYUNG H. Eraser: Egocentric ratio of pseudo occupancy-based dynamic object removal for static 3D point cloud map building [J]. *IEEE Robotics and Automation Letters*, 2021, 6(2): 2272-2279.
- [28] ZEINELDIN R A, EL-FISHAWY N A. Fast and accurate ground plane detection for the visually impaired from 3D organized point clouds [C]. 2016 SAI Computing Conference(SAI), 2016: 373-379.

作者简介

陈晔鑫, 硕士研究生, 主要研究方向为单目视觉 SLAM、点云处理、地面分割等。

E-mail: chenyeixin123@foxmail.com

张涛(通信作者), 博士, 教授, 主要研究方向为惯性组合导航技术、惯性/视觉定位技术等。

E-mail: zhangtao22@seu.edu.cn