

中图法分类号: TP29 文献标识码: A 文章编号: 1006-8961(2026)03-0958-15
论文引用格式: Zhong Z W, Shan Y X and Zhou X D. 2026. Bayesian inference-based terrain elevation map completion method for off-road environments. Journal of Image and Graphics, 31(3):0958-0972(钟梓玮, 单云霄, 周循道. 2026. 基于贝叶斯推理的越野环境高程地图补全方法. 中国图象图形学报, 31(3):0958-0972)[DOI:10.11834/jig.250193]

基于贝叶斯推理的越野环境高程地图补全方法

钟梓玮¹, 单云霄^{1*}, 周循道²

1. 中山大学人工智能学院, 珠海 519000; 2. 工业和信息化部电子第五研究所, 广州 510640

摘要: 目的 无人驾驶的应用已不再局限于城市环境, 正逐渐向野外扩展。在野外复杂环境中, 准确提取可通行区域并构建可通行地图, 对无人驾驶的安全行驶至关重要。与计算机视觉相比, 基于激光雷达的高程地图更适合表达野外复杂场景。然而, 受激光雷达稀疏性和环境遮挡等因素影响, 现有高程地图普遍存在信息缺失问题。为补全稀疏高程地图缺失信息并提高补全准确性, 提出一种融合多源数据并引入语义信息的稀疏核贝叶斯预测方法, 以完善高程地图, 进而获取更安全的可通行区域。**方法** 第1步: 融合相机的单目估计数据, 填补由于雷达近距离盲区导致的数据缺失; 第2步: 使用可通行条件的判断得到可通行和不可通行的二分语义, 赋予高程地图语义信息, 并对缺失高程信息的位置进行统计概率的判断, 得到缺失高程信息位置的语义; 第3步: 利用贝叶斯稀疏核结合缺失位置的语义进行推理预测, 补全相应缺失位置的高程信息。最后得到准确完善的高程地图, 提高可通行区域提取的准确性。**结果** 在公开数据集 RELIS-3D 和 TartanDrive2.0 上验证本文补全方法的有效性。使用本文方法完善后的高程地图, 在 RELIS-3D 数据集上, 信息缺失率从原本的 25.42% 降低到 1.56%, 误差均值是 0.045 5 m, 准确率 94.37%; 在 TartanDrive2.0 数据集上, 信息缺失率从原本的 65.16% 降低到 25.15%, 误差均值是 0.103 m, 准确率 93.28%。通过与现有方法在不同野外场景进行对比, 证明本文补全方法具有一定的泛用性和有效性。**结论** 本文提出的一种多源数据融合和考虑二分语义的贝叶斯稀疏核预测的高程地图补全方法, 可有效且准确地补全稀疏高程地图缺失的信息, 提高可通行区域的提取精度。

关键词: 高程地图; 语义稀疏核贝叶斯; 补全方法; 越野环境; 可通行区域识别

Bayesian inference-based terrain elevation map completion method for off-road environments

Zhong Ziwei¹, Shan Yunxiao^{1*}, Zhou Xundao²

1. School of Artificial Intelligence, Sun Yat-sen University, Zhuhai 519000, China;

2. Fifth Institute of Electronics, Ministry of Industry and Information Technology, Guangzhou 510640, China

Abstract: Objective Current research on autonomous vehicles primarily focuses on structured environments, such as self-driving on urban roads and highways, unmanned transport vehicles in warehouse logistics, and autonomous guidance robots in hospitals and banks. These scenarios are characterized by uniform environmental information and well-defined road

收稿日期: 2025-04-25; 修回日期: 2025-10-12; 预印本日期: 2025-10-19

* 通信作者: 单云霄 shanyx@mail.sysu.edu.cn

基金项目: 国家自然科学基金项目(62232008); 广东省自然科学基金项目(2025A1515010252); 智能产品质量评价与可靠性技术工业和信息化部重点实验室项目(CEPREI2023-02)

Supported by: National Natural Science Foundation of China(62232008); Natural Science Foundation of Guangdong Province, China(2025A1515010252); Key Laboratory of Quality Evaluation and Reliability Technology for Intelligent Product, Ministry of Industry and Information Technology(CEPREI2023-02)

boundaries, enabling autonomous vehicles to efficiently acquire road information, generate precise trajectory plans, and complete tasks safely and reliably. However, with continuous technological advancements, autonomous driving technology is gradually expanding into unstructured scenarios, including agricultural plant protection, field rescue, military reconnaissance, and field exploration. These environments often feature complex terrain, dynamic and variable conditions, sparse perceptual information, and lack clear boundaries between traversable and non-traversable areas. Moreover, different terrain characteristics have varying impacts on vehicle traversal, increasing the requirements for the autonomous navigation capabilities of unmanned vehicles. Therefore, in autonomous navigation tasks, the accurate extraction of traversable areas in complex off-road environments and the construction of traversability maps are crucial for the safe operation of autonomous vehicles. To extract traversable regions, autonomous vehicles need to use sensors such as cameras or LiDAR to acquire real-time environmental information, including obstacle locations and terrain features. This data are then processed to ultimately achieve the extraction of traversable areas. However, while cameras can capture rich semantic information in unstructured environments, their performance is susceptible to degradation due to lighting variations. By contrast, LiDAR provides accurate three-dimensional positional information of the environment and is less affected by lighting conditions. However, LiDAR point clouds lack strong semantic information, making it difficult to clearly interpret terrain features, and issues such as the sparse nature of LiDAR and environmental occlusions lead to widespread information gaps in existing elevation maps. To address the missing information in sparse elevation maps and improve the accuracy of the completed data, this paper proposes an elevation map completion method that utilizes multisource data fusion and a sparse kernel Bayesian prediction approach incorporating semantic information. This method enhances the elevation map and enables the extraction of safer traversable areas. **Method** The first step involves fusing monocular estimation data from cameras to fill gaps caused by LiDAR's near-range blind spots. The second step applies traversability condition judgments to obtain binary semantics (traversable and non-traversable), assigning semantic information to the elevation map. Statistical probability judgments are then used to determine the semantics of locations with missing elevation information. The third step employs Bayesian sparse kernel inference, combined with the semantics of missing locations, to predict and complete the elevation information at those locations. This process results in an accurate and refined elevation map, improving the precision of traversable area extraction. **Result** To validate the effectiveness of the proposed multisource data fusion and semantic-aware sparse kernel Bayesian prediction method for elevation map completion, multiple experiments were designed to individually test the efficacy of each module. First, real off-road datasets RELLIS-3D and TartanDrive2.0 were used as data sources, and a series of experiments was conducted. Comparative experiments were designed comparing the proposed method with other completion methods to verify the effectiveness of the proposed Bayesian inference-based elevation map completion method for off-road environments. The effectiveness, accuracy, and completeness of different methods were evaluated using metrics such as error, accuracy rate, and completion rate. On the RELLIS-3D dataset, the information missing rate was reduced from 25.42% to 1.56%, with a mean error of 0.045 5 m and an accuracy rate of 94.37%. On the TartanDrive2.0 dataset, the information missing rate was reduced from 65.16% to 25.15%, with a mean error of 0.103 m and an accuracy rate of 93.28%. Comparisons with existing methods across various off-road scenarios demonstrate the generality and effectiveness of the proposed completion method. To address the limitations of LiDAR-only completion methods, such as insufficient robustness and the inability to effectively complete nearby grids, the proposed algorithm adopts a multisource data fusion approach by incorporating monocular depth estimation to achieve effective completion of nearby grids. A comparative experiment was designed to validate the accuracy and effectiveness of the proposed monocular depth estimation network proposed in this chapter. Experimental results demonstrate that the depth estimation algorithm presented in this paper achieves the smallest error, confirming its effectiveness. **Conclusion** The proposed elevation map completion method, which integrates multisource data fusion and Bayesian sparse kernel prediction with binary semantics, not only obtains continuously varying elevation information in complex environments but also provides rich and accurate elevation data for cost computation in traversability cost maps, thereby achieving effective completion of elevation maps. To validate the effectiveness of the method, this chapter conducts accuracy verification and performance evaluation of each algorithmic module on the basis of real off-road environment datasets. Experimental results demonstrate that the proposed multisource data fusion module achieves the best performance in terms of both accuracy and completion rate. By systemati-

cally addressing issues such as elevation data sparsity, the proposed method effectively and accurately completes missing information in sparse elevation maps, significantly improving the precision of traversable area extraction.

