文章编号:1001-9014(2025)06-0840-16

DOI:10.11972/j.issn.1001-9014.2025.06.003

改进球形体素局部形状描述符的跨源点云配准

李 健[1], 李焕涛[1], 吴 浩[2], 崔 昊[1*]

(1. 郑州大学 地球科学与技术学院,河南 郑州 450001;
2. 华中师范大学 城市与环境科学学院,湖北 武汉 430079)

摘要:针对跨源点云质量差异导致的配准难题,本文提出一种改进球形体素局部形状描述符(Spherical Voxel Center Descriptor,SVCD)的跨源点云配准方法。SVCD通过双权重局部参考框架(Local Reference Frame,LRF)计算和球形体素分割,有效克服密度与分布差异。其核心创新在于利用体素中心到关键点的距离进行特征编码,增强描述符的区分度与鲁棒性。配准过程通过最近邻相似比建立对应关系,结合奇异值分解求解刚性变换。在3DCSR和真实数据集上的实验表明:SVCD配准误差低至0.004 8,召回率达82.83%和83.45%(较基线提升10.24和11.16个百分点),F1-score最高(0.803/0.832)。在高斯噪声实验中,SVCD仍保持76.54%的平均召回率,显著优于对比方法,验证了其在复杂场景下的强鲁棒性。该方法为跨源点云的高精度配准提供了有效解决方案。

关 键 词:跨源点云配准;局部形状描述符;球形体素;体素中心;最近邻相似比

中图分类号:TP391 **文献标识码**:A

Cross-source point cloud registration using an improved spherical voxel-based local shape descriptor

LI Jian[1], LI Huan-Tao[1], WU Hao[2], CUI Hao[1*]

(1. School of Geo-Science & Technology, Zhengzhou University, Zhengzhou 450001, China;
2. College of Urban and Environmental Sciences, Central China Normal University, Wuhan 430079, China)

Abstract: To address the registration challenges caused by cross-source point cloud quality disparities, this paper proposes an improved spherical voxel local shape descriptor (Spherical Voxel Center Descriptor, SVCD) for cross-source point cloud registration. SVCD effectively mitigates density and distribution variations through dual-weighted Local Reference Frame (LRF) computation and spherical voxel segmentation. Its core innovation lies in feature encoding based on the distance from voxel centers to keypoints, enhancing the distinctiveness and robustness of the descriptor. The registration process establishes correspondences via the nearest neighbor similarity ratio and solves the rigid transformation using the singular value decomposition. Experimental results on the 3DCSR and real-world datasets demonstrate that SVCD achieves a registration error as low as 0.004 8, with recall rates of 82.83% and 83.45% (improving baseline performance by 10.24 and 11.16 percentage points, respectively), and the F1-scores are the highest (0.803 and 0.832). In Gaussian noise experiments, SVCD maintains an average recall rate of 76.54%, significantly outperforming comparative methods, validating its strong robustness in complex scenarios. This method provides an effective solution for high-precision cross-source point cloud registration.

Key words: cross-source point cloud registration, local shape descriptor, spherical voxel, voxel center, the nearest neighbor similarity rate

收稿日期:2024-12-04,**修回日期**:2025-02-21 **Received date**:2024-12-04,**Revised date**:2025-02-21

基金项目:国家自然科学基金(42241759);国家自然科学基金青年基金(42001405);河南省自然科学基金(242300420212);中国博士后科学基金(2024M752938)

Foundation items: Supported by the National Natural Science Foundation of China (42241759); the National Natural Science Foundation of China Youth Fund (42001405); the Natural Science Foundation of Henan Province (CN) (242300420212); the China Postdoctoral Science Foundation (2024M752938)

作者简介(Biography):李健(1983—),男,河南焦作人,教授,博士学位,主要研究领域为三维激光雷达遥感数据智能处理与应用. E-mail: lijian5277@163.com

[*] **通讯作者**(Corresponding author): E-mail: cuihao@zzu.edu.cn

引言

随着三维观测设备的快速发展和普及,不同观测平台在不同时段从不同传感器(地面和手持激光扫描仪、深度相机等)获取大规模点云成为可能[1]。然而,由于不同传感器的成像机制不同,每种传感器在捕捉3D场景时都有其特定的优势和局限性。例如,激光雷达点云数据分辨率高但稀疏且分布不均匀,而深度相机生成的点云密集但容易受到反射率变化影响,产生噪声和数据空洞。此外,不同视角和采集条件导致的重叠区域较少,进一步增加了数据融合的难度。这些差异在跨源点云配准中造成了巨大的挑战,影响了数据的统一表示和进一步分析。通过多点云融合不仅可以大幅提升对被测物体或场景的观测能力,整合多传感器的优势,而且能提升对被测物体或场景的观测精度[2]。在此过程中,跨源点云配准[3]作为多源点云融合的核心技术,能够将不同来源的数据对齐,实现统一的三维表示。这一技术在无人驾驶、遥感、文物数字化保护、医学影像等领域展现了重要的应用价值[4],比如在无人驾驶中,激光雷达用于检测物体的空间位置,而摄像头提供场景的纹理信息;在遥感领域,融合地面激光扫描仪和手持设备采集的数据能够更精确地还原地形;在北宋皇陵石刻数字化保护中,地面激光扫描仪可捕捉高精度几何细节,而手持SLAM设备能快速获取密集表面纹理,二者配准后可将几何精度提升至亚毫米级,为文物修复提供完整三维档案。然而跨模态点云数据固有的质量差异给跨源点云配准带来了诸多挑战,包括:(1)点云数据的密度和分布不一致;(2)噪声和异常值的存在[5];(3)视角差异导致的局部重叠和旋转等。这些挑战增加了实现高精度跨源配准的难度。

为解决上述问题,近年来出现了许多跨源点云配准算法[6]。Peng等人[7]率先将来自不同传感器的点云与真实街道视图融合,提出了一种两阶段方法来对齐激光点云和运动结构点云,为跨源点云配准研究奠定了基础。Huang等人[8]通过基于高斯混合模型缩放的样本实现精细化匹配,从粗到精地完成跨模态点云的对齐。然而,这些方法在处理点云密度和分布差异问题时表现有限。Yan等人[9]通过提取点云的宏微观结构来构建一种新的2线5点结构,并结合仿射不变性、角度不变性、长度不变性和全局基线不变性四个约束条件完成虚拟与现实对象的配准,这种方法提升了特征匹配的精度,但对于高噪声数据的适应性仍显不足。Jia等人[10]考虑到图模型的结构表示能力,设计了稳健的特征描述符来描述局部节点,并从位置和方向上捕获空间关系来描述全局边,通过构建新颖的图模型来表示异构点云,但该方法在点云分布稀疏的场景中表现有限。随着深度学习技术的发展,基于神经网络的跨源点云配准方法得到了广泛关注。Zhao等人[11]将跨模态配准问题表述为一致性聚类过程,基于自适应模糊形状聚类研究不同模态之间的结构相似性进行对齐。FF-LOGO[12]通过跨模态特征相关性过滤模块提取几何变换不变的特征以实现点选择,并采用局部自适应关键区域聚合模块和全局模态一致性融合优化模块进行局部到全局的联合优化。Zhao等人[13]提出了一种基于体素表示和分层对应关系过滤的跨源点云配准方法VRHCF,利用球形体素增强描述符的鲁棒性,并通过自适应对应关系过滤提高匹配精度。然而,该方法在处理点云严重稀疏或局部几何信息缺失的情况时,匹配精度有所下降,且体素划分策略在高噪声环境下可能引入额外误匹配。Cross-PCR[14]采用密度鲁棒特征提取和松弛到严格匹配策略,实现了跨源点云的高效对齐,能够较好地应对点云密度和分布不均的挑战。然而,该方法在特征提取过程中对局部几何细节的敏感度较低,可能影响精细结构匹配的准确性,且在极端视角差异下,其特征匹配阶段的错误对应率较高。尽管基于深度学习的跨源配准方法在结构化场景中表现优异,但其依赖大规模标注数据的特点限制了在文化遗产等小样本场景中的应用。此外,跨模态配准中的噪声和密度变化会影响深度特征提取,使得基于深度学习的方法发展受阻[15]。相比之下,基于传统优化的方法通过设计鲁棒的描述符来进行跨源点云配准具有重要的研究价值。故本文采用基于传统优化的算法进行跨源配准,相较于基于深度学习的方法,本文所提方法无需大量的数据进行预训练,不依赖于跨源数据集,配准效率更高,更具有适用性。

尽管上述提到的算法在一定程度上可以有效应对跨源挑战,但跨源配准中仍普遍存在大量不准确的点对点对应关系,使得找到最优解变得仍极具挑战性。考虑到跨源点云虽然存在很大差异,但人类的视觉系统通常能够毫不费力地以高精度对齐它们。这得益于人类利用的是两个跨源点云形状之间的相似性而不是详细的点[16]。而局部形状描