Key words: elevation map; semantic sparse kernel Bayesian; completion method; off-road environment; traversable area identification

0 引言

无人驾驶系统的环境感知模块中,车前三维地图构建技术至关重要,其为后续的决策与规划提供了基础的环境空间信息表征(宁小娟等,2022;周梦如等,2022)。根据地图对环境信息描述方式的不同,现有方法主要可分为3类:特征地图、栅格地图和高程地图,其发展演进始终围绕着如何更精确、更高效以及更鲁棒地表征复杂三维环境这一核心问题(师瑞卓等,2022)。

首先,特征地图通过提取点云中的几何特征实现环境建模。Kagami等人(2010)利用主成分分析(principal component analysis, PCA)提取环境中的平面特征,但是该方法在非结构化野外地形的泛化能力有限。为进一步描述非结构场景中的复杂环境建模,Hähnel等人(2003)对点云数据使用概率扫描匹配算法,通过计算距离误差对点云进行配准并拟合出曲面特征,从而构建出特征地图。该方法虽然数据量小响应速度快,但是在非结构的越野场景下,难以描述复杂的环境特征,难以支撑非结构化环境下的精细规划。

为了解决特征地图难以描述复杂环境三维空间信息的问题,Wang等人(2021)利用高效的基于点云的神经网络进行障碍物识别,将栅格表示为占用、空白和未知3种状态,构建出占据栅格地图。该方法仅能提供环境的平面视图,缺乏高程维度信息。为此,Saarinen等人(2013)进一步提出将正态分布变换地图与三维占用栅格地图融合,构建新型三维栅格地图。该地图能够支持多分辨率建图,提升了地图在动态环境的适应性。Zhao等人(2021)提出了一种动态八叉树算法,并结合激光惯性里程计构建出三维栅格地图,部分优化了地图的精度和存储效率。Hornung等人(2013)提出了一种在八叉树结构中存储空间占用信息的地图,以体素形式构建出三维栅格地图。虽然三维栅格地图可以较好地还原空间三维地形信息,但其存储和计算开销与体素分

辨率呈指数级增长,在精度与效率之间难以权衡。

为平衡信息完整性与计算复杂度,高程地图作为一种2.5D地图表达方式得到广泛研究。它每个单元格仅存储均值和方差的高程统计量,既保留了地形关键垂直信息,又大幅降低了数据复杂度。Souza和Gonçalves(2016)创建了一种2.5D高程地图,每个栅格代表占用概率,并存储地形的高度和方差。Jaspers和Wuensche(2014)使用双目相机获取数据周围环境的深度信息,以B样条曲线估计地形,实现了车辆周围行驶区域2.5D高程地图的快速构建。Eidehall等人(2006)使用立体相机获取车前行驶区域的稠密点云,并生成观测区域的局部高程地图,以判断该区域的可通行性。Chilian和Hirschmüller(2009)利用视觉里程计和多帧图像数据进行匹配计算,将二维图像数据重建成三维地形地图。虽然通过相机可以获取环境稠密的空间数据,但是这些基于相机构建高程地图的方法对环境条件具有较高的敏感性,在强光照射或黑暗环境等极端条件下其效果均难以达到理想状态。后续,Fankhauser和Hutter(2016)利用激光雷达构建出高程地图,实现四足机器人在复杂环境下的行走能力。该算法充分考虑了机器人运行状态估计中的漂移现象和传感器噪声引起的不确定性影响,能够有效地反映周边地形信息,生成能够记录周围地形高程信息的栅格图。然而,由于该方法主要依赖单一的激光雷达,受雷达数据稀疏性和复杂环境的双重影响,部分区域可能无法返回任何高程信息,这将导致生成的高程地图信息存在缺失,进而影响后续的可通行区域提取以及决策规划。

针对基于稀疏雷达构建得到的高程地图存在数据缺失问题,Xue等人(2023)提出一种贝叶斯补全的方法,对稀疏高程地图进行补全。尽管该方法能够实现对大部分缺失数据栅格的补全,但由于其在建模过程中未能充分考虑观测数据与待预测数据之间的语义关联性,导致补全结果的准确率和补全率均较低。Shan等人(2018)提出利用稀疏雷达数据进行可通行区域建图,从而提高计算效率,并且使用

广义高斯核方法解决数据稀疏问题,然后再进行可遍历性区域的计算,由此得到可通行区域。该方法虽然可提高一定的计算速度,但在解决数据稀疏问题时并未考虑观测数据之间的语义关系,同时也未考虑实际雷达使用时的局限性,使得雷达周围有大量的缺失点,导致广义高斯核方法补全的准确率不足。

现有研究在解决高程地图数据缺失问题上已取得一定进展,但上述方法未能对缺失成因进行区分处理,仍存在显著局限性。激光雷达的数据缺失主要源于两个方面:一是传感器固有的物理盲区,二是环境遮挡导致的点云稀疏。前者需要外部信息源进行直接补充,后者则需利用上下文信息进行推断。现有方法未能针对这两种截然不同的缺失机制设计差异化的补全策略,因而难以实现全域高精度的重建。因此,开发一种能融合多源信息、区分缺失类型并引入语义感知的高程地图补全框架,对于提升无人系统在复杂环境下的感知鲁棒性至关重要。

为了解决对激光雷达的固有盲区以及复杂地形造成的严重遮挡问题缺乏专门优化的问题,本文提出一种高程地图缺失信息补全的方法,并在其基础上辨识可通行区域。具体地,首先借鉴 Fankhauser 等人(2018)提出的高程地图生成方法构建环境高程地图,并利用单目深度估计模块填补激光雷达自身的局限性导致的盲区。针对非盲区,采用二分语义的贝叶斯稀疏核预测的补全方法,弥补点云稀疏和环境遮挡导致的高程信息的缺失。最后,根据得到的栅格地图特性,定义带有可通行信息的地图。

1 方法

1.1 算法框架

基于考虑语义的贝叶斯补全高程地图算法框架如图1所示。具体方法为:1)利用激光雷达数据构建得到稀疏和缺失部分信息的高程地图。2)为了解决由于单一激光雷达数据的稀疏性,以及弥补近距离周围信息大量缺失的问题,利用相机采集得到的图像信息和单目深度估计网络估计深度信息,补全近距离激光雷达缺失的数据;接着利用高程地图丰富的地形信息,通过地形信息坡度、高度和粗糙度对每个栅格凹凸特性(Moosmann等,2009)进行通行代价的量化,计算栅格的可通行代价;最后根据设定的可通行阈值,获得可通行栅格和不可通行栅格两种语义类型,为每一个栅格赋予是否可通行的语义信息,构建二分语义高程地图,为后续预测补全模块做准备。3)为了解决由于复杂环境造成的遮挡和点云数据的丢失导致的信息缺失问题,首先,对丢失信息的栅格区域进行统计学概率分析,判断该栅格能否通行的最大可能性,确认该栅格的语义类型;其次,依据相应的类型,输入以缺失信息的栅格为中心的一定范围内具有相同类型的栅格的高程值,并利用基于稀疏核函数的贝叶斯进行预测,得到缺失信息的栅格的高程值,获得补全缺失信息后的高程地图;最后,根据补全后的高程地图,计算更准确的可通行区域,为无人驾驶车辆提供可靠的路径规划参考。

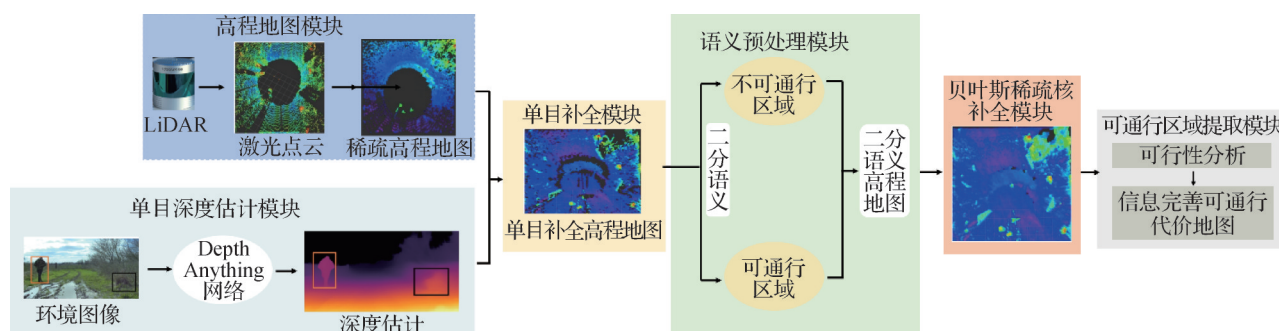


图1 基于二分语义的贝叶斯补全高程地图算法框架

Fig. 1 A Bayesian framework for completing elevation map based on binary semantics

1.2 高程地图模块

为了对所有区域的环境地形信息特征进行分析,本文方法基于瑞士苏黎世理工大学开源的

GripMap 工具(Fankhauser 和 Hutter, 2016)以及 Fankhauser P在构建四足机器人时使用的考虑不确定因素和状态估计漂移的基于栅格 GripMap 的高程

地图。在构建这个高程地图的过程中,机器人不断接收点云数据并映射进相应的栅格,然后对每个点云对应的栅格 $cell(x, y)$ 进行处理计算(Ma 等, 2020),得到相应的高程信息。通过高程地图模块,将基于激光雷达感知到的环境信息转变为描述周围地形特征的高程地图,并结合车辆的通行性能,构建适合车辆的可通行区域。图2是输入的点云经过高程地图模块后得到的高程地图结果。由图2(b)可见,右上角的红色矩形框内可看到有部分的缺失点,显示初始高程地图的高程信息是不够完善的。




图2 高程地图模块得到的高程地图结果

Fig. 2 Elevation map results obtained from the elevation map module ((a) original point cloud; (b) elevation map with missing information)

1.3 单目深度估计模块

1.3.1 单目深度估计方法

原始的高程地图由于激光雷达的稀疏性和环境遮挡导致的点云缺失将影响其完整性。如图2(b)的红色圈可见,以激光雷达为圆心的近距离范围内缺失大量的高程信息。主要原因如图3所示,由于激光雷达扫描有一定角度限制,导致近距离存在盲区,使得该区域缺少点云信息。为了解决激光雷达近距离构建高程地图失效的问题,本文通过单目深度估计方法,利用相机图像获取近距离的环境深度信息;通过引入相机的图像信息,增加新的数据源,使得环境的感知数据来源更丰富,并不再只有单一点云数据,进一步增加了基于高程地图可通行区域识别算法的鲁棒性。

单目深度估计还具备以下几个优势:1)相比于双目估计,单目估计的计算资源更低,硬件成本开销低;2)不需要进行图像之间的特征匹配,具有多场景的适用性;3)数据量需求小,这对要求高实时性的感




图3 速腾 Helios 激光雷达的扫描线束的分布

Fig. 3 Distribution of scan beams from the Helios LiDAR

知模块具有显著的优势。

利用 Yang 等人(2024)人工标注并且结合迁移学习数据标注方式获取的6 200万幅图像,使用这些图像训练了 Depth-Anything 单目深度估计网络。Depth-Anything 单目深度估计网络具有良好的泛化性,无需针对特定的场景进行训练,就可直接在陌生的场景下采集单目图像预测环境深度信息。

利用单目深度估计完善近距离的高程值信息原理如下: f 是相机的焦距, F_c 是相机坐标系, O 是世界坐标系, $P(X, Y, Z)$ 是世界坐标系下的某个点的位置信息, (u, v) 则是 P 在图像坐标系下的坐标。需要注意的是,单目深度估计网络得到的只是像素之间的深度相对关系,并不是相机坐标系下物体的绝对距离,因此需要通过小孔成像的原理,将得到的相对深度值,变成绝对的高程值。利用世界坐标系下的 P 点的实际深度和单目深度估计得到的深度进行比较,得到缩放的比例,通过比例关系,就可将单目深度估计的相对高程值转换为绝对高程值。通过单目深度估计网络得到的值是 (u, v) 到相机坐标系原点的距离,该距离设置为 D_c ; Y_c 是通过直角三角形公式得到的高程值;世界坐标系下的点 P 到原点的距离是 D 。则可以得到一个相对值到绝对值的比例关系,具体为

$$r = \frac{D_c}{D} \quad (1)$$

由三角形相似性和比例关系可以推理得到所需的高程值 Y , 具体为

$$Y = r \times Y_c \quad (2)$$

图4展示了单目深度估计原理。

1.3.2 数据融合标定

单目深度估计得到的高程值融合到高程地图里,需要对相机和激光雷达进行标定。在时间对齐上,本文使用相同时间戳的图像和点云数据,确保




图4 单目深度估计原理

Fig. 4 Principle of monocular depth estimation

在同一时刻下对高程地图进行的补全操作。在空间对齐上,本文通过 AutoWare 软件(Kato 等,2018)提供的 *lidar_camera_calibration* 标定软件库,使用张正友标定法(Zhang,2000)得到外参参数,相机内参参数由相机厂商提供,使用 CV 软件库结合已知的外参和内参参数可以得到高程地图中待预测栅格位置映射到图像中的位置,实现图像和高程地图的空间对齐。