述符(Local Shape Descriptor,LSD)已被广泛用于描述局部曲面,进而建立对应关系,是基于传统优化点云配准算法的重要组成部分[17]。其核心是通过在关键点处构建局部参考框架或局部参考轴(Local Reference Axis,LRA)来将局部表面中的几何信息编码为特征向量表示,并通过特征匹配搜索出正确的对应点对。SHOT[18]是第一个消除轴符号模糊性的LRF方法,基于邻域法向量与z轴偏差角的余弦值生成直方图,通过串联形成最终的特征向量,但其易受点密度变化的影响。Malassiotis和Strintzis[19]将局部点云从单个视图投影到LRF的XY平面上,提出了Snapshots描述子。然而,仅对单个视图的局部邻域信息进行编码,导致大量信息丢失。为此,Yang等人[20]提出了一种名为TOLDI的描述符,利用多视图机制对局部邻域信息进行编码。Tao等人[21]考虑了局部表面的自遮挡,从五个视图对局部邻域信息进行编码,提出了TriLCI描述符。多视图策略虽然使得这两个描述子包含更多的局部信息,但是在一定程度上增加了算法复杂度。为了进一步提高描述符效率,许多学者提出了二进制描述符(BSC[22]、LOVS[23])。其中LOVS仅使用点空间位置将局部形状结构编码为二进制位串,而无需在特征表示阶段计算复杂的几何属性(例如法线和曲率)。LOVC[24]是对LOVS的一种改进,通过对称局部体素编码更多表面信息。LVC[25]是一种用于地面点云配准的新型LSD,通过开发高重复性的LRF和基于体素中心的三维空间编码来增强描述符的描述性和稳健性。然而,该描述符仅适用于地面点云,且性能依赖于LRF的重复性,限制了其应用范围。受制于跨源点云固有的密度和分布差异等影响,在构建跨源配准描述符时通常存在描述性不足、可重复性差及鲁棒性弱的问题,导致在捕捉跨源点云之间的几何和结构特征时存在局限性,增加了跨源配准的复杂性和不确定性。

基于上述跨源点云配准的固有挑战及LSD在跨源匹配中存在的问题,本文提出了一种改进球形体素局部形状描述符的跨源点云配准方法,具体来说是设计了一个用于跨源配准的局部形状描述符,即SVCD。本文通过优化LRF构建和特征编码方法,可以有效应对不同传感器数据的密度、分布和视角差异带来的影响,增强配准的鲁棒性和准确性。具体来说,算法首先引入双权重来构建具有高重复性的LRF。然后,采用球形体素划分策略对关键点处的局部曲面进行分割。之后,采用局部体素中心到关键点的距离来编码特征,以获取关键点处的准确特征表示。其次,本文采用最近邻相似比(Nearest Neighbor Similarity Rate,NNSR)[26]来过滤错误对应,以生成高质量对应关系。最后,基于正确对应的局部参考框架构建协方差矩阵,并通过奇异值分解(Singular Value Decomposition,SVD)[27]求解配准变换矩阵参数,实现了更稳健、更准确的配准。实验证明所提方法在3DCSR跨源公开数据集[28]和真实数据集中都表现出色。

1 算法原理及步骤

本文主要提出了一个用于跨源点云配准的局部形状描述符SVCD。算法流程如图1所示,主要包含四个部分:关键点提取、LRF构建、SVCD描述符构建、特征匹配。更具体地说,本文首先对输入点云进行体素下采样,以提取关键点。然后,采用高效稳健的LRF构建方法,构建适用于跨源局部曲面特征表示的LRF。在此基础上,构建SVCD描述符,具体包含两个步骤:球形体素划分和特征编码,以获取特征向量表示。之后,采用NNSR算法进行对应过滤,以去除跨源配准之间的大量错误对应点对。最后,对正确对应点对的LRF组成的矩阵进行奇异值分解完成跨源配准。

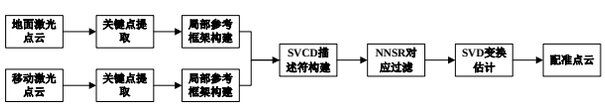

图1 算法流程图

Fig. 1 Algorithm flowchart

1.1 关键点提取

本文首先通过体素下采样提取候选关键点,采样间隔为7 mr。其中,mr代表点云分辨率,即点与其最近点之间距离的平均值[29]。为尽可能捕获更多的邻域信息以及考虑到跨源点云分辨率不同,本文选取点云密度较低的mr作为输入。其次,为避免平坦区域处的关键点特征描述符高度相似而产生误匹配问题,去除平坦区域候选关键点。最后,过滤掉包含点数较少的体素,进一步降低后续配准所需时间。最终剩下的候选关键点即为最终关键点。

1.2 LRF构建

LRF通过构建完整的局部参考坐标系可以提供包括径向、方位角和仰角方向在内的整个三维空间信息。然而由于受到跨源挑战的影响,导致LRF的

x轴和y轴的可重复性和稳定性通常较差,不利于跨源特征表示。为此,本文引入双权重来构建LRF。首先,给定一个点云$P=\{p_1,p_2,\cdots,p_s\}$,S代表点云数量,关键点p通过上述方法获取。则关键点p处的局部参考框架$L(p)$和其临近点集$N_R(p)$分别为:

$$L(p)=\left[\overrightarrow{x(p)}\quad \overrightarrow{x(p)}\times\overrightarrow{z(p)}\quad \overrightarrow{z(p)}\right], \tag{1}$$

$$N_R(p)=\left\{p_i\in P\,\middle|\,\|p_i-p\|\leqslant R\right\}, \tag{2}$$

其中,$\overrightarrow{x(p)}$和$\overrightarrow{z(p)}$表示$L(p)$的x轴和z轴,×表示叉乘,p_i是关键点p的邻域点,R代表邻域点搜索半径。为了实现对杂波和遮挡的鲁棒性,本文只使用局部表面中的一小部分点,即使用距离关键点小于$r_s=R/3$的邻近点构建协方差矩阵,详细计算如下:

$$M=\sum(p_i-p)(p_i-p)^{\mathrm{T}}. \tag{3}$$

通过对M进行特征值分解,得到三个特征值($\zeta_1>\zeta_2>\zeta_3$)和相应的三个特征向量($\vec{v}_1$、$\vec{v}_2$、$\vec{v}_3$)。为了消除LRF轴符号的歧义,z轴朝向向量的多数方向,则z轴定义为:

$$\overrightarrow{z(p)}=\begin{cases}\vec{v}_3 & \text{if } \vec{v}_3\cdot\sum_{i=1}^{k}p_ip\geqslant 0,\\ -\vec{v}_3 & \text{otherwise}\end{cases}, \tag{4}$$

其中,p是关键点,p_i是p的邻居点,p_ip是从p_i到p的向量,k是邻居点的数量。则x轴的定义如下:

$$\overrightarrow{x(p)}=\sum_{i=1}^{k}w_{i1}w_{i2}\vec{v}_i\Big/\left\|\sum_{i=1}^{k}w_{i1}w_{i2}\vec{v}_i\right\|, \tag{5}$$

其中,$\vec{v}_i=pp_i-\left(pp_i\cdot\overrightarrow{z(p)}\right)\cdot\overrightarrow{z(p)}$,表示从关键点$p$指向邻居点$p_i$的向量在$z$轴拟合平面上的投影矢量。通过提取邻居点的投影矢量,能够在局部表面内进一步消除z轴方向的影响,从而更稳定地定义x轴。$\|\cdot\|$表示欧几里得距离。ω_{i1}和ω_{i2}的定义如下:

$$\omega_{i1}=\left(r_s-\|p-p_i\|\right)^2, \tag{6}$$

$$\omega_{i2}=\left(pp_i\cdot\overrightarrow{z(p)}\right)^2, \tag{7}$$

权重ω_{i1}用于增强对遮挡和杂波的鲁棒性,权重ω_{i2}用于增加平坦区域的可重复性。其中,距离权重ω_{i1}反映了邻居点到关键点距离的重要性,距离关键点越近的邻居点越能体现关键点的局部几何结构,其对LRF构建的贡献越大,有效降低了远离关键点的噪声点影响,增强了对遮挡和杂波的鲁棒性;法向一致性权重ω_{i2}则反映了邻居点相对于关键点的法向一致性,邻居点与LRF的　　轴方向越一致,越能准确反映局部表面的主方向特性,其权重越高,有效增强了平坦区域LRF的稳定性并抑制异常点的干扰。最后,y轴被计算为x轴和z轴的叉积。通过该方法,获得的LRF是唯一且可重复的。最终LRF可用3×3正交矩阵表示。其表达式如下:

$$\mathrm{LRF}=\left[\overrightarrow{x(p)}\quad \overrightarrow{x(p)}\times\overrightarrow{z(p)}\quad \overrightarrow{z(p)}\right]. \tag{8}$$

1.3　SVCD特征描述符

本节详细介绍SVCD描述符的技术细节,如图2所示。具体来说,生成SVCD描述符的过程包含两个主要部分:球形体素分割和特征编码。首先给定一个点云或表面,邻域点由关键点p和支持半径R确定。将关键点p处的局部曲面定义为$P_L=\{p_1,p_2,\cdots,p_n\}$。首先对局部曲面$P_L$进行坐标变换,将其变换到LRF下,以实现旋转和平移不变性。旋转后的局部曲面P'_L表示为$P'_L=\{p'_1,p'_2,\cdots,p'_n\}$。

1.3.1　球形体素分割

受地球地理坐标系的启发,本文偏离了常规的立方体体素化和八叉树方法,并沿经度、纬度和半径三个维度对P'_L进行球形体素分割。在跨源点云配准任务中,由于传感器种类、采样方式及视角不同,不同点云数据间往往存在尺度、密度和分布差异。直角坐标系划分方式在面对这些变化时可能会引入特征不稳定性,特别是在旋转或尺度变化较大的情况下,固定网格划分可能导致不同点云间的体素索引不一致,影响匹配精度。相比之下,球坐标系体素划分天然具备旋转不变性和尺度自适应性,能够保证同一物体在不同点云中的局部结构划分方式一致,从而提升匹配的稳定性。此外,球坐标体素能够更合理地适应点云数据的几何分布,避免直角坐标划分可能出现的空体素过多或密集区域划分不均的问题,提高空间利用率和计算效率。

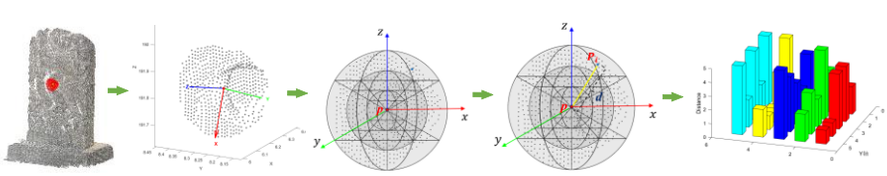

图2　SVCD描述符构建流程图

Fig. 2　SVCD descriptor construction process flowchart

通过球形体素分割，能够在高密度区域提供更精细的特征表达，而在稀疏区域减少不必要的划分，从而在保证描述能力的同时优化存储开销。该方法不仅提高了跨源点云配准的匹配鲁棒性，同时也减少了点云数据的冗余信息，使得后续特征计算更加高效。具体步骤如下：首先将P_L'的笛卡尔坐标变换成极坐标，其中极坐标系的极轴方向为Z轴正方向，坐标变换如下：

$$[\varphi,\theta,r]=f\left(p_x',p_y',p_z'\right) \quad , \quad (9)$$

其中，$\left(p_x',p_y',p_z'\right)$为变换到LRF下的邻居点坐标，$f(\cdot)$为极坐标变换函数，$(\varphi,\theta,r)$为邻居点的极坐标。方位角$\varphi$和俯仰角$\theta$分别表示为从正$X$轴逆时针旋转的角度以及从正$Z$轴向下旋转的角度，径向$r$表示为从原点（关键点）到邻居点的距离，其范围分别为$[0,2\pi]$、$[0,\pi]$、$[0,R]$。然后，分别沿着方位角、俯仰角和径向三个维度对球形体素进行等间隔划分，每个维度分别被划分成N、M和K个体素。因此，生成了以关键点p为中心的$N\times M\times K$个球面体素$V=\left\{V_{ijk}\right\}$，其中$i\in[0,N]$、$j\in[0,M]$、$k\in[0,K]$表示三维球体中每个球面体素沿着方位角、俯仰角和径向方向的索引值，且均为正整数。通过将所有邻居点的坐标换算成极坐标，以计算出每个邻居点所在球形体素中的索引值。

$$\varphi_{\text{bins}}=\text{INT}\left(\varphi N/2\pi\right) \quad , \quad (10)$$

$$\theta_{\text{bins}}=\text{INT}\left(\theta M/\pi\right) \quad , \quad (11)$$

$$r_{\text{bins}}=\text{INT}\left(rK/R\right) \quad , \quad (12)$$

其中，INT是取整函数，r_{bins}、θ_{bins}和φ_{bins}表示每个邻居点所处的球面体素在三个维度上的索引值。在获得每个邻居点所在的球形体素索引之后，便可以计算球形特征表示。

1.3.2 特征表示

SVCD采用球形体素中心距离来进行特征表示，这一特征独立于原始点分布，可以有效消除跨源点云密度和分布差异的影响。为了确保特征计算的数值稳定性，在特征编码阶段，本文仍然转换回直角坐标系进行欧氏距离计算，以充分利用直角坐标的计算优势，避免球坐标系在极点附近可能出现的不稳定问题。具体来说，对于体素V_{ijk}，为计算其中心坐标，首先需要根据其体素索引值计算出每个体素中心点在极坐标系下的坐标(φ_c,θ_c,r_c)，如下所示：

$$\varphi_c=2\pi(i-1/2)/N \quad , \quad (13)$$

$$\theta_c=\pi\left(j-1/2\right)/M \quad , \quad (14)$$

$$r_c=R\left(k-1/2\right)/K \quad , \quad (15)$$

其中，i,j,k为球面体素的索引号。进一步将其转换为局部笛卡尔坐标系下的中心坐标，则其LRF中的体素中心坐标分别为：

$$x_c=r_c\cdot\sin\left(\theta_c\right)\cdot\cos\left(\varphi_c\right) \quad , \quad (16)$$

$$y_c=r_c\cdot\sin\left(\theta_c\right)\cdot\sin\left(\varphi_c\right) \quad , \quad (17)$$

$$z_c=r_c\cdot\cos\left(\theta_c\right) \quad , \quad (18)$$

其中，x_c、y_c、z_c分别为体素中心在局部参考框架下的坐标，则体素V_{ijk}的体素中心坐标为$V_{ijk}^c=\left(x_c,y_c,z_c\right)$。由于在局部参考坐标系下，关键点$p$即为坐标原点，故体素中心到关键点的距离$d_{ijk}$为：

$$d_{ijk}=\left\|V_{ijk}^c\right\| \quad , \quad (19)$$

$\|\cdot\|$表示欧氏距离。进一步可以获得球形体素的距离特征值。

$$f_{d\,ijk}=d_{ijk}/R \quad , \quad (20)$$

其中，$f_{d\,ijk}$表示球形体素中心到关键点的归一化距离，R为搜索半径。通过遍历整个局部领域，可获得所有球面体素的特征值，表达式如下：

$$F\left(V_{ijk}\right)=\begin{cases}\left[f_{d\,ijk}\right] & \text{if}\left|C_{ijk}>0\right|\\ 0 & \text{otherwise}\end{cases} \quad , \quad (21)$$

其中，C_{ijk}表示球形体素分割后的所有局部体素。如果有点落在体素中，则其体素特征值为$f_{d\,ijk}$。如果体素为空，则其体素值为0。所有体素值被连接起来以得到关键点处的SVCD描述符，其特征维度为$N\times M\times K$。通过采用局部体素信息而不依赖于局部体素中的单一邻居点坐标来计算特征向量，使得特征表示不受点密度和分布的影响，提高了跨源点云特征表示的鲁棒性和准确性。

1.4 对应关系过滤和匹配

跨源点云固有的密度和分布差异导致配准点云之间通常不存在同名特征，使特征匹配结果往往会出现大量虚假对应关系。为了克服这一挑战，本文采用最近邻相似比匹配进行对应过滤。具体公式如下所示。

$$\left\|F_i^P-F_j^Q\right\|/\left\|F_i^P-F_k^Q\right\|\leqslant\varepsilon \quad , \quad (22)$$

F_i^P表示源关键点的描述子，F_j^Q和F_k^Q表示与源关键点最接近的两个目标关键点描述子，其中F_j^Q为最接近的描述子，F_k^Q为第二接近的描述子。本文设置$\varepsilon=0.9$，以获得正确对应C_0。在获得正确对应后，本文利用源关键点和目标关键点的LRF来计算旋转矩

阵。首先构造两个矩阵如下:

$$A_{3m\times 3}=\begin{bmatrix}\left(V_1^{\mathrm{P}}\right)^{\mathrm{T}}\\ \left(V_2^{\mathrm{P}}\right)^{\mathrm{T}}\\ \vdots\\ \left(V_m^{\mathrm{P}}\right)^{\mathrm{T}}\end{bmatrix}\quad B_{3m\times 3}=\begin{bmatrix}\left(V_1^{\mathrm{Q}}\right)^{\mathrm{T}}\\ \left(V_2^{\mathrm{Q}}\right)^{\mathrm{T}}\\ \vdots\\ \left(V_m^{\mathrm{Q}}\right)^{\mathrm{T}}\end{bmatrix},\quad (23)$$

其中m是正确对应的个数,V_i^{P}和V_j^{Q}分别表示源关键点和目标关键点处的LRF。将上述两个矩阵相乘,并执行SVD。

$$\begin{bmatrix}U & S & V\end{bmatrix}=\mathrm{SVD}\left(A^{\mathrm{T}}B\right),\quad (24)$$

则旋转矩阵计算如下:

$$R=V\Sigma\mathrm{U}^{\mathrm{T}},\quad (25)$$

其中$\Sigma=\mathrm{diag}\begin{bmatrix}1 & 1 & \det\left(UV^{\mathrm{T}}\right)\end{bmatrix}$是对角矩阵,$\det(\cdot)$为矩阵的行列式。平移向量计算如下:

$$t=\bar{q}-R\bar{p},\quad (26)$$

其中$\bar{p}$和$\bar{q}$分别是正确对应关系所对应的源关键点和目标关键点的平均值。

2　实验和讨论

在本节中,首先介绍实验数据集和评估标准。然后设置SVCD描述符的参数,并报告本文测试的所有描述符的参数值。最后将提出的方法与几种最先进的描述符方法(包括LVC、LOVS、LOVC、TOLDI、TriLCI)以及经典配准算法(ICP[27]、FGR[30])和目前主流的跨源配准算法(VRHCF、Cross-PCR)进行比较,来测试所提描述符的鲁棒性和跨源点云配准精度。该算法基于MATLAB实现,所有实验均在配备Intel i7-12700H CPU和16 GB RAM的笔记本上进行测试。

2.1　数据集

实验在两个跨源点云数据集上进行,包括真实数据集和3DCSR数据集。其中,真实数据集包含各种类型的北宋皇陵石刻文物点云,如“瑞禽”、“门狮”、“文官”、“角端”等,这些点云分别由法如地面激光扫描仪和GeoSLAM手持激光扫描仪获得,其中不同传感器获取的“瑞禽”点云数据及真实数据集传感器相关参数如图3和表1示。3DCSR数据集中的点云来自三种不同的模态:激光雷达(LiDAR)、Kinect红外深度传感器和相机传感器(SFM)。LiDAR产生的点云相对稀疏,而Kinect深度相机产生的点云密集且均匀。第三种模态数据是使用运动结构(SFM)方法从一系列室内二维图像构建的。该数据集提供了地面真实变换,用于将LiDAR或SFM数据与密集的Kinect数据对齐,其中“lab1”数据及3DCSR数据集中的传感器相关参数分别如图4和表2所示。

2.2　评价标准

2.2.1　特征描述符性能

为了定量评估SVCD的描述性和鲁棒性,采用召回率与精度曲线(Recall vs. Precision curve ,RP曲线)[31]。RP曲线是通过计算不同阈值ψ下的召回率和准确率得到的,这两个指标定义为:

(1)精度计算为正确特征匹配的数量与总特征匹配的数量之比:

$$\mathrm{precision}=\frac{\#\text{correct feature matches}}{\#\text{feature matches}}.\quad (27)$$