实现相机和激光雷达的时空配准后,通过单目深度估计模块配合小孔成像原理和三角相似原理,可快速准确地补全激光雷达近距离缺失的高程信息,补全高程地图。

1.4 考虑语义的稀疏核函数的贝叶斯估计模块

使用单目估计模块只能补全近距离缺失的高程信息,对于远距离由于点云稀疏导致的信息缺失,或者是障碍物遮挡导致的高程信息缺失问题,单目深度估计模块无法解决。此外,由于野外非结构化的场景下,地形复杂,仅使用贝叶斯函数进行估计,不考虑点云的稀疏条件和缺失位置周围的语义类型容易产生预测错误。这主要源于输入的观测数据类型和待预测栅格语义类型不匹配。因此,保证输入观测数据类型和待预测栅格类型的一致性是关键。此外,考虑到在稀疏场景下补全预测,本文使用稀疏核作为核函数以提高预测的准确性。

1.4.1 二分语义预处理

激光的语义稀疏性导致构建的高程地图缺少相应的语义信息。现有直接采用近邻点补全的方法忽略了激光点云的语义信息(师瑞卓等,2022;Shan等,2018),难以有效实现准确补全。基于此,本文提

出利用高程地图丰富的地形特征特点,结合高度和坡度两个特征维度,获取可通行和不可通行的二分语义,并利用二分语义提高补全的准确率。由式(3)和式(4)可知, h_i 是位置*i*处的高度, h_t 是可通行高度, α_1 为权重信息; s_i 是*i*处的坡度, s_t 是可通行的权重; v_t 则是分类的阈值判断。高度 h_i 可以由高程地图得到;坡度 s_i 则可以通过*i*点处的法向量和*z*轴方向的夹角计算得到。

$$v = \alpha_1 \frac{h_i}{h_t} + \alpha_2 \frac{s_i}{s_t} \quad (3)$$

$$state = \begin{cases} 0 & v < v_t \\ 1 & \text{其他} \end{cases} \quad (4)$$

经过式(3)和式(4)的分类之后,可以得到图5的二分类语义示意图,其中灰色栅格代表缺失高程信息的栅格,0和1则分别代表该栅格是属于可通行类别和不可通行类别。

0	0	0	0	1	1	1	1
0	0	0	1	1	1	1	1
0	0	0	1	1	1	1	1
0	0	0	1	1	1	1	1
0	0	1	1	1	1	1	1
0	0	1	1	1	1	1	1
0	0	1	1	1	1	1	1
0	0	1	1	1	1	1	1

图5 二分语义示意图

Fig. 5 Schematic diagram of binary semantics

1.4.2 基于统计的语义预测

首先,对初始的高程地图进行二分语义的预处理后,每个含有高程值的栅格都取得了相应的语义信息;其次,使用二分语义对栅格类型进行0、1赋值,0代表可通行,1代表不可通行。由图5可知,灰色栅格表示需要补全高程信息的待预测栅格。由于信息的丢失,灰色栅格最初没有语义信息和高程信息,需利用周围已知栅格的数据,进行基于统计学概率分析和距离加权的语义预测,用最高概率的语义作为缺失信息栅格的语义类型。观测数据离得越远,其权重占比越小。具体为

$$P(x=1) = \sum_{i=1}^N \cos\left(\frac{d}{l}\right) \times f(i) \quad (5)$$

$$f(x) = \begin{cases} 1 & P(x=1) > \alpha \\ 0 & \text{其他} \end{cases} \quad (6)$$

式中, $P(x=1)$ 代表缺失信息的栅格属于1语义的置

信度, α 则是置信度阈值, 二分语义为 $f(i) = 0$ 或 1 。图 5 中, 黑色的 0 和 1 分别代表该栅格属于可通行和不可通行的类别。

1.4.3 考虑语义的稀疏核贝叶斯预测

得到待预测栅格的语义类型后, 对观测数据进行同类型的过滤, 只保留与待预测栅格语义类型一致的观测数据。二分语义示意图由图 5 可见。红色圈则是推理所需使用的观测数据集 $D = \{(x_i, y_i)\}_{i=1:N}$, 红色的 1 是待预测栅格通过周围已知的栅格语义推理得到置信度最高的语义类型。观测数据集的过滤是指将观测数据集中语义类型与待预测栅格类型 1 不一致的数据过滤掉, 而保留语义类型与待预测栅格类型 1 一致的数据。

贝叶斯推理运用在预测缺失高程值栅格的具体推理计算过程如下:

首先, 观测数据是已知且确定的, $D = \{(x_i, y_i)\}_{i=1:N}$, 并且 D 是经过语义过滤后, 与待预测栅格的 $\mathbf{x}^*$ 是一样的语义; 其次, 对缺失高程值的栅格的 $\mathbf{y}^*$ 进行值预测。根据贝叶斯估计方法原理, 对于信息缺失栅格的高程值, 其概率分布满足下式的形式, 具体为

$$\Theta: p(\theta^* | \mathbf{x}^*, D) \propto \int p(y^* | \theta^*) p(\theta^* | \mathbf{x}^*, D) d\theta^* \quad (7)$$

式中, $p(\theta^* | \mathbf{x}^*, D)$ 为输入值与贝叶斯估计参数的后验分布形式, 具体展开形式为

$$p(\theta^* | \mathbf{x}^*, D) \propto \int \prod_{i=1}^N p(y_i | \theta_i) p(\theta_{1:N}, \theta^* | \mathbf{x}_{1:N}, \mathbf{x}^*) d\theta \quad (8)$$

式中, $\mathbf{x}^*$ 为输入向量, 在本文算法中则是栅格的坐标 $cell(x, y)$, $\mathbf{y}^*$ 是待预测的栅格高程值, θ^* 为贝叶斯估计参数。根据贝叶斯估计的特性, 即参数之间是相互条件独立的, 利用下式代替计算 $p(\theta_{1:N}, \theta^* | \mathbf{x}_{1:N}, \mathbf{x}^*) d\theta_{1:N}$, 具体为

$$p(\theta_{1:N}, \theta^* | \mathbf{x}_{1:N}, \mathbf{x}^*) d\theta_{1:N} = \prod_{i=1}^N p(\theta_i | x_i, \theta^*, \mathbf{x}^*) p((\theta^* | \mathbf{x}^*)) \quad (9)$$

计算有了更进一步的优化后, 参数的后验形式为

$$p((\theta^* | \mathbf{x}^*, D) \propto \prod_{i=1}^N p(y_i | \theta^*)^{k(x_i, \mathbf{x}^*)} p((\theta^* | \mathbf{x}^*)) \quad (10)$$

式中, $k(x_i, \mathbf{x}^*)$ 是核函数。假设缺失高程信息值栅格的高度由正态分布 $y \sim \mathcal{N}(\mu, \sigma^2)$ 表示, 其高度共轭

分布同样满足高斯分 $\mu \sim \mathcal{N}(\mu_0, \sigma^2/\lambda)$, 其中, λ 表示先验置信度的超参数。当 λ 趋近于无穷大时, 代表当前模型对预测具有较高置信度; 而 λ 为 0 则表示本次预测计算准确度非常低。因此, 结合式 (10) 和上述假设, 可推导出原有公式的新表达形式, 具体为

$$p(\mu^* | \mathbf{x}^*, D) \propto \prod_{i=1}^N \exp \left\{ -\frac{1}{2} \frac{(r_i - \mu)^2}{\sigma^2} k(x_i, \mathbf{x}^*) \right\} \exp \left\{ -\frac{1}{2} \frac{(r_i - \mu)^2}{\sigma^2} \lambda \right\} \quad (11)$$