(2)召回率的计算方法是正确特征匹配的数量与相应关键点对的数量之比:

$$\mathrm{recall}=\frac{\#\text{correct feature matches}}{\#\text{corresponding keypoint pairs}}.\quad (28)$$

表1　真实数据集相关参数

Table 1　Real-world dataset parameters

仪器	测距方法	最大测量距离/m	最大扫描速率/(points/s)	测距精度/mm	视场角/°	“瑞禽”数据点数量	“瑞禽”数据点分辨率/m
FARO S350	相位式	350	2 000 000	±1	H:360 V:300	54 853	0.011 7
GeoSLAM ZEB Horizon	脉冲式	100	300 000	±(10~30)	H:360 V:270	1 031 633	0.001 2

表2　3DCSR数据集相关参数

Table 2　3DCSR dataset parameters

仪器	测距方法	最大测量距离/m	最大扫描速率/(points/s)	测距精度/mm	视场角/°	“lab1”数据点数量	“lab1”数据点分辨率/m
SFM	多视图几何重建	视场依赖	依赖输入图像数量	精度依赖于相机标定和场景	视场依赖	65 470	0.002 8
Kinect	结构光深度测量	0.5~5	30 帧/秒(点云实时生成)	±2	H:70 V:60	15 031	0.005 3

(a)“瑞禽”数据模型

(b)地面激光扫描仪获取的点云数据

(c)GeoSLAM获取的点云数据

图3 不同传感器获取的“瑞禽”点云数据

Fig. 3 ' Auspicious poultry ' point cloud data acquired by different sensors

通过改变阈值ψ,可以获得一组精确度和召回率值来生成RP曲线。通过真实变换对源关键点进行变换后,如果变换后的源关键点与其目标关键点之间的距离小于0.5 mr,则认为该对应是正确的。如果该特征同时具有高召回率和精确度,则RP曲线将落在图的左上角。

为了更全面地衡量特征描述符的匹配能力,本文进一步引入F1-score作为评价指标,F1-score结合了精度(Precision)和召回率(Recall),用于衡量匹配性能的综合表现。其表达式如下:

$$F1 = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad . \quad (29)$$

F1-score的取值范围为0到1,其值越大,表示匹配效果越优,说明该描述符在确保高召回率的同时,也具备较高的匹配精度,从而提升整体匹配性能。F1-score作为RP曲线的补充指标,能够有效反映精度与召回率之间的平衡关系,特别适用于召回率较高但精度略低的描述符,使得对比分析更加全面。

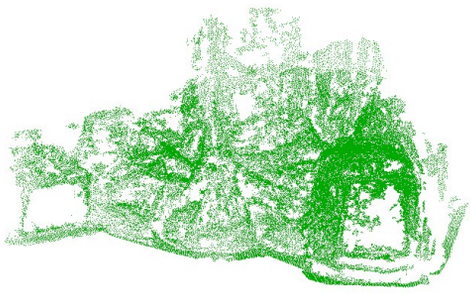

(a)SFM获取的“lab1”点云数据

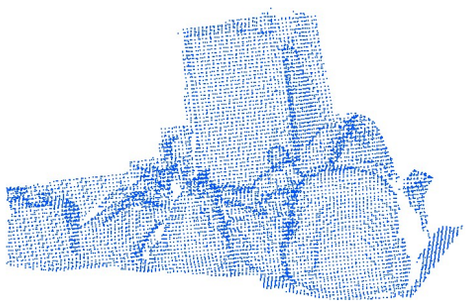

(b)Kinect获取的“lab1”点云数据

图4 不同传感器获取的“lab1”点云数据

Fig. 4 ' lab1 ' point cloud data acquired by different sensors

2.2.2 配准精度

本文采用两个标准来定量评估配准精度[25],即估计的旋转矩阵R_E与地面真实值R_{GT}之间的旋转误差ErrorR以及估计的平移向量t_E与地面真实值t_{GT}之间的平移误差Errort。具体表达式如下:

$$ErrorR = \arccos\left(\frac{\mathrm{trace}\left(R_{GT}R_E^{-1}\right) - 1}{2}\right)\frac{180}{\pi}, \quad (30)$$

$$Errort = \left\| t_{GT} - t_E \right\| \quad , \quad (31)$$

其中,R_E是估计的旋转矩阵,t_E是估计的平移向量,R_{GT}表示真实旋转矩阵,t_{GT}表示真实平移向量。所有点云对的真实变换均通过手动配准获得。通过综合分析旋转误差(ErrorR)和平移误差(Errort),能够全面量化点云配准的精度,确保所提算法在跨源点云配准中的准确性和鲁棒性。

2.3 参数设置与敏感性分析

SVCD描述符需要设置的参数共有4个,分别为搜索半径R以及沿着方位角、俯仰角、径向三个维度等间隔划分的体素数量($N \times M \times K$)。搜索半径R是

描述符的一个重要参数,R越大计算效率越低,容易受到遮挡,R越小区别性越差,本文将支持半径R设置为15 mr(mr代表点云分辨率)。为尽可能地获取更多的邻域信息以及在描述符性能和配准精度之间取得平衡,本文将N、M均设置为18,即分别沿着方位角每隔20°、俯仰角每隔10°进行划分。对于不同的K设置会严重影响描述符的性能,如果该值太大,描述符会对噪声和点密度变化敏感。如果该值太小,则会丢失一些细节,从而降低描述符的描述性。因此K应设置为一个适当的值,以达到描述性和鲁棒性之间的平衡。为了确定一个合适的值,本文选择了四对点云来计算召回率与精度(RP)曲线,分别包括两组真实数据集数据和两组公开数据集数据。通过将K的值从3增加到8,进而得到SVCD在四个场景中不同K值下的RP曲线,实验结果分别如图5和图6所示。从图中可以看出K的值从3增加到5时,无论是在公开数据集还是在真实数据集中,所提出的SVCD描述符的匹配性能都在不断增加,并在K取得5时,描述符性能达到峰值。随着K的值继续增加,描述符在两个数据集上的性能均开始退化。随着K的值越来越大,性能持续降低。综上,本文取K值为5,以获得一个紧凑且高效的描述子。

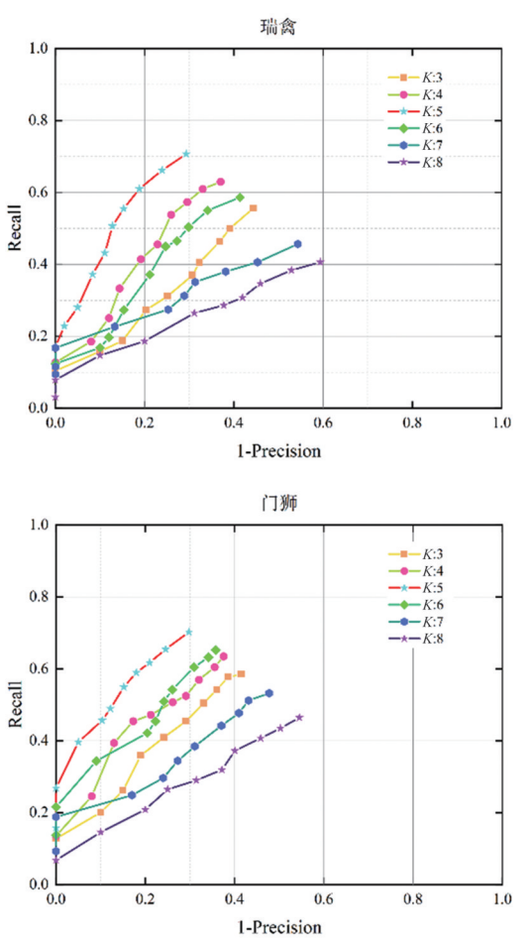

图5　真实数据集中不同K值下的RP曲线

Fig. 5　RP Curves under different K values in Real-world datasets

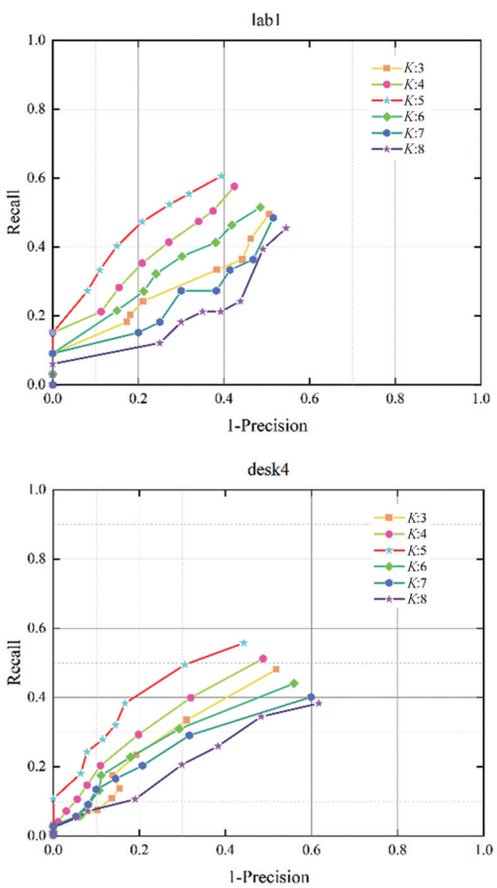

图6　3DCSR数据集中不同K值下的RP曲线

Fig. 6　RP curves under different K values in 3DCSR datasets

2.4　对比方法

本文将SVCD与几个典型的描述符进行了比较,以评估所提描述符较其他描述符的描述性,包括LVC、LOVC、LOVS、TriLCI、TOLDI。这些描述符的参数设置列于表3。为了公平比较,这些描述符中使用的LRF及对应过滤和变换估计方法均采用本文所介绍的算法。此外我们额外对比了经典的点云配准算法(ICP、FGR)以及目前主流的跨源配准算法(VRHCF、Cross-PCR)来评估SVCD在跨源配准中的性能。通过将上述算法分别应用到公开数据集和真实数据集中,从多方面来验证所提算法在跨源点云配准中的精度和有效性。

表3 六个描述符的信息

Table 3 Information on six descriptors

描述符	支撑半径/ mr	维度	长度/(bit)
TriLCI	15	18×18×5	972
TOLDI	15	18×18×3	972
LOVC	15	15×15×15	3 375
LOVS	15	15×15×15	3 375
LVC	15	10×10×10	1 000
SVCD	15	18×18×5	1 620

2.5 结果与评估

2.5.1 SVCD描述符性能评估

(1)描述性:图7和图8展示了六个描述符在八个场景中的RP曲线,其中前四个为在真实数据集中的实验结果,后四个为3DCSR数据集实验结果。实验结果表明,SVCD描述符在真实数据集和3DCSR数据集上的RP曲线均位于左上角,表明其在具有高召回率的同时保持了较高的精度,具有优越的描述性和匹配性能。在所有实验场景中,SVCD的召回率均超过75%,并在多个数据集上展现出稳定性和泛化能力。相比之下,LVC、LOVS和TOLDI的描述性要低于SVCD,匹配性能较弱。TriLCI在部分场景下表现良好但整体稳定性不足,而LOVC的表现最差,在多个场景下的RP曲线均落在图上的右下角,表明其在两个数据集上的描述性均较差。

表4定量描述了六种描述符在真实数据集和3DCSR数据集上的召回率,从中可以看出,SVCD在两个数据集上的召回率分别达到了83.45%和82.83%,远高于其他描述符。结果表明SVCD在编码具有密度和分布差异的跨源数据时,仍能保持较好的描述性。SVCD通过对局部曲面进行球形体素分割,并采用局部体素中心距离特征对局部曲面进行编码,而不依赖于体素中的点分布情况,可以有效地应对跨源点云固有的密度和分布差异等挑战。LVC描述符在真实数据集上的描述性是第二好,但其在3DCSR数据集上的描述性极差。LOVS和LOVC也采用局部体素信息来编码特征,但由于其均采用立方体体素分割,易受到跨源点云密度和分布差异的影响,进而使得描述性较低。尤其是LOVC,其通过对称体素来编码局部曲面,增加了其受影响程度。TOLDI和TriLCI采用多视角投影策略来描述局部曲面,虽然对跨源点云具有一定的鲁棒性,但由于投影操作易导致存在信息丢失的情况,

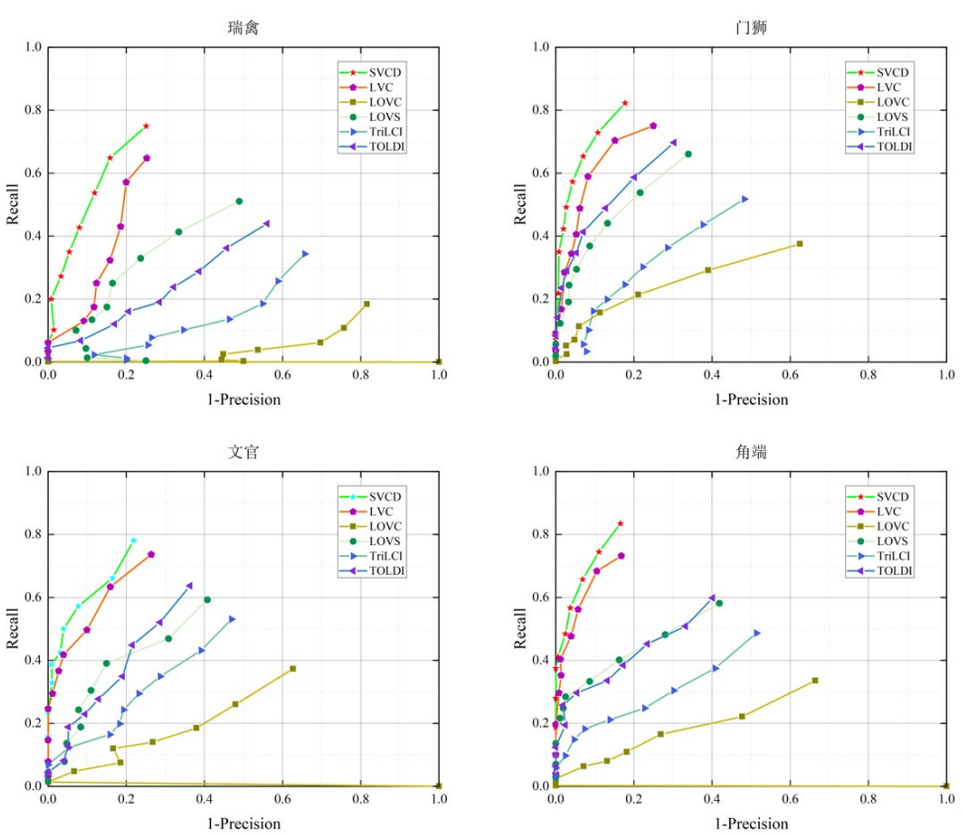

图7 真实数据集上的RP曲线

Fig. 7 RP curves on Real-world datasets

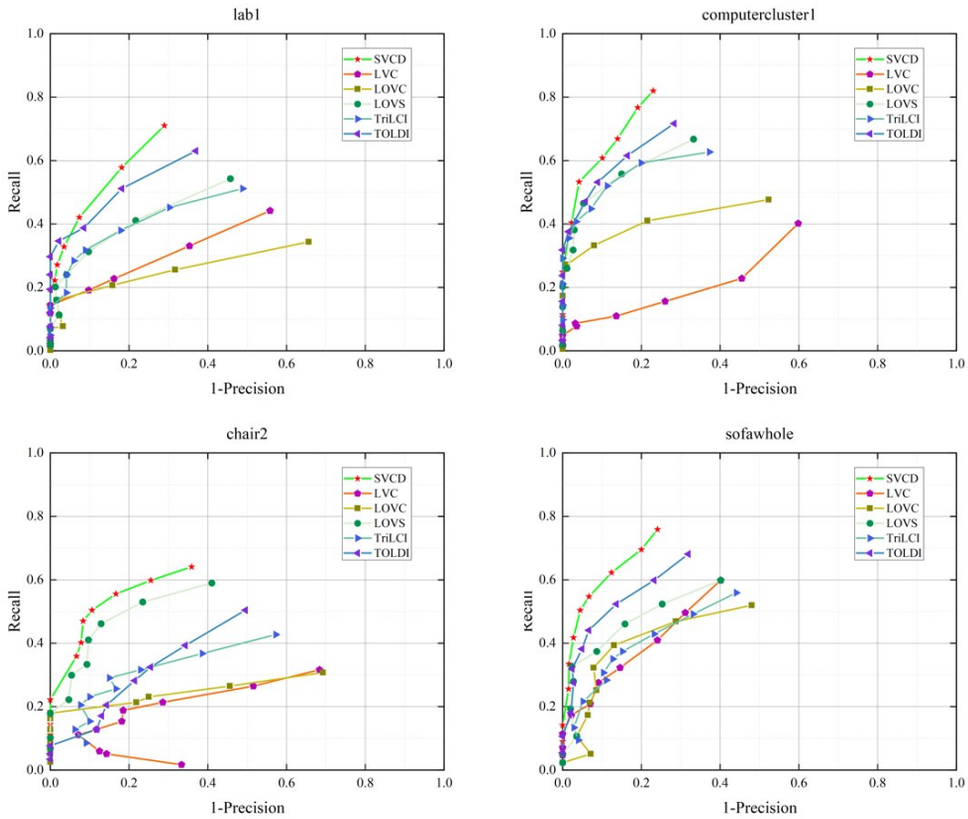

图8　3DCSR数据集上的RP曲线

Fig. 8　RP curves on 3DCSR datasets

使得其描述性整体上不是很高。

表4　六种描述符在真实数据集和3DCSR数据集上的召回率(%)

Table 4　Recall of six descriptors on Real-world and 3DCSR datasets(%)

方法	真实数据集	3DCSR	平均值
LOVS	58.16	66.76	62.46
LOVC	33.57	47.68	40.62
LVC	73.21	40.17	56.69
TriLCI	48.66	62.71	55.68
TOLDI	59.85	71.67	65.76
SVCD	83.45	82.83	83.14

表5定量描述了六种描述符在真实数据集和3DCSR数据集上的F1-score。实验结果表明,SVCD在真实数据集和3DCSR数据集上的F1-score均显著优于其他描述符,展现出卓越的匹配性能和跨源点云鲁棒性。其高匹配精度和稳定性证明了其在不同点云密度、分布及传感器数据质量差异下的广泛适用性。相比之下,LVC在真实数据集上表现良好,但在3DCSR数据集上的匹配性能明显下降,表明其对点云密度变化较为敏感,泛化能力不足。LOVS、TriLCI和TOLDI处于中等水平,虽在特定情况下有所优势,但整体匹配性能仍不及SVCD。LOVC表现最差,F1-score远低于其他描述符,说明其编码方式难以应对跨源点云的密度和几何分布差异。

表5　六种描述符在真实数据集和3DCSR数据集上的F1-score

Table 5　F1-score of six descriptors on Real-world and 3DCSR datasets

方法	真实数据集	3DCSR	平均值
LOVS	0.472	0.403	0.438
LOVC	0.238	0.210	0.224
LVC	0.781	0.683	0.732
TriLCI	0.523	0.483	0.503
TOLDI	0.594	0.541	0.568
SVCD	0.832	0.803	0.818