其次, 根据下式推理得到贝叶斯后验参数正态分布中的均值和方差。具体为

$$E[\mu^* | \lambda, D, \mathbf{x}^*] = \frac{\lambda \mu_0 + \sum_{i=1}^N k(x_i, \mathbf{x}^*) y_i}{\lambda + \sum_{i=1}^N k(x_i, \mathbf{x}^*)} \quad (12)$$

$$Var[\mu^* | \lambda, D, \mathbf{x}^*] = \frac{\sigma^2}{\lambda^*} \quad (13)$$

式中, $\lambda^* = \lambda + \sum_{i=1}^N k(x_i, \mathbf{x}^*)$ 。


一个好的核函数可以让预测值更加准确。考虑到雷达点云本身稀疏的特性, 以及越远距离的值的置信度越低的情况, 预测时, 需要将距离因素考虑进去。本文综合评估了多种核函数的贝叶斯估计方法, 最后使用一种考虑距离的稀疏核函数的方法, 核函数由下式给出, 具体为

$$k(\mathbf{x}_i, \mathbf{x}^*) = \begin{cases} \frac{2 + \cos\left(2\pi \frac{d}{l}\right)}{3} \left(1 - \frac{d}{l}\right) + \frac{1}{2\pi} \sin\left(2\pi \frac{d}{l}\right) & d \leq l \\ 0 & \text{其他} \end{cases} \quad (14)$$

式中, d 表示输入向量与参考栅格输入向量之间的 L2 范数 $\|\mathbf{x} - \mathbf{x}^*\|_2$, l 是参数。缺失高程值的待预测栅格位置 $\mathbf{x}^*$ 的高程值的预测值的计算式为

$$E[\mu^* | \lambda, D, \mathbf{x}^*] = \frac{\lambda \mu_0 + \sum_{i=1}^N k(\mathbf{x}_i, \mathbf{x}^*) y_i}{\lambda + \sum_{i=1}^N k(\mathbf{x}_i, \mathbf{x}^*)} \quad (15)$$

式中, D 是相同类型观测值的栅格集合。考虑语义的稀疏核函数贝叶斯估计模块得到的效果如图 6 所示。



(a) 初始信息稀疏的高程地图 (b) 贝叶斯估计补全后的高程地图

图6 贝叶斯估计效果图

Fig. 6 Effect of Bayesian estimation ((a) elevation map with initially sparse information; (b) elevation map completed using Bayesian estimation)

1.5 可通行地图构建

如图6(b)所示,使用单目深度估计模块和考虑语义的稀疏核函数贝叶斯估计模块后,缺失高程信息被补全,构建了完善的环境地形特征高程图。在估计模块中,为了填补栅格数据中缺失的高程值,采用了二分法进行语义分类,将区域划分为可通行和不可通行两类。然而,这种方法无法充分捕捉到复杂地形的特征,这对于高精度的地形分析和应用是不足的。基于此,本文基于补全完善后的高程地图,进一步细致化评估和量化栅格的可通行代价。本文算法主要使用坡度、高度、粗糙度和动力代价进行细致的量化评估。

高度通常是指地形的高度,可以由高程地图中获取得到。坡度通常是指水平面与路面上某一点的切平面的夹角,反映了路面的倾斜程度。坡度可以通过计算得到。使用随机采样一致性(random sample consensus, RANSAC)平面拟合的方法(Fschler和Bolles, 1981)对点云进行拟合,得到的平面可以表示为

$$Ax + By + Cz = 0 \quad (16)$$

式中, A 、 B 、 C 是平面系数,该平面法向量是 $\mathbf{n}_{\text{plane}}$, X - Y 平面的法向量 $\mathbf{n}_{xy} = (0, 0, 1)$ 。坡度为

$$S_{\text{ins}} = \arccos\left(\frac{|\mathbf{n}_{\text{plane}} \cdot \mathbf{n}_{xy}|}{|\mathbf{n}_{\text{plane}}| \cdot |\mathbf{n}_{xy}|}\right) \quad (17)$$

粗糙度是指路面起伏程度和不平整程度,一定程度上能表征路面的凹凸不平特性。粗糙度为

$$R_{\text{ns}} = \sum_{i=1}^n \frac{Ax + By + Cz + D}{\sqrt{x^2 + y^2 + z^2}} \quad (18)$$

本文算法中通行代价的计算还将加入无人驾驶车辆通过某栅格需要耗费的动力代价。具体计算方

式如下:对于待计算的栅格,算法将进行两次区域遍历。第1次遍历时,将记录每一个栅格以及其相邻 10×10 窗口大小其他栅格的局部高度差。如果该窗口中的任意栅格与窗口中心栅格之间高度差大于提前设定好的临界步高 h_{tire} ,则该区域内的临界步高将变为窗口内栅格最大高度差。第2次遍历时,圆形区域中心栅格步高计算为

$$h = \min(h_{\text{max}}, h_{\text{max}} \cdot \frac{n_{\text{st}}}{n}) \quad (19)$$

式中, h_{max} 为圆形区域中所有栅格的最大临界步高, n_{st} 为临界步高度高于步高阈值的单元格数, n 为圆形区域栅格数量。

最后,栅格的动力学代价计算具体为

$$D_{\text{yn}} = \frac{h}{h_{\text{tire}}} \quad (20)$$

式中, h_{tire} 为步高阈值,其真实意义为车辆行驶时不卡顿的最大高度,该值一般与无人驾驶车辆的轮毂大小有关,需要根据车辆大小提前设定。

综上所述,本节算法通过构建通行地图时量化计算栅格的通行代价,同时考虑坡度、粗糙度和动力学代价等多个指标,最终得到通行代价 C_{st} 。具体为

$$C_{\text{st}} = \alpha_1 \frac{S_{\text{ins}}}{S_t} + \alpha_2 \frac{R_{\text{ns}}}{R_t} + \alpha_3 D_{\text{yn}} \quad (21)$$

图7为采用本文算法构建的通行地图。图7(c)(f)是二维的代价地图,不同颜色代表不同的通行代价大小,颜色越深代表通行代价越大。

2 实验

2.1 实验设计和数据集的构建

为了验证本文方法的有效性,使用RELLIS-3D(Jiang等, 2021)和TartanDrive2.0(Sivaprakasam等, 2024)公开数据集。RELLIS-3D和TartanDrive2.0数据集的传感器设备如表1所示。这两个数据集是在相对复杂的野外场景下采集得到的,与结构化的城市场景不同,RELLIS-3D和TartanDrive2.0数据集场景更加复杂,可通行区域的识别难度更大,所以使用这两个数据集能够较好地评估本文提出的补全完善高程地图的可通行区域识别算法。图8是RELLIS-3D和TartanDrive2.0采集的野外场景。

实验由以下两个部分构成。首先,在两个数据集下进行对比实验,使用本文方法与其他的可通行




图7 可通行代价地图

Fig. 7 Traversability cost maps ((a) complex field scene; (b) elevation map of complex field scene; (c) cost map of complex field scene; (d) obstacle scene; (e) elevation map of obstacle scene; (f) cost map of obstacle scene)

表1 RELLIS-3D和TartanDrive2.0数据集的传感器信息
Table 1 RELLIS-3D and TartanDrive2.0 dataset sensor information