(2)鲁棒性:通过计算不同高斯噪声水平下的RP曲线来评估表3列出的6个描述符的鲁棒性。为了评估这些描述符在高斯噪声下的鲁棒性,在两个

跨源数据集中添加了不同级别的噪声，这些噪声的标准差分别为0.1 mr、0.5 mr和0.9 mr。其中，在“瑞禽”数据上的定量实验结果如表6所示。从表中可以看出，随着高斯噪声的增加，所有描述符的匹配性能都有所下降，但下降程度不同。其中，SVCD描述符在不同高斯噪声水平影响下的召回率分别达到了81.99%、76.70%和70.93%，均远高于其他描述符。并且随着高斯噪声标准差从0.1 mr增加到0.9 mr，其召回率仅下降了11.06个百分点，下降趋势较为平缓。此外，SVCD的平均召回率也较其他描述符高。上述结果表明，SVCD描述符受高斯噪声的影响最小，具有极高的鲁棒性。该鲁棒性主要取决于两方面因素。一方面，得益于所采用的LRF构建方法，通过引入双权重来计算LRF的三个轴，降低了高斯噪声的影响。另一方面，通过采用球形体素分割法，并且使用局部体素中心距离进行特征编码，进一步提高了所提描述符对高斯噪声的鲁棒性。从表中还可以看出，LOVC是最差的描述符，这是由于其采用对称体素来编码特征向量，较依赖于原始数据的质量，易受高斯噪声的影响，进而导致其召回率下降程度较大。

表6 六种描述符在不同高斯噪声水平下的“瑞禽”数据上的召回率(%)

Table 6 Recall of six descriptors on the ´ Auspicious poultry ´ data under different levels of Gaussian Noise(%)

方法	0.1 mr	0.5 mr	0.9 mr	平均值
LOVS	63.34	52.58	43.87	53.26
LOVC	42.74	29.70	19.81	30.75
LVC	75.47	64.39	54.92	64.93
TriLDI	50.13	41.39	35.61	42.37
TOLDI	52.85	44.07	40.44	45.78
SVCD	81.99	76.70	70.93	76.54

2.5.2 跨源点云配准性能

为了评估SVCD描述符在跨源点云配准中的性能，本文分别使用LVC、LOVS、LOVC、TriLCI、TOLDI描述符来替换配准流程中的SVCD描述符。通过插入到所提出的跨源配准流程中，从侧面论证了所提算法流程及描述符在跨源配准中的有效性。此外，为了进一步说明SVCD的跨源配准性能，本文还采用了经典配准算法(ICP、FGR)以及目前主流的跨源配准算法(VRHCF、Cross-PCR)与本文算法进行对比。通过计算SVCD和上述十种算法在两个跨源数据集(3DCSR和真实数据集)中八个场景上的旋转误差和平移误差来定量评估SVCD在跨源配准中的性能。

图9和图10分别展示了上述十个算法在真实数据集和公开数据集中的配准结果，并分别将旋转和平移误差列于表7和表8中。从配准结果中可以看出，SVCD在“瑞禽”和“lab1”上的配准结果与真实变换最为相近，配准效果最好，得益于SVCD采用球形体素分割策略和中心特征来编码局部曲面，该编码策略独立于体素中的点分布，可以消除跨源点云密度和分布差异的影响。VRHCF采用球面体素表示与分层对应关系过滤的策略来生成高质量对应关系，能够在不同传感器生成的点云之间提取鲁棒的局部特征，有效降低了密度变化、遮挡和噪声对匹配精度的影响，其配准效果仅次于SVCD。Cross-PCR的配准效果略差于VRHCF，其通过引入密度鲁棒特征提取编码器来提取特征，并采用一对多策略来松散地生成初始对应关系。随后，通过稀疏匹配和密集匹配严格选择高质量的对应关系以实现鲁棒配准。从图中还可以看出，其他算法的配准结果均存在一定偏差。其中，LVC虽然也采用了局部体素信息对跨源局部曲面进行编码，但由于其采用立方体体素分割，导致存在误划分的情况，使得其配准效果较差。且其在3DCSR数据集中“lab1”数据上的配准效果进一步下降，偏差较大。该现象与前面章节所描述的情况相符，是由于其易受到点云空洞的影响，敏感性较高。

表7和表8结果表明，SVCD与其他九种算法相比在真实数据集和3DCSR数据集中均获得了最高的配准性能，实现高精度跨源配准。其中，在真实数据集中，SVCD的旋转误差和平移误差分别达到了0.056°和0.039 6 m。在3DCSR数据集中的“sofawhole”数据上的平移误差甚至高达0.004 8 m，远高于其他对比算法。这表明球形体素分割和中心特征策略的引入有效地提高了SVCD的跨源配准精度和鲁棒性。VRHCF的配准精度达到了0.753 9°和0.051 2 m，仅次于SVCD描述符，其在两个数据集中均获得了较高的配准精度。Cross-PCR在两个数据集中的配准精度与VRHCF相当。LVC在跨源数据中的配准精度处于中等水平。LOVS和TOLDI在两个数据集上的配准精度均不理想，具体表现为：在真实数据集中，整体配准精度较低。而在3DCSR数据集中，匹配性能有

所提高,并在部分数据中取得了不错的配准结果,如“chair2”数据中 LOVS 描述符的平移误差高达 0.042。在所有基于描述符的算法中,TriLCI 和 LOVC 描述子表现最差。它们分别通过多视图投影和对称体素的方式来编码特征信息,其中投影操作会导致信息丢失,而对称体素易受到密度和分布差异的影响,导致它们在两个数据集中的配准精度始终较低。此外,表 7 和表 8 还显示出基于描述符的配准算法在跨源配准中的表现均要高于经典的配准算法。其中,ICP 算法在跨源配准中的表现最差。这是由于 ICP 算法对初始位姿和密度均匀性要求高,而论文所采用的不同源点云存在较大的密度差异和噪声(尤其在真实数据集中),导致配准效果不佳。FGR 算法的性能与 ICP 相比,性能有所提升,但整体精度仍低于基于描述符的配准算法。这是由于 FGR 算法通过优化全局一致的特征匹配来实现高效配准,减少了对初始位姿的依赖,但对噪声和特征提取质量仍较为敏感,整体配准精度较低。

综上所述,SVCD 描述符与其余九个算法相比,在两个数据集中均取得了最好的匹配性能,这主要得益于稳健的 LRF 构建方法和独特的球形体素划分策略提高了 SVCD 应对跨源点云密度和分布差异的鲁棒性,并且通过采用局部体素中心距离来编码特征,而不是采用单一的点特征进行编码,可以有效提高对跨源点云的描述能力和鲁棒性,进而实现了高精度跨源配准。

2.5.3　算法复杂度分析

SVCD 描述符的时间和空间复杂度主要由球形体素分割和特征编码两个核心步骤决定。在球形体素分割阶段,首先需要将邻域点转换至局部参考坐标系,并进行极坐标转换,其时间复杂度为 $O(S)$,其中 S 代表输入点云的总点数。随后,SVCD 采用三维球形体素划分,每个关键点的邻域点需进行 $O(N\times M\times K)$ 次索引计算(其中 N、M、K 分别为球形体素沿方位角、俯仰角和径向方向的划分数量)。由于该操作仅针对选定的 n 个关键点执行,因此球形体素分割的总体时间复杂度为 $O(n\times N\times M\times K)$。在特征编码阶段,需遍历所有球形体素,并计算其中心至关键点的距离,其计算复杂度同样为 $O(n\times N\times$

表 7　十个算法在真实数据集中的配准精度

Table 7　Registration accuracy of ten algorithms on Real-world datasets

数据	精度	ICP	FGR	LOVS	LOVC	LVC	TriLCI	TOLDI	Cross-PCR	VRHCF	This article
文官	ErrorR	135.992 1	10.462 6	3.173 3	6.131 9	1.406 8	4.242 1	3.081 5	1.210 3	1.053 9	0.536 7
	Errort	9.072 4	7.827 6	4.249 8	6.112 7	1.533 2	4.498 9	3.326 1	0.062 3	0.051 2	0.039 6
角端	ErrorR	159.717 9	4.036 8	3.928 8	7.195 8	1.714 0	4.463 7	3.575 2	1.513 4	1.204 5	0.056 0
	Errort	240.482 0	12.812 1	4.327 2	6.562 6	1.682 7	4.706 7	4.185 0	0.896 2	0.794 5	0.214 1
瑞禽	ErrorR	175.527 2	17.642 4	4.094 7	7.407 3	2.175 8	5.553 9	3.800 0	1.454 1	1.204 4	0.812 8
	Errort	78.353 9	9.312 3	5.266 4	8.573 5	0.982 3	6.418 6	6.956 7	0.953 3	0.842 4	0.152 4
门狮	ErrorR	112.522 9	7.030 8	3.627 4	6.634 3	1.579 5	5.489 9	2.163 7	0.845 3	0.753 9	0.316 5
	Errort	271.257 0	9.505 3	4.219 3	7.790 2	1.701 8	5.565 8	3.433 1	1.984 2	1.864 2	0.900 5

表 8　十个算法在 3DCSR 数据集中的配准精度

Table 8　Registration accuracy of ten algorithms on 3DCSR datasets

数据	精度	ICP	FGR	LOVS	LOVC	LVC	TriLCI	TOLDI	Cross-PCR	VRHCF	This article
Chair2	ErrorR	28.693 0	10.080 2	2.536 5	6.213 3	6.076 8	4.610 3	3.851 7	2.231 3	2.063 4	1.845 0
	Errort	10.715 5	7.380 3	0.042 0	5.155 7	4.159 9	2.192 8	2.194 1	0.068 3	0.063 2	0.047 1
Lab1	ErrorR	35.912 8	9.079 8	3.755 3	4.979 7	3.917 9	3.726 2	1.917 9	1.903 4	1.856 3	1.228 2
	Errort	15.077 5	7.214 3	3.114 5	6.032 6	4.532 7	3.033 2	1.032 7	0.094 4	0.084 2	0.028 2
Sofawhole	ErrorR	23.656 6	9.210 8	3.022 4	4.850 6	3.476 7	3.082 8	2.097 4	1.783 4	1.503 2	0.512 8
	Errort	10.795 6	5.805 7	2.131 2	2.136 3	2.055 2	3.029 3	0.076 3	0.061 2	0.054 3	0.004 8
Computercluster1	ErrorR	27.991 8	8.544 5	1.707 8	3.874 8	5.702 0	3.055 6	1.980 3	1.803 1	1.731 2	1.526 4
	Errort	13.478 5	9.351 0	2.546 9	4.106 1	6.139 1	0.095 3	2.073 1	0.104 1	0.083 1	0.032 4