数据集	传感器型号	参数
RELLIS-3D	激光雷达:Ouster OS1	64线、200 m 测距、45° 垂直视场角
	单目相机:Basler acA1920-50gc	分辨率 1 920 × 1 200 像素,采样频率 50 帧/s
	惯导组合:Vectornav VN300 Dual Antenna GNSS/INS	采样频率 400 Hz, 朝向角分辨率 0.2°, 翻滚角、俯仰角分辨率 0.03°
TartanDrive2.0	激光雷达:velodyne	32线、200 m 测距,采样频率 10 Hz
	单目相机:MultiSense	分辨率 1 280 × 1 024 像素、采样频率 10 Hz
	惯导组合:NovAtel PROPAK-V3-RT2i GNSS	100 Hz IMU 数据,50 Hz 姿态数据

性地图构建方法进行对比,验证本文方法的优势;然后,分别针对方法中的两个核心模块(单目深度估计模块和信息补全模块),进行它们的有效性分析。

2.2 对比实验

为了验证本文提出融合多源数据的越野环境高程地图补全方法更有效,将在RELLIS-3D和TartanDrive2.0数据集上分别对比以下这4种方法对缺失高程值栅格补全的实验指标,并分别计算这几种方

法的误差和准确率。若补全得到的误差小于真值的0.3倍,则认为预测准确。

方法1:稀疏高程地图(Fankhauser等,2018)的方法;

方法2:不考虑语义下直接均值计算补全的方法(非语义+均值);

方法3:不考虑语义下稀疏核函数的贝叶斯估计方法(Shan等,2018)(非语义+稀疏核+贝叶斯);

本文方法:融合多源数据的补全方法(单目+语



图 8 RELLIS-3D 和 TartanDrive2.0 数据集采集场景

Fig. 8 RELLIS-3D and TartanDrive2.0 dataset collection scene

((a) puddle; (b) muddy; (c) dense vegetation; (d) obstacle; (e) mountain; (f) grass)

义+稀疏核+贝叶斯)。

本文主要在小障碍物、茂密植被、复杂野外场景和草丛 4 个场景进行实验,其中,小障碍物、茂密植被和复杂野外场景取自 RELLIS-3D 数据集,复杂草丛场景取自 TartanDrive2.0 数据集。首先,通过数据集的激光雷达数据构建出分辨率为 0.1 m、尺寸大小为 15 m × 15 m 的稀疏高程地图;其次,随机选取 20% 数量的具有有效值的栅格作为评估对象,记录它们的高程值作为真值;最后,利用上述 4 种方法依次对随机选出的栅格进行预测,分别计算它们的信息缺失率、误差、误差均值和准确率。实验结果如表 2 所示,误差分布如图 9 所示。

从表 2 可以看出,方法 2 信息缺失率最小,但因

其完全未考虑观测数据与待预测数据之间任何关联特性,虽然信息缺失率最低,准确性却是最差的,难以在实际中使用。而本文的信息缺失率仅次于方法 2,准确率和误差却是最好的。这是因为本文使用了单目深度估计模块来弥补激光雷达近距离局限性导致信息缺失的问题。所以在表 2 中,本文方法的平均缺失数量是相对较少的,并且由于考虑待预测栅格的语义类型,同时对观测数据进行语义预处理,使用相同语义类型的观测数据对待预测栅格进行预测,极大地提高了补全准确性,所以在误差和误差均值上本文方法也是最小的,表明本文方法的准确性和实用性是最好的。从表 2 的准确率可以看到,在 RELLIS-3D 数据集和 TartanDrive2.0 数据集下,本文

表 2 估计误差
Table 2 Estimation errors

方法	总栅格数量	RELLIS-3D 数据集					TartanDrive2.0 数据集				
		平均缺失数量	信息缺失率/%	误差均值/m	误差/m	准确率/%	平均缺失数量	信息缺失率/%	误差均值/m	误差/m	准确率/%
方法 1	22 500	5 719	25.42	—	—	—	14 661	65.16	—	—	—
方法 2	22 500	121	0.47	0.463 1	0.515	50.23	4 592	20.41	0.553 2	0.432	59.31
方法 3	22 500	2 161	9.6	0.261 1	0.374	83.25	9 274	41.22	0.215 3	0.265	81.26
本文	22 500	353	1.56	0.045 5	0.145	94.37	5 658	25.15	0.087 1	0.103	93.28

注:加粗字体表示各列最优结果。“—”表示没有该方法的数值结果。




图9 补全方法的误差分布

Fig. 9 Error distribution of Bayesian prediction ((a) scenes; (b) method two; (c) method three; (d) ours)

方法补全的准确率均为最高,说明本文方法有较好的补全精度。

图9为不同方法下贝叶斯预测的误差分布情况,是双图层结构,上层紫红色区域代表预测错误的位置,下层是预测补全后的高程地图,为俯视图视角,所以上层图层会覆盖下层图层,凸显高程地图中发生预测错误的位置。对比结果显示,在不考虑语义补全方法的情况下,方法2的红框内紫红色区域是比较多的,证明补全的错误点比较多;而使用了语义补全后,本文方法的红色框内的紫红色区域显著降低,由此可证明本文提出采用考虑语义的方法可有效提高准确率。在小障碍物场景,从图9(b)可以看出,方法2的大部分发生预测错误的分布集中于此,这是因为发生数据缺失的位置语义是不可通行的障碍物类型,由于没有语义判别,使用的观测数据可能会包含大量的路面点,导致预测的高程值更偏向于路面点,从而发生预测错误。由图9(d)可以看出,采用本文方法结合语义信息进行预测后,结果显示在有小障碍物场景上的预测误差显著减少。这一结果证实了引入二分语义分类机制可较好地提升预测精度。这主要是由于缺失高程值信息使障碍物类别的栅格被划分为不可通行的语义,并以此为过滤条件对观测数据进行过滤,使得观测的数据都是相同类型,从而提高了预测的准确度。在复杂野外场景,由图9(b)可见,方法2在狭窄可通行道路中,大

量的误差点出现在可通行类型的路面,这是因为过多采用周围高大树木的观测数值进行预测导致的预测错误。由图9(d)可见,本文方法考虑了语义之后,可明显发现误差点显著减少,只有部分错误点分布在高大树林和路面的分界处,这得益于本文的补全方法使用二分语义,提高了道路和高大树林交界处的补全准确率。

使用考虑语义的稀疏核贝叶斯估计方法得到的最终补全后的高程地图效果如图10所示。图10(b)中红框部分是因为激光雷达的稀疏性和野外环境的遮挡导致高程地图上出现信息缺失。而由图10(c)中的红框可见,由于遮挡导致缺失的信息已被准确地预测出高程值。

上述对比实验验证了本文方法相对其他补全方法,在野外越野环境下,其补全性和准确性上具有一定的优势。

2.3 单目深度估计模块

为了解决激光雷达在近距离场景失效的问题,本文方法提出融合单目相机,利用单目深度估计值估计近距离的高程值,完善高程地图。1)通过对比多种深度估计方法证明本文方法使用 Depth-Anything 深度估计网络是精准的;2)通过对深度估计误差进行量化计算,验证单目估计网络的有效性。

2.3.1 单目深度估计算法对比实验

将目前使用的 Depth-Anything 网络与其他几个最新的网络 MiDaS (monocular depth estimation via mutual information disentangling and aggregation strategy) (Ranftl 等, 2022)、DPT (dense prediction Transformer) (Ranftl 等, 2021)、glpn (global-local path networks) (Kim 等, 2022)、Marigold (Ke 等, 2024) 进行对比,结果如表3所示。

由实验结果数据可知,相对于其他的一些深度网络预测结果,Depth-Anything 和 DPT 网络在误差均值、误差和误差方差这几个指标下表现出良好预估深度信息的性能。Depth-Anything 和 DPT 相比,DPT 需要在预测之前对所需预测环境进行针对性的学习才能得到良好的效果,而 Depth-Anything 可使用预训练好的模型直接对陌生的环境进行预测,并且预测精度和 DPT 学习后的精度接近。

2.3.2 单目深度估计误差实验

为了更好地验证 Depth-Anything 单目深度估计网络的准确性,对估计深度的误差进行量化计算实




图10 考虑语义的稀疏核贝叶斯估计方法的效果

Fig. 10 Effect of semantic-aware sparse kernel Bayesian estimation method ((a) original laser point cloud map;
(b) sparse and information-deficient elevation map; (c) completion result of the proposed)

验。设计3组实验,分别是在0~5 m、5~10 m、10~15 m这3个不同范围中,测试单目深度估计误差的大小。结果如表4所示。

由于单目深度估计网络得到的估计值是相对深度,因此还需通过点云投影确定相对深度与绝对深度的比例关系。由于只有存在点云点投影到对应图像上的像素点可以获得深度真值,也就是真值是点

云点,估计值则是该点云点投影到图像上对应的像素点通过深度估计网络得到的深度值,因此表4中的结果仅能够在拥有投影点的像素中计算得到,参与计算的像素点个数也列在表4中。

由上述实验可以得出以下结论:1)单目深度估计在0~5 m的误差均值低于0.047 m,并且误差只有0.005 m,表现出极高的精准度。2)单目深度估计的精度,随距离的增大,精度相应下降;但由于该单目深度估计模块主要是为了补全近距离雷达失效的场景,该场景是在0~5 m范围内,使用Depth-Anything单目深度估计网络足够应对。3)在整体的0~15 m范围内,单目深度估计对地形高度误差低于0.3 m,在较为复杂颠簸的野外场景下,这个误差是可接受的。

2.4 多源数据融合并考虑语义的贝叶斯稀疏核预测的补全算法有效性实验

为了验证每一个模块对最终补全效果的贡献并验证本文算法对原始稀疏高程图的提升,本文统计了每一个模块的误差和信息缺失率,最终结果如表5和图11所示。

从表5可以看出,原始的稀疏高程地图缺失率为25.47%,经过单目深度估计模块和语义稀疏核贝叶斯模块补全之后,信息缺失率下降到1.56%;预测的误差均值为0.045 m,优于其他补全方法,证明了通过融合多源的单目相机数据可较好地提高补全的完善率和准确性;同时,使用考虑语义的稀疏核贝叶斯估计可更好地考虑观测对象和预测对象的语义类别关系,提高预测的准确性。

表3 单目深度网络对比

Table 3 Comparison of monocular depth networks

单目深度估计网络	误差 均值/m	误差/m	误差 方差/m ²
DPT	0.273	0.137	0.058
glpn	0.268	0.161	0.077
MiDas	0.319	0.171	0.067
Marigold	0.273	0.165	0.079
Depth-Anything	0.264	0.159	0.078

注:加粗字体表示各列最优结果。

表4 单目深度估计误差

Table 4 Monocular depth estimation errors

距离/m	计算点 数量	误差 均值/m	误差/m	误差 方差/m ²
0~5	501	0.047	0.005	0.002
5~10	3 626	0.168	0.054	0.023
10~15	1 664	0.363	0.281	0.111
0~15	5 767	0.264	0.159	0.078

注:加粗字体表示各列最优结果。

表 5 各模块误差计算
Table 5 Error calculation for each module

算法模块	信息缺失率/%	误差均值/m	误差/m	误差方差/m ²
稀疏高程地图	25.47	—	—	—
稀疏高程地图 + 单目深度估计	15.82	0.264	0.149	0.019
稀疏高程地图 + 语义稀疏核贝叶斯	8.09	0.127	0.279	0.119
稀疏高程地图 + 单目深度估计 + 语义稀疏核贝叶斯(补全完善的高程地图)	1.56	0.045	0.145	0.027

注:加粗字体表示各列最优结果。“—”表示没有该方法的数值结果。




图 11 高程地图补全方法的效果展示

Fig. 11 Demonstration of the effectiveness of elevation map completion methods
((a) scenes; (b) sparse and incomplete elevation map; (c) completed and enhanced elevation map)

图 11 主要展示非结构化和复杂的两种不同野外场景下使用本文所提方法后得到的效果,具体如图 11(c)所示。图 11(b)红框中原本存在大量缺失数据的栅格,使用补全方法后,图 11(c)红框中的缺失数据的栅格已经被补全。本文补全方法在这两种不同场景下都有着较好的补全效果,进一步证明本文方法可适应多种野外的复杂场景,可在不同场景下进行相应的预测填补,具有良好的泛化性。

3 结 论

本文提出一种融合多源数据且考虑二分语义的贝叶斯稀疏核补全方法,主要解决两个问题。一是原始高程地图由于激光雷达稀疏性和复杂环境遮挡导致的信息缺失问题;二是在近距离下激光雷达盲区难以补全的问题。提出的方法具有以下优点: 1)融合单目相机的深度估计值;2)提供多源的环境

数据,提高补全算法的鲁棒性;3)对缺失语义信息的高程地图进行二分语义的预处理,并且使用稀疏核贝叶斯估计方法,考虑预测点和观测点之间的语义关系,得到更准确的预测结果;4)针对补全完善后的高程地图,根据高程地图的地形高度、坡度和粗糙度特征,结合车辆可通行能力,计算得到可通行代价,定义更安全的可通行区域。实验结果表明,本文所提出的各模块在准确度和有效性方面均优于现有方法,使得补全后的高程地图信息更为精确和完善。本研究后续拟在多模态数据融合与精细化语义建模方向展开深入探索,重点解决当前算法在可通行区域代价评估上的局限性。尽管现有方法能够识别泥泞路面与正常路面均属于可通行区域,但未能充分考虑二者在运动能耗、通过效率及安全性等方面的显著差异,导致代价地图的精细化程度不足。未来工作将致力于构建层次化语义解析框架,通过融合高分辨率视觉语义信息,对可通行区域进行细粒度分类(如干硬路面、湿滑路面、松软泥地等),并基于物理特性与运动学约束建立差异化的通行代价模型。

参考文献(References)