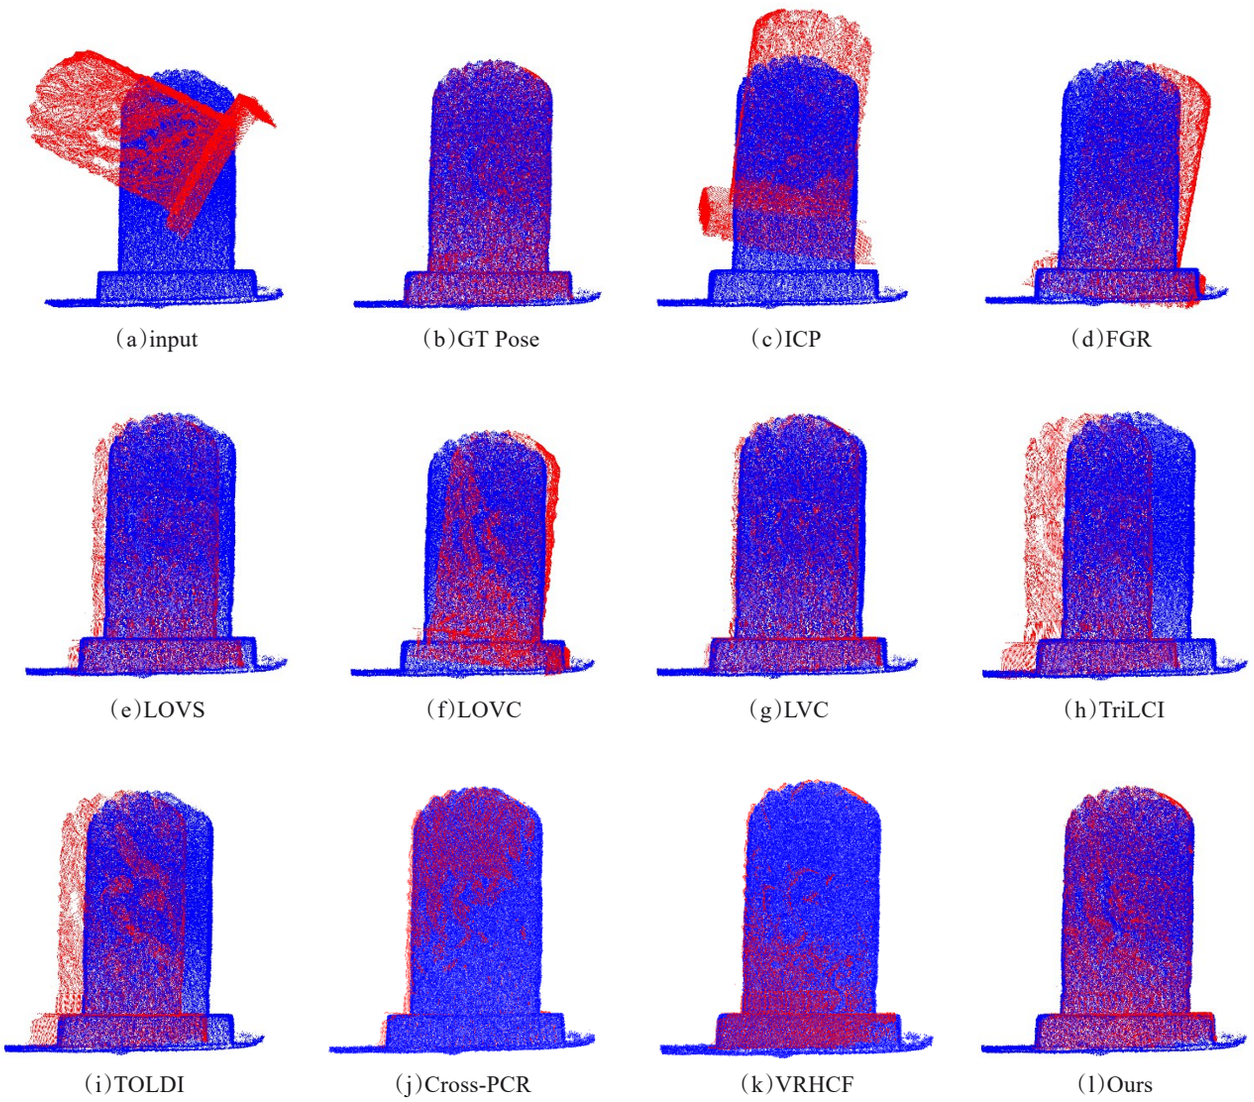

图9 十种算法在“瑞禽”数据下的配准结果

Fig. 9 Registration results of ' Auspicious poultry ' data using ten algorithms

$M\times K$)。综合来看,SVCD描述符的总时间复杂度可表示为O($n\times N\times M\times K$),即其计算开销主要由体素划分总数$V=N\times M\times K$线性决定。在空间复杂度方面,SVCD主要包括输入点云存储、球形体素索引和特征描述符存储。输入点云数据的存储需求为O(S),球形体素索引存储需求为O($n\times N\times M\times K$),特征描述符存储需求与体素划分总数一致,因此同样为O($n\times N\times M\times K$)。因此,SVCD描述符的总空间复杂度为O($S+n\times N\times M\times K$),即主要受输入点云规模和关键点特征描述向量的大小影响。相比传统描述符,SVCD通过球形体素划分增强了特征表达能力,尽管存储需求相对较高,但这一策略有效提升了描述符的鲁棒性和匹配精度,使其在跨源点云配准任务中表现更优。

表9定量显示出测试的十个算法在两个数据集中的配准时间对比,从表中可以看出,SVCD算法在计算时间上处于中等水平,表现出较为均衡的计算效率。在真实数据集上,其计算时间为120.58 s,远低于ICP(476.3 s),但高于Cross-PCR(40.65 s)和VRHCF(28.86 s);在3DCSR数据集上,其计算时间为23.01 s,优于ICP(49.99 s)和LOVC(41.77 s),但仍高于VRHCF(8.32 s)和Cross-PCR(13.42 s)。SVCD计算时间略高的主要原因在于其采用了球形体素分割和体素中心距离特征编码,尽管这增加了一定计算开销,但有效增强了特征表达能力和匹配鲁棒性。相比于FGR等全局匹配方法,SVCD在计

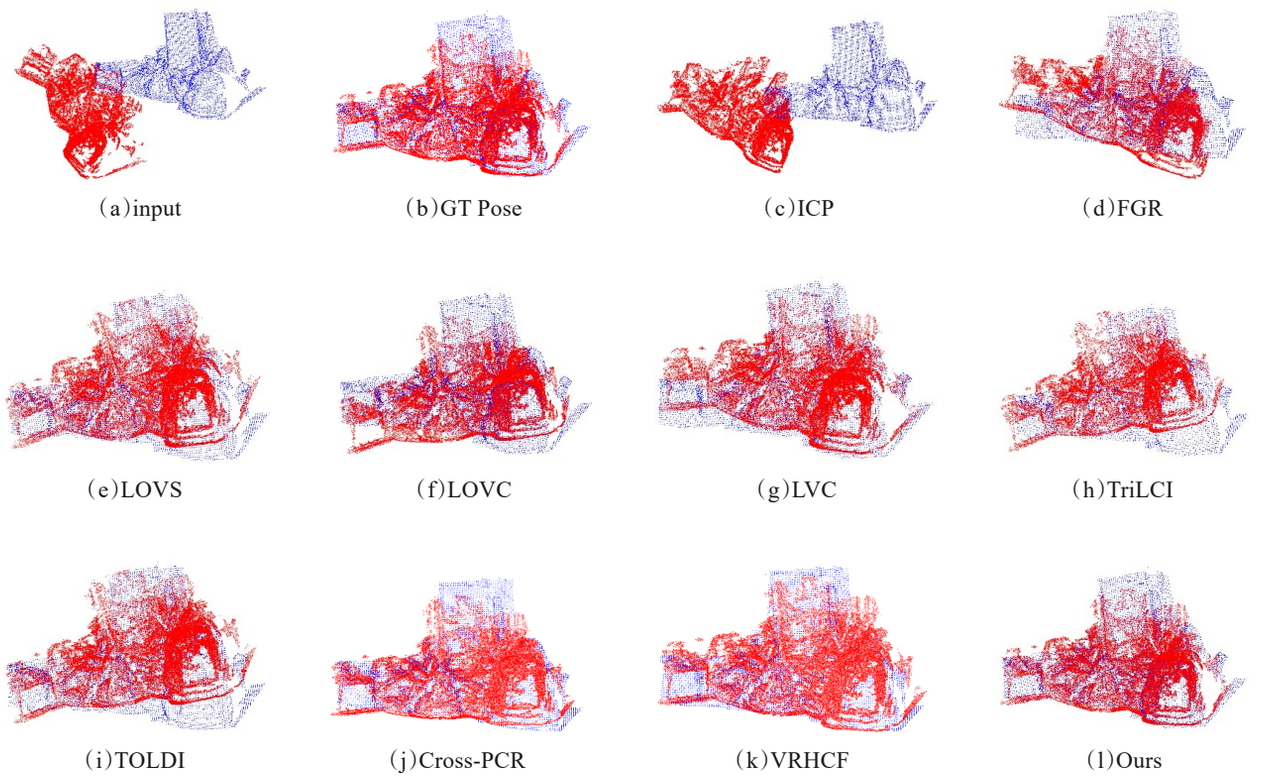

图 10　十种算法在“lab1”数据下的配准结果

Fig. 10　Registration results of ' lab1 ' data using ten algorithms

算时间上要较多一些,但在跨源点云配准的精度和稳健性上具有明显优势。因此,SVCD 通过适度增加计算成本,在精度、鲁棒性和计算效率之间取得了良好的平衡,使其在跨源点云配准任务中具备较高的应用价值。