- Chilian A and Hirschmüller H. 2009. Stereo camera based navigation of mobile robots on rough terrain//Proceedings of 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems. St. Louis, USA: IEEE: 4571-4576 [DOI: 10.1109/IROS.2009.5354535]
- Eidehall A, Asklund J and Spies H. 2006. Real Time Drivable Surface Determination Based on Stereo Vision. SAE International: 1-7 [DOI: 10.4271/2006-01-0169]
- Fankhauser P, Bloesch M and Hutter M. 2018. Probabilistic terrain mapping for mobile robots with uncertain localization. IEEE Robotics and Automation Letters, 3(4): 3019-3026 [DOI: 10.1109/LRA.2018.2849506]
- Fankhauser P and Hutter M. 2016. A universal grid map library: implementation and use case for rough terrain navigation//Koubaa A, ed. Robot Operating System (ROS): the Complete Reference (Volume 1). Cham, Germany: Springer: 99-120 [DOI: 10.1007/978-3-319-26054-9_5]
- Fischler M A and Bolles R C. 1981. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. Communications of the ACM, 24(6): 381-395 [DOI: 10.1145/358669.358692]
- Hähnel D, Burgard W and Thrun S. 2003. Learning compact 3D models of indoor and outdoor environments with a mobile robot. Robotics and Autonomous Systems, 44(1): 15-27 [DOI: 10.1016/S0921-8890(03)00007-1]
- Hornung A, Wurm K M, Bennewitz M, Stachniss C and Burgard W. 2013. OctoMap: an efficient probabilistic 3D mapping framework based on octrees. Autonomous Robots, 34(3): 189-206 [DOI: 10.1007/s10514-012-9321-0]
- Jaspers H and Wuensche H J. 2014. Fast and robust b-spline terrain estimation for off-road navigation with stereo vision//Proceedings of 2014 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC). Espinho, Portugal: IEEE: 140-145 [DOI: 10.1109/ICARSC.2014.6849776]
- Jiang P, Osteen P, Wigness M and Saripalli S. 2021. Rellis-3D dataset: data, benchmarks and analysis//Proceedings of 2021 IEEE International Conference on Robotics and Automation (ICRA). Xi'an, China: IEEE: 1110-1116 [DOI: 10.1109/ICRA48506.2021.9561251]
- Kagami S, Hanai R, Hatao N and Inaba M. 2010. Outdoor 3D map generation based on planar feature for autonomous vehicle navigation in urban environment//Proceedings of 2010 IEEE/RSJ International Conference on Intelligent Robots and Systems. Taipei, China: IEEE: 1526-1531 [DOI: 10.1109/IROS.2010.5653687]
- Kato S, Tokunaga S, Maruyama Y, Maeda S, Hirabayashi M, Kitsukawa Y, et al. 2018. Autoware on board: enabling autonomous vehicles with embedded systems//Proceedings of the 9th ACM/IEEE International Conference on Cyber-Physical Systems (ICCPs). Porto, Portugal: IEEE: 287-296 [DOI: 10.1109/ICCPs.2018.00035]
- Ke B X, Obukhov A, Huang S Y, Metzger N, Daudt R C and Schindler K. 2024. Repurposing diffusion-based image generators for monocular depth estimation//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, USA: IEEE: 9492-9502 [DOI: 10.1109/CVPR52733.2024.00907]
- Kim D, Ka W, Ahn P, Joo D, Chun S and Kim J. 2022. Global-local path networks for monocular depth estimation with vertical Cut-Depth [EB/OL]. [2025-04-25]. <https://arxiv.org/pdf/2201.07436.pdf>
- Ma H B, Yan L P, Xia Y Q and Fu M Y. 2020. Kalman Filtering and Information Fusion. Singapore, Singapore: Springer [DOI: 10.1007/978-981-15-0806-6]
- Moosmann F, Pink O and Stiller C. 2009. Segmentation of 3D lidar data in non-flat urban environments using a local convexity criterion//Proceedings of 2009 IEEE Intelligent Vehicles Symposium. Xi'an, China: IEEE: 215-220 [DOI: 10.1109/IVS.2009.5164280]
- Ning X J, Gong L and Zhang J L. 2022. Detection method of passable road areas based on laser point clouds. Computer Engineering, 48(4): 22-29 (宁小娟, 巩亮, 张金磊. 2022. 基于激光点云的道路可通行区域检测方法. 计算机工程, 48(4): 22-29) [DOI: 10.19678/j.issn.1000-3428.0061717]
- Ranfil R, Bochkovskiy A and Koltun V. 2021. Vision transformers for

- dense prediction//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, Canada: IEEE: 12159-12168 [DOI: 10.1109/ICCV48922.2021.01196]
- Ranftl R, Lasinger K, Hafner D, Schindler K and Koltun V. 2022. Towards robust monocular depth estimation: mixing datasets for zero-shot cross-dataset transfer. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(3): 1623-1637 [DOI: 10.1109/TPAMI.2020.3019967]
- Saarienen J P, Andreasson H, Stoyanov T and Lilienthal A J. 2013. 3D normal distributions transform occupancy maps: an efficient representation for mapping in dynamic environments. *The International Journal of Robotics Research*, 32(14): 1627-1644 [DOI: 10.1177/0278364913499415]
- Shan T X, Wang J K, Englot B and Doherty K. 2018. Bayesian generalized kernel inference for terrain traversability mapping//Proceedings of the 2nd Conference on Robot Learning. Zurich, Switzerland: PMLR: 829-838
- Shi R Z, Zhang X J, Sun L Y and Pei X L. 2022. Research on 3D shape reconstruction method based on single-line lidar. *Laser and Infrared*, 52(2): 188-195 (师瑞卓, 张小俊, 孙凌宇, 裴香丽. 2022. 基于单线激光雷达的三维形貌重建方法研究. *激光与红外*, 52(2): 188-195) [DOI: 10.3969/j.issn.1001-5078.2022.02.007]
- Sivaprakasam M, Maheshwari P, Castro M G, Triest S, Nye M, Willits S, et al. 2024. TartanDrive 2.0: more modalities and better infrastructure to further self-supervised learning research in off-road driving tasks [EB/OL]. [2025-04-25]. <https://arxiv.org/pdf/2402.01913.pdf>
- Souza A and Gonçalves L M G. 2016. Occupancy-elevation grid: an alternative approach for robotic mapping and navigation. *Robotica*, 34(11): 2592-2609 [DOI: 10.1017/S0263574715000235]
- Wang B, Zhu M, Lu Y, Wang J R, Gao W and Wei H. 2021. Real-time 3D object detection from point cloud through foreground segmentation. *IEEE Access*, 9: 84886-84898 [DOI: 10.1109/ACCESS.2021.3087179]
- Xue H Z, Fu H, Xiao L, Fan Y M, Zhao D W and Dai B. 2023. Traversability analysis for autonomous driving in complex environment: a LiDAR-based terrain modeling approach. *Journal of Field Robotics*, 40(7): 1779-1803 [DOI: 10.1002/rob.22209]
- Yang L H, Kang B Y, Huang Z L, Xu X G, Feng J S and Zhao H S. 2024. Depth anything: unleashing the power of large-scale unlabeled data//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, USA: IEEE: 10371-10381 [DOI: 10.1109/CVPR52733.2024.00987]
- Zhao S B, Zhang H R, Wang P, Nogueira L and Scherer S. 2021. Super odometry: IMU-centric LiDAR-visual-inertial estimator for challenging environments//Proceedings of 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Prague, Czech Republic: IEEE: 8729-8736 [DOI: 10.1109/IROS51168.2021.9635862]
- Zhou M R, Chen H Y, Xiong G M, Guan H J and Liu Q X. 2022. Road traversability analysis of unmanned tracked platform in off-road environment. *Acta Armamentarii*, 43(10): 2485-2496 (周梦如, 陈慧岩, 熊光明, 关海杰, 刘庆霄. 2022. 越野环境下无人履带平台的道路可通行性分析. *兵工学报*, 43(10): 2485-2496) [DOI: 10.12382/bgxb.2021.0824]

作者简介

钟梓玮,男,硕士研究生,主要研究方向为点云感知。

E-mail:zhongzw7@mail2.sysu.edu.cn

单云霄,通信作者,男,副教授,主要研究方向为可通行区域和多机器人协同定位。E-mail:shanyx@mail.sysu.edu.cn

周循道,男,高级工程师,主要研究方向为无人驾驶测试。

E-mail:zhouxundao@ceprei.biz