3　结论和展望

本文提出了一种改进球形体素局部形状描述符的跨源点云配准方法,算法核心是设计了一个用于跨源配准的局部形状描述符,SVCD,以实现稳健且准确的配准。SVCD 采用双权重来构建 LRF,以提高在不同源数据间的可重复性,并且通过引入球形体素来对局部曲面进行体素划分,可以有效解决跨源数据中密度和分布差异带来的挑战。基于球形体素分割结果,使用局部体素中心到关键点的距离来编码局部曲面,进一步提高了对密度和分布差异的鲁棒性。此外,为了解决匹配跨源点特征困难的影响,本文采用最近邻相似比来进行对应过滤,可以有效去除大量错误匹配,从而实现更稳健的高精度配准。分别在公开数据集和真实数据集上进行了实验,并与一些优秀的描述符、经典配准算法以及目前先进的跨源配准算法进行了对比,以严格评估其性能。结果表明,SVCD 描述符表现出了高描述性以及对噪声和密度变化的强鲁棒性,其性能在所有数据集上明显优于其他描述符。并且所提出的算法流程实现了高精度的跨源配准,在所有对比算法中均取得了最高的配准精度。具体来说,SVCD 在两个数据集上分别实现了最高 82.83% 和 83.45% 的召回率,提高了 10.24 和 11.16 个百分点,并在跨源配准中获得了高达 0.004 8 的配准误

表 9　十个算法在真实数据集和 3DCSR 数据集上的配准时间对比

Table 9　Comparison of registration time for ten algorithms on Real-world and 3DCSR datasets

效率	数据集	ICP	FGR	LOVS	LOVC	LVC	TriLCI	TOLDI	Cross-PCR	VRHCF	This article
Time/(s)	真实数据	476.3	48.69	261.26	299.63	33.72	142.37	112.24	40.65	28.86	120.58
	3DCSR	49.99	4.04	37.27	41.77	9.41	19.80	19.24	13.42	8.32	23.01

差。此外,在应对高斯噪声的影响时,SVCD的平均召回率为76.54%,远高于其他描述符,证明了SVCD的鲁棒性。然而我们的描述符也存在一定的局限性,即其特征向量的长度过大,效率不高。未来,计划应用降维技术以减少特征向量的长度。

References

[1] Wang Y, Bu S, Chen L, et al. HybridFusion: LiDAR and vision cross-source point cloud fusion [J/OL]. 2024, arXiv:2304.04508.

[2] Wang Peng, Gao Yin Hui, Wang Ping, et al. Infrared and visual image point set registration based on sensor parameters and refined CPD algorithm [J]. J. Infrared Millim. Waves, 2012,31(2): 171-176.
王鹏, 高颖慧, 王平, 等. 基于传感器参数和改良CPD算法的红外与可见光图像点云配准[J]. 红外与毫米波学报, 2012,31(2): 171-176.

[3] Huang X, Mei G, Zhang J. Cross-source point cloud registration: Challenges, progress and prospects [J]. 2023, 548: 126383.1-126383.9.

[4] Zhang Wen Hao, Li Song, Ma Yue, et al. Photon-counting lidar simulation method based on three dimensional sea surface[J]. J. Infrared Millim.Waves, 2020,39(4): 483-490.
张文豪, 李松, 马跃, 等. 星载光子计数激光雷达海面点云仿真方法[J]. 红外与毫米波学报, 2020,39(4): 483-490.

[5] He Guang Hui, Wang Hong, Fang Qiang, et al. Spaceborne photon counting lidar point cloud denoising method with the adaptive mountain slope [J]. J. Infrared Millim. Waves, 2023,42(2): 250-259.
何光辉, 王虹, 方强, 等. 山地坡度自适应星载光子计数激光雷达点云去噪方法[J]. 红外与毫米波学报, 2023,42(2): 250-259.

[6] Lai Xu Dong, Pian Wei Ran, Bo Li Ming, et al. A building extraction method based on IGA that fuses point cloud and image data [J]. J. Infrared Millim. Waves, 2024, 43(1): 116-125.
赖旭东, 骈蔚然, 薄立明, 等. 一种基于IGA的融合点云和影像的建筑物提取方法[J]. 红外与毫米波学报, 2024,43(1): 116-125.

[7] Peng F, Wu Q, Fan L, et al. Street view cross-sourced point cloud matching and registration [C]. Proceedings of the 2014 IEEE International Conference on Image Processing (ICIP), 2014:2026-2030.

[8] Huang X, Zhang J, Wu Q, et al. A coarse-to-fine algorithm for matching and registration in 3D cross-source point clouds [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2018, 28(10): 2965-2977.

[9] Zhang Y, Zhang L, Zhao X, et al. Automatic point cloud registration for 3D virtual-to-real registration using macro and micro structures [J]. IEEE Transactions on Multimedia, 2024, 26: 6566-6581.

[10] Jia S, Liu C, Wu H, et al. Incremental registration towards large-scale heterogeneous point clouds by hierarchical graph matching [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2024, 213: 87-106.

[11] Zhao M, Huang X, Jiang J, et al. Accurate registration of cross-modality geometry via consistent clustering [J]. IEEE Transactions on Visualization and Computer Graphics, 2024, 30(7): 4055-4067.

[12] Ma N, Wang M, Han Y, et al. FF-LOGO: Cross-modality point cloud registration with feature filtering and local to global optimization [C]. 2024 IEEE International Conference on Robotics and Automation, 2024: 744-750.

[13] Zhao G, Du Z, Guo Z, et al. VRHCF: Cross-source point cloud registration via voxel representation and hierarchical correspondence filtering [C]. 2024 IEEE International Conference on Multimedia and Expo, 2024: 1-6.

[14] Zhao G, Guo Z, Du Z, et al. Cross-PCR: A robust cross-source point cloud registration framework [J]. Computer Vision and Pattern Recognition (csCV), 2024, 2412: 18873.

[15] Cuevas-Velsaquez H, Galán-Cuenca A, Gallego A J, et al. Global point cloud registration network for large transformations [J]. Pattern Analysis and Applications, 2024, 27(4): 137.1-137.18.

[16] Huang X, Zhang J, Fan L, et al. A systematic approach for cross-source point cloud registration by preserving macro and micro structures [J]. IEEE Transactions on Image Processing, 2017, 26(7): 3261-3276.

[17] Wang Z, Fang Q, Wang Y, et al. Double-layer descriptors and high-dimensional search mechanisms for partial point cloud registration[C]. Proceedings of the 2023 China Automation Congress (CAC), 2023: 6736-6740.

[18] Salti S, Tombari F, Di Stefano L. SHOT: Unique signatures of histograms for surface and texture description [J]. Computer Vision and Image Understanding, 2014, 125: 251-264.

[19] Malassiotis S, Strintzis M G. Snapshots: A novel local surface descriptor and matching algorithm for robust 3D surface alignment [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(7): 1285-1290.

[20] Yang J, Zhang Q, Xiao Y, et al. TOLDI: An effective and robust approach for 3D local shape description [J]. Pattern Recognition, 2017, 65: 175-187.

[21] Tao W, Hua X, Yu K, et al. A pipeline for 3-D object recognition based on local shape description in cluttered scenes [J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(1): 801-816.

[22] Dong Z, Yang B, Liu Y, et al. A novel binary shape context for 3D local surface description [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2017, 130: 431-452.

[23] Quan S, Ma J, Hu F, et al. Local voxelized structure for 3D binary feature representation and robust registration of point clouds from low-cost sensors [J]. Information Sciences, 2018, 444: 153-171.

[24] Tao W, Xu S, Huang W, et al. A distinctive binary descriptor and two-point RANSACWC for point cloud registration [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2023, 16: 7529-7542.

[25] Tao W, Lu T, Chen X, et al. A local shape descriptor designed for registration of terrestrial point clouds [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 1-13.

[26] Sun J, Shen Z, Wang Y, et al. LoFTR: Detector-free local feature matching with transformers[C]. Proceedings of the IEEE/CVF conference on Computer Vision and Pattern Recognition, 2021: 8918-8927.

[27] Besl P J, Mckay N D. A method for registration of 3-D shapes [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2): 239-256.

[28] Huang X, Mei G, Zhang J, et al. A comprehensive survey on point cloud registration [J]. Computer Vision and Pattern Recognition (csCV), 2021, 2103: 02690.

[29] Wang Zhen Hua, Yang Wu Zhong, Liu Xiang Feng, et al. An adaptive denoising of the photon point cloud based on two-level voxel[J]. J. Infrared Millim. Waves, 2024, 43(6): 832-845.
王振华, 杨武钟, 刘向锋, 等. 利用两级体素的光子点云自适应降噪[J]. 红外与毫米波学报, 2024,43(6): 832-845.

[30] Zhou Q Y, Park J, Koltun V. Fast global registration[C]. Proceedings of the Computer Vision-ECCV 2016, Cham, 2016: 766-782.

[31] Zhao B, Wang Z, Chen X, et al. FApSH: An effective and robust local feature descriptor for 3D registration and object recognition [J]. Pattern Recognition, 2024, 151: 110354.1-110354.14